



UNIVERSIDAD DE MÁLAGA

PhD Thesis - Tesis Doctoral  
Tesis por compendio de publicaciones

Sinergia entre Navegación Social  
y Deep Learning en Robots Sociales:  
Un Análisis Evolutivo

Silvia Guillén Ruiz

Departamento de Tecnología Electrónica  
Programa de doctorado: Ingeniería de Telecomunicación

*Supervisado por:*

Dr. Antonio Jesús Bandera Rubio

Dr. Juan Pedro Bandera Rubio

Enero 2024






UNIVERSIDAD  
DE MÁLAGA

AUTORA: Silvia Guillén Ruiz

 <https://orcid.org/0000-0003-0386-101X>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): [riuma.uma.es](http://riuma.uma.es)



## DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD DE LA TESIS PRESENTADA PARA OBTENER EL TÍTULO DE DOCTOR

D./Dña SILVIA GUILLÉN RUIZ

Estudiante del programa de doctorado INGENIERÍA DE TELECOMUNICACIÓN de la Universidad de Málaga, autor/a de la tesis, presentada para la obtención del título de doctor por la Universidad de Málaga, titulada: SINERGIA ENTRE NAVEGACIÓN SOCIAL Y DEEP LEARNING EN ROBOTS SOCIALES: UN ANÁLISIS EVOLUTIVO

Realizada bajo la tutorización de BANDERA RUBIO, ANTONIO JESUS y dirección de BANDERA RUBIO, ANTONIO JESUS; BANDERA RUBIO, JUAN PEDRO (si tuviera varios directores deberá hacer constar el nombre de todos)

DECLARO QUE:

La tesis presentada es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial u otros, conforme al ordenamiento jurídico vigente (Real Decreto Legislativo 1/1996, de 12 de abril, por el que se aprueba el texto refundido de la Ley de Propiedad Intelectual, regularizando, aclarando y armonizando las disposiciones legales vigentes sobre la materia), modificado por la Ley 2/2019, de 1 de marzo.

Igualmente asumo, ante a la Universidad de Málaga y ante cualquier otra instancia, la responsabilidad que pudiera derivarse en caso de plagio de contenidos en la tesis presentada, conforme al ordenamiento jurídico vigente.

En Málaga, a 16 de ENERO de 2023

Fdo.: SILVIA GUILLÉN RUIZ Doctorando/a	Fdo.: BANDERA RUBIO, ANTONIO JESUS Tutor/a
Fdo.: BANDERA RUBIO, ANTONIO JESUS; BANDERA RUBIO, JUAN PEDRO	





UNIVERSIDAD  
DE MÁLAGA



Escuela de Doctorado

Director/es de tesis

UNIVERSIDAD  
DE MÁLAGA



EFQM AENOR



Edificio Pabellón de Gobierno. Campus El Ejido.  
29071  
Tel.: 952 13 10 28 / 952 13 14 61 / 952 13 71 10  
E-mail: doctorado@uma.es

UNIVERSIDAD DE MÁLAGA  
DEPARTAMENTO DE TECNOLOGÍA ELECTRÓNICA

El Dr. Antonio Jesús Bandera Rubio, Profesor Titular de Universidad, perteneciente al Departamento de Tecnología Electrónica de la E.T.S de Ingeniería de Telecomunicación de la Universidad de Málaga, y el Dr. Juan Pedro Bandera Rubio, Profesor Titular de Universidad, perteneciente al Departamento de Tecnología Electrónica de la E.T.S de Ingeniería de Telecomunicación de la Universidad de Málaga,

Certifican que Doña Silvia Guillén Ruiz, Ingeniera en Telecomunicaciones, ha realizado en el Departamento de Tecnología Electrónica de la Universidad de Málaga en el programa de doctorado Ingeniería de Telecomunicación, bajo nuestra dirección, el trabajo de investigación correspondiente a su Tesis Doctoral titulada:

*Sinergia entre Navegación Social y Deep Learning en Robots  
Sociales: Un Análisis Evolutivo*

Revisado el presente trabajo, estimamos que puede ser presentado al tribunal que ha de juzgarlo, y autorizamos la presentación de esta Tesis Doctoral en la Universidad de Málaga. Además certifican que las publicaciones en coautoría que avalan la tesis no han sido utilizadas en tesis anteriores.

Málaga, Enero de 2024

**Fdo. Antonio J. Bandera Rubio**  
Prof. Dpto. Tecnología Electrónica

**Fdo. Juan P. Bandera Rubio**  
Prof. Dpto. Tecnología Electrónica



UNIVERSIDAD  
DE MÁLAGA



UNIVERSIDAD  
DE MÁLAGA



UNIVERSIDAD  
DE MÁLAGA

“No lo intentes. Hazlo, o no lo hagas, pero no lo intentes.”  
— Maestro Yoda (STAR WARS, episodio V)

*A mi pareja, Javier, gracias por creer en mí, por apoyarme durante todos estos años*



UNIVERSIDAD  
DE MÁLAGA

# Índice general

<b>Lista de figuras</b>	<b>15</b>
<b>Lista de tablas</b>	<b>19</b>
<b>Resumen</b>	<b>21</b>
<b>Agradecimientos</b>	<b>25</b>
<b>1. Introducción</b>	<b>27</b>
1.1. Introducción . . . . .	27
1.1.1. Objetivos . . . . .	36
1.2. Motivación . . . . .	37
1.3. Planificación temporal . . . . .	40
1.3.1. Conferencias . . . . .	40
1.3.2. Asignaturas . . . . .	41
1.3.3. Seminarios . . . . .	41
1.3.4. Jornadas de doctorando . . . . .	42
1.3.5. Jornadas de seguimiento . . . . .	42
1.3.6. Cursos . . . . .	43

1.3.7.	Publicaciones . . . . .	46
1.3.8.	Participación en congresos . . . . .	47
1.3.9.	Otros méritos congresos . . . . .	47
1.4.	Estructura de la Tesis . . . . .	48
<b>2.</b>	<b>Estado del arte</b>	<b>49</b>
2.1.	El problema de la navegación . . . . .	50
2.1.1.	Seguridad y longitud como prioridad . . . . .	50
2.1.2.	Longitud y suavidad como prioridad . . . . .	51
2.1.3.	Longitud, suavidad y seguridad como prioridad . . . . .	54
2.1.4.	Suavidad como prioridad . . . . .	56
2.1.5.	Otros factores . . . . .	57
2.1.5.1.	MAPA DE COSTOS . . . . .	57
2.1.5.2.	TIEMPO . . . . .	58
2.1.5.3.	BIOLÓGICOS . . . . .	60
2.2.	Hacia una navegación socialmente apropiada. . . . .	61
2.2.1.	Enfoques reactivos . . . . .	72
2.2.2.	Enfoques proactivos . . . . .	77
2.2.2.1.	Modelos predictivos . . . . .	77
2.2.2.2.	Estrategias de navegación utilizando modelos de movimiento de agentes . . . . .	93
2.2.3.	Enfoques basados en el aprendizaje . . . . .	100
2.2.3.1.	Aprendizaje profundo por refuerzo y enfoques de principio a fin . . . . .	100
2.2.3.2.	Aprendizaje por refuerzo inverso . . . . .	112
2.2.4.	Enfoques de navegación de múltiples comportamientos . . . . .	118
2.3.	Navegación con Paralelización . . . . .	124
2.4.	Navegación con Jetson Nano . . . . .	136
<b>3.</b>	<b>Resultados Experimentales</b>	<b>145</b>
3.1.	Simulador y robot . . . . .	145
3.1.1.	Relación del factor de suavidad con el consumo de energía y la percepción social del movimiento del robot . . . . .	149

<b>4. Conclusiones y trabajo futuro</b>	<b>155</b>
4.1. Principales Aportaciones . . . . .	157
<b>5. Copia de los trabajos</b>	<b>159</b>
5.1. Measuring Smoothness as a Factor for Efficient and Socially Accepted Robot Motion . . . . .	159
5.2. Evolution of socially-aware robot navigation . . . . .	160
5.3. Best Practices for Developing Socially-Aware Service Robots with Predictive Techniques to Enhance Social Comfort	161
5.4. Exploring Learning Techniques for Developing Socially-Aware Service Robots: Best Practices for Social Comfort .	162
<b>Bibliografía</b>	<b>163</b>



UNIVERSIDAD  
DE MÁLAGA

## Lista de figuras

2.1. Esquema Algoritmo PSO,(imagen tomada de Masehian and Sedighizadeh [2010]) . . . . .	52
2.2. Representación de la actualización de la posición de una partícula en PSO,(imagen tomada de Masehian and Sedighizadeh [2010]) . . . . .	54
2.3. Esquema del experimento (imagen tomada de Marghi et al. [2017]) . . . . .	58
2.4. Ilustración de diferentes zonas de confort (imagen tomada de Li and Huang [2010]) . . . . .	62
2.5. Web of Science Analyze filtro: (TS=(social AND navigation)) AND TS=(robot) . . . . .	70
2.6. Web of Science Analyze filtro: (TS=(social AND navigation)) AND TS=(robot) AND TS=(prediction) . . . . .	70
2.7. Web of Science Analyze filter: (TS=(social AND navigation)) AND TS=(robot) AND TS=(learning) . . . . .	71
2.8. Distribución de publicaciones a lo largo de los años considerados por el artículo de revisión de Kruse et al. [2013] y la encuesta actual . . . . .	71

- 2.9. Las fuerzas (izquierda) de SFM. La fuerza resultante  $f$  en el robot  $R_i$  es provocada por un obstáculo estático (la pared,  $f_{iw}$ ) y uno móvil  $A_j$  ( $f_{ij}$ ). (Derecha) El obstáculo de velocidad  $VO_{ij}$  para un robot  $R_i$  inducido por un agente móvil  $A_j$ , con velocidad  $v_j$ . . . . . 73
- 2.10. FM con predicción explícita de colisiones (imagen tomada de Zanlungo et al. [2011]): la posición de los agentes de color rojo y azul se proyecta en el momento en el que se espera la distancia mínima entre ellos (círculos punteados). Para evitar esa situación, los agentes acelerarán con los vectores de aceleración indicados por las flechas continuas (dibujadas tanto en las posiciones actuales como en las posiciones predichas). Las flechas punteadas (solo dibujadas en las posiciones actuales) son los vectores de aceleración si se aplica el modelo CS sin predicción. Permiso de Editorial EPL (Europhysics Letters) . . . . . 79
- 2.11. Descripción general del enfoque de Ikeda et al. [2013] . . . . 81
- 2.12. Ejemplos de distribución de submetas en un entorno. (Imagen basada en Ikeda et al. [2013]) . . . . . 82
- 2.13. El problema del robot congelado (FRP). El robot es  $R_i$  y las elipses representan la covarianza predictiva. No es fácil para el robot encontrar una ruta hacia el objetivo. . . . . 84
- 2.14. El robot Dabo acompañando a una persona hasta la meta deseada mientras navega en un escenario lleno de gente (imagen tomada de Ferrer and Sanfeliu [2014a]): (Izquierda) imagen capturada por la cámara del robot; (centro) el robot Dabo; (derecha) la GUI del robot. Los cilindros verdes corresponden a personas y el cilindro naranja corresponde al objetivo. Permiso por ELSEVIER 5483750554512 94

2.15. Estructura de la CNN empleada (imagen basada de Pfeiffer et al. [2017]). Dos bloques de construcción residuales proporcionan la estructura de la parte CNN (He et al. [2016]), que toma los datos de entrada (datos láser) y proporciona el vector de características a la parte FC. La capa FC del modelo fusiona este vector de características con la información del objetivo para obtener los comandos de dirección de traslación y rotación. La regularización L1 se aplica a todos los parámetros del modelo. . . . .	105
2.16. Descripción general de la NRTIRL. (imagen tomada de Wang et al. [2022a]) . . . . .	114
2.17. Artículos Paralelización Web of Science . . . . .	124
2.18. Artículos Jetson Web of Science . . . . .	137
3.1. Robot Completo . . . . .	146
3.2. Control Remoto MQTT . . . . .	147
3.3. Control Remoto MQTT . . . . .	148
3.4. Aplicación con el mapa . . . . .	149



UNIVERSIDAD  
DE MÁLAGA

## Lista de tablas

2.1. Métodos que utilizan para resolver el problema de navegación local . . . . .	75
2.2. Métodos que se utilizan para modelar el movimiento humano	87
2.3. Métodos que se utilizan para modelar el movimiento humano II . . . . .	88
2.4. Métodos que se utilizan para resolver el problema de navegación. . . . .	98
2.5. Métodos para enfoques de DRL y E2E . . . . .	107
2.6. Métodos para enfoques de DRL y E2E II . . . . .	108
2.7. Métodos para enfoques de DRL y E2E III . . . . .	109
2.8. Métodos revisados para IRL . . . . .	115
2.9. Enfoques de navegación de múltiples comportamientos y enfoques de navegación de comportamiento multimodal . . . . .	120
2.10. Enfoques de navegación con Paralelización . . . . .	126
2.11. Enfoques de navegación con Paralelización II . . . . .	128
2.12. Enfoques de navegación con Paralelización III . . . . .	130
2.13. Enfoques de navegación con Paralelización IV . . . . .	133
2.14. Enfoques de navegación con Jetson Nano . . . . .	141

3.1. Consumo de batería: Sin caminos curvos. . . . . 150  
3.2. Consumo de batería: Caminos curvos. . . . . 151  
3.3. Escenarios. . . . . 152

## Resumen

Los robots móviles han experimentado un crecimiento exponencial en la sociedad contemporánea, expandiéndose más allá de entornos controlados para convertirse en parte integral de la vida diaria. Cuando se diseñan meticulosamente con un enfoque centrado en el usuario, los robots logran resultados notables, posicionándose como una tecnología prometedora capaz de transformar hábitos y costumbres sociales de manera significativa. Esta investigación explora la evolución e integración de los robots móviles en diversos ámbitos, desde operaciones industriales hasta interacciones sociales, con énfasis en la navegación social y la interacción humano-robot.

Los avances tecnológicos han permitido a los humanos delegar tareas esenciales a los robots, liberando tiempo para actividades más complejas y relevantes. Los robots móviles sobresalen en operaciones que requieren atención constante y precisión, superando frecuentemente las capacidades humanas en dominios industriales específicos. Actualmente desempeñan roles fundamentales en campos que incluyen misiones de rescate, exploración, vigilancia, logística de almacenes, entregas y asistencia personal.

Sin embargo, a pesar de los avances en inteligencia artificial y robótica, ciertas tareas complejas requieren atención y razonamiento más allá de la automatización total. Los robots sociales emergentes, capaces de interac-

tuar y cuidar a personas mayores, presentan un potencial avanzado en la robótica actual. La integración de estos robots en la vida diaria plantea preguntas sobre la usabilidad, consideraciones éticas y el alcance de su impacto en la dinámica social.

Esta investigación se sumerge en la Robótica Social con el objetivo de desarrollar aplicaciones responsables que integren valores y múltiples disciplinas. A pesar de que los robots desempeñan un papel de apoyo en el cuidado, los estudios enfatizan la importancia de mantener el apoyo psicológico humano junto con la asistencia robótica.

En escenarios como la terapia para niños autistas, los robots sirven como ayudas complementarias en lugar de sustituir las terapias convencionales. La colaboración potencial entre la interacción humano-robot enriquece la vida diaria, mejorando la productividad y el bienestar emocional.

A pesar de estos avances, la integración fluida de los robots en entornos sociales requiere abordar varios desafíos. En este sentido, es especialmente relevante el desarrollo de comportamientos socialmente aceptables en los robots, un aspecto crítico para la coexistencia humano-robot. Los robots necesitan adaptar sus comportamientos para garantizar la adecuación social y permitir interacciones más naturales con los humanos.

Esta tesis se enfoca en perfeccionar los sistemas de navegación al integrar convenciones sociales en los comportamientos de los robots, fomentando así una experiencia de usuario más cómoda y segura. Explora diversos algoritmos de navegación y su evolución, abordando desafíos como la planificación de rutas multiobjetivo, la optimización energética y la aceptabilidad social en las interacciones humano-robot. Al emplear metaheurísticas y técnicas de computación paralela, la tesis busca mejorar la planificación de rutas al considerar múltiples factores simultáneamente, priorizando la seguridad, la longitud de la ruta, la suavidad y la adecuación social.

La investigación se basa en un enfoque multidisciplinario que entrelaza la robótica, la inteligencia artificial y las ciencias sociales para cerrar la brecha entre los robots y la sociedad. Al enfatizar la importancia del diseño centrado en el ser humano, este estudio se esfuerza por crear robots como herramientas cotidianas que faciliten las rutinas de las personas sin

causar interrupciones en situaciones específicas. A través de una combinación de exploración teórica e implementaciones prácticas, esta tesis busca contribuir al avance de los robots móviles capaces de integrarse sin problemas en diversos entornos humanos, manteniendo las normas sociales y mejorando la comodidad del usuario.

En resumen, esta investigación se centra en ampliar los límites de la robótica móvil, no solo refinando aspectos técnicos, sino también mejorando las dimensiones sociales y éticas, allanando el camino para una coexistencia armoniosa entre humanos y robots en nuestra vida diaria.



UNIVERSIDAD  
DE MÁLAGA

## Agradecimientos

Desde el inicio de mis estudios en Ingeniería Técnica de Telecomunicaciones, tuve claro que este sería el primer paso para acceder a una carrera o máster centrados en el campo de la robótica. Sin embargo, al completar mi carrera y observar los cambios en el plan de estudios de Bolonia, opté por embarcarme en el camino del doctorado.

Este camino no fue descubierto solo; me gustaría expresar mi agradecimiento a mi directora, Carmen, por su orientación y enseñanzas durante el proyecto de fin de carrera y el trabajo de fin de grado. Gracias a ella, pude encontrar un camino que se adaptaba mejor a mis circunstancias sin tener que renunciar a mi sueño.

Esta travesía ha sido larga y desafiante. Conciliar mi vida profesional con la académica ha representado un reto personal considerable. Sin embargo, mi pasión por adquirir conocimientos en un área que realmente me apasiona y mi curiosidad por la robótica me han ayudado a superar los obstáculos a lo largo del camino.

Debo reconocer que nada de esto hubiera sido posible sin el apoyo incondicional de mi pareja, Javier. Ambos hemos tenido que sacrificar tiempo de ocio para que yo pudiera dedicarme de lleno a mis investigaciones. Además, la realización de mi trabajo desde casa se ha vuelto aún

más complicada debido a las dificultades impuestas por la pandemia, que limitaron mi acceso al laboratorio.

Deseo expresar mi más sincero agradecimiento a mis compañeros, Alejandro y Luiky, cuya colaboración resultó fundamental para el éxito de este proyecto, enriqueciendo de manera significativa la calidad del trabajo.

No puedo pasar por alto el papel fundamental desempeñado por mis directores, Juan Pedro y Antonio. Su constante motivación y atención a mis necesidades han sido fundamentales para mi progreso. Siempre estuvieron dispuestos a brindarme todos los recursos necesarios para mi investigación.

Agradezco de corazón a todos los que contribuyeron a hacer realidad este sueño.

# Introducción

“Muchas de las verdades que creemos dependen del punto de vista”

— Obi-Wan Kenobi

## 1.1. Introducción

Los robots móviles han ganado una creciente importancia en nuestra sociedad contemporánea. En los últimos años, su presencia ha crecido exponencialmente, extendiéndose más allá de entornos controlados y específicos para integrarse de manera más cotidiana en nuestra vida diaria. Cuando son diseñados con un enfoque centrado en el usuario y un proceso meticuloso, los robots logran resultados notables. Esta cualidad los coloca como una tecnología prometedora con el potencial de transformar significativamente nuestros hábitos y costumbres sociales (SPARC [2015]).

Los actuales avances tecnológicos han allanado el camino para que los seres humanos deleguen ciertas tareas necesarias a los robots, lo que les permite invertir su tiempo en actividades de mayor complejidad y relevancia. Asimismo, los robots pueden llevar a cabo operaciones que requieren

atención constante y precisión, superando en eficiencia a las capacidades humanas en algunas áreas industriales específicas (Robots [2023]). Por ello, la presencia de los robots móviles se ha ampliado en diversos campos, abarcando tareas como rescates, exploraciones, supervisión, logística de almacenes, entregas y asistencia personal Iglesias et al. [2020], Ilijoski et al. [2022] son algunos ejemplos. Además, las funciones que estos robots desempeñan en estas áreas han evolucionado considerablemente, volviéndose más complejas y diversificadas. Por ejemplo, los drones autónomos no solo pueden ser controlados a distancia, sino que también pueden recopilar datos valiosos en situaciones de desastres naturales, lo que permite una respuesta más rápida y eficaz para ayudar a las personas afectadas. Tanto los UAV (Vehículos Aéreos No Tripulados) (Torres et al. [2020]; Azevedo et al. [2021]) como los AGV (Vehículos Terrestres Autónomos) (Ma et al. [2021]; Yu et al. [2022]), se utilizan actualmente no solo en tareas de alto riesgo, como en escenarios de desastres nucleares o desactivación de bombas, sino también en contextos más habituales como el transporte y la logística.

En la actualidad, estamos presenciando el surgimiento de una generación de robots colaborativos que se integran directamente en la vida de las personas, estableciendo interacciones a través de canales naturales e intuitivos. Un ejemplo claro de esto son los robots auxiliares, que desempeñan un papel fundamental en la supervisión de personas mayores en entornos residenciales (Iglesias et al. [2020]). Estos robots están diseñados para asistir a los cuidadores en sus labores diarias, identificando situaciones de riesgo y activando alarmas de forma oportuna para salvaguardar la seguridad de los residentes (Abdi et al. [2018]). Además, se utilizan en la facilitación de terapias y ejercicios físicos en pacientes, así como en la mejora de los procesos de evaluación geriátrica (Calderita et al. [2014]; Voilmy et al. [2017]).

A pesar de los avances en inteligencia artificial y robótica, los robots sociales emergentes que interactúan y cuidan a personas mayores aún muestran deficiencias en su usabilidad, como señala el estudio de Keizer et al. [2019] sobre robots para el entrenamiento de salud en personas mayores. Aunque los pacientes los aceptan, se observan problemas en la comunicación y las mecánicas de interacción social.

En otros estudios, como los de Iglesias et al. [2020], Ting et al. [2018], Karine Lan Hing Ting and Voilmy [2018] y Gallego Pérez et al. [2014], se exploran los usos de robots en el cuidado de personas mayores, sugiriendo su utilidad como apoyo a los cuidadores y adaptándose a las necesidades individuales. No obstante, Matarić [2017] enfatiza que los robots no reemplazan el apoyo psicológico proporcionado por cuidadores humanos. En terapias con niños autistas, Ilijoski et al. [2022] y Mavadati et al. [2016] muestran una mayor aceptación de los robots, aunque se utilizan como complemento, no como sustituto de las terapias.

El concepto de “Integrative Social Robotics” (ISR), propuesto por Seibt et al. [2020], busca desarrollar aplicaciones de robótica social integrando valores y múltiples disciplinas. En este sentido, trabajos como el de Vandemeulebroucke et al. [2019] resaltan las consideraciones éticas en la regulación de robots de asistencia social, máquinas carentes de empatía, lo que resulta de gran interés.

Esta línea de ISR se desarrolla en Gladden [2019] donde se detalla un proyecto en Japón donde se propone una mejora de la vida diaria mediante la colaboración entre humanos y sistemas de inteligencia artificial. En este punto se abre una nueva vertiente donde los humanos y los robots colaboran, dando como ejemplos los trabajos de Ajoudani et al. [2018] que reflexionan sobre la colaboración entre robots avanzados y humanos, manteniendo el propósito humano en el trabajo. Kotseruba and Tsotsos [2020] y Sandini et al. [2021] dan un paso más y profundizan en la capacidad cognitiva de los robots, adaptando su comportamiento para mejorar su efectividad a largo plazo en las interacciones.

El campo de la robótica está evolucionando hacia una mayor naturalidad en el comportamiento de los robots, acercándolos cada vez más al comportamiento humano. Esta necesidad surge en respuesta al previsible aumento de la presencia de robots en entornos cotidianos, un fenómeno que está siendo ampliamente discutido en revistas especializadas y en los medios de comunicación (Gladden [2019]; Seibt et al. [2020]; Gallego Pérez et al. [2014]). Esto nos obliga a interactuar de manera más frecuente con estas máquinas, lo que demanda que sus acciones sean eficientes y respetuosas con nuestra comodidad. En consecuencia, es crucial que los robots se adapten a diversas circunstancias y personas, minimizando al

máximo cualquier comportamiento que pudiera resultar incómodo. Este escenario impulsa diversas líneas de investigación, todas ellas muy activas. Esta Tesis se centra en una de esas líneas: la navegación social. En este sentido, se sigue la hipótesis de que es necesario que el robot se mueva de forma socialmente correcta para ser aceptado por las personas en su entorno. A partir de esta premisa, este trabajo se enfoca en realizar un análisis exhaustivo de los métodos que los robots pueden emplear actualmente para moverse adecuadamente en presencia de personas. Sobre este análisis se propondrán líneas de desarrollo que permitan maximizar la aceptabilidad social de los desplazamientos del robot.

Por ejemplo, consideremos el caso de un robot que necesita desplazarse desde el punto A hasta el punto B, y en su ruta se encuentran dos personas conversando a una distancia suficiente para que el robot pueda pasar entre ellas y llegar más rápidamente a su destino. Esta acción, aunque óptima en términos de distancia recorrida, podría sin embargo interrumpir la conversación y causar molestias a las personas presentes. La opción socialmente aceptable, aunque menos eficiente desde el punto de vista de la distancia, sería rodear a ambas personas para llegar al destino sin causar interrupciones.

Para habilitar estas capacidades, los robots móviles dependen en gran medida de un sistema de navegación eficiente. En entornos cotidianos, este sistema no solo debe calcular la mejor manera de moverse entre personas, considerando aspectos de seguridad, sino también respetando las convenciones sociales mientras se desplaza desde un punto inicial hacia un destino específico. Estos cálculos se realizan mediante algoritmos de planificación de rutas (PP). Esta tesis se enfoca precisamente en este aspecto fundamental: mejorar el sistema de navegación integrando y adaptando convenciones sociales al comportamiento humano, lo que resulta en una experiencia más cómoda y segura para el usuario.

Durante la elaboración de esta tesis, se llevó a cabo un riguroso estudio de estos métodos y su evolución a lo largo del tiempo, culminando en el trabajo publicado en 5.2. Con el fin de comprender qué métodos o combinaciones podríamos utilizar, nos enfocamos en un análisis más detallado de los algoritmos predictivos, evaluando sus ventajas y desventajas en el artículo 5.3. Del mismo modo, se profundizó en el estudio de los

algoritmos de aprendizaje, dando origen al artículo 5.4.

Existen varios algoritmos disponibles que pueden combinarse para lograr una planificación de rutas viable, como aquellos basados en técnicas de Computación Evolutiva (EC) o Inteligencia Artificial (AI), entre otras. La elección del algoritmo depende de los factores pertinentes al entorno del robot. En general, se consideran tres factores al evaluar la trayectoria de un robot: longitud, seguridad y suavidad de la ruta ([Ahmed and Deb \[2013\]](#); [Hidalgo-Paniagua et al. \[2015\]](#)).

La priorización de la importancia de estos factores debe tener en cuenta el propósito y las características específicas del robot.

1. Importancia de la optimización energética en robots móviles: En el caso de los robots móviles, el consumo de energía es un desafío crítico. Optimizar este consumo es fundamental para permitir la realización de tareas complejas en intervalos de tiempo específicos. Esto se traduce en una asistencia integral en diversas áreas como el cuidado de personas, tareas de rescate y transporte autónomo de mercancías. Un robot capaz de funcionar durante largos períodos sin necesidad de recargarse se vuelve un activo valioso en estos contextos.

2. Factores influenciadores en el consumo de energía y en la planificación de trayectorias: Normalmente, se considera que la longitud de la ruta es el factor primordial en el consumo de batería. Sin embargo, en ocasiones, una ruta más corta con ángulos cerrados podría resultar en un mayor gasto de energía, especialmente para robots con múltiples ruedas debido al constante cambio de dirección de rotación de los motores. Esto puede dar la impresión de un movimiento discontinuo en el robot ([Zhang et al. \[2011\]](#)).

3. Planificación de trayectorias con múltiples objetivos: En la planificación de trayectorias con múltiples objetivos, se emplea una función de idoneidad que asigna valores numéricos representativos a cada objetivo en la trayectoria final ([Ahmed and Deb \[2013\]](#); [Hidalgo-Paniagua et al. \[2016\]](#); [Lucas et al. \[2018\]](#)). Por lo general, se considera que la seguridad del recorrido es el aspecto más crucial, seguido por la longitud y la suavidad del trayecto. Sin embargo, en la búsqueda de la combinación óptima de rutas, se utilizan simulaciones para evaluar la seguridad, longitud y suavidad de la ruta en comparación con otras combinaciones posibles

(Ahmed and Deb [2013]). A pesar de estos resultados, este enfoque no tiene en cuenta la aceptación social y el consumo energético. La suavidad, aunque no sea el factor principal vinculado al consumo de energía, adquiere relevancia al considerar robots en entornos compartidos, contribuyendo a la creación de trayectos socialmente aceptables (Núñez et al. [2016]).

En esta tesis, el enfoque se centra en desarrollar un algoritmo que utilice una función “fitness” para ponderar diversos factores. Además, se llevó a cabo un estudio sobre el impacto del factor de suavidad en el consumo de las baterías y en la percepción social. Los resultados de este trabajo se encuentran publicados en el artículo 5.1.

La forma en que un robot interactúa con las personas, y la impresión o sensación que genera en ellas, es fundamental para asegurar que la interacción sea cómoda y agradable. Un momento crucial de esta interacción es, por ejemplo, cuando el robot se acerca a una persona: debe acercarse lo suficiente como para permitir la comunicación o interacción, pero sin acercarse demasiado, ya que esto podría generar una sensación de amenaza o incomodidad. Otros ejemplos relacionados con esta aceptación del robot tienen que ver con el robot evitando interrumpir a las personas cuando se desplaza por su entorno, o teniendo en cuenta si la persona está de frente a él o no, para incrementar la distancia a la persona cuando pasa por detrás de ella. Para comprender mejor las sensaciones que el robot suscita, se llevan a cabo experimentos que observan y evalúan las reacciones de las personas al comportamiento del robot. En estudios, como los de Thomaz and Cakmak [2009], Dautenhahn et al. [2006] y Shiomi et al. [2014], las conclusiones coinciden en que, en general, las personas prefieren que el robot se acerque desde un lateral en lugar de frontalmente, ya que este último enfoque puede generar una sensación de amenaza o sorpresa. Además, aunque las pruebas en este sentido no han sido concluyentes, también se plantea que estas sensaciones pueden variar según el sexo de la persona.

En cuanto al desplazamiento de los robots, es fundamental que no perciban a las personas como simples obstáculos. En su lugar, se establece una zona de confort alrededor de la persona, que el robot debe respetar y no invadir, como señalan los estudios Dautenhahn et al. [2006]. Esta área

de confort generalmente se representa como una circunferencia alrededor de la persona, aunque en casos donde la persona está en movimiento, puede representarse como una elipse. Respetar esta zona asegura que la interacción entre la persona y el robot sea placentera y cómoda.

No obstante, el desafío no se reduce únicamente a trazar un círculo alrededor de la persona y evitar que el robot se acerque o ingrese en esa zona, especialmente considerando que las personas suelen estar en movimiento y que puede haber más de una persona y múltiples obstáculos, lo que inevitablemente implica una interacción frecuente con la zona de confort, como han señalado estudios anteriores (Dautenhahn et al. [2006]; Li and Huang [2010]). Resolver este tipo de situaciones de manera socialmente aceptable se vuelve una tarea compleja.

Los experimentos indican que la representación elíptica resulta efectiva, incluso en escenarios donde varias personas se desplazan en espacios reducidos. A pesar de que esta modificación en la forma y los parámetros ayuda a reducir las situaciones de intersección con las zonas de confort, no se pueden evitar por completo (Li and Huang [2010]).

El comportamiento del robot en todas estas situaciones debe adaptarse a circunstancias específicas, como quién es la persona en cuestión, el momento y el tipo de acción a realizar, entre otros. Dada la complejidad general del contexto, resulta difícil programar todos los factores. Por lo tanto, se propone enseñar al robot cómo comportarse y tomar decisiones adecuadas basadas en un contexto que podríamos clasificar como aprendizaje basado en casos. Este aprendizaje generalmente se realiza a través del autoaprendizaje o del aprendizaje por imitación. La idea subyacente es que el robot aprenda a realizar diversas acciones según los diferentes factores presentes en cada situación, lo que hará que su comportamiento resulte menos artificial para los seres humanos.

Respecto a qué técnica es más efectiva, los estudios consultados no arrojan una conclusión definitiva, ya que no hay un claro vencedor entre ambas técnicas. Si bien el autoaprendizaje tiende a ser más lento y puede llevar al robot a cometer errores con más frecuencia, el aprendizaje por imitación, aunque más rápido y propenso a reducir las opciones erróneas, requiere tiempo para observar a las personas. Sin embargo, el hecho de que el robot imite acciones que podrían ser físicamente imposibles para sus

capacidades de movimiento plantea un desafío adicional en el aprendizaje a través de la observación de seres humanos.

La interacción social entre humanos y robots plantea un interesante campo para ampliar el autoaprendizaje y el aprendizaje automático. A pesar de que los robots pueden proporcionar señales sociales durante la interacción humano-robot, hasta ahora no se ha integrado el diseño físico del robot con los algoritmos de aprendizaje.

Se han llevado a cabo varios experimentos para medir las capacidades sensoriales que un robot puede transmitir a los humanos y cómo estas capacidades pueden influir en el aprendizaje del robot cuando se introduce un tutor en este proceso. Aunque el aprendizaje social desempeña un papel crucial en la cognición humana, su contribución al aprendizaje de una máquina aún es relativamente limitada. No obstante, se cree que su implementación podría resultar sumamente beneficiosa y acelerar el proceso de aprendizaje del robot.

Basándose en estas premisas, se han llevado a cabo experimentos como el mencionado en [Thomaz and Cakmak \[2009\]](#), en el que se parte de la hipótesis de que el aprendizaje de un robot puede beneficiarse de un comportamiento social, y que la interacción humano-robot proporciona un contexto natural para lograr este propósito.

En este experimento, se utilizó un juego en el que el robot, diseñado para proporcionar respuestas sociales positivas, debe adivinar la imagen que la persona está viendo a través de juegos de palabras. Durante las interacciones con las personas, el robot emplea señales sociales para mejorar su proceso de aprendizaje. Además, estos tutores proporcionan una estructura de entrada que permite que el robot aprenda de manera más efectiva.

Los resultados obtenidos revelan cómo un robot puede influir positivamente en una interacción con una persona mediante el uso de señales sociales que se perciben como naturales, lo que elimina la necesidad de capacitación por parte del usuario. Aunque el robot era capaz de expresar preferencias en el juego de palabras, no se reflejó su influencia en los participantes, pero sí se notó la sensación de que el robot era un compañero de interacción al cual debían adaptar su comportamiento como tutor.

No se observaron diferencias de género significativas en el éxito de los

participantes en la enseñanza del robot ni en cómo los participantes experimentaron subjetivamente al robot. Este estudio sugiere una dirección para el desarrollo de la interacción humano-robot social (HRI social) y, más ampliamente, el aprendizaje automático, cuando los sistemas artificiales, como los robots, utilizan eficazmente los canales sociales para beneficiarse de la tutoría humana. El potencial de esta dirección es significativo, ya que cada persona está naturalmente equipada con una comprensión sofisticada de las señales sociales al interactuar con los demás.

Actualmente, ha surgido una nueva alternativa conocida como aprendizaje profundo, o *Deep Learning*. El *Deep Learning* ha emergido como una herramienta fundamental en el campo de la robótica, revolucionando la forma en que los robots interactúan con su entorno y realizan tareas complejas. Esta rama de la inteligencia artificial se enfoca en el entrenamiento de redes neuronales profundas para aprender automáticamente características y patrones complejos a partir de datos brutos. En el contexto de los robots, el *Deep Learning* se utiliza para una variedad de aplicaciones, desde la percepción sensorial hasta la planificación de movimientos y la toma de decisiones autónomas. Al permitir que los robots aprendan y se adapten a nuevas situaciones de manera flexible, el *Deep Learning* está allanando el camino hacia una generación de robots más inteligentes y versátiles, capaces de realizar una amplia gama de tareas en entornos dinámicos y desafiantes. Podemos encontrar varios ejemplos en los trabajos realizados por [Pinto de Aguiar et al. \[2020\]](#), [Newman et al. \[2020\]](#), [Kameli and Khan \[2022\]](#), y [Yu et al. \[2023\]](#).

Desarrollar comportamientos socialmente aceptables permite al robot interactuar de manera más natural con las personas y adaptarse de manera más fluida a su contexto, fomentando así una percepción más positiva por parte de las personas, que conduce a largo plazo a la aceptabilidad, necesaria para la implantación de la tecnología. El objetivo primordial de la presente investigación es utilizar los robots como herramientas cotidianas que faciliten la rutina de las personas sin generar dificultades ni obstáculos en determinadas situaciones. Este comportamiento social es totalmente necesario en este segmento de la robótica.

Aunque se trata de un campo relativamente nuevo en el que aún hay mucho por investigar, diversos estudios [Shiomi et al. \[2014\]](#), [Chen et al.](#)

[2017a], Li et al. [2018] han dado pasos iniciales y logrados avances significativos, permitiendo a los robots llevar a cabo una amplia gama de tareas y emular el comportamiento humano de manera más acorde a las normas sociales. Como por ejemplo Bera et al. [2016] que nos presentan un algoritmo en tiempo real que predice trayectorias de peatones sin suposiciones sobre movimiento o densidad, aprendiendo patrones de desplazamiento 2D mediante inferencia bayesiana.

Aun así, hay mucho sobre lo que trabajar y es necesario centrar el foco en mejorar el área social. Según lo planteado por Sciutti et al. [2022], la reflexión sobre las investigaciones actuales evidencia cómo el modelado del comportamiento afectivo frecuentemente descuida la dinámica de la percepción compartida. Esto ocurre al centrarse en modelos de aprendizaje basados en datos o en la mera imitación del comportamiento humano en modelos computacionales, lo que reduce su aplicabilidad a situaciones simples. Para avanzar hacia un sistema de computación afectiva más realista, es crucial comprender la percepción compartida como parte fundamental del procesamiento afectivo. Este enfoque multidisciplinario abordado en el Tema de Investigación es esencial para superar este desafío y mejorar la comprensión entre humanos y máquinas, considerando elementos como las normas sociales y la evaluación de las emociones de los usuarios (Rossi et al. [2020]; Cominelli et al. [2017]).

### 1.1.1. Objetivos

A continuación se presentan los objetivos que se han abordado en la presente Tesis Doctoral:

- Analizar la literatura existente sobre la evolución de la navegación social en los robots para identificar las técnicas más adecuadas según los objetivos específicos de interacción humana.
- Desarrollar métodos de análisis para evaluar de manera efectiva las mejoras en el comportamiento social del robot, centrándose en técnicas avanzadas para potenciar la interacción humano-robot de manera natural y fluida.
- Establecer soluciones para abordar los desafíos del *Path Planning* (PP) en entornos complejos y con restricciones temporales estrictas,

priorizando el confort social durante la interacción con humanos, asegurando una experiencia de usuario satisfactoria.

- Explorar y aplicar nuevas tecnologías a la robótica con el propósito de adaptarla a las demandas actuales, enfocándose en mejorar la capacidad de los robots para desempeñar comportamientos sociales adecuados y contextualmente relevantes en su interacción con las personas.

## 1.2. Motivación

La robótica ha representado uno de los avances tecnológicos más significativos del siglo XX, desencadenando una revolución continua impulsada por la dedicación de la comunidad científica. Esta evolución ha llevado a la presencia de robots en lugares que anteriormente eran impensables. Inicialmente confinada al ámbito industrial, la robótica contaba con robots estáticos y capacidades limitadas. No obstante, en la actualidad, su alcance se ha diversificado enormemente, incursionando en campos como la medicina y el entorno doméstico. Además, los robots han evolucionado adquiriendo inteligencia y movilidad, dos aspectos cruciales que definen la naturaleza de los robots contemporáneos.

La movilidad en los robots plantea desafíos computacionales complejos, especialmente al abordar problemas categorizados como *NP-hard* y *NP-completos*. Resolver este tipo de problemas mediante técnicas de programación convencional resulta ineficiente. En lugar de ello, se han implementado técnicas de programación basadas en *metaheurísticas*.

Las metaheurísticas, cuando están bien diseñadas, generan soluciones aceptables en tiempos razonables para problemas de *optimización combinatoria*, buscando maximizar o minimizar una función específica. Estos algoritmos se adaptan a problemas *NP-hard* o *NP-completos*, buscando el subconjunto de estados que mejor se ajusten a una función dada.

La computación paralela se enfoca en reducir el tiempo de procesamiento al dividir un problema en subproblemas que se resuelven simultáneamente. Esta técnica ha progresado gracias al uso creciente de Unidades Centrales de Procesamiento (CPUs) *multi-core* y, más recientemente, a la Unidad de Procesamiento Gráfico (GPU). La integración de la GPU ha

permitido la incorporación de técnicas de computación altamente paralela directamente en los robots, empleando un conjunto de cores capaces de abordar tareas altamente paralelas.

En el ámbito de la robótica, los robots se pueden dividir en dos grupos: móviles y no móviles. Los robots móviles presentan desafíos interesantes debido a su capacidad de movimiento, como el *Path Planning* (PP). Este problema implica encontrar un camino válido para que un robot se desplace de un punto a otro sin riesgo de daño. Las claves para solucionar este problema consisten en obtener una representación computacional del entorno del robot, el punto de inicio y el punto de destino del camino a calcular.

El PP, al ser un problema *NP-hard* y de optimización combinatoria, se aborda eficientemente con metaheurísticas. Estas técnicas pueden optimizar varios objetivos simultáneamente, como la longitud del camino, la seguridad y la suavidad. La seguridad implica minimizar las colisiones con obstáculos conocidos del entorno, asignándoles pesos según su nivel de peligro. La suavidad del camino busca reducir los giros bruscos para disminuir el consumo energético del robot.

Durante años, el enfoque predominante en la planificación de rutas de robots ha sido unidimensional, utilizando algoritmos secuenciales para abordar un único objetivo. Sin embargo, recientemente se ha abierto un nuevo horizonte mediante la exploración de enfoques multi-objetivo utilizando la poderosa técnica de *Computación Evolutiva multi-objetivo*. Esta evolución ha dado vida a la disciplina emergente conocida como *Robótica Evolutiva Multi-Objetivo*, que se apoya en algoritmos evolutivos inspirados en la teoría de la evolución biológica para desarrollar controladores robóticos avanzados.

A pesar de que las técnicas multi-objetivo pueden ser más exigentes en términos computacionales, se complementan de forma eficaz con la computación paralela. Dentro del campo de la robótica, la computación paralela se esfuerza por acelerar los procesos de cálculo y mejorar las soluciones mediante algoritmos que trabajan simultáneamente en varios aspectos.

En paralelo, en los últimos años ha surgido una creciente necesidad de adaptar los robots al entorno humano. Con la integración de robots en

tareas como el cuidado de personas en hospitales y otros servicios, es esencial que los humanos se sientan cómodos y confiados al interactuar con ellos. En el ámbito de la navegación, este requisito se traduce en la capacidad del robot para comprender una amplia gama de contextos humanos y poseer una serie de habilidades sociales que mejoren la experiencia de interacción.

Para alcanzar estos objetivos, se han explorado diversos métodos y habilidades sociales que los robots pueden adquirir. Estos necesitan de una capacidad de procesamiento compleja, en la que la aplicación de técnicas de paralelización puede resultar fundamental para su desarrollo y aplicación práctica.

En resumen, el foco principal de esta investigación reside en encontrar nuevas técnicas para resolver los desafíos del *Path Planning* (PP) en mapas complejos y con restricciones temporales estrictas, mientras se asegura una experiencia cómoda y fluida en la interacción entre humanos y robots. Para lograr este propósito, se investigan y aplican nuevas tecnologías con el objetivo de adaptar la robótica a las necesidades actuales y lograr que los robots puedan desempeñar comportamientos sociales adecuados en su interacción con las personas.

### 1.3. Planificación temporal

En este capítulo, se presentarán de manera cronológica las actividades realizadas por la tesitanda desde el inicio de su Tesis. En el marco de este programa de doctorado, se requería una participación mínima en tres conferencias, tres seminarios con profesores invitados, la finalización del Seminario sobre 'Aspectos Fundamentales de la Investigación en Ingeniería de Telecomunicación', y la realización de una serie de asignaturas, considerando su formación previa en Ingeniería Técnica.

#### 1.3.1. Conferencias

- **Substrate Integrated Waveguide Components for the Internet Of Things, (2016).** Conferencia realizada en la Universidad de Málaga con Luca Perregrini, University of Pavia, Italia como ponente. Nos presentó su trabajo en el Laboratorio de Microondas centrado en explotar el concepto de sustrato integrado de guía de ondas como los ISM filtros, antenas portátiles, entre otros.
- **Algoritmos de detección de intrusos y los filtros de spam basados en búsquedas aproximadas, (2017).** Conferencia realizada en la Universidad de Málaga con Dr.Slobodan Petrovic, Norwegian University of Science and Technology como ponente. Nos presentó las técnicas empleadas en la detección de intrusos en redes de telecomunicación y los resultados de las investigaciones recientes.
- **Las patentes, herramienta clave para la investigación, (2017).** Conferencia realizada en la Universidad de Málaga organizado por OTRI-Vicerrectorado de Transferencia, Empresa y Transformación Digital. Durante esta conferencia se nos informó de la importancia de publicar patentes o modelos de utilidad. Así como del mecanismo para llevarlo a cabo y como en la Universidad de Malaga teníamos un organismo para solicitar ayuda.
- **Europa como solución. La alfabetización digital y el pensamiento crítico ante la desinformación, (2020).** Un foro de encuentro y debate sobre el impacto de la desinformación, los bulos

y las Fake News en la sociedad, la política, la economía y la cultura, y cómo mitigarlo a través de la educación y de la alfabetización digital dirigido por varios ponentes entre ellos Javier Bustos Díaz y Francisco Ruiz del Olmo.

### 1.3.2. Asignaturas

La tesitanda tuvo que realizar las siguientes asignaturas en la Universidad de Málaga para completar la formación investigadora exigida por el programa de Doctorado.

- Ingeniería de desarrollo de sistemas de telecomunicación (2015-2016).
- Gestión de proyectos de I+D+i (2015-2016).
- Técnicas de Modelado y Simulación (2015-2016).
- Diseño de Experimentos en la Ingeniería (2015-2016).

### 1.3.3. Seminarios

- **Seminario sobre aspectos básicos de la investigación en ingeniería de telecomunicación, (2016)**. Impartido por Francisco Sandoval y Carlos Camacho profesores de la Universidad Málaga. El objetivo del seminario era presentar las características de la actividad investigadora en el ámbito de la ingeniería de telecomunicación y proporcionar las bases de la metodología de investigación y de la realización de la tesis doctoral.
- **Transceptor opto-electrónico multicanal: del Concepto al Prototipo Final, (2017)**. En este seminario con el Dr. Álvaro Moscoso Mártir (Institute of Integrated Photonics, Universidad Técnica de Aquisgrán) como ponente se nos presentó el trabajo desarrollado dentro del proyecto europeo BIGPIPES. En este proyecto algunos grupos de investigación habían colaborado con una empresa líder del sector como es Mellanox, para desarrollar un nuevo concepto de transceptor opto-electrónico WDM (Wavelength División Multiplexing).

- **Silicon Photonics: The next revolution in telecom and beyond, (2018)**. En este seminario se nos presentó el trabajo desarrollado en el Optoelectronic Research Centre de la Universidad de Southampton por el grupo del Prof. Dr. Goran Mashanovich en fónica de silicio, el cuál fue el ponente de este seminario.
- **5G, MOBILITY OPTIMIZATION AND SECURITY, (2018)**. En este seminario impartido por Ashutosh Dutta en la Universidad de Málaga, se abordó la evolución de las tecnologías celulares hacia 5G y la virtualización de la función de seguridad.

#### 1.3.4. Jornadas de doctorando

Durante las jornadas de doctorando, la tesitanda presenta el trabajo de la tesis realizado hasta la fecha de cada jornada a otros doctorandos asistentes.

- Jornada de doctorando del 23/03/2017, (2017)
- Jornada de doctorando del 02/07/2017, (2017)
- Jornada de doctorando del 20/02/2018, (2018)

#### 1.3.5. Jornadas de seguimiento

Cada año se evalúa a la tesitanda por la comisión de evaluación del programa de doctorado. Se presenta el plan de investigación actualizado y el progreso realizado durante el año.

- Evaluación Positiva, (09/2016)
- Evaluación Positiva, (09/2017)
- Evaluación Positiva, (09/2018)
- Evaluación Positiva, (09/2019)
- Evaluación Positiva, (09/2020)
- Evaluación Positiva, (09/2021)
- Evaluación Positiva, (09/2022)
- Evaluación Positiva, (09/2023)

### 1.3.6. Cursos

- **Curso de computación de alto rendimiento, Elixir-Excelerate HPC Course (2017)**. Curso organizado por Elixir durante los días 6 y 7 de abril del 2017. El objetivo del curso ha sido: introducir a los participantes a conceptos de paralelismo con ejercicios introductorios y un caso de uso real en algoritmos de comparación de genomas.
- **Curso Inglés para la comunicación oral en el ámbito académico, (2016 - 2017)**. Curso realizado en la Universidad de Málaga para mejorar la comunicación oral en Inglés.
- **International Databases: Web of Science, Scopus, Academic Search Ultimate, Periodicals Archive Online (course in English), 1st ed, (2017 - 2018)**. Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Gestión de referencias bibliográficas: Mendeley, 1ª ed, (2017 - 2018)**. Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **English Lessons B2/C1, (2019 - 2023)**. Curso realizado por la empresa Sequel para la mejora de la comunicación oral.
- **Fundamentals of accelerated computing with CUDA C/C++, (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón para conocer los fundamentos de computación acelerada con CUDA C/C++.
- **Curso Recursos de información en Ingenierías, (2020 - 2021)**. Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Curso Normas para citas y gestión de bibliografía, (2020 - 2021)**. Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Curso Evaluación de la publicación científica: indicios de calidad y factor de impacto, (2020 - 2021)**. Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.

- **Fundamentals of deep learning for computer vision, (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón para conocer los fundamentos del aprendizaje profundo para la visión por computadora.
- **Accelerating CUDA C++ applications with multiple GPUS, (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón para conocer las aplicaciones CUDA C++ con múltiples GPUS.
- **Getting started with AI on Jetson Nano, (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón para conocer las funcionalidades de la Jetson Nano.
- **Fundamentals of deep learning, (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón para conocer los fundamentos del deep learning.
- **Jetson AI specialist, (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón para desarrollar aplicaciones con la Jetson Nano.
- **Deep learning y CUDA (50h), (2020 - 2021)**. Curso realizado por NVIDIA Deep Learning Institute impartido por Manuel Ujaldón sobre Deep Learning y CUDA.
- **Taller sobre Gestión de APC (Article Process Charges), (2021 - 2022)**. Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **IMFAHE's Online Quarter Course on "Innovation, Entrepreneurship and Leadership", (2021 - 2022)**. Curso impartido por INTERNATIONAL MENTORSHIP FOUNDATION FOR THE ADVANCEMENT OF HIGHER EDUCATION (IMFAHE) que consistía en un asesoramiento personalizado con formación individualizada por parte de científicos y profesionales con experiencia internacional, por medio de videoconferencias, con la finalidad de mejorar sus conocimientos acerca de sus salidas profesionales, preparación

para entrevistas de trabajo, preparación para su próximo paso hacia el mercado laboral, incorporación laboral, etc.

- **IMFAHE´s Online Quarter Course on “Careers in Science”, (2021 - 2022).** Curso impartido por INTERNATIONAL MENTORSHIP FOUNDATION FOR THE ADVANCEMENT OF HIGHER EDUCATION (IMFAHE) que consistía en un asesoramiento personalizado con formación individualizada por parte de científicos y profesionales con experiencia internacional, por medio de videoconferencias, con la finalidad de mejorar sus conocimientos acerca de sus salidas profesionales, preparación para entrevistas de trabajo, preparación para su próximo paso hacia el mercado laboral, incorporación laboral, etc.
- **Ciclo formativo wednesday fulbright workshps (WFW), (2021 - 2022).** Ciclo que consistía en una serie de conferencias (Brown Bag Lectures) impartidas por Prof. de diferentes áreas de conocimiento de prestigiosos centros estadounidenses, así como dos talleres (Workshops) relacionados con las competencias de comunicación científica organizado por la Universidad de Málaga y la Comisión Fulbright España.
- **Taller sobre Gestión de Datos Abiertos de Investigación, (2021 - 2022).** Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Taller sobre Visibilidad de la Producción Científica, (2021 - 2022).** Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Curso avanzado sobre recursos de información y publicación científica, (2021 - 2022).** Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Ciclo formativo wednesday fulbright workshops (WFW), (2022 - 2023).** Ciclo que consistía en una serie de conferencias (Brown Bag Lectures) impartidas por Prof. de diferentes áreas de conocimiento de prestigiosos centros estadounidenses, así como dos

talleres (Workshops) relacionados con las competencias de comunicación científica organizado por la Universidad de Málaga y la Comisión Fullbright España.

- **Curso avanzado sobre recursos de información para estudiantes de Doctorado (Curso en seis módulos independientes), (2022 - 2023).** Curso realizado por la biblioteca universitaria de Málaga para la formación de doctorandos.
- **Workshop Doctoral de la EDFES “La comunicación de los resultados de investigación. Cómo realizar presentaciones académicas visuales y eficaces” (2022 - 2023).** Curso impartido por la EDFES sobre cómo realizar presentaciones académicas visuales y eficaces.

### 1.3.7. Publicaciones

- **Artículo JCR Q1 - Silvia Guillén Ruiz, Luis V. Calderita, Alejandro Hidalgo - Paniagua, Juan P. Bandera Rubio: Measuring Smoothness as a Factor for Efficient and Socially Accepted Robot Motion.** Sensors 2020, 20(23), 6822 (2020) (DOI: 10.3390/S20236822)
- **Artículo JCR Q2 Silvia Guillén Ruiz, Juan P. Bandera Rubio, Alejandro Hidalgo -Paniagua, Antonio Bandera: Evolution of Socially-Aware Robot Navigation.** Electronics 2023, 12(7), 1570 (2023) (DOI: 10.3390/electronics12071570)
- **Proceedings SCOPUS- Silvia Guillén Ruiz, Juan P. Bandera Rubio, Alejandro Hidalgo - Paniagua, Antonio Bandera: Best Practices for Developing Socially - Aware Service Robots with Predictive Techniques to Enhance Social Comfort.** 2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME), Tenerife, Canary Islands, Spain, 2023, pp. 1-6, doi: 10.1109/ ICECCME 57830.2023.10252708.(2023) [SCOPUS] (DOI: 10.1109/ iceccme 57830.2023.10252708)

- **Capítulo de libro SCOPUS Q4 -Silvia Guillén Ruiz, Juan P. Bandera Rubio, Alejandro Hidalgo - Paniagua, Antonio Bandera: Exploring Learning Techniques for Developing Socially-Aware Service Robots: Best Practices for Social Comfort.** Artificial Intelligence Research and Development 2023 ,267 - 272 (2023) ( DOI: 10.3233/ FAIA 230692)

### 1.3.8. Participación en congresos

La tesitanda ha participado en varios congresos de ámbito internacional relacionados con la robótica y el deep learning, en los que ha presentado las siguientes publicaciones.

- **2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME) (2023).** Ponencia realizada por la tesitanda en el congreso organizado por el IEEE en Tenerife. La ponencia fue sobre las técnicas de aprendizaje que se usan para mejorar el confort en la navegación social.
- **Congreso Internacional de la Asociación catalana de Inteligencia Artificial (CCIA) (2023).** Ponencia realizada por la tesitanda en el congreso organizado por la CCIA en Mont Sant Benet. La ponencia fue sobre las técnicas predictivas que se usan para mejorar el confort en la navegación social.

### 1.3.9. Otros méritos congresos

Además el tesitando ha participado como chair en los siguientes congresos:

- **2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering** *Conducted a session as a chairman in ICECCME 2023.* (2023)

## 1.4. Estructura de la Tesis

Esta tesis doctoral se divide en cinco capítulos, los cuales están organizados en diversas secciones y subsecciones. En este primer capítulo introductorio, se analiza el creciente papel de los robots móviles en la sociedad contemporánea y se destacan las áreas clave de enfoque para el desarrollo de la tesis, particularmente la planificación de rutas y su influencia en la aceptación social de los robots. Además, comprende de un resumen del objeto de investigación y los criterios necesarios para su validación. Posteriormente en el capítulo dos se presentará el estado del arte, llevando a cabo un análisis exhaustivo del estado actual de la planificación de rutas y su evolución a lo largo del tiempo.

El tercer capítulo abarcará los resultados obtenidos durante el proceso de investigación, detallando el desarrollo de nuestro sistema de planificación y las herramientas empleadas para su creación.

En el capítulo 4, se presentarán las conclusiones derivadas de esta investigación, junto con las proyecciones para futuros trabajos. La tesis culmina en el capítulo 5 con la inclusión de una recopilación de las publicaciones realizadas con relación al tema tratado.

## Estado del arte

Con el avance continuo de las nuevas tecnologías y el constante progreso en el ámbito de la robótica de servicio, se busca cada vez más una similitud en el comportamiento de los robots con el de los seres humanos, para lograr una interacción más natural y fluida. Este impulso se deriva del creciente pronóstico de la presencia cada vez más frecuente de robots en diversos entornos, tal como se reporta en publicaciones especializadas y medios de comunicación<sup>1</sup>. Con el objetivo de garantizar una interacción armoniosa en la vida cotidiana, se requiere que las acciones de los robots sean eficaces y respetuosas, adaptándose según la situación y las preferencias individuales, minimizando en la medida de lo posible cualquier desviación en su comportamiento (SPARC [2015]; Int [2020]; Gladden [2019]).

Esta dinámica ha generado una notable actividad en varias líneas de investigación, todas ellas enfocadas en el desarrollo de soluciones adecuadas. Esta Tesis se centra en el análisis de los métodos mediante los cuales un robot puede aprender a desplazarse de manera precisa y segura en presencia de personas.

---

<sup>1</sup>Fresneda, C. (2016, 20 enero).El 47 % de los empleos está en «alto riesgo» de ser automatizado. ELMUNDO. <https://www.elmundo.es/economia/2016/01/20/5697d766268e3e76078b46d4.html>

## 2.1. El problema de la navegación

Aunque existen ya técnicas muy maduras (Deb et al. [2002]; Guo et al. [2009]; Ahmed and Deb [2013]) para hacer que un robot se desplace en un entorno compartido con personas, la navegación ha sido tradicionalmente uno de los retos de la robótica. La elección del método, o combinaciones de ellos, que se empleará en una aplicación se suele realizar dependiendo de la ponderación de distintos factores. Estos factores suelen incluir la longitud del recorrido y la seguridad, priorizando la ruta con menos obstáculos a sortear. Sin embargo, una consideración que está emergiendo en las nuevas líneas de investigación es la suavidad del recorrido, es decir, el camino que menos giros implique o tenga los giros menos angulados.

En las arquitecturas de navegación actuales, se puede apreciar que la combinación de diversas técnicas conlleva a la creación de algoritmos altamente eficientes, capaces de satisfacer estos factores y lograr buenos resultados en términos de la navegación autónoma de los robots. A continuación, se exponen diferentes propuestas de algoritmos de navegación para robots, que enfatizan uno u otro de estos factores.

### 2.1.1. Seguridad y longitud como prioridad

Los algoritmos en cuestión abordan, de manera general, la minimización de la longitud de la ruta y la maximización de la seguridad durante el trayecto. En este contexto, Lucas et al. [2018] y Lucas et al. [2019] han propuesto la implementación del elitista NSGA-II (un algoritmo genético de clasificación no dominado) (Deb et al. [2002]) para la generación simultánea de diversas soluciones de planificación de la trayectoria. Estas rutas son obtenidas mediante la alteración de un conjunto de variables en una función de ajuste (fitness), lo que da lugar a la generación de rutas con características variadas. La comparación de estas rutas resultantes conduce a la selección de las más óptimas, configurando en consecuencia la función de fitness a emplear. Además, los autores proponen como trabajos futuros la inclusión de más factores en la función de fitness, incluyendo el consumo de energía.

Conforme a lo mencionado anteriormente, las arquitecturas comúnmente enfatizan la seguridad y la longitud de la ruta como los parámetros

fundamentales, tal y como han ilustrado Guo et al. [2009], Zhang et al. [2013] y Park and Huh [2016] en sus respectivos trabajos.

Otras investigaciones optan por la consideración primordial de los dos factores mencionados, utilizando la suavidad como criterio determinante en situaciones de empate entre propuestas competidoras (Ahmed and Deb [2013]).

### 2.1.2. Longitud y suavidad como prioridad

Existen casos que consideran tanto la longitud como la suavidad como parámetros primordiales en la planificación de rutas. Un ejemplo de ello es el trabajo propuesto por Masehian and Sedighzadeh [2010], quienes introducen un algoritmo de planificación de movimiento para robots basado en el enjambre de partículas (PSO), el cual aborda simultáneamente dos objetivos clave: la minimización de la distancia recorrida y la optimización de la suavidad del trayecto. Este algoritmo se compone de dos elementos principales: un componente PSO empleado como planificador global y un componente PRM (Roadmap Probabilístico) modificado utilizado como planificador local.

El algoritmo PSO, derivado del concepto de la optimización del enjambre de partículas, fue presentado en noviembre de 1995 por Kennedy and Eberhart [1995]. Su inspiración se basa en el comportamiento colectivo de enjambres naturales, como aves y peces, y propone un método de optimización en el que las soluciones, denominadas partículas, imitan este comportamiento mediante la interacción y la comunicación basadas en procesos de cómputos evolutivo. El PSO combina las experiencias individuales de las partículas con las experiencias colectivas del enjambre para lograr una convergencia eficiente hacia un óptimo global.

El funcionamiento del algoritmo implica la manipulación de una colección de partículas en un espacio de búsqueda, en el que cada partícula representa una solución potencial, y se dirige hacia regiones prometedoras para alcanzar un óptimo global. Las partículas evolucionan en este espacio de búsqueda a partir de posiciones iniciales aleatorias, y su movimiento de una posición a otra se actualiza en cada iteración del algoritmo en función de una función de evaluación conocida como función de ajuste (fitness). El procedimiento general del algoritmo PSO se esquematiza en la Figura

2.1, en la que se muestra un bucle principal anidado que se detiene una vez que se alcanza un límite predefinido de iteraciones o se cumple un umbral mínimo de error. En cada iteración, se generan nuevas partículas y se calculan los valores óptimos individuales (*pbest*) y globales (*gbest*) de acuerdo con la función de ajuste.

```

Procedure Basic PSO
while maximum iterations or minimum error criteria is not attained do
  for each particle do
    Initialize particle
  end
  for each particle do
    Calculate the fitness value
    If the fitness value is better than the best fitness value in history (pbest)
      then Set current value as the new pbest
    end
  end
  for each particle do
    Find in the particle neighborhood the particle with the best fitness (gbest)
    Calculate particle velocity  $prv_{vel}^i$  according to the velocity equation (2)
    Apply the velocity constriction
    Update the particle position  $prp_{pos}^i$  according to the position equation (1)
    Apply the position constriction
  end
end

```

Figura 2.1: Esquema Algoritmo PSO, (imagen tomada de Masehian and Sedighizadeh [2010])

El método de planificación de rutas probabilísticas, conocido como Roadmap Probabilístico (PRM) (Vega et al. [2019]; Park and Huh [2016] o Velagic et al. [2014]), ha adquirido notable prominencia en los planificadores de navegación modernos, debido a su capacidad para resolver una serie de desafíos complejos en espacios de configuración de alta dimensionalidad de manera eficiente.

A lo largo de los años, este método ha evolucionado, dando lugar a variantes como el PRM basado en visibilidad, MAPRM (Masehian and Sedighizadeh [2010]) y OBPRM (Alarabi et al. [2022]), mejorando sustancialmente el proceso de generación de nodos aleatorios y su efectividad en la resolución de problemas. La estructura convencional del PRM se desglosa en tres fases:

- Generación de nodos aleatorios en regiones de configuración libre.
- Conexión de los nodos mediante aristas que se encuentran en el espacio libre, formando un único gráfico.
- Búsqueda del camino más corto en el gráfico para alcanzar la conexión entre los nodos de inicio y de destino.

En la presente versión del PRM, se consideran cuatro conjuntos de nodos en el espacio libre, que son:

1. Un conjunto de nodos generados de forma aleatoria.
2. La posición actual del robot.
3. Las mejores partículas generadas por el algoritmo PSO.
4. Dos puntos localizados alrededor de cada esquina de los obstáculos presentes.

Esta combinación de nodos propuesta por primera vez en este trabajo garantiza una integración coherente entre los métodos PSO y PRM. Además de los nodos generados aleatoriamente, típicos en el método PRM y que representan aproximadamente el 50 % del total de nodos, se integra en el gráfico PRM alrededor del 30 % - 40 % de las partículas del PSO con los valores de aptitud más altos (pbests). El elemento (4) contribuye a evitar intersecciones con los obstáculos en las esquinas convexas gracias a la incorporación de bordes en el PRM entre nodos, facilitando así la navegación en los vértices de los obstáculos de manera natural y fluida.

En consonancia con esta línea de investigación, los autores también proponen en su estudio técnicas adicionales, como se detalla en [Sedighizadeh and Masehian \[2010\]](#), donde se describe un enfoque único y novedoso para combinar y unificar los componentes PSO y PRM, junto con los componentes NPSO.

El procedimiento de NPSO se asemeja al del PSO, con la excepción de que, en lugar de determinar la mejor dirección basada en la mejor posición de todas las partículas (gbest), se identifica y evita la peor posición de todas las partículas (gworst).

En este caso se integran cuatro grupos de nodos en una sola población: las mejores soluciones generadas por los algoritmos de PSO y NPSO por separado son elegidas, y generan de forma aleatoria los nodos para el algoritmo de PRM modificado como ya se explicó en el método anterior; estos corresponden a la posición actual, las sucesivas posiciones y los nodos alrededor de cada obstáculo para bordearlo como se puede ver en la Figura 2.2. Con esta información el algoritmo de PRM lo procesa y busca la ruta más corta entre cada par de posiciones.




Figura 2.2: Representación de la actualización de la posición de una partícula en PSO, (imagen tomada de Masehian and Sedighizadeh [2010])

Con esto, el espacio libre alrededor de los obstáculos se computa eficientemente en mucho menos tiempo que cuando se emplea el PRM clásico. Tras los buenos resultados obtenidos se propone añadir el factor de la seguridad como línea futura.

### 2.1.3. Longitud, suavidad y seguridad como prioridad

En el trabajo de Jun and Qingbao [2010], se introduce un algoritmo de planificación de rutas para robots con objetivos múltiples basado en un algoritmo genético mejorado, que incorpora la consideración de tres factores fundamentales: longitud, suavidad y seguridad. Los resultados obtenidos a través de experimentos de simulación demuestran la obtención

de soluciones optimizadas de Pareto, que abarcan múltiples rutas óptimas, lo que aumenta la viabilidad y aplicabilidad de las soluciones en escenarios de la vida real.

La eficiencia de Pareto, también conocida como optimalidad de Pareto, denota un estado de asignación de recursos en el cual es imposible reasignar dichos recursos de manera que se mejore al menos un criterio de preferencia sin empeorar otro criterio. Este concepto formal de optimización de Pareto es esencial para determinar la eficiencia en un contexto multiobjetivo. Una asignación no alcanza la eficiencia de Pareto si existe una alternativa que mejora al menos el bienestar de un participante sin disminuir el bienestar de otro. Si no es posible realizar más mejoras de Pareto, la asignación se considera un “óptimo de Pareto”.

En el trabajo de [Ahmed and Deb \[2013\]](#), se presenta una modificación del NSGA-II (un algoritmo genético no dominado, previamente discutido en relación con la seguridad y la longitud), incorporando un tercer factor: la suavidad de la trayectoria. La longitud de la ruta y la vulnerabilidad de la ruta se emplean como dos objetivos durante el proceso de planificación, en el que, de manera similar a otros trabajos, el espacio se modela como una cuadrícula. La restricción del número de celdas que interfiere se gestiona utilizando un enfoque de función de penalización. La suavidad se considera cuando el algoritmo se enfrenta a soluciones con un mismo rango, priorizando aquella con la suavidad más óptima. Además, el valor de suavidad también se utiliza durante la etapa de posprocesamiento en situaciones en las que dos soluciones coinciden en un mismo punto. La solución preferida es aquella que exhibe el mayor grado de suavidad, con ángulos más amplios considerados más fluidos que los estrechos.

Estos enfoques subrayan la importancia de la suavidad como un factor crítico, ya que contribuye a generar trayectorias continuas que reducen el deslizamiento, lo que resulta en un menor consumo de energía y tiempos de viaje más eficientes. Los resultados de las simulaciones demuestran que esta consideración específica permite identificar trayectorias viables con mayor precisión, incluso en entornos de gran tamaño con una densidad significativa de obstáculos (hasta un 91 % de la superficie). La diversidad inherente preservada en los algoritmos genéticos multiobjetivo permite hallar soluciones en estos entornos desafiantes, en los cuales los enfoques

convencionales o los algoritmos de objetivo único podrían enfrentar dificultades considerables para encontrar rutas adecuadas.

Un ejemplo adicional de planificadores de rutas multiobjetivo que consideran estos tres factores (longitud, seguridad y suavidad) se encuentra en el trabajo de [Mac et al. \[2017\]](#), donde la suavidad se trata como un objetivo secundario. La adaptación de este algoritmo implica el desarrollo de un innovador algoritmo jerárquico de planificación de rutas global en un entorno desordenado, enfocado en minimizar la longitud de la ruta y maximizar la suavidad de la misma a través de una optimización de enjambre de partículas con una metodología de actualización acelerada basada en Pareto, logrando así un algoritmo con una eficiencia computacional notable. En resumen, este método implica tres pasos de cálculo: en primer lugar, se establecen los obstáculos, las limitaciones del espacio y el espacio de seguridad, y se aplica el método de descomposición triangular para identificar el espacio libre; en segundo lugar, se utiliza el algoritmo de Dijkstra para generar una ruta libre de colisiones; por último, se emplea la función MOPSO para obtener la ruta óptima, considerando inicialmente la longitud de la ruta y posteriormente la suavidad de la misma.

Siguiendo este enfoque de trabajo se destacan también las contribuciones de [Geetha et al. \[2011\]](#), [Nayl et al. \[2017\]](#), [Hidalgo-Paniagua et al. \[2015\]](#), [Hidalgo-Paniagua et al. \[2017\]](#), [Hidalgo-Paniagua et al. \[2016\]](#).

#### 2.1.4. Suavidad como prioridad

En otros estudios, se ha puesto un énfasis particular en el factor de “suavidad”. Por ejemplo, en el trabajo de [Kanayama and Hartman \[1989\]](#), se emplea una estrategia de planificación de trayectorias basada en curvas clotoides para generar trayectorias continuas sin interrupciones. Este enfoque se centra en la optimización de la suavidad y ha demostrado lograr resultados superiores en comparación con enfoques anteriores. La suavidad de la trayectoria se convierte en una prioridad esencial en situaciones que requieren movimientos fluidos y continuos, como en la programación de sistemas de navegación para vehículos autónomos.

Por otro lado, los trabajos de [Zhang et al. \[2011\]](#) y [Minh and Pumwa \[2014\]](#) presentan una evolución de la metodología mencionada anterior-

mente, donde ambos enfoques emplean la planificación de trayectorias polinómicas. A pesar de que la cuestión del deslizamiento del vehículo posteriormente se pasó por alto debido a la velocidad en las curvas, en general, estos estudios demostraron la viabilidad, seguridad y suavidad de las trayectorias obtenidas.

### 2.1.5. Otros factores

#### 2.1.5.1. MAPA DE COSTOS

Diversos algoritmos avanzados en la literatura científica consideran tanto la longitud de la ruta como la seguridad, tal como se menciona en Lavin [2015b], Lavin [2015c], y Lavin [2015a]. Estos algoritmos también introducen el concepto de un “mapa de costos”. La región en la cual el robot se desplaza se modela como una cuadrícula subdividida en celdas. Estas celdas pueden estar desocupadas, completamente obstruidas por obstáculos, o parcialmente libres. En consecuencia, el mapa de costos emite distintos valores dependiendo del grado de ocupación, que varían desde un costo mínimo para celdas desocupadas hasta un costo infinito para celdas totalmente bloqueadas. Esta representación de mapa de costos se utiliza para calcular rutas mediante los algoritmos D\*-PO y A\*-PO. Se ha demostrado que estos algoritmos no solo resuelven de manera efectiva la planificación de rutas, sino que también logran tiempos de cálculo superiores en comparación con los algoritmos clásicos A\* y D\*.

En la publicación Li et al. [2015], se presenta una variante del algoritmo A\* que utiliza segmentos de ruta planificados a través de los métodos de Marcha Rápida (FMM) y Método de Superficie Potencial (PSM). Este enfoque divide el proceso de planificación de rutas en dos fases independientes: la planificación propiamente dicha y el ensamblaje de rutas. Aunque ofrece un tiempo de cálculo eficiente, la ruta resultante no siempre es óptima, ya que su longitud tiende a ser mayor que la ruta óptima. Una variación que emplea heurísticas en los algoritmos A\* y D\* se describe en Toscano-Moreno et al. [2019]. Esta variante ha demostrado resultados prometedores en la planificación de trayectorias, con una reducción en el costo computacional, aunque este último está directamente vinculado al número de matrices que deben calcularse.

### 2.1.5.2. TIEMPO

En el contexto de los esquemas de navegación, un factor adicional de gran relevancia es el tiempo requerido para calcular la ruta, especialmente en entornos con elementos dinámicos, donde la rapidez de cálculo puede resultar crítica. En tales situaciones, la implementación de algoritmos complejos que consuman una cantidad significativa de tiempo de procesamiento puede no ser eficiente, ya que las soluciones obtenidas podrían carecer de validez en tiempo real (Petres et al. [2007]; Drake et al. [2018]).

Algunas investigaciones, como las expuestas en Marghi et al. [2017], proponen un cambio de paradigma, sugiriendo replicar el proceso predictivo utilizado por los seres humanos para la toma de decisiones de navegación. En este contexto, los autores presentan un modelo predictivo que evalúan en un escenario de planificación de rutas durante la conducción de vehículos.

Con el fin de abordar estas cuestiones, se diseñaron dos conjuntos de experimentos para analizar el comportamiento de los individuos en la planificación durante la conducción. En la figura 2.3 podemos ver el esquema del experimento. Se configuraron el punto de partida y los destinos de tal manera que la ruta más corta entre ellos sería una línea recta, sin obstáculos presentes. Se manipularon las velocidades relativas del automóvil y otros objetos dinámicos, como peatones y vehículos, para garantizar la posibilidad de colisión si el automóvil continuaba en línea recta.




Figura 2.3: Esquema del experimento (imagen tomada de Marghi et al. [2017])

Cada grupo de estudio realizó cuatro tareas de conducción orientada a objetivos (GDT) con diferentes configuraciones ambientales. En todos los casos, hubo cuatro objetos como obstáculos ambientales: dos peatones y dos automóviles. Antes de realizar las tareas de prueba, los sujetos tuvieron tiempo suficiente para familiarizarse con el volante del simulador de automóviles, el medio ambiente y los objetos virtuales. Cada experimento fue repetido hasta que se lograron tres ensayos sin colisiones.

La calidad de las rutas se evaluó considerando factores como la distancia, el desplazamiento lateral y la seguridad, en términos de generar la ruta más corta entre las opciones disponibles, respetando una distancia segura con los objetos y evitando colisiones. La evaluación del rendimiento de las rutas generadas se basó en la distancia mínima y la máxima seguridad.

Se obtuvieron varios resultados según el grupo:

-En el Grupo de Estudio I, se reveló que el cerebro humano adapta la longitud temporal de la predicción durante la planificación, según las configuraciones ambientales. Esto implica la capacidad de prever un horizonte temporal más largo o más corto, dependiendo de la ubicación y los movimientos de los objetos. Se demostró que, al emplear esta estrategia, la mayoría de los participantes lograron planificar una ruta sin colisiones que se acercaba a la ruta óptima en función de los factores especificados.

-En el Grupo de Estudio II, se analizó el rendimiento de los individuos en un entorno con visibilidad limitada y se comparó con los resultados del Grupo I. La comparación entre ambos grupos ilustró que, incluso con una limitación en el campo visual, los sujetos aún podían planificar una trayectoria eficiente ajustando la predicción del horizonte.

Estos resultados respaldan la teoría que sostiene que el cerebro humano emplea un enfoque de predicción basado en modelos. En efecto, el cerebro utiliza un modelo interno construido a partir del entorno y los objetos presentes para estimar posibles puntos de colisión. Cuando no hay probabilidad de colisión, el cerebro prevé a corto plazo, ignorando los obstáculos y manteniendo la ruta estimada. Sin embargo, cuando se percibe una colisión como probable, la ruta se ajusta en consecuencia.

Siguiendo esta línea de investigación, se han propuesto otros enfoques relevantes. En el trabajo de [Chen et al. \[2018a\]](#), se presenta un algorit-

mo de navegación que, al basarse en los patrones de comportamiento del usuario, toma como referencia las soluciones adoptadas por un grupo similar y las adapta de manera personalizada. Por otro lado, [Gong et al. \[2018\]](#) proponen un modelo para simular la planificación de rutas en humanos. Si bien tienen en cuenta tres factores fundamentales -seguridad, curvatura del camino y distancia-, priorizan la seguridad sobre los demás. Asignan valores a cada factor para establecer su prioridad y realizan pruebas ajustando estos valores para generar rutas acordes a requisitos específicos sobre la importancia relativa de cada factor.

### 2.1.5.3. BIOLÓGICOS

Las metodologías de inspiración biológica han llevado el concepto de emplear tres objetivos para descubrir rutas viables a un nivel más avanzado. En [Hidalgo-Paniagua et al. \[2015\]](#), se aplican algoritmos de salto de rana, mientras que en [Hidalgo-Paniagua et al. \[2017\]](#), se utilizan algoritmos basados en el comportamiento de las luciérnagas para abordar la planificación de rutas. Por otro lado, en [Hidalgo-Paniagua et al. \[2016\]](#), se introduce por primera vez el concepto de una Búsqueda de Vecindad Variable Multiobjetivo (MOVNS) para resolver la planificación de rutas en robots móviles. En esta contribución, el factor de suavidad se considera no solo como un criterio de discriminación en situaciones coincidentes, sino también como un objetivo en sí mismo. Por lo tanto, en [Hidalgo-Paniagua et al. \[2016\]](#), se ajusta la función de idoneidad para lograr una mejor armonización de los tres factores. Se elige la combinación óptima basada en el rendimiento que proporcione las mejores soluciones para la planificación de rutas. Estas tres aportaciones han logrado mejorar significativamente la calidad de la planificación de trayectorias en comparación con el clásico método NSGA-II. Además, se analiza la relación entre la suavidad de la ruta y el consumo de energía, proporcionando así una comprensión más profunda de su impacto en la eficiencia general del sistema.

## 2.2. Hacia una navegación socialmente apropiada.

La interacción efectiva entre el robot y las personas, junto con la percepción que dicha interacción genera en ellas, es fundamental para asegurar que la experiencia sea cómoda y agradable para el usuario. Es necesario tener en cuenta no sólo criterios de proxémica, sino también ser consciente del contexto social (Wang et al. [2016]). Así, por ejemplo, cuando el robot se acerca a la persona debe evitar acercarse demasiado para no generar una sensación de amenaza o incomodidad. Es crucial que el robot se mueva de manera adecuada alrededor de las personas, evitando interrupciones y manteniendo una distancia segura al pasar por detrás, entre otros aspectos relevantes.

Para evaluar con mayor precisión las sensaciones provocadas por el robot, se realizan experimentos que observan y evalúan estas respuestas a través de encuestas. Estudios como los presentados en Thomaz and Cakmak [2009], Dautenhahn et al. [2006] y Shiomi et al. [2014] han concluido que el enfoque preferido de aproximación del robot debería ser lateral en lugar de frontal, ya que el enfoque frontal podría generar sentimientos de amenaza o sorpresa. Además, se plantea que estas sensaciones pueden variar según el sexo de la persona, aunque no se han obtenido conclusiones definitivas al respecto.

Con respecto al desplazamiento del robot, se considera fundamental que el robot reconozca y respete la *zona de confort* definida alrededor de las personas, tal como se ha planteado en Dautenhahn et al. [2006]. Estas zonas de confort se definen como áreas de seguridad alrededor de las personas, que pueden tener forma de círculo o elipse, especialmente cuando las personas están en movimiento como se ilustra en la figura 2.4. Si bien una primera intuición sería simplemente evitar estas zonas, en la práctica la solución no suele ser tan simple como trazar un círculo alrededor de la persona y evitar que el robot lo penetre, ya sea para interactuar o moverse en su entorno. Dado que las personas pueden estar en constante movimiento y puede haber múltiples individuos y obstáculos presentes, en muchas ocasiones resulta inevitable que se produzca esta invasión con la zona de confort definida. En estos casos se suele aconsejar que el robot se quede inactivo hasta que, por la propia dinámica de la escena, se

salga de esta zona (Dautenhahn et al. [2006]; Li and Huang [2010]). Pero esta aproximación también puede provocar situaciones problemáticas, por ejemplo, en un pasillo. El proceso, en definitiva, es complejo si quiere resolverse de forma socialmente correcta.




Figura 2.4: Ilustración de diferentes zonas de confort (imagen tomada de Li and Huang [2010])

A la hora de aproximar una solución a estas situaciones, es interesante examinar el estudio llevado a cabo en Shiomi et al. [2014], donde se plantea la necesidad de combinar la navegación segura (sin colisiones) con la navegación basada en las normas sociales. Esta premisa se debe a que la percepción de inseguridad por parte de las personas a menudo se origina en el propio comportamiento del robot. Si dicho comportamiento busca sólo la navegación segura, aunque se utilicen técnicas de planificación y predicción que hagan que el robot evite el contacto físico, en entornos reales pueden surgir dificultades por las propias reacciones de las personas. Por ejemplo, existen casos en los que la persona no percibe inicialmente la presencia del robot y, al notarlo repentinamente, experimenta sentimientos de inseguridad, aunque no haya una amenaza real. Estas situaciones pueden provocar reacciones repentinas o desviaciones imprevistas por parte de las personas, lo que a su vez puede conducir a colisiones no previstas por el robot. Los resultados de este experimento, que evaluó ambos enfoques, revelaron que el método propuesto por los autores, que combina la navegación segura con la navegación social en consonancia con las normas aceptadas, es percibido como más seguro que un método alternativo como puede ser un método de planificación de movimiento con restricciones sobre la distancia social o el espacio personal. La conclusión que sugiere este trabajo es que, al imitar los movimientos

de los seres humanos, el robot evita los obstáculos de una manera socialmente más aceptable, según la percepción de las personas. Y como resultado, el método propuesto no interrumpe el flujo normal de la multitud, evitando movimientos bruscos entre los peatones circundantes, ya que éstos perciben los movimientos del robot como *socialmente adecuados*. Esta conclusión se sustenta en ejemplos específicos en los que tanto los peatones como el robot lograron evitar colisiones de manera exitosa.

En contraste, los enfoques alternativos parecen reflejar la falta de esfuerzos por reproducir un comportamiento socialmente aceptable. Por ejemplo, un método determinado planea una trayectoria que garantiza evitar colisiones con los peatones, asumiendo que estos obstáculos se mueven con velocidad constante. Esta suposición resulta ser bastante restrictiva, lo que le permite al método evitar colisiones de manera consistente, lo que se etiquetó como “seguro” durante el experimento. Pero a pesar de la ausencia de colisiones, el robot a veces era percibido como inseguro por los peatones, ya que no se alineaba con la “norma social” esperada. Por ejemplo, en una escena específica, el peatón comenzó a desviarse ligeramente de su curso antes de acercarse al robot. El robot esperó hasta que estuvo cerca del peatón para detenerse y girar a la derecha, lo que el peatón percibió como una acción insegura. Es posible que el peatón esperara que el robot comenzara a desviarse mucho antes y de manera más suave, lo que causó que el peatón se apartara para evitar el robot, sugiriendo así un comportamiento socialmente inaceptable.

Además, se evaluó el comportamiento del robot en situaciones concurridas. En una instancia, el método propuesto permitió que el robot navegara con éxito en un entorno abarrotado en el que había múltiples personas. El robot inicialmente se dirigía hacia un grupo de personas, pero su trayectoria se ajustó para evitarlas de manera efectiva al girar hacia la derecha. Luego, el robot modificó su dirección nuevamente para sortear a otro grupo con éxito. Este ejemplo ilustra cómo el método propuesto logra evitar colisiones con personas incluso en entornos densamente poblados.

En contraste, el método tradicional dio lugar a situaciones incómodas en entornos con múltiples personas. En una situación, el robot en cuestión se acercó a un grupo de peatones, quienes se apartaron para permitir que el robot pasara. Aunque el método tradicional evitó la colisión en esta

ocasión, la necesidad de que los peatones se apartaran activamente para dejar pasar al robot fue una interacción poco común entre ellos. A pesar de que el robot tuvo suficiente tiempo para ajustar su trayectoria y evitar la colisión, este cambio de curso ocurrió demasiado tarde y no fue percibido como aceptable por los peatones.

Además, se describen las limitaciones y variaciones de este tipo de navegación, dada la complejidad del comportamiento humano y los múltiples factores involucrados. Por ejemplo, el método se basó en el análisis de características dinámicas de las trayectorias peatonales, asumiendo un comportamiento completamente simétrico de los peatones involucrados en la maniobra de evasión de colisiones. Sin embargo, el comportamiento humano es más complejo debido a la presencia de normas sociales variables.

El modelo propuesto solo considera los comportamientos relacionados con la evasión de colisiones y la interacción directa con los peatones, pasando por alto otras actividades sociales que los seres humanos pueden realizar en entornos peatonales. El experimento también destaca la necesidad de un conjunto de aprendizaje sólido de las trayectorias peatonales alrededor del robot, junto con un algoritmo de aprendizaje adecuado, para capturar con precisión la función de fuerza de interacción correcta.

Es crucial dotar a los robots de la capacidad de comportarse de manera socialmente aceptable. En este contexto emergen varios trabajos destacados, como el presentado por [Núñez et al. \[2016\]](#). En su investigación, proponen la implementación de un planificador de ruta semántica global en conjunto con un modelo de navegación social. Esta propuesta teórica permite al robot elegir la mejor ruta desde su posición actual hasta otra posición, incluso en escenarios dinámicos y complejos. Esto se logra al aplicar reglas sociales que garantizan su aceptación en el entorno. Para lograr una alta funcionalidad y robustez, se emplea la arquitectura cognitiva CORTEX, que se caracteriza por su conjunto de agentes diversos en el espectro deliberativo-reactivo y la representación de estado profundo.

En otra investigación relevante, presentada en [Vega et al. \[2019\]](#), se describe una novedosa estrategia para la navegación de robots sociales. Esta estrategia se basa en una función de densidad espacial adaptativa para agrupar eficientemente a grupos de personas según sus patrones de orga-

nización. La función propuesta define las regiones en las que la navegación está desaconsejada o prohibida. La arquitectura de navegación combina un mapa de carreteras probabilístico con planificadores de rutas de árbol aleatorio de exploración rápida, y también incorpora una adaptación del algoritmo de banda elástica para considerar el comportamiento social. Se realizaron numerosos ensayos en entornos reales y simulados para demostrar el rendimiento del algoritmo de agrupamiento y la arquitectura de navegación social.

En los estudios anteriores se pone de manifiesto la importancia de tener en cuenta las normas y convenciones sociales para modular la navegación. Pero una característica de dicho contexto es su variabilidad. Así, es necesario tener en cuenta el factor cultural, ya que las distancias que las personas mantienen con el robot dependerán de cómo la apariencia y el comportamiento del mismo se integren en la cultura particular de dichas personas. De hecho, puede ser necesario recalibrar el método de navegación antes de aplicarlo a diferentes robots y culturas. Y aun así, el comportamiento que el robot debe adoptar en cada situación puede variar según otras circunstancias más concretas, tales como la identidad de la persona con la que interactúa, el momento del encuentro, o el tipo de acción a realizar.

Esta adaptación al contexto no sólo es importante en la navegación: la Robótica Socialmente Consciente (*Socially Aware Robots o SAWR*) ha surgido como un campo de investigación crucial para comprender cómo los robots pueden integrarse de manera más efectiva en entornos sociales complejos. En particular, se destaca la importancia de que los robots sean capaces de percibir y anticipar el comportamiento humano, respondiendo de acuerdo con las normas sociales establecidas (Gao and Huang [2022]; Rios-Martinez et al. [2015]; Truong and Ngo [2017]; Ferrer et al. [2017]; Chen et al. [2017a]; Vega et al. [2019]). En cuanto a la navegación, una habilidad esencial para la mayoría de las soluciones robóticas, se requiere una consideración más profunda de la comodidad humana y las normas sociales. Los enfoques convencionales resultan limitados en entornos dinámicos, lo que ha motivado el surgimiento de nuevas propuestas y un análisis exhaustivo en el campo de la navegación consciente social. Los conceptos relacionados con el factor humano se destacaron en los docu-

mentos de investigación de Rios-Martinez et al. [2014], Samarakoon et al. [2022] (proxémica), y Charalampous et al. [2017] (mapeo semántico y social). El artículo de revisión de Gao and Huang [2022] se centra en los métodos de evaluación, escenarios, conjuntos de datos y métricas comúnmente utilizados en investigaciones anteriores sobre navegación consciente social. Zhu and Zhang [2021] revisan los métodos de Aprendizaje Profundo por Reforzamiento (DRL) y los marcos de navegación basados en DRL. Diferencian entre varios escenarios típicos de aplicación: evasión local de obstáculos, navegación en interiores, navegación multirobot y navegación social. Chik et al. [2016] se centra en la navegación de robots como una tarea jerárquica, que implica una colección de subproblemas que pueden ir desde la decisión de alto nivel hasta la evitación reactiva de obstáculos de bajo nivel. La revisión resaltó cómo toda la pila de navegación debería evolucionar para abordar el problema de lidiar con entornos humanos dinámicos, incluida la detección y el seguimiento de humanos, y la modelización predictiva, a un nivel más local, y considerar los costos sociales a un nivel más alto.

El análisis de Kruse et al. [2013] sobre la navegación consciente de los humanos y su taxonomía de enfoques ha sentado las bases para investigaciones posteriores que buscan comprender mejor cómo los robots pueden adaptarse a entornos sociales dinámicos y mejorar su interacción con los seres humanos. Estos esfuerzos se centran en desarrollar sistemas de navegación que se asemejen más a la percepción y comportamiento humanos, lo que resulta fundamental a medida que los robots desempeñan un papel cada vez más importante en entornos sociales complejos.

En esta tesis se amplía el marco establecido por Kruse et al. [2013] en dos dimensiones cruciales. En primer lugar, se actualiza el análisis para incluir enfoques recientes y hallazgos de investigación de la última década en el ámbito de la navegación social. En segundo lugar, se enfoca en métodos que permiten que un robot ajuste su comportamiento en presencia de otros agentes móviles o al trazar una ruta específica, considerando, por ejemplo, el no interrumpir a grupos de individuos en conversación. Por lo tanto, este enfoque difiere significativamente del marco establecido por Kruse et al. [2013], al centrarse no sólo en la funcionalidad, sino en la capacidad del método para aprender de observaciones anteriores y

prever eventos futuros inmediatos. Los términos “Predicción” y “Aprendizaje” guiarán la revisión bibliográfica, permitiendo la identificación de subgrupos dentro del ámbito más amplio de la navegación social.

Además, esta investigación tiene como objetivo resaltar estudios que prioricen la comodidad social y explorar la evolución de los métodos de navegación social para dotar a los robots de habilidades más humanas. A medida que los robots se vuelven cada vez más similares a los humanos, comprender las complejidades de las normas sociales y adaptarse a ellas se convierte en un factor crucial para maximizar la aceptabilidad y utilidad. Los hallazgos de estos estudios arrojan luz sobre cómo diseñar robots con capacidades mejoradas, para interactuar de manera más efectiva y natural con los humanos en entornos sociales específicos.

### Metodología

Para llevar a cabo este estudio, se ha realizado una selección de una colección de documentos sobre los temas de navegación social, con un enfoque especial en las palabras clave “predicción” y “aprendizaje”. Nuestro proceso de selección involucró una revisión exhaustiva de la literatura, basada en los trabajos de Kruse et al. [2013], Chik et al. [2016], Gao and Huang [2022] y Zhu and Zhang [2021], ampliándolos con citas recientes. Se seleccionaron los documentos más relevantes que exploraban áreas como la navegación social, la comodidad, la predicción y el aprendizaje. Estos documentos se redujeron al evaluar la calidad y relevancia de las referencias citadas en cada artículo. Finalmente, se dio prioridad a los documentos que fueron citados con mayor frecuencia en investigaciones previas.

Para obtener una comprensión del número de documentos publicados sobre estos temas de interés, se pueden referir a los gráficos presentados en las Figuras 2.5 a 2.7. Estas visualizaciones se crearon utilizando datos de Web of Science<sup>2</sup>. Al investigar el tema (TS=(social AND navigation)) AND TS=(robot), se encontraron 723 resultados en el período de 1994 a 2022. La omisión de los datos del año en curso, 2023, se debe a que el año aún no ha concluido y podría distorsionar las estadísticas. Al agre-

<sup>2</sup><https://clarivate.com/webofsciencelgroup/solutions/web-of-science/>

gar  $TS=(\text{learning})$ , el número de referencias se reduce a 207 resultados (Figura 2.7). Con la inclusión de  $TS=(\text{prediction})$ , el recuento se reduce aún más a 80 resultados (Figura 2.6). De este extenso conjunto de datos, se han examinado minuciosamente 100 documentos en este estudio. La Figura 2.8 contrasta los documentos abordados en el estudio de Kruse et al. [2013] con los de la revisión actual.

La navegación social consciente, como se ha señalado previamente, tiene como objetivo no sólo encontrar una ruta libre de colisiones entre un punto de partida y un destino, sino también considerar meticulosamente el desplazamiento de las personas alrededor del robot y los procesos de interacción entre el robot y dichas personas. Cuando el número de individuos es reducido, se requieren pocas interacciones para evitar posibles colisiones, y estos tienden a moverse en trayectorias rectilíneas durante largos lapsos de tiempo. Sin embargo, a medida que aumenta la densidad de personas, surgen desafíos (Chen et al. [2022]). En estos escenarios, las personas deben modificar frecuentemente sus estados de movimiento (incluyendo dirección, velocidad y aceleración) en tiempo real para evitar colisiones mientras se esfuerzan por alcanzar sus destinos. Los modelos lineales ya no resultan adecuados para modelar las interacciones, ya sean entre humano-robot o humano-humano. La percepción del movimiento del robot por parte de los otros se vuelve especialmente relevante. Por tanto, además de garantizar la seguridad, es crucial que el movimiento del robot sea comprensible, permitiendo que las personas en las cercanías del robot entiendan fácilmente su intención de movimiento (Sisbot et al. [2007]).

El análisis de la evolución de la navegación consciente social de robots aborda dos temas fundamentales: (1) evaluar cómo las habilidades sociales del robot han contribuido a hacer las interacciones humanas más cómodas y naturales; (2) evaluar cómo los algoritmos abordan la navegación en entornos concurridos.

Siguiendo el trabajo previo de diversos investigadores sobre la navegación de robots en multitudes densas, clasificaremos en esta encuesta trabajos sobre la navegación de robots en tres categorías (Chen et al. [2022]; Kamezaki et al. [2022]): (1) enfoques reactivos; (2) enfoques proactivos; y (3) enfoques basados en el aprendizaje. Además, hemos agregado

una cuarta categoría: (4) enfoques de navegación con múltiples comportamientos. En los enfoques “reactivos”, el robot reacciona a otros agentes móviles mediante estrategias de “mirada adelante” de un solo paso (Chen et al. [2022]). Estos enfoques suelen ser altamente eficientes (por ejemplo, el modelo de fuerza social (Fiorini and Shiller [1993])). Los enfoques “proactivos” predicen el comportamiento humano y luego planean una ruta apropiada. Las predicciones pueden basarse en razonamientos (supuestos sobre el comportamiento general de los agentes) o en el aprendizaje (respaldado por observaciones sobre el comportamiento de los agentes) (Kruse et al. [2013]). Las estrategias de predicción pueden abordar tanto el movimiento humano (Rudenko et al. [2018]) como las intenciones (Chen et al. [2022]). Los enfoques “basados en el aprendizaje” buscan que el robot aprenda la política de navegación y la adapte al escenario objetivo. El aprendizaje profundo por refuerzo (DRL) ha sido ampliamente empleado para resolver este problema (Zhu and Zhang [2021]; Lee et al. [2018]). Por último, hemos añadido enfoques de “navegación con múltiples comportamientos” como una subsección aparte. Los enfoques de punta para la navegación de robots entre humanos generalmente se restringen a acciones de movimiento en el plano. Este trabajo aborda la cuestión de si puede resultar beneficioso emplear acciones de interacción, como hablar, tocar y hacer gestos, para permitir que los robots naveguen en entornos no estructurados y concurridos.

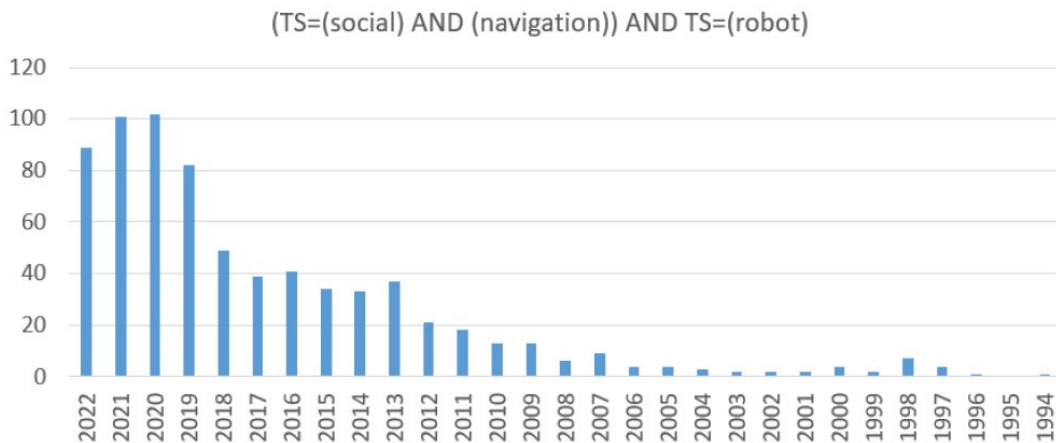


Figura 2.5: Web of Science Analyze filtro: (TS=(social AND navigation)) AND TS=(robot)

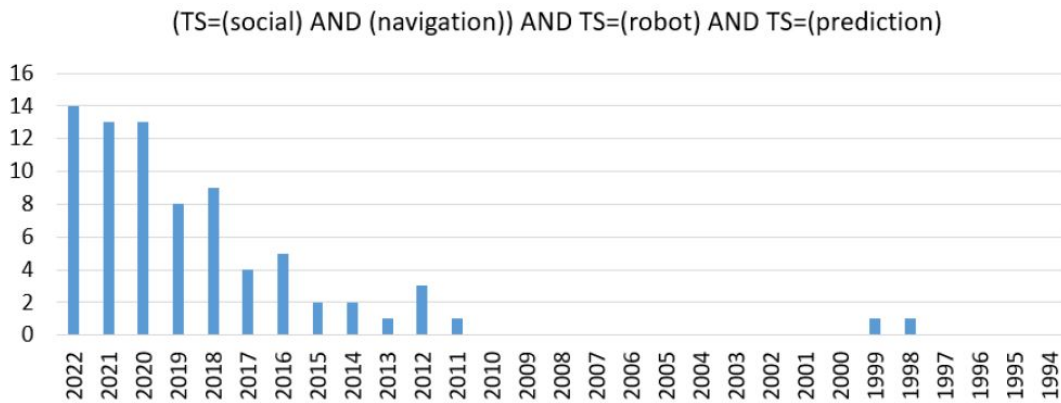


Figura 2.6: Web of Science Analyze filtro: (TS=(social AND navigation)) AND TS=(robot) AND TS=(prediction)






Figura 2.7: Web of Science Analyze filter: (TS=(social AND navigation)) AND TS=(robot) AND TS=(learning)




Figura 2.8: Distribución de publicaciones a lo largo de los años considerados por el artículo de revisión de Kruse et al. [2013] y la encuesta actual

### 2.2.1. Enfoques reactivos

Los robots que se desplazan en un entorno dinámico o desconocido pueden utilizar planificadores de trayectorias basados en búsqueda heurística de cuadrícula, o un enfoque basado en muestreo, para obtener rutas de alto nivel. Sin embargo, aunque estos planificadores de trayectorias pueden proporcionar rutas de bajo riesgo (Karlsson et al. [2021]), siempre deben combinarse con un sistema reactivo de evasión de colisiones. Esta capa de navegación reactiva debe operar a una alta frecuencia, para garantizar una detección y evasión de obstáculos lo suficientemente rápidas. Además, la presencia de diferentes agentes móviles en el entorno (personas u otros vehículos autónomos) convierte a este esquema de navegación local y reactivo en un elemento básico para mantener un entorno seguro. Estos dos factores (requisitos de velocidad y problemas de seguridad) convierten al procesador a bordo del robot en el dispositivo adecuado para ejecutar esta capa reactiva.

Esta sección recopila artículos que tratan sobre la navegación reactiva y local cuando hay otros agentes móviles en el entorno. Al ser enfoques reactivos, es posible que no tengan en cuenta la predicción o el aprendizaje. La Tabla 2.1 evalúa los enfoques cubiertos en esta sección. La mayoría de estos métodos se basan en el concepto de Obstáculo de Velocidad (VO), Campos Potenciales Artificiales (APF), Histograma de Campos Vectoriales (VFH) o Modelo de Fuerza Social (SFM). El concepto de VO fue introducido por Fiorini and Shiller [1993], y se ha utilizado ampliamente para garantizar una navegación segura (por ejemplo, Shiller et al. [2001], Kluge and Prassler [2004], Fulgenzi et al. [2007]). El concepto de VO de un obstáculo móvil  $A_j$  para un agente  $R_i$  es el conjunto de todas aquellas velocidades para  $R_i$  que resultarán en una colisión, en algún momento, con el obstáculo. Por lo tanto, en cada ciclo de planificación, el agente debe elegir una velocidad diferente a cualquiera de los VOs inducidos por los obstáculos móviles (ver Figura 2.9 (Derecha)). El APF es un enfoque de campo de fuerza virtual propuesto inicialmente por Khatib [1985]. En resumen, el movimiento del robot está controlado por una fuerza gravitatoria, generada por el objetivo a alcanzar, y fuerzas repulsivas, generadas por los obstáculos. Yao et al. [2020] proponen mejorar el APF tradicional con aprendizaje por refuerzo para lidiar con escenarios dinámicos. El en-

foque VFH utiliza una cuadrícula de histograma cartesiana bidimensional como modelo del mundo, que se actualiza continuamente con datos muestreados por sensores a bordo (Borenstein and Koren [1991]). Babinec et al. [2018] modifican el VFH\* para lidiar tanto con obstáculos estáticos como móviles. Como desventaja relevante, no puede manejar el movimiento no lineal.

El SFM simula la dinámica de los agentes utilizando fuerzas de interacción, como se ilustra en la Figura 2.9 (Izquierda). Permite expresar el comportamiento de evasión de colisiones a través de una función. Las entradas para esta función son las posiciones y velocidades relativas y absolutas de los agentes móviles (Helbing and Molnar [1995]). El SFM es un enfoque poderoso para la navegación de multitudes, como se discute en la siguiente sección, que presenta varios tipos de SFMs modificados propuestos para la navegación de robots y modelado humano. Por ejemplo, Zheng et al. [2020] proponen un SFM basado en el contagio emocional para asistente de evacuación (ecaSFM). El contagio emocional se trata principalmente de cómo las personas influyen en los comportamientos y sentimientos de los demás al notar los cambios emocionales en las personas cercanas y en el entorno (Xu et al. [2021]). Reddy et al. [2021] proponen un enfoque híbrido novedoso que extiende el SFM con restricciones geométricas. Esta propuesta mantiene la naturaleza proactiva del enfoque geométrico y conserva la naturaleza reactiva del SFM.




Figura 2.9: Las fuerzas (izquierda) de SFM. La fuerza resultante  $f$  en el robot  $R_i$  es provocada por un obstáculo estático (la pared,  $f_{iw}$ ) y uno móvil  $A_j$  ( $f_{ij}$ ). (Derecha) El obstáculo de velocidad  $VO_{ij}$  para un robot  $R_i$  inducido por un agente móvil  $A_j$ , con velocidad  $v_j$ .

Finalmente, resulta interesante incluir en esta lista la propuesta de [Palm and Driankov \[2015\]](#), como un ejemplo representativo de propuestas reactivas no basadas en los enfoques anteriores. [Palm and Driankov \[2015\]](#) utilizan el comportamiento de un fluido en presencia de obstáculos como similitud. Luego, proponen un método de navegación local en el que un conjunto de líneas de corriente se actualiza continuamente. El método es aplicable en un entorno donde hay otros elementos móviles, como robots o personas.

En la tabla 2.1 podemos ver una comparación de los métodos descritos, así como que estudios realizan simulaciones o experimentos reales y cuales añaden alguna característica específica para mejorar el confort social.

## Experimentos

Resulta fascinante comparar los experimentos simulados con aquellos realizados en el mundo real, con el propósito de establecer directrices que orienten la ejecución adecuada de los experimentos. Esta comparación busca validar los métodos que estamos investigando y, al mismo tiempo, generar nuevas ideas.

En cuanto a las simulaciones, diversos estudios utilizan este enfoque para evaluar la evitación de obstáculos, aunque con diferentes configuraciones de agentes. Por ejemplo, [Kluge and Prassler \[2004\]](#) examinan colisiones entre dos individuos y dos grupos de agentes, mientras que [Palm and Driankov \[2015\]](#) emplean combinaciones de humano y uno o dos robots.

Resulta interesante observar cómo algunas de estas simulaciones buscan replicar posibles experimentos reales: [Shiller et al. \[2001\]](#) emplean una aplicación interactiva; [Kluge and Prassler \[2004\]](#) simula situaciones reales como un partido de fútbol americano y una danza folclórica irlandesa; [Fulgenzi et al. \[2007\]](#) presentan el cruce de dos coches; [Palm and Driankov \[2015\]](#) utilizan datos reales y simulados en sus experimentos, y [Reddy et al. \[2021\]](#) modelan un Pioneer con datos muy similares a los utilizados en experimentos reales.

En relación con los experimentos reales, no todos se llevan a cabo exclusivamente en un entorno virtual. [Babinec et al. \[2018\]](#), [Yao et al. \[2020\]](#),

Zheng et al. [2020] y Reddy et al. [2021] validan sus resultados mediante pruebas en robots reales. Babinec et al. [2018] emplean un robot que crea obstáculos en movimiento; Yao et al. [2020] realizan experimentos en un espacio libre sin colisiones; Reddy et al. [2021] usan un Pioneer y ejecuta experimentos muy similares a los simulados, involucrando detección de rostros y humanos en movimiento.

Tabla 2.1: Métodos que utilizan para resolver el problema de navegación local

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Fiorini and Shiller [1993]	Obstáculo de velocidad (VO)	SI	NO	NO
Shiller et al. [2001]	Obstáculo de velocidad no lineal (NLVO)	SI	NO	NO
Kluge and Prassler [2004]	Obstáculos de velocidad probabilística recursiva	SI	NO	SI
Fulgenzi et al. [2007]	Obstáculo de velocidad probabilística (PVO) Cuadrícula dinámica de ocupación proporcionada por un sistema de sensores	SI	NO	SI
Palm and Driankov [2015]	Potencial de velocidad de un fluido incompresible	SI	NO	SI
Babinec et al. [2018]	Histograma de campo vectorial (VFH*)	SI	SI	NO
Yao et al. [2020]	BHPF. Calibrado utilizando el Q-learning profundo del campo potencial de agujero negro (BHDQN)	SI	SI	SI
Zheng et al. [2020]	Modelo de fuerza social mejorado basado en contagio emocional y asistente de evacuación	SI	SI	SI
Reddy et al. [2021]	Ampliar el modelo de fuerza social para incorporar las señales sociales Enfoque híbrido que combina el campo de potencial social y el método geométrico	SI	SI	SI

## Confort Social

En esta sección, se llevará a cabo un análisis pormenorizado de las características que se han incorporado o considerado para mejorar el confort social en la navegación e interacción robótica. Se abordarán diversos aspectos clave, como la gestión de la incertidumbre, la adaptabilidad, el reconocimiento de las intenciones humanas y el respeto a las normas sociales en las interacciones entre humanos y robots.

Entre las contribuciones más destacadas para el confort social, se encuentra la propuesta de [Kluge and Prassler \[2004\]](#), que plantea una navegación reflexiva basada en un enfoque probabilístico para abordar la incertidumbre inherente en la percepción y toma de decisiones. Este método se enfoca en suposiciones sobre el comportamiento futuro de otros agentes en el entorno. De forma similar, [Fulgenzi et al. \[2007\]](#) se basa en la adaptación del robot a la información disponible, aunque su enfoque reactivo y la limitación en la percepción podrían resultar en dificultades para lograr objetivos sin enfrentar emergencias evitables. En la misma línea, [Yao et al. \[2020\]](#) proponen un enfoque donde los agentes se adaptan automáticamente al entorno, utilizando información ambiental básica para encontrar objetivos, resaltando la capacidad de adaptación de los agentes en su interacción con el entorno.

El trabajo de [Palm and Driankov \[2015\]](#) resulta sumamente interesante al centrarse en el reconocimiento de las intenciones humanas para mejorar la interacción humano-robot. Este método implica la predicción de movimientos humanos, la planificación de reacciones y su ejecución en tiempo real. Además, [Zheng et al. \[2020\]](#) presentan un modelo de simulación que refleja con precisión los comportamientos de los peatones, incorporando elementos como el contagio emocional y la asistencia durante emergencias, lo que destaca las complejas reacciones de los peatones y el papel del contagio emocional en la dinámica social.

Por último, la propuesta de [Reddy et al. \[2021\]](#) aborda etiquetas sociales de navegación al solicitar espacio al ser humano y darle espacio cuando es demandado. Este enfoque incorpora una fuerza social adicional, permitiendo que el robot seleccione y navegue en una brecha socialmente adecuada, maximizando así el espacio disponible y favoreciendo una in-

teracción más armoniosa.

### 2.2.2. Enfoques proactivos

Los métodos puramente reactivos no son muy comunes en la navegación social. Al navegar entre personas, resulta interesante que el robot considere a estas personas como socios cooperativos. Por lo tanto, el robot puede interactuar con las personas para evitar colisiones conjuntamente (Trautman and Krause [2010]). Este enfoque cooperativo requiere que el robot (1) prediga el comportamiento (es decir, las trayectorias) de las personas y luego (2) planifique proactivamente la ruta a seguir. Existen una multitud de métodos para predecir el comportamiento de otros agentes móviles que comparten el entorno con el robot: desde aquellos que asumen ciertas suposiciones sobre cómo estos agentes se comportan en general (predicción basada en el razonamiento), hasta aquellos que se justifican en base a observaciones de cómo estos agentes se comportan, generalmente en un entorno específico o bajo condiciones específicas (técnicas basadas en el aprendizaje) (Kruse et al. [2013]). Los métodos subsiguientes de planificación de rutas incluyen, entre otros, versiones modificadas de SFM (Truong and Ngo [2017]) o el concepto de VO (Snape et al. [2011]). Las subsecciones siguientes describen el estado del arte en modelos predictivos y modelos de movimiento de agentes.

#### 2.2.2.1. Modelos predictivos

Los primeros intentos de modelar el comportamiento de otros agentes móviles, y así evitar rutas que pudieran llevar a colisiones, se basaron en modelos altamente deterministas de movimiento, sin considerar la incertidumbre y generalmente en un contexto de múltiples robots. En las propuestas de van den Berg et al. [2008] y Snape et al. [2011], se adaptó el concepto de Obstáculo de Velocidad para hacer frente a un escenario en el que varios robots coexisten, pero cada uno de ellos opera de manera independiente. Suponiendo que todos los robots emplean la misma técnica de navegación, el objetivo del Obstáculo de Velocidad Recíproco (RVO) (van den Berg et al. [2008]) es evitar el comportamiento oscilatorio que podrían adoptar al aproximarse o cruzarse con otro robot. El Obstáculo

de Velocidad Recíproco Híbrido (Snape et al. [2011]) amplía este enfoque al establecer prioridades en la interacción entre robots.

Muchos métodos proponen modificaciones al SFM (Zanlungo et al. [2011]; Ferrer et al. [2013a]; Shiomi et al. [2014]). El propósito de todas estas aproximaciones es trazar una ruta suave y libre de colisiones, teniendo en cuenta la presencia de agentes móviles, ya sean personas u otros vehículos autónomos. Para lograr esto, se utilizan técnicas interesantes. Por ejemplo, Zanlungo et al. [2011] suponen que las desviaciones del robot de la trayectoria recta hacia su destino se deben exclusivamente a la evasión de colisiones con otros agentes en movimiento, y prevén el momento futuro en el que las distancias relativas con cada agente que se aproxima sean mínimas. Luego, asumen que las fuerzas en ese momento dependen de la distancia entre los agentes móviles (especificación circular, CS). La Figura 2.10 ilustra la situación en la que interactúan dos agentes que se acercan. Las fuerzas son simétricas y circulares, como las utilizadas en CS, pero se basan en esta situación futura, que se considera la más relevante para el agente, ya que es cuando podría producirse una colisión. Shiomi et al. [2014] utilizan una versión específica del SFM, llamada CP-SFM, para simular un comportamiento de evasión de colisiones similar al de los humanos en robots, especialmente en entornos de baja densidad, como los pasillos de centros comerciales. Las rutas generadas por el planificador mantienen una distancia social de las personas y respetan su espacio personal.

Motores como el filtro de Kalman podrían emplearse para predecir la posición de agentes móviles alrededor del robot al tomar en cuenta la dimensión de la incertidumbre. No obstante, cuando hay múltiples agentes, el uso de estos motores conlleva a una *explosión de incertidumbre* (Trautman et al. [2015]), lo que potencialmente dificulta que el robot encuentre un camino seguro hacia su objetivo. Para mitigar este aumento en la incertidumbre, se han propuesto diversos modelos del movimiento humano Large et al. [2004], Thompson et al. [2009]. Por ejemplo, Du Toit and Burdick [2012] sugieren restringir directamente la incertidumbre predictiva de cada agente individual. Además, Joseph et al. [2011] detallan un modelo de movimiento más complejo: una combinación de procesos gaussianos con una prioridad de Proceso de Dirichlet en los pesos de la

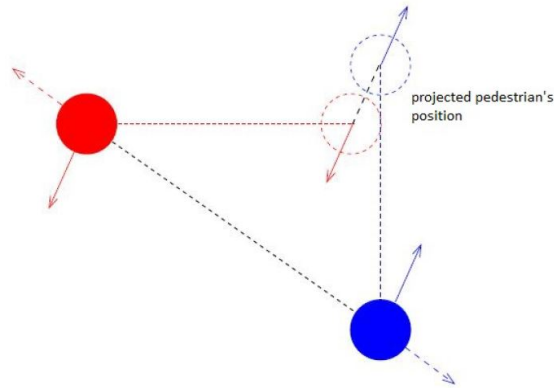


Figura 2.10: FM con predicción explícita de colisiones (imagen tomada de [Zanlungo et al. \[2011\]](#)): la posición de los agentes de color rojo y azul se proyecta en el momento en el que se espera la distancia mínima entre ellos (círculos punteados). Para evitar esa situación, los agentes acelerarán con los vectores de aceleración indicados por las flechas continuas (dibujadas tanto en las posiciones actuales como en las posiciones predichas). Las flechas punteadas (solo dibujadas en las posiciones actuales) son los vectores de aceleración si se aplica el modelo CS sin predicción. Permiso de Editorial EPL (Europhysics Letters)

mezcla. Sin embargo, este modelo no paramétrico conlleva un alto costo computacional. La solución a este problema se encuentra en el algoritmo RR-GP ([Aoude et al. \[2013\]](#)), una solución de predicción de trayectoria que se basa en el agrupamiento y utiliza árboles de alcance bayesianos no paramétricos para mejorar la precisión de la predicción gaussiana. A pesar de la propuesta de modelos individuales más sofisticados para lidiar con la incertidumbre de la posición, esta línea de investigación no considera la interacción entre agentes en sus modelos ([Trautman et al. \[2015\]](#)).

Como se mencionó previamente, la incertidumbre en el comportamiento futuro de las personas dificulta que un robot determine las acciones adecuadas para evitar colisiones. Además, evitar colisiones solamente aborda parcialmente el problema, ya que también se espera que el robot evite situaciones en las que su comportamiento moleste a las personas, como la proximidad excesiva. En un entorno en el que el robot interactúa con varias personas, en lugar de analizar el comportamiento de cada individuo

por separado, el robot debe poder predecir cómo evolucionará el comportamiento de las personas a lo largo del tiempo. Los enfoques comunes para predecir trayectorias, como el filtro de Kalman o los filtros de partículas, presentan limitaciones en este escenario (Ziebart et al. [2009]). Por ende, los métodos que consideran políticas basadas en objetivos resultan más apropiados. Por lo tanto, se asume que el comportamiento humano se refleja en las trayectorias observadas previamente, y el desafío radica en identificar a qué grupo de trayectorias pertenece la actual. Por ejemplo, Bennewitz et al. [2002] emplean modelos de patrones de movimiento humano, que pueden aprenderse mediante un algoritmo de Expectation-Maximization (EM). Con esta información, el robot puede predecir la ubicación actual y futura de las personas. Ziebart et al. [2009] sugieren el uso del control óptimo inverso de entropía máxima para modelar las trayectorias dirigidas por objetivos de las personas, un enfoque también adoptado por Kuderer et al. [2013]. Se analizan características representativas de las trayectorias de las personas para identificar las distribuciones de probabilidad que guían sus comportamientos de navegación. En Ferrer and Sanfeliu [2011] se describen varias funciones de predicción que utilizan el concepto de mínima variación de curvatura. Basado en el Predictor de Longitud de Curvatura (CLP), el wCLP promedia las predicciones anteriores en una ventana de tiempo limitada, demostrando su capacidad para identificar rápidamente nuevas intenciones de movimiento o comportamientos inesperados. Por otro lado, Kabtoul et al. [2020] proponen el uso de una función cuantitativa variable en el tiempo para modelar la cooperación humano-robot en un escenario de interacción. Mediante esta estimación de cooperación, el modelo de planificación de trayectorias basado en la cooperación puede predecir la trayectoria de movimiento humano. La Figura 2.11 ofrece un resumen del enfoque propuesto por Ikeda et al. [2013]. Este enfoque realiza un análisis offline para estimar subobjetivos (y un modelo de transición probabilístico) en el entorno (Figura 2.12). Posteriormente, durante la ejecución, el enfoque permite predecir las posiciones futuras de las personas según la secuencia de subobjetivos atravesados previamente y la velocidad actual.

En lugar de predecir trayectorias, Luber et al. [2011] explotan la influencia del entorno en el comportamiento humano para desarrollar un

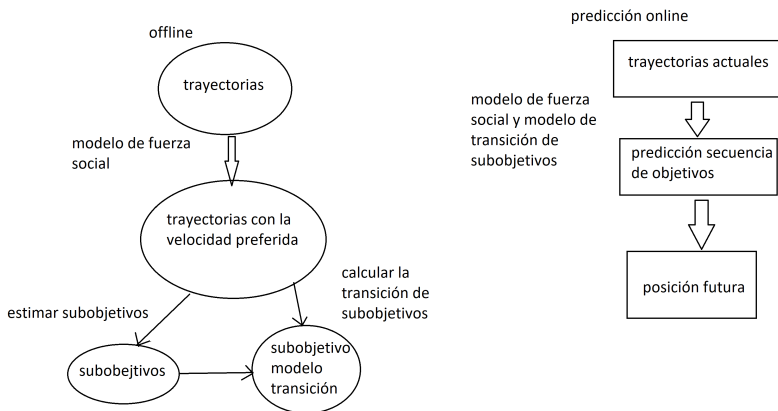


Figura 2.11: Descripción general del enfoque de Ikeda et al. [2013]

mapa de capacidades espaciales. El proceso de aprendizaje de este modelo espacial de conducta humana se plantea como una cuestión de estimación de parámetros de un proceso de Poisson espacial no homogéneo. El mapa de capacidades espaciales se genera mediante inferencia bayesiana a partir de observaciones de eventos de creación de rutas, coincidencias y falsas alarmas, obtenidas mediante la introspección de un rastreador de personas basado en láser que considera múltiples hipótesis. Si bien el marco se describe en el contexto de detección y seguimiento de personas, por ejemplo, se ha integrado en el esquema de navegación propuesto por Ferrer et al. [2013b].

Con el propósito de abordar la interacción humano-robot, varios autores han demostrado la utilidad de las mismas zonas proxémicas presentes en la interacción entre humanos para explicar escenarios de interacción humano-robot Vega et al. [2019], Mead and Mataric [2012], Mead et al. [2011]. Sisbot et al. [2007] proponen la inclusión de criterios relacionados con la seguridad y la visibilidad en el modelo, a fin de controlar la distancia entre el robot y el humano y mantener al robot mayormente en el campo de visión del humano. Las redes de seguridad, visibilidad y zonas ocultas

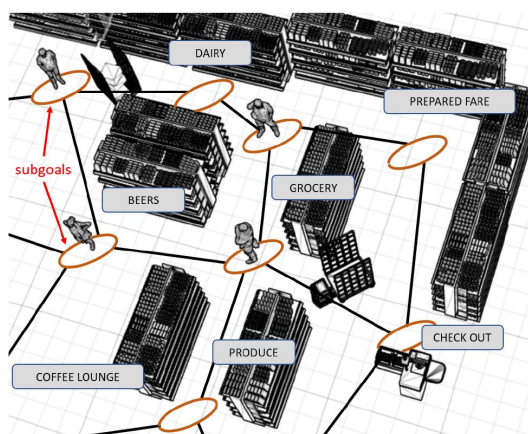


Figura 2.12: Ejemplos de distribución de submetas en un entorno. (Imagen basada en Ikeda et al. [2013])

se fusionan en una sola para encontrar la ruta más eficiente en términos de coste. En el trabajo de [Svenstrup et al. \[2009\]](#), el comportamiento del robot se basa en funciones de potencial adaptativas que se ajustan para respetar los espacios sociales de las personas. [Castro-González et al. \[2010\]](#) proponen un método para predecir las posiciones de las personas en situaciones de cruce utilizando la proxémica. El Modelo de Fuerza Social Modificado (MSFM) ([Ratsamee et al. \[2013\]](#)) integra componentes sociales (postura corporal, orientación facial y espacio personal durante el movimiento) en el SFM clásico basado en la posición humana. En el MSFM, la dirección prevista a corto plazo se describe mediante la postura corporal, y se añade una fuerza complementaria relacionada con la orientación facial para la estimación de la intención. La orientación facial se utiliza como la mejor indicación de la dirección del espacio personal durante el movimiento. Con el fin de dotar a los robots con la capacidad de navegar en entornos humanos dinámicos de manera socialmente aceptable, garantizando la comodidad y seguridad de las personas, [Truong and Ngo \[2017\]](#) proponen ampliar el SFM con la técnica del Obstáculo de Velocidad Recíproco Híbrido. El resultado es el llamado Modelo de Movimiento Social Proactivo (PSMM), que considera no solo los estados humanos (posición, orientación, movimiento, campo de visión y posturas

de las manos) en relación con el robot, sino también información interactiva social sobre las interacciones humano-objeto y humano-grupo. Se proporcionó un artículo de investigación que describe los conceptos sociales de la teoría proxémica aplicada en el contexto de la navegación autónoma con conciencia humana por [Rios-Martinez et al. \[2015\]](#), y más recientemente por [Samarakoon et al. \[2022\]](#). En general, estos algoritmos de navegación modelan la interacción humano-robot, haciendo hincapié en mantener distancias de seguridad adecuadas, pero no consideran la cooperación humano-robot.

En escenarios con multitudes densas, un problema común en los enfoques proactivos que consideran la incertidumbre en la posición de humanos o robots es el conocido como Problema del Robot Congelado (PRC) ([Trautman et al. \[2015\]](#); [Chen et al. \[2022\]](#)) (Figura 2.13). En pocas palabras, este problema surge cuando el robot no logra encontrar una ruta viable debido a la discrepancia entre el movimiento predicho y el movimiento real de los agentes móviles. Para abordar este desafío, se debe tener en cuenta la interacción de todos los agentes con los obstáculos estáticos y dinámicos del entorno. Esta estrategia es adoptada por los enfoques basados en SFM ([Ferrer and Sanfeliu \[2014b\]](#); [Farina et al. \[2016\]](#)) y por los enfoques de evitación de colisiones recíprocas óptimas (ORCA) ([van den Berg et al. \[2011\]](#); [Bera et al. \[2016\]](#); [Luo et al. \[2018\]](#); [Chen et al. \[2022\]](#)). En el enfoque de [Farina et al. \[2016\]](#), se propone la integración del SFM con los modelos de locomoción humana de Laumond, lo que permite reproducir de manera fiable los movimientos humanos tanto en espacios libres como en entornos altamente concurridos. En el planificador cinemático proactivo de [Ferrer and Sanfeliu \[2014b\]](#), se utiliza el Modelo de Fuerza Social Extendida (ESFM) para simplificar tanto el modelo de predicción como el sistema de planificación bajo restricciones diferenciales. Uno de los principales problemas de los enfoques basados en SFM es que la configuración de los parámetros depende del escenario específico ([Kim et al. \[2015\]](#)). Por su parte, el enfoque ORCA lleva a cabo una búsqueda optimizada en el espacio geométrico viable para calcular rutas libres. En la evitación de colisiones recíprocas n-cuerpos propuesta por [van den Berg et al. \[2011\]](#), el problema se reduce a resolver un programa lineal de baja dimensión basado en el concepto de VO. El enfoque

de Patrones de Movimiento Global y Local (GLMP) (Bera et al. [2016]) aprende las características del movimiento de los agentes y los patrones de movimiento a partir de trayectorias 2D utilizando la inferencia bayesiana. En este enfoque, los patrones de movimiento consideran aspectos locales, como las velocidades actuales y preferidas, así como características globales, como puntos de entrada y características de movimiento. Por otro lado, el Modelo de Evitación de Colisión Recíproca Óptima para Peatones (PORCA) propuesto por Luo et al. [2018] es un modelo de predicción de movimiento humano que tiene en cuenta la intención de navegación global de la persona y las interacciones locales con el robot y otras personas. El enfoque iORCA propuesto por Chen et al. [2022] utiliza un clasificador bayesiano ingenuo para estimar el destino más probable del peatón y calcular su velocidad. Además, para manejar posibles cambios de intención, el iORCA actualiza estos destinos en cada paso de tiempo. Por último, inspirado en el modelo RVO, el modelo eRVO integra el efecto emocional en la toma de decisiones de la velocidad (Xu et al. [2021]). En general, se ha demostrado que los enfoques ORCA son más estables que el SFM en escenarios de baja tasa de muestreo y en situaciones con multitudes densas (Curtis et al. [2013]; Xu et al. [2021]).




Figura 2.13: El problema del robot congelado (FRP). El robot es  $R_i$  y las elipses representan la covarianza predictiva. No es fácil para el robot encontrar una ruta hacia el objetivo.

Enfoques basados en datos también han sido propuestos para capturar el movimiento de agentes considerando interacciones con obstáculos estáticos y dinámicos. Inspirado en el éxito de las redes de Memoria a Corto y Largo Plazo (LSTM) en otras tareas de investigación, [Alahi et al. \[2016\]](#) presentan el Social-LSTM, una arquitectura basada en datos para predecir las trayectorias humanas en momentos futuros. Para capturar las dependencias entre múltiples secuencias correlacionadas, se introduce una capa de agrupamiento social que permite que las LSTMs asociadas a secuencias espacialmente cercanas compartan sus estados ocultos entre sí. De esta manera, el modelo puede aprender automáticamente interacciones típicas que ocurren entre trayectorias que coinciden en el tiempo.

Considerando que cada persona dentro de una multitud coopera implícitamente para evitar colisiones, la Atención Social propuesta por [Vemula et al. \[2018\]](#) captura la importancia relativa de cada individuo al navegar, sin enfatizar la proximidad. No obstante, el desafío de estos enfoques radica en su alto costo computacional, lo que dificulta su implementación en robots móviles.

En las tablas 2.2 y 2.3 podemos ver una comparación de los métodos descritos, así como que estudios realizan simulaciones o experimentos reales y cuales añaden alguna característica específica para mejorar el confort social.

## Experimentos

Los experimentos simulados en este grupo de métodos son de gran importancia, ya que se están obteniendo parámetros para la navegación, y la calibración de estos parámetros determina la eficiencia de la navegación en experimentos reales. Sin embargo, la necesidad de correcciones y recalibraciones puede afectar el rendimiento, y los resultados en los experimentos reales podrían no ser satisfactorios, lo que conlleva una considerable inversión de tiempo en la recalibración de estos parámetros.

Es importante comparar los diferentes escenarios que se usan para realizar las simulaciones así como los obstáculos dinámicos que se usan en la mayoría agentes o peatones para provocar las colisiones con el robot.

En primer lugar, tenemos aquellos que sólo usan entornos simulados

como van den Berg et al. [2008], Snape et al. [2011], Zanlungo et al. [2011], Aoude et al. [2013], Farina et al. [2016] y van den Berg et al. [2011]. En este grupo van den Berg et al. [2008], Snape et al. [2011] y Farina et al. [2016] juegan variando los agentes implicados para ir modificando los parámetros de los entrenamientos. Mientras Farina et al. [2016] demuestran a través de simulaciones cómo su Modelo de Fuerza Social Dirigida (HSFM) puede cambiar suavemente entre comportamientos holonómicos y no holonómicos según las condiciones externas actuales. Además, van den Berg et al. [2011] evalúan el rendimiento de su algoritmo de planificación de movimiento lineal cuadrático gaussiano (LQG-MP) mediante simulaciones para seleccionar una ruta. Mientras que Aoude et al. [2013] modelaron tres escenarios con distintos niveles de complejidad y comportamientos.

El resto simula entornos obtenidos del mundo real. Ferrer et al. [2013a] simulan entornos urbanos con personas en movimiento. No obstante, en Luber et al. [2011] se recopila un conjunto de datos para un registro de video y se compara el método de Seguimiento de Múltiples Hipótesis (MHT) con su enfoque. Por su parte, Large et al. [2004] realizaron una recopilación de datos híbrida, utilizando datos modelados en un simulador y datos de un sistema de seguimiento. Los datos recopilados por Thompson et al. [2009] provienen de un entorno de oficina con movimiento humano. A su vez, Du Toit and Burdick [2012] modelaron diferentes tipos de entornos, abarcando desde entornos estáticos hasta dinámicos con diferentes situaciones. Los datos obtenidos por Joseph et al. [2011] se registraron mediante el seguimiento de helicópteros, mientras Ziebart et al. [2009] instalaron medidores de distancia láser en ubicaciones fijas alrededor del laboratorio y ejecutó un algoritmo de seguimiento de peatones.

Por otro lado, Kuderer et al. [2013] modelaron escenarios aleatorios y evaluó el comportamiento de los peatones. Por su parte, Ferrer and Sanfeliu [2011] utilizaron un conjunto de datos públicos de la base de datos del mundo real del Edinburgh Informatics Forum, que incluye más de 92,000 trayectorias observadas de caminatas humanas en entornos públicos. Finalmente, Kabtoul et al. [2020] modelaron simulaciones que involucran tanto a peatones como a vehículos, mientras que Ikeda et al. [2013] recopilaron trayectorias en un gran centro comercial.

Tabla 2.2: Métodos que se utilizan para modelar el movimiento humano

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
van den Berg et al. [2008]	Obstáculo de velocidad recíproca	SI	NO	NO
Snape et al. [2011]	Obstáculos híbridos de velocidad recíproca	SI	SI	NO
Zanlungo et al. [2011]	SFM se extiende al futuro cercano	SI	SI	SI
Ferrer et al. [2013a]	Modelo de Fuerza Social (SFM)	SI	SI	SI
Shiomi et al. [2014]	Modelo de Fuerza Social de Predicción de Colisiones (CP-SFM)	NO	SI	SI
Trautman et al. [2015]	Algoritmo de procesos Gaussianos que interactúan con Múltiples Objetivos	NO	SI	NO
Large et al. [2004]	Velocidad de obstáculos (VO) Predicción del movimiento de obstáculos	SI	NO	NO
Thompson et al. [2009]	Modelo Probabilístico del Movimiento Humano	SI	NO	NO
Du Toit and Burdick [2012]	Umbral de la incertidumbre	SI	NO	NO
Joseph et al. [2011]	Procesos gaussianos (GP) Proceso de Dirichlet (DP)	SI	NO	NO
Aoude et al. [2013]	RR-GP: modelo de patrón de movimiento aprendido combinando la flexibilidad de los procesos gaussianos (GP) con la eficiencia de RRT-Reach	SI	NO	NO
Ziebart et al. [2009]	Control óptimo inverso de entropía máxima	SI	NO	NO
Bennewitz et al. [2002]	Patrones de movimiento humano	NO	SI	SI
Kuderer et al. [2013]	Entropía máxima	SI	SI	SI
Ferrer and Sanfeliu [2011]	Predictor de ventana de tiempo CLP	SI	NO	NO
Kabtoul et al. [2020]	Función cuantitativa variable en el tiempo para modelar la cooperación HR	SI	NO	NO
Ikeda et al. [2013]	Subobjetivos para recuperar información útil Modelado del entorno y simulación de peatones Subobjetivos utilizados como nodos del planificador de trayectorias global del robot y como nodos del planificador en el simulador de peatones	SI	NO	NO
Luber et al. [2011]	Proceso de Poisson espacial no homogéneo Inferencia bayesiana a partir de observaciones de creación de trayectorias Eventos de coincidencia y falsas alarmas Obtenidos mediante introspección de un rastreador de personas de múltiples hipótesis basado en láser	SI	NO	NO

Tabla 2.3: Métodos que se utilizan para modelar el movimiento humano II

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Vega et al. [2019]	Función de densidad espacial adaptativa Representación gaussiana asimétrica para el espacio personal Inclusión de las capacidades espaciales Mapeo de caminos probabilísticos (PRM) Árbol aleatorio de exploración rápida (RRT)	SI	SI	SI
Mead and Mataric [2012]	Algoritmo de banda elástica Marco probabilístico para la producción de comportamiento proxémico en (HRI)	SI	NO	SI
Mead et al. [2011]	Enfoques basados en heurísticas vs. Enfoques aprendidos	SI	NO	SI
Sisbot et al. [2007]	Criterios relacionados con la seguridad y la visibilidad	SI	SI	SI
Svenstrup et al. [2009]	Funciones de potencial adaptativas que respetan los espacios sociales	SI	SI	SI
Castro-González et al. [2010]	Modelos ocultos de Markov para predicciones	SI	NO	SI
Ratsamee et al. [2013]	Modelo SFM modificado (MSFM) que considera la postura corporal, la orientación facial y el espacio personal	SI	SI	SI
Truong and Ngo [2017]	Modelo de Movimiento Social Proactivo (PSMM)	SI	SI	SI
Ferrer and Sanfeliu [2014b]	Modelo de Fuerza Social Extendida (ESFM)	SI	SI	SI
Farina et al. [2016]	SFM con modelos de locomoción humana de Laumond	SI	NO	SI
van den Berg et al. [2011]	Evitación recíproca de colisiones de n-cuerpos	SI	NO	NO
Bera et al. [2016]	Enfoque GLMP - Patrones de Movimiento Global y Local Datos de trayectorias peatonales utilizando Inferencia Bayesiana Filtros de Kalman de Conjunto (EnKF) y Expectación Maximización (EM)	SI	NO	SI
Luo et al. [2018]	Evitación Óptima Recíproca de Colisiones de Peatones (PORCA) combinado con un algoritmo de Procesos de Decisión de Markov Parcialmente Observables (POMDP)	SI	SI	SI
Chen et al. [2022]	Marco de Control Predictivo en Tiempo Real (MPC) Interactivo ORCA Mejorado por Intención (iORCA)	SI	SI	SI
Xu et al. [2021]	Obstáculos de Velocidad Recíproca Emocionales (eRVO)	SI	NO	SI
Alahi et al. [2016]	Redes de Memoria a Largo y Corto Plazo Sociales (Social-LTSM)	SI	NO	SI
Vemula et al. [2018]	Atención Social Arquitectura S-RNN	SI	NO	SI

Vega et al. [2019] simularon diferentes comportamientos en un apartamento real modelado. Además, Mead and Mataric [2012] llevaron a cabo modelados y simulaciones en varios entornos, mientras que Mead et al. [2011] distinguen al registrar características corporales a través de un kinect para mejorar algoritmos de navegación predictiva en futuros métodos. Sisbot et al. [2007] modelaron diversas situaciones basadas en escenarios reales y compara el Planificador de Movimiento Consciente de Humanos (HAMP) con un planificador de movimiento estándar.

Por su parte, Svenstrup et al. [2009] realizaron dos simulaciones en entornos de laboratorio modelados, mientras que Castro-González et al. [2010] utilizaron datos registrados de un centro comercial, enfocándose en un “área caliente” donde las personas modifican sus trayectorias al cruzarse. Asimismo, Ratsamee et al. [2013] registraron el comportamiento humano durante movimientos de evasión y Truong and Ngo [2017] simularon un centro comercial.

En último lugar, Ferrer and Sanfeliu [2014b] validaron su planificador en un entorno simulado antes de cualquier interacción real con personas.

Los restantes se centran en realizar simulaciones a partir de los comportamientos del mundo real fijándose en datos recopilados en zonas de tránsito de peatones:

Bera et al. [2016] presentan un algoritmo que aprende flujos de movimiento a partir de trayectorias peatonales del mundo real extraídas de videos y lo prueba en diversos conjuntos de datos de multitudes con diferentes densidades. Luo et al. [2018] evalúan la precisión de predicción de su modelo de movimiento de peatones utilizando datos del mundo real e ilustra el rendimiento de su sistema de planificación en tres escenarios desafiantes en simulación. Además, Chen et al. [2022] evalúan el rendimiento de predicción de su modelo de evasión de colisión recíproca óptima interactiva (iORCA) y lo compara con enfoques líderes en la predicción de movimientos de peatones utilizando conjuntos de datos de video públicos reales. También evalúa y compara experimentalmente el rendimiento de navegación de su algoritmo de control predictivo interactivo (iMPC) con enfoques de navegación de vanguardia utilizando simuladores, además de probar iMPC en un experimento del mundo real con un robot

móvil. Finalmente, [Xu et al. \[2021\]](#) llevan a cabo un conjunto diverso de simulaciones de multitudes en situaciones de múltiples peligros y valida su enfoque comparando los resultados de las simulaciones con videos de evacuación de multitudes del mundo real.

Finalmente, [Alahi et al. \[2016\]](#) y [Vemula et al. \[2018\]](#) presentan experimentos utilizando conjuntos de datos de trayectorias humanas para evaluar sus modelos propuestos. Los conjuntos de datos utilizados, ETH y UCY, están disponibles públicamente y representan entornos concurridos del mundo real con comportamientos grupales complejos, como parejas caminando juntas, grupos cruzándose y formándose y dispersándose en algunas escenas. El primer artículo, [Alahi et al. \[2016\]](#), evalúan su modelo propuesto en 5 conjuntos de datos: el conjunto de datos ETH, que contiene dos escenas con 750 peatones diferentes en cada una y se divide en dos conjuntos (ETH y Hotel); y el conjunto de datos UCY, que contiene dos escenas con 786 personas y tiene 3 componentes: ZARA-01, ZARA-02 y UCY. El número total de trayectorias evaluadas no se especifica en el artículo. Por otro lado, el segundo artículo, [Vemula et al. \[2018\]](#), evalúan su modelo propuesto, Atención Social, en los mismos dos conjuntos de datos, ETH y UCY, pero con un total de 1536 peatones y 5 conjuntos de multitudes, en comparación con el primer artículo. También compara el rendimiento de su modelo con Social LSTM, que se demostró que tiene un mejor rendimiento que otros métodos tradicionales, como el modelo lineal, el modelo de fuerzas sociales y los Procesos Gaussianos Interactivos en un estudio previo.

Realizar experimentos reales es crucial, ya que evidencian la interacción entre las personas y los robots, permitiéndonos evaluar su rendimiento y su capacidad de adaptarse rápidamente a situaciones imprevistas.

Es relevante mencionar que [Ferrer et al. \[2013a\]](#) y [Shiomi et al. \[2014\]](#) emplean entornos exteriores; no obstante, sería interesante probar en diversos escenarios exteriores para validar el método, más allá del entorno basado en simulaciones.

Al analizar [Trautman et al. \[2015\]](#) y [Bennewitz et al. \[2002\]](#), se destaca que los experimentos se centran en interrumpir a personas que suelen llevar a cabo tareas específicas en dichos entornos, como disfrutar de una comida en Chandler Dinner Hall, trabajar en una oficina o en una residen-

cia. En cuanto a [Kuderer et al. \[2013\]](#), todos los experimentos se enfocan en el cruce con seres humanos.

Los experimentos de [Vega et al. \[2019\]](#) se llevaron a cabo en un apartamento, centrándose en demostrar una maniobra socialmente aceptable. En [Sisbot et al. \[2007\]](#), el concepto de *zona oculata* resulta relevante, siendo el primero en abordar este concepto, el cual es fundamental tener presente.

Las experiencias de [Svenstrup et al. \[2009\]](#) demuestran el potencial del sistema, mostrando que el método de Razonamiento Basado en Casos (CBR) implementado puede aplicarse de manera efectiva a un robot que necesita evaluar el comportamiento humano. Por otro lado, [Ratsamee et al. \[2013\]](#) es significativo, ya que analizan la orientación facial. Finalmente, [Truong and Ngo \[2017\]](#) compararon los resultados del Modelo de Fuerza Social (SFM) con el Modelo de Movimiento Social Proactivo (PSMM).

En el caso de [Ferrer and Sanfeliu \[2014b\]](#), se utilizó un entorno real controlado, mientras que [Luo et al. \[2018\]](#) resulta interesante por el uso de un robot móvil en un entorno exterior. En [Chen et al. \[2022\]](#), el robot navega en un área interior abierta con al menos cinco peatones, simulando la navegación en multitudes densas en el área circundante.

Asimismo, es destacable la variedad de robots utilizados en los experimentos realizados por diferentes autores. Por ejemplo, [Snape et al. \[2011\]](#) emplearon un robot aspirador iRobot, mientras que los robots móviles fueron ampliamente utilizados por [Ferrer et al. \[2013a\]](#) y [Ferrer and Sanfeliu \[2014b\]](#) con Tibi & Dabo; [Kuderer et al. \[2013\]](#) con un robot móvil, [Truong and Ngo \[2017\]](#) con la plataforma de robot móvil Eddie equipada con un sensor Microsoft Kinect, y [Chen et al. \[2022\]](#) con el robot móvil SUMMIT-XL STEEL proporcionado por Robotnik. Por su parte, Pioneer 3-DX fue utilizado por [Shiomi et al. \[2014\]](#), [Trautman et al. \[2015\]](#) optaron por Pioneer 3-DXR, y [Bennewitz et al. \[2002\]](#) utilizaron Pioneer I.

Entre otros tipos de robots, se emplearon el manipulador autónomo omnidireccional Shelly por [Vega et al. \[2019\]](#); la plataforma robótica Rackham por [Sisbot et al. \[2007\]](#); la plataforma FESTO Robotino por [Svenstrup et al. \[2009\]](#); un robot humanoide con un Kinect por [Ratsamee et al. \[2013\]](#); y un scooter robot por [Luo et al. \[2018\]](#).

## Confort Social

Todos estos documentos son conscientes de la necesidad de evitar colisiones, priorizando una interacción fluida y segura. Sin embargo, algunos presentan características interesantes para mejorar el confort social. Destaca que [Shiomi et al. \[2014\]](#) introducen normas sociales, mientras que [Kuderer et al. \[2013\]](#) incorporan las posturas actuales de los seres humanos y [Kabtoul et al. \[2020\]](#) emplean la navegación cooperativa. En [Vega et al. \[2019\]](#), se propone el uso de una función de densidad espacial adaptable para la navegación social en entornos estáticos con seres humanos. [Mead and Mataric \[2012\]](#) agregan parámetros espaciales, y [Mead et al. \[2011\]](#) presentan métricas para analizar el comportamiento espacial humano, discutiendo su utilidad en sistemas autónomos de interacción social. [Svenstrup et al. \[2009\]](#) describen un método para estimar la postura de una persona en un escenario de interacción con un robot móvil mediante un escáner láser y adaptando el comportamiento del robot en consecuencia. Por otro lado, [Castro-González et al. \[2010\]](#) se enfoca en predecir las posiciones futuras de las personas para ayudar a los robots a comprender y reaccionar de manera segura y natural al comportamiento humano.

En el caso de [Ratsamee et al. \[2013\]](#), se incorpora la cognición facial y la postura corporal, lo que introduce una interacción más natural para los humanos. Mientras tanto, [Truong and Ngo \[2017\]](#) se centra en una planificación segura y proactiva. Por otro lado, [Ferrer and Sanfeliu \[2014b\]](#) se enfoca en minimizar las molestias a otros peatones, y los estudios de [Farina et al. \[2016\]](#), [Bera et al. \[2016\]](#) y [Luo et al. \[2018\]](#) se llevan a cabo en entornos concurridos. [Chen et al. \[2022\]](#) miden el nivel de comodidad de los peatones durante el movimiento y la interacción.

Además, el enfoque presentado en [Xu et al. \[2021\]](#) es sólido y capaz de generar de manera efectiva dinámicas realistas de multitudes y emociones de pánico, lo que lo hace adecuado para entornos complejos y con múltiples riesgos. Finalmente, [Alahi et al. \[2016\]](#) y [Vemula et al. \[2018\]](#) se centran en las interacciones sociales.

### 2.2.2.2. Estrategias de navegación utilizando modelos de movimiento de agentes

Una vez que se dispone de un modelo del movimiento humano, el siguiente paso en un enfoque proactivo es definir un planificador capaz de encontrar una política de navegación óptima. Foka and Trahania [2010] sugieren un modelo unificado para considerar la planificación global y local (así como la localización). El modelo es una instancia específica del Proceso de Decisión de Markov Parcialmente Observable Jerárquico (POMDP), llamado Robot Navigation-HPOMDP (RN-HPOMDP). El marco estima el destino final de todos los agentes móviles, y esta información se emplea para evitar obstáculos de manera efectiva. Svenstrup et al. [2010] proponen un algoritmo para la planificación de la trayectoria del robot en entornos humanos dinámicos, utilizando un campo potencial generado a partir de las posiciones y movimientos percibidos de las personas. El problema se resuelve utilizando un algoritmo de Árbol Aleatorio de Exploración Rápida (RRT) mejorado con un modelo y controlador de movimiento del robot, y utilizando un enfoque de Control Predictivo de Modelo (MPC) para ejecutar solo un segmento corto de la trayectoria planificada. El método minimiza el costo de atravesar el campo potencial, lo que resulta en trayectorias de robot cómodas y naturales. Du Toit and Burdick [2012] describen un marco de MPC para la planificación en una escena dinámica.

Park and Kuipers [2011] y Park et al. [2012] proponen combinar MPC y el control del punto de equilibrio para proporcionar un control de punto de equilibrio predictivo del modelo (MPEPC) para un robot de silla de ruedas que navega en multitudes. Para tener en cuenta la intención humana y las interacciones humano-robot, el marco interactivo MPC (iMPC) fue propuesto por Chen et al. [2022]. El marco iMPC aplica el modelo iORCA en la función de transición de estado para predecir los estados humanos, y amplía este modelo interactivo con restricciones de robot.

Basados en el SFM, Ferrer et al. [2013a,b] ponen énfasis en el diseño de marcos de navegación conscientes de la sociedad, donde temas como la comodidad y seguridad humanas son de vital relevancia. Ferrer et al. [2013b] integraron la intención y la interacción del peatón en un esquema de navegación consciente de la presencia humana del robot basado en el



Figura 2.14: El robot Dabo acompañando a una persona hasta la meta deseada mientras navega en un escenario lleno de gente (imagen tomada de Ferrer and Sanfeliu [2014a]): (Izquierda) imagen capturada por la cámara del robot; (centro) el robot Dabo; (derecha) la GUI del robot. Los cilindros verdes corresponden a personas y el cilindro naranja corresponde al objetivo. Permiso por ELSEVIER 5483750554512

concepto de fuerzas sociales. Sus experimentos muestran que la navegación consciente de la sociedad es adecuada para una tarea de compañía de robot en espacios abiertos.

Para respetar el espacio personal de las personas, evitando al mismo tiempo las colisiones, Rios-Martinez et al. [2011] proponen una extensión del algoritmo RRT para la navegación. El enfoque Risk-RRT utiliza un aprendizaje de procedimientos gaussianos para estimar el área ocupada por la persona (o-space).

Aunque la intencionalidad humana fue predicha, en cierto sentido, por Ikeda et al. [2013], el tema es el núcleo de las propuestas de Ferrer and Sanfeliu [2014a] y Palm et al. [2016]. La Predicción de Intencionalidad del Movimiento Humano Bayesiano (BHMIP) emplea el método de Expectation - Maximization para estimar puntos de destino Ferrer and Sanfeliu [2014a]. El método tiene una formulación sencilla, una complejidad computacional baja y supera a los métodos existentes como los propuestos por Foka and Trahania [2010]. La Figura 2.14 proporciona una instantánea del robot Dabo, utilizado para probar el BHMIP. La propuesta de Palm et al. [2016] se centra en el reconocimiento de las intenciones humanas en un escenario de interacción humano-robot. El marco incluye un método para predecir y evitar colisiones mediante la extrapolación de las intenciones humanas.

Teniendo en cuenta la interacción entre humanos y robots, Ferrer et al.

[2017] proponen un marco de navegación consciente de la sociedad que permite al robot acompañar a la persona de manera segura y natural. En este escenario, el robot compañero tiene que cumplir con dos objetivos simultáneamente: navegar hacia el destino predicho de la persona y acercarse a la persona que lo acompaña. El modelo de predicción se basa en el Extended SFM (ESFM).

El planificador de navegación cooperativa de [Khambhaita and Alami \[2017\]](#) es una herramienta diseñada para planificar trayectorias cooperativas para robots y humanos, respetando las restricciones cinemáticas del robot y evitando otros obstáculos dinámicos no humanos. El planificador puede adaptar la trayectoria del robot y proponer soluciones de co-navegación incluso en espacios reducidos. Predice una trayectoria plausible para los humanos y planifica una trayectoria correspondiente para el robot que cumple con las restricciones sociales. El planificador genera trayectorias tanto para humanos como para robots utilizando un solucionador óptimo basado en gráficos y equilibra los esfuerzos entre ambos agentes para resolver la tarea de co-navegación. El enfoque incluye proxémica, tiempo de colisión y restricciones direccionales durante la optimización. La optimización de la trayectoria utiliza un enfoque de banda elástica y mapea un problema de mínimos cuadrados en una representación de hipergrafos para ajustar la posición y orientación de los nodos y minimizar las restricciones impuestas.

De manera similar a lo descrito en la subsección anterior, ignorar la cooperación entre los agentes móviles en la planificación de la ruta puede llevar al *bloqueo* del robot. En la propuesta de [Kaboul et al. \[2022\]](#), se sugiere una maniobra proactiva y natural para la navegación alrededor de las personas. El enfoque consta de dos pasos principales. En primer lugar, se explora el espacio y se divide dinámicamente en un conjunto de canales utilizando un segmento local de la ruta global. El canal óptimo se determina utilizando un modelo de costo difuso y su línea central proporciona la ruta objetivo al módulo de navegación local. Para simular un comportamiento de dirección similar al humano, se adapta una maniobra de cambio de carril suave para desplazarse entre canales mediante una ruta de transición cúbica. En la etapa final, se derivan comandos de control de seguimiento precisos utilizando un método de control de modo

deslizante.

En la tabla 2.4 podemos ver una comparación de los métodos descritos, así como que estudios realizan simulaciones o experimentos reales y cuales añaden alguna característica específica para mejorar el confort social.

## Experimentos

A continuación, analizaremos brevemente los experimentos realizados por estos métodos para comprobar su validez en diferentes entornos.

En primer lugar, [Svenstrup et al. \[2010\]](#) exploran la dinámica en una calle peatonal simulada, proporcionando información sobre cómo los robots pueden interactuar y navegar en un entorno similar al de una calle peatonal real. [Foka and Trahania \[2010\]](#) combinan datos reales y simulados en un cuarto vestíbulo de entrada principal, resaltando la utilidad de la simulación para estudiar y mejorar el comportamiento del robot en situaciones específicas. [Rios-Martinez et al. \[2011\]](#) introducen una conversación entre dos humanos en un área espaciosa, utilizando un mapa previamente construido mediante la función SLAM. Este enfoque contribuye al entendimiento de la interacción social en entornos robotizados. En los estudios presentados en [Park and Kuipers \[2011\]](#) y [Park et al. \[2012\]](#) se usan entornos mapeados, con el segundo replicando un corredor en forma de L, similar a un experimento real. Estos enfoques subrayan la importancia de la replicación y adaptación a escenarios específicos. [Du Toit and Burdick \[2012\]](#) abordan comportamientos complicados e independientes del agente, explorando escenarios interactivos entre el robot y el agente humano. Este enfoque proporciona información sobre la autonomía y complejidad de los comportamientos robóticos. Finalmente, [Ferrer et al. \[2013b\]](#) y [Ferrer and Sanfeliu \[2014a\]](#) utilizan entornos sociales simulados y un foro de informática simulado en Edimburgo, respectivamente. Estos estudios amplían el análisis a entornos más complejos y específicos, explorando la adaptabilidad del robot en situaciones sociales variadas.

[Palm et al. \[2016\]](#) examinan la interacción entre un humano y dos robots, destacando la capacidad del robot para gestionar múltiples interacciones simultáneas. [Ferrer et al. \[2017\]](#) se centra en el aprendizaje de parámetros en diferentes escenarios y densidades de peatones, proporcio-

nando información crucial sobre la capacidad del robot para aprender y adaptarse en entornos urbanos. [Khambhaita and Alami \[2017\]](#) abordan la navegación con restricciones sociales, incorporando la complejidad de factores sociales en la planificación del robot. [Kaboul et al. \[2022\]](#) introducen densidades espaciales variables y escenarios de cruce frontal y lateral, comparando con el método de planificación probabilística Risk-RRT. Este estudio contribuye a la evaluación y mejora de métodos de planificación en entornos complejos.

No todos llevan a cabo experimentos con robots reales, sin embargo, realizar pruebas con robots reales añade un valor significativo a los métodos al aumentar la confiabilidad y la robustez de estos. Entre aquellos que realizan estos experimentos nos encontramos con el estudio de [Foka and Trahania \[2010\]](#), que destaca un comportamiento robusto del robot al alcanzar puntos de destino asignados y evitar obstáculos humanos u otros objetos en un vestíbulo.

En contraste, el trabajo de [Park and Kuipers \[2011\]](#) se desarrolla en un entorno controlado, utilizando un robot en silla de ruedas con objetivos predefinidos. Este escenario proporciona control sobre variables específicas, permitiendo una evaluación más precisa del rendimiento del robot en condiciones particulares.

Posteriormente en [Park et al. \[2012\]](#) llevan la investigación un paso más allá, explorando el desempeño del robot en silla de ruedas en diferentes espacios, desde pasillos estrechos hasta salas abiertas. Este enfoque ampliado arroja luz sobre la capacidad del robot para adaptarse a variaciones en el entorno y enfrentar desafíos específicos de movilidad.

[Ferrer et al. \[2013b\]](#) llevan la interacción humano-robot a entornos urbanos, donde los robots Tibi y Dabo participan en escenarios más complejos e impredecibles. Este cambio en el entorno destaca la versatilidad del robot y su capacidad para interactuar de manera efectiva en contextos urbanos dinámicos.

Tabla 2.4: Métodos que se utilizan para resolver el problema de navegación.

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Svenstrup et al. [2010]	Árbol aleatorio de exploración rápida (RRT) Problema de generación de trayectorias Control predictivo basado en modelo (MPC) Campo potencial dinámico	SI	NO	NO
Foka and Trahanias [2010]	Navegación predictiva realizada de manera global con el uso de un POMDP Red neuronal polinómica (PNN) Predicción de movimiento futuro Navegación Robot-HPOMDP (RN-HPOMDP)	SI	SI	NO
Rios-Martinez et al. [2011]	Algoritmo de navegación RISK-RRT Procesos Gaussianos aprendidos Espacio personal Modelo de o-espacio en formaciones en F	SI	NO	SI
Park and Kuipers [2011]	La formulación de la ley de control cinemático El algoritmo de seguimiento de postura para un movimiento suave y cómodo de robots de tipo monociclo	SI	SI	NO
Park et al. [2012]	Framework de Control Predictivo del Punto de Equilibrio (MPEPC)	SI	SI	SI
Du Toit and Burdick [2012]	Planificación de movimiento	SI	NO	SI
Ferrer et al. [2013b]	SFM e información de predicción	SI	SI	SI
Ferrer and Sanfeliu [2014a]	Predicción de Intencionalidad del Movimiento Humano Bayesiano BHMIP de ventana deslizante (BHMIP) Dos variantes: el BHMIP de ventana deslizante y el BHMIP de decaimiento temporal Método de expectación-maximización	SI	SI	SI
Palm et al. [2016]	Reconocer la intención humana con velocidades relativas Evitar colisiones mediante la extrapolación de intenciones humanas y el ángulo de dirección Esfera de brújula Reglas difusas para interacciones humano-robot	SI	NO	SI
Ferrer et al. [2017]	Marco de navegación consciente de la sociedad para permitir que un robot navegue acompañando a la persona	SI	NO	SI
Khambhaita and Alami [2017]	Planificador de navegación cooperativa Optimización de trayectorias: Banda elástica Método de expectación-maximización Marco de optimización Solucionador óptimo basado en gráficos Restricciones de tiempo de colisión y direccionales durante la optimización	SI	SI	SI
Kabtoul et al. [2022]	Planificador de navegación cooperativa	SI	NO	SI

Las investigaciones posteriores de Ferrer and Sanfeliu [2014a] y Ferrer et al. [2017] profundizan en la interacción humano-robot al involucrar voluntarios que caminan junto al robot y explorar el aprendizaje interactivo. Estos estudios ofrecen una comprensión más rica de la capacidad del robot para adaptarse y aprender en tiempo real, mejorando su interacción con los usuarios.

Finalmente, el trabajo de Khambhaita and Alami [2017] destaca la importancia de la implementación en un entorno real con restricciones reales. La plataforma robótica enfrenta desafíos y limitaciones del mundo real, lo que proporciona información valiosa sobre la viabilidad y eficacia del robot en situaciones más complejas

### Confort Social

Los métodos analizados presentan enfoques diversos para mejorar la interacción entre robots y entornos sociales.

Rios-Martinez et al. [2011] incorporan convenciones sociales en la estrategia de navegación, Park et al. [2012] realizan una adaptación del comportamiento en la detección de peatones, Du Toit and Burdick [2012] añaden la habilidad para enfrentar agentes en diversas circunstancias, Ferrer et al. [2013b] se centran en una navegación basada en reacciones instantáneas a información sensorial y fuerzas sociales.

Por otro lado, Ferrer and Sanfeliu [2014a] realizan una predicción del destino humano y posicionamiento del robot en consecuencia. Mientras Palm et al. [2016] realizan una predicción de movimientos humanos para planificación de reacciones.

Finalmente, Ferrer et al. [2017] proponen un Modelo de retroalimentación humana capaz de manejar situaciones realistas. Khambhaita and Alami [2017] consideran las restricciones sociales. Kabtoul et al. [2022] realizan maniobras proactivas y comprensión de la reacción e intención de peatones e incorpora una transmisión de comportamiento de dirección similar al humano para una navegación amigable.

### 2.2.3. Enfoques basados en el aprendizaje

En los últimos años, varios investigadores han explorado métodos para que los robots aprendan políticas de navegación adaptadas a entornos específicos. El Aprendizaje Profundo por Refuerzo (DRL) se ha utilizado con frecuencia para este propósito. Se han propuesto enfoques como la Evitación de Colisiones con DRL (CADRL) (Chen et al. [2017b]), el Aprendizaje por Refuerzo Atento a lo Social (SARL) (Chen et al. [2019]) y el DRL Atento a los Objetos Sociales (SOADRL) (Liu et al. [2020]) para abordar este desafío. Sin embargo, la estimación exacta de las posiciones de los peatones puede resultar complicada en situaciones del mundo real. Para evitar este cálculo, los enfoques de Aprendizaje de Extremo a Extremo (E2E) mapean directamente las entradas sensoriales en bruto a los comandos de dirección deseados. Por otro lado, el problema de automatizar el cálculo de la función de recompensa en enfoques basados en DRL se ha tratado mediante el Aprendizaje Inverso por Refuerzo (IRL). Al aprender directamente la función de recompensa a partir de los datos, el IRL puede mejorar la velocidad de aprendizaje y el rendimiento del sistema. Se han utilizado varios enfoques de IRL para aprender comportamientos de navegación social para robots, que incluyen la optimización de los parámetros de la función de recompensa mediante la estimación de máxima verosimilitud (Henry et al. [2010]), y el modelado de IRL desde una perspectiva bayesiana (Kim and Pineau [2016]).

#### 2.2.3.1. Aprendizaje profundo por refuerzo y enfoques de principio a fin

Recientemente, el Aprendizaje Profundo por Refuerzo (DRL) ha surgido como una herramienta exitosa para abordar tareas que no admiten soluciones directas de ingeniería. En esencia, el DRL introduce redes neuronales profundas para resolver problemas de aprendizaje por refuerzo. En el contexto de la navegación de robots, se han propuesto numerosos enfoques para entrenar una política de evitación de colisiones basada en DRL en la última década, algunos de los cuales consideran la conciencia social. Chen et al. [2017b] utilizan DRL para entrenar una estrategia de navegación en un escenario multiagente (Evitación de Colisiones con DRL, CADRL). La función de recompensa creada manualmente beneficia positivamente el logro del objetivo deseado y penaliza las colisiones. Esta

propuesta se amplió para considerar a los humanos y las normas sociales en [Chen et al. \[2017a\]](#) (SA-CADRL). Específicamente, en este trabajo, se aprendió un comportamiento socialmente conforme (por ejemplo, pasar por el lado derecho) utilizando una función de recompensa que depende de la dinámica situacional. El esquema fue mejorado por [Everett et al. \[2018\]](#), que aprovecharon el procesamiento de GPU para entrenar múltiples agentes en paralelo y la Memoria a Corto y Largo Plazo (LSTM) para convertir el estado de tamaño variable de la multitud en un vector de tamaño fijo. Aunque estos enfoques tuvieron éxito en la navegación multiagente, no tuvieron en cuenta interacciones complejas entre humanos ([Samsani and Muhammad \[2021\]](#)). Para mejorar la comodidad de las personas que comparten el espacio con un robot, [Hu et al. \[2022\]](#) utilizan índices de estrés social en la función de recompensa y en la red de valores del marco de DRL. Emplea un perceptrón multicapa para extraer características locales y puntuaciones de atención social. Al igual que los enfoques mencionados, utilizan posiciones precisas de los peatones como entrada, lo cual presenta un desafío para un robot real en un entorno real ([Dugas et al. \[2021\]](#)). Por su parte, [Gil et al. \[2021\]](#) proponen calcular las acciones del robot mediante una combinación de velocidades del robot aprendidas mediante un modelo de RL (AutoRL [Francis et al. \[2020\]](#)) y velocidades del robot calculadas utilizando un SFM ([Zanlungo et al. \[2011\]](#)).

Enfoques anteriores suelen abordar la navegación del robot en entornos concurridos como un problema de interacción humano-robot unidireccional, presentando dificultades a medida que la multitud crece. Para superar esta situación, [Chen et al. \[2019\]](#) proponen modelar explícitamente la interacción entre la multitud y el robot (mediante el enfoque de Aprendizaje por Refuerzo Atento a lo Social, SARL). Se emplea la autoatención para comprender la importancia colectiva de la multitud al considerar las interacciones tanto entre humanos como entre humanos y robots. Sin embargo, el enfoque SARL no abarca los obstáculos en las políticas aprendidas, cuestión que el SOADRL en [Liu et al. \[2020\]](#) abordan. Este último amplía el SARL al procesar por separado la información relacionada con objetos estáticos y dinámicos, además de lidiar con el desafío de la navegación en multitudes con sensores que tienen un campo

de visión limitado. Al igual que el SA-CADRL, tanto el SARL como el SOADRL hacen uso de la posición exacta de los agentes móviles en la entrada.

Para abordar el problema de las multitudes de gran tamaño, [Chen et al. \[2020\]](#) proponen capacitar al sistema para identificar a las personas en la multitud que son críticas para la navegación. Este enfoque utiliza una representación gráfica para aprender esta política, codificando información sobre la multitud y previniendo los niveles de atención humana en la tarea de navegación. Se entrena una red convolucional gráfica basada en datos de la mirada humana, la cual predice con precisión la atención humana hacia distintos agentes en la multitud durante una tarea de navegación. La atención aprendida se integra en la arquitectura de aprendizaje por refuerzo basada en gráficos.

El problema de la observación parcial (debido a limitaciones de los sensores, obstrucciones o incertidumbre en la percepción) es abordado por [Gao et al. \[2019\]](#) mediante el uso de una red neuronal recurrente (RNN) conocida como unidad recurrente con compuertas (GRU) para inferir los estados no observables. Para responder en tiempo real a los comportamientos humanos, [Samsani and Muhammad \[2021\]](#) proponen modelar “Zonas de Peligro” para el robot. Estas zonas se formulan teniendo en cuenta el comportamiento humano en tiempo real y codifican todas las posibles acciones que las personas pueden tomar en un momento dado. El robot se entrena para evitar estas zonas de peligro y así garantizar una navegación segura y fiable.

Con la ayuda de las redes neuronales profundas, el DRL puede aplicar el aprendizaje de extremo a extremo (E2E), es decir, aprender un modelo de caja negra que extrae características de datos de alta dimensionalidad capturados y aprende políticas complejas. De esta manera, evitan la necesidad de detección y seguimiento eficiente de personas. Desde un punto de vista general, donde el objetivo es mapear directamente las entradas sensoriales en bruto a comandos de dirección deseados, el proceso de aprendizaje se puede resumir de la siguiente manera ([Long et al. \[2018\]](#)):

- el robot se mueve según una acción dada y obtiene información del entorno (observaciones) y una recompensa;
- siguiendo una política y dada la observación capturada, se genera

una acción;

- la política se actualiza mediante un algoritmo basado en RL.

El robot finalmente obtiene la política óptima para lograr el objetivo al repetir el proceso de aprendizaje. Para aplicar DRL en el contexto de navegación de extremo a extremo (E2E) de robots, es esencial establecer toda la configuración del problema y traducirla a un marco de RL (Gromniak and Stenzel [2019]). Por ejemplo, para evitar colisiones, Long et al. [2018] proponen mapear directamente las mediciones de láser 2D sin procesar a comandos de movimiento deseados mediante una red neuronal de 4 capas ocultas. Por otro lado, Shi et al. [2020] proponen un marco de navegación E2E que traduce los resultados dispersos de alcance láser en acciones de movimiento. El objetivo de utilizar estos datos altamente abstractos como entrada es permitir que los robots entrenados en simulaciones también se desplieguen en entornos reales. Aunque la propuesta demuestra una navegación robusta, se aplica en entornos relativamente simples.

Una propuesta interesante es el Aprendizaje de Roles en Juego (RPL) que propone Li et al. [2018] dotando a un robot de comportamientos grupales apropiados cuando viaja con un acompañante humano. Esta propuesta E2E utiliza redes neuronales para mapear datos sensoriales a salidas de velocidad mientras se adhiere a normas sociales. El proceso RPL se formula bajo un marco de RL y se optimiza utilizando la Optimización de la Región de Confianza de Políticas (TRPO). Para aprender directamente estrategias de control a partir de entradas visuales, Mnih et al. [2015] combinan una Red Neuronal Convolutiva (CNN) con un algoritmo de aprendizaje Q (modelo de red DQN). Lee and Yusuf [2022] mapean los datos de una cámara RGB-D a comandos de dirección. Se emplea una red neuronal profunda para detectar el objetivo, y la evasión de colisiones y la navegación son abordadas por un modelo DQN (o un Doble DQN (DDQN)). El enfoque puede manejar obstáculos estáticos y dinámicos, pero no considera factores sociales.

Los enfoques de planificación E2E mencionados anteriormente utilizan RL. Otra opción es emplear un esquema de aprendizaje supervisado para imitar demostraciones de expertos (aprendizaje por imitación, IL).

IL es eficiente en términos de muestras y, con un conjunto de datos de entrenamiento, se puede encontrar un modelo de navegación rápidamente (Pfeiffer et al. [2017]). Sin embargo, IL es conceptualmente menos robusto que RL (Pfeiffer et al. [2018]), ya que RL permite que el robot aprenda de sus propios errores durante el entrenamiento (Tai et al. [2017]). Pfeiffer et al. [2017] proponen un planificador de movimiento E2E basado en datos, donde el robot aprende a navegar según las preferencias del usuario humano. Para lograr esto, se proporcionan demostraciones de expertos sobre cómo navegar en un entorno de entrenamiento específico. El objetivo no es solo replicar las demostraciones proporcionadas en un escenario determinado, sino también aprender políticas de evasión de colisiones y transferirlas a entornos desconocidos. Utiliza un modelo único basado en el marco de TensorFlow (Abadi et al. [2016]) para extraer información y estimar los comandos de dirección. En el caso de Pfeiffer et al. [2018], se combinan IL y RL en un solo escenario de navegación sin mapas dirigido por objetivos. El Aprendizaje de Imitación Reforzada (R-IL) utiliza demostraciones de expertos para pre-entrenar la política de navegación y luego aplica una Optimización de Política Restringida (CPO) (Achiam et al. [2017]) para incorporar restricciones durante el entrenamiento de RL. Los autores demuestran que este enfoque puede reducir el tiempo de entrenamiento para alcanzar el mismo nivel de rendimiento que el RL simple en un factor de 5. Las pruebas de Pfeiffer et al. [2017, 2018] se realizaron en un entorno estático. El enfoque CrowdMove (Fan et al. [2018]) es un marco de entrenamiento multirobot, multiescenario y multietapa (3M). Utiliza una red neuronal de 4 capas ocultas como un aproximador de función no lineal para la política de navegación y amplía la Optimización de Política Proximal (PPO) (Schulman et al. [2017]) al escenario de múltiples robots. Los experimentos demuestran que la política de navegación puede lograr la navegación autónoma para diferentes plataformas móviles en una amplia variedad de entornos con multitudes.

La planificación y el aprendizaje a largo plazo para la navegación en medio de otros agentes móviles también se han combinado como módulos separados, pero estrechamente vinculados. En lugar de las soluciones anteriores de extremo a extremo (E2E), el objetivo aquí es permitir que el planificador de movimiento estime la ruta y la descomponga en una serie

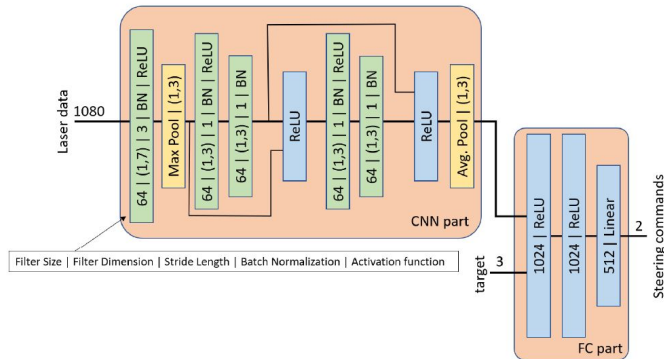


Figura 2.15: Estructura de la CNN empleada (imagen basada de Pfeiffer et al. [2017]). Dos bloques de construcción residuales proporcionan la estructura de la parte CNN (He et al. [2016]), que toma los datos de entrada (datos láser) y proporciona el vector de características a la parte FC. La capa FC del modelo fusiona este vector de características con la información del objetivo para obtener los comandos de dirección de traslación y rotación. La regularización L1 se aplica a todos los parámetros del modelo.

de subobjetivos, siendo el controlador de bajo nivel aprendido el encargado de adaptar la ruta a la dinámica de la situación actual. Gao et al. [2017] proponen la combinación de un planificador de ruta con un controlador de movimiento basado en una red neuronal (la red de intenciones). La red de intenciones mapea imágenes a comandos de movimiento en un esquema E2E. El planificador de ruta utiliza un mapa 2D previo para calcular las rutas, proporcionando estas intenciones a la capa de red de intenciones. El sistema de navegación presentado por Pokle et al. [2019] también fusiona un planificador de ruta y aprendizaje automático. En este caso, el planificador global calcula rutas hacia un objetivo, mientras que un planificador local profundo de trayectoria y un controlador de velocidad proporcionan comandos de movimiento. El controlador de movimiento de bajo nivel se encarga de evitar obstáculos y respetar el espacio de los peatones cercanos. Ambos enfoques han demostrado superar a un marco de extremo a extremo donde no se considera la guía de planificación. Por otro lado, Pérez-D'Arpino et al. [2021] proponen una pila de navegación que combina la planificación de movimiento y el aprendizaje por refuerzo

(RL). El componente de RL aprende a manejar las interacciones locales con otros agentes móviles mientras sigue la trayectoria globalmente planificada. [Choi et al. \[2020\]](#) plantean un marco en el que el DRL aprende políticas de navegación que se adaptan a una amplia gama de ponderaciones de recompensa y otros parámetros de navegación. Luego, utilizan un método de aprendizaje profundo bayesiano para optimizar los parámetros de navegación según las preferencias humanas.

En las tablas 2.5, 2.6 y 2.7 podemos ver una comparación de los métodos descritos, así como que estudios realizan simulaciones o experimentos reales y cuales añaden alguna característica específica para mejorar el confort social.

## Experimentos

El objetivo de esta sección es examinar y comparar diversas técnicas de simulación y pruebas presentes en los documentos recopilados. Estos detalles buscan proporcionar una visión completa de los documentos y servir como un recurso valioso para analizar las técnicas de simulación utilizadas en el campo.

Esta fase se emplea para realizar entrenamientos y obtener los parámetros más óptimos con el mejor rendimiento posible. Muchos de estos trabajos utilizan esta fase para comparar distintos métodos y validar sus mejoras al contrastar resultados. Por ejemplo, [Everett et al. \[2018\]](#) comparan 2 métodos de deep RL. [Samsani and Muhammad \[2021\]](#) evalúan funciones de recompensa ajustadas socialmente, [Liu et al. \[2020\]](#) comparan un modelo propuesto con otros en entornos aleatorios, y [Gao et al. \[2019\]](#) proponen y compara un algoritmo de navegación socialmente normativo con varios métodos (ORCA, CADRL, GA3C-CADRL, SNNRL-GRU y SNNRL). Por otro lado, [Long et al. \[2018\]](#) comparan su política con la evitación óptima recíproca no holonómica (NH-ORCA).

Tabla 2.5: Métodos para enfoques de DRL y E2E

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Chen et al. [2017b]	Algoritmo de Evitación de Colisión Multiagente Descentralizado basado en una nueva aplicación de aprendizaje profundo por refuerzo	SI	NO	NO
Chen et al. [2017a]	SA-CADRL, un algoritmo de evitación de colisión multiagente que considera y muestra comportamientos socialmente conformes Política de navegación eficiente en el tiempo que respeta normas sociales comunes Marco de aprendizaje por refuerzo	SI	SI	SI
Everett et al. [2018]	Algoritmo de evitación de colisiones, GA3C-CADRL, que se entrena en simulación con aprendizaje profundo por refuerzo sin requerir ningún conocimiento de la dinámica de otros agentes Memoria a corto y largo plazo (LSTM) LSTM que permite al algoritmo utilizar observaciones de un número arbitrario de otros agentes	SI	SI	SI
Samsani and Muhammad [2021]	Semejanza de comportamiento humano mediante Aprendizaje Profundo por Refuerzo Las Zonas de Peligro se formulan teniendo en cuenta el comportamiento humano en tiempo real	SI	NO	SI
Hu et al. [2022]	Marco de aprendizaje profundo por refuerzo (DRL) y la red de valor El marco DRL incorpora estos índices de estrés social	NO	NO	NO
Dugas et al. [2021]	Aprendizaje por refuerzo de la navegación de robots en entornos humanos dinámicos El entorno NavRepSim está diseñado teniendo en cuenta las aplicaciones de RL	SI	SI	NO
Gil et al. [2021]	Modelo de Fuerza Social (SFM) que permite la conciencia humana Dos técnicas de Aprendizaje Automático: navegación social y Red Neuronal (NN) Técnica de aprendizaje por refuerzo (RL)	SI	SI	SI
Francis et al. [2020]	PRM-RL: Mapas de caminos probabilísticos (PRMs) como planificador basado en muestreo y método de aprendizaje por refuerzo-RL en el contexto de navegación interior	SI	SI	NO
Chen et al. [2019]	Interacción Multitud-Robot (CRI) Aprendizaje Profundo por Refuerzo basado en la Atención	NO	NO	NO
Liu et al. [2020]	Enfoque de aprendizaje por imitación y aprendizaje profundo por refuerzo para la planificación de movimiento en entornos tan concurridos y desordenados	SI	SI	NO
Chen et al. [2020]	Red Convolutiva de Grafos (GCN) para el aprendizaje por refuerzo para integrar información Red de atención entrenada utilizando datos de mirada humana para asignar valores de adyacencia	SI	NO	NO

Tabla 2.6: Métodos para enfoques de DRL y E2E II

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Gao et al. [2019]	Aprender una política de navegación eficiente que exhiba comportamientos de navegación socialmente normativos Capa de agrupación social convolucional que modela de manera robusta las cooperaciones humano-robot e interacciones complejas entre peatones Observabilidad parcial en la navegación socialmente normativa	SI	NO	SI
Long et al. [2018]	Política de evitación de colisiones a nivel de sensor descentralizado para sistemas multirobot Algoritmo de aprendizaje por refuerzo basado en gradiente de política	SI	NO	NO
Gromniak and Stenzel [2019] extremo a extremo	Aprendizaje profundo de refuerzo de	SI	NO	NO
Shi et al. [2020]	Estrategia de navegación basada en aprendizaje profundo por refuerzo (DRL) Se propuso un modelo convencional A3C, un modelo A3C de ICM	SI	SI	NO
Li et al. [2018]	Aprendizaje de Roles (RPL) La política de NN se optimiza de extremo a extremo	SI	SI	NO
Mnih et al. [2015]	Una red Q profunda (DQN), que combina aprendizaje de refuerzo con una red neuronal profunda	SI	NO	NO
Lee and Yusuf [2022]	Aprendizaje profundo por refuerzo para móviles autónomos Las políticas DQN y DDQN entrenadas son evaluadas en un entorno de prueba de Gazebo Dos tipos de agentes de aprendizaje Q profundo, como redes Q profundas y agentes de doble red Q profunda	SI	SI	NO
Pfeiffer et al. [2017]	Enfoque de planificación de movimiento de extremo a extremo impulsado por datos para una plataforma robótica El modelo de extremo a extremo se basa en una CNN Aprender estrategias de navegación	SI	SI	NO
Pfeiffer et al. [2018]	Aprendizaje por imitación (IL) y aprendizaje de refuerzo (RL)	SI	SI	NO

Tabla 2.7: Métodos para enfoques de DRL y E2E III

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Tai et al. [2017]	Se entrenó un planificador de movimiento sin mapa de extremo a extremo a través de un control continuo de RL profundo desde cero El planificador aprendido puede generalizarse a una plataforma de robot diferencial no holonómico real sin ningún ajuste fino a muestras del mundo real	SI	SI	NO
Fan et al. [2018]	Marco de entrenamiento de múltiples robots, escenarios múltiples y etapas múltiples	SI	SI	NO
Gao et al. [2017]	Enfoque jerárquico de dos niveles: Aprendizaje profundo sin modelo y planificación de trayectorias basada en modelo Controlador de movimiento de red neuronal, llamado intention-net, se entrena de extremo a extremo para proporcionar una navegación local robusta El planificador de rutas utiliza un mapa rudimentario	SI	SI	NO
Pokle et al. [2019]	Planificación jerárquica y aprendizaje automático Planificador global tradicional para calcular trayectorias óptimas hacia un objetivo Planificador local profundo de trayectorias y controlador de velocidad para calcular comandos de movimiento Combina la planificación tradicional con técnicas modernas de aprendizaje profundo	SI	NO	SI
Pérez-D'Arpino et al. [2021]	Aprendizaje por refuerzo para aprender políticas de robots El modelo propuesto utiliza un planificador de movimiento que proporciona una trayectoria planificada globalmente, mientras que el componente de refuerzo maneja las interacciones locales necesarias para la adaptación en línea a los peatones	SI	NO	SI
Choi et al. [2020]	Método de navegación de aprendizaje profundo por refuerzo novedoso que puede adaptar su política a una amplia gama de parámetros y funciones de recompensa sin necesidad de un reentrenamiento costoso Método de aprendizaje profundo bayesiano	SI	SI	NO

En contraste, Gao et al. [2017] y Pokle et al. [2019] se enfocan en recopilar demostraciones de expertos y evaluar algoritmos de planificación de rutas en la simulación. Dos estudios, Lee and Yusuf [2022] y Pfeiffer et al.

[2017], evalúan sus métodos de navegación utilizando simulaciones. Por ejemplo, Lee and Yusuf [2022] prueban la capacidad de un agente DQN para navegar en un entorno interior desconocido, evitando obstáculos.

En relación con los entrenamientos propuestos, existe una amplia diversidad para calibrar los parámetros. Dugas et al. [2021] evalúan un enfoque de entrenamiento de controlador. Mientras que Gil et al. [2021] utilizan parámetros optimizados (OP-DDPG) para entrenar un modelo de evasión de colisiones. Francis et al. [2020] evalúan el mapa de probabilidades (PRM-RL) en diferentes entornos para aplicaciones del mundo real. Chen et al. [2020] entrenan una red basada en la modulación de la mirada de RL (G-GCNRL) para la navegación de robots y compara su rendimiento con SARL. Gromniak and Stenzel [2019] emplean DRL para entrenar a un robot en la navegación en un entorno simulado con ubicaciones de obstáculos cambiantes.

Otros enfoques introducidos en estos experimentos incluyen a Shi et al. [2020], que proponen utilizar la curiosidad para fomentar la exploración, y Li et al. [2018], quienes presentan un entorno de aprendizaje simulado para la navegación socialmente concomitante. Los resultados experimentales demuestran la efectividad de ambos métodos. Por otro lado, Mnih et al. [2015] introducen un agente de red Q profunda (DQN) que supera a los algoritmos anteriores en el aprendizaje de tareas desafiantes utilizando solo píxeles y puntuaciones de juego como entradas; y Chen et al. [2017b] utilizan redes de valor y DRL profundo para aprender normas sociales y evitar colisiones.

La simulación se utiliza en varios métodos para entrenar planificadores de movimiento para robots móviles. Por ejemplo, Tai et al. [2017] utilizan el simulador V-REP para entrenar un planificador de movimiento para un robot móvil no holonómico, permitiéndole navegar hacia objetivos deseados sin colisionar con obstáculos. Asimismo, Fan et al. [2018] entrenan múltiples robots simultáneamente para explorar eficientemente el espacio de estados utilizando el simulador de robot móvil. Por su parte, Pérez-D'Arpino et al. [2021] utilizan un enfoque de proceso de decisión de Markov observable (POMDP) para entrenar políticas de navegación en diferentes entornos con diseños variables, mientras que Choi et al. [2020] emplean un robot rastreado en un simulador Gazebo para entrenar

el algoritmo de navegación y así evitar obstáculos y navegar de manera autónoma en un entorno específico.

Además, Pfeiffer et al. [2017] entrenan un planificador de movimiento basado en redes neuronales para guiar al robot de manera segura a través de entornos con obstáculos y así alcanzar los objetivos establecidos. Es relevante destacar que, si bien Pfeiffer et al. [2017] también evalúan su método en experimentos del mundo real, los resultados de su simulación demuestran que puede transferirse a entornos virtuales y del mundo real previamente no vistos.

Algunos de ellos usan datos de repositorios públicos bastante útiles para esta fase, ya que recopilan mucha información del mundo real, Un ejemplo de ello es Li et al. [2018] , que usan los repositorios ETH, EWAP, Motion Capture , ZARA, y UCY ; y Pérez-D'Arpino et al. [2021] usan los repositorios WALLS-G, WALLS-H y WALLS-I.

En lo que respecta a aquellos que llevan a cabo experimentos con robots reales, se han realizado varios enfoques significativos: las políticas SA-CADRL en Chen et al. [2017a] y GA3C-CADRL en Everett et al. [2018] se implementaron en vehículos robóticos en entornos peatonales, mientras que Gil et al. [2021] realizaron experimentos en interiores con el robot IVO. Otros enfoques, como el método basado en PRM de Francis et al. [2020], utilizan el aprendizaje profundo con lidar 3D y cámaras estéreo para la detección de obstáculos dinámicos. Asimismo, Shi et al. [2020] probaron su algoritmo utilizando un sensor de alcance láser en un entorno real. El trabajo de Li et al. [2018] evaluó la transferibilidad de su política en comparación con el comportamiento humano en dos escenarios del mundo real.

Además, el algoritmo DQL fue evaluado para la navegación autónoma de robots móviles en simulación y en experimentos del mundo real, como se describe en Lee and Yusuf [2022]. Por otro lado, Pfeiffer et al. [2017] se enfocaron en generar datos de entrenamiento para la navegación en un área laberíntica, y Pfeiffer et al. [2018] demostraron las capacidades de generalización y robustez de los modelos entrenados exclusivamente en simulación. El desempeño del algoritmo de navegación de un robot para alcanzar objetivos en el mundo real fue evaluado por Tai et al. [2017]. En el caso de Fan et al. [2018], se probó con éxito una política de evasión de

colisiones en varias plataformas móviles en diferentes entornos del mundo real, logrando navegar con éxito y evitar obstáculos y peatones. En otro trabajo, Gao et al. [2017] entrenaron a un robot para navegar en un entorno del mundo real utilizando datos recopilados por expertos humanos. Finalmente, Choi et al. [2020] entrenaron un modelo en un entorno de simulación y luego lo probaron en un robot rastreado real sin realizar ajustes adicionales, demostrando la capacidad del modelo propuesto para adaptarse a las incertidumbres del mundo real.

### Confort Social

Los siguientes métodos aseguran la navegación consciente de los seres humanos y logran el cumplimiento social en entornos dinámicos con peatones. Estos métodos incluyen SA-CADRL (Chen et al. [2017a]), la extensión de memoria a corto y largo plazo (LSTM) (Everett et al. [2018]), el algoritmo SOADRL (Liu et al. [2020]), el enfoque basado en redes neuronales (Li et al. [2018]), el método de predicción de la zona de peligro propuesto por Samsani and Muhammad [2021], la propuesta de Gil et al. [2021] que combina técnicas de aprendizaje automático con el Modelo de Fuerza Social, el método propuesto por Gao et al. [2019] que modela tanto la cooperación humano-robot como las interacciones entre humanos, el sistema basado en mecanismos de atención propuesto por Pokle et al. [2019], y el enfoque propuesto por Pérez-D'Arpino et al. [2021] que se adapta a los peatones en tiempo real mientras garantiza la planificación de trayectorias.

#### 2.2.3.2. Aprendizaje por refuerzo inverso

El diseño de un esquema basado en DRL plantea uno de los principales desafíos, la elección de la función de recompensa. Una elección deficiente puede impactar drásticamente en la velocidad de aprendizaje y el rendimiento (Baghi and Dudek [2021]). Una alternativa a la configuración manual de la función de recompensa es aprenderla directamente a partir de los datos. El Aprendizaje por Reforzamiento Inverso (IRL) se presenta como un mecanismo efectivo para abordar este proceso de aprendizaje. Ziebart et al. [2008] propone un enfoque probabilístico basado en el prin-

cipio de máxima entropía que optimiza los parámetros de una función de recompensa mediante la estimación de máxima verosimilitud (MLE). Este esquema se ha utilizado con éxito para aprender comportamientos de navegación similares a los humanos en entornos concurridos (Henry et al. [2010]). El enfoque aprende a partir de trayectorias de ejemplo estimando valores como la densidad de multitudes utilizando procesos gaussianos, lo que resulta en trayectorias naturales que se integran sin problemas en los movimientos existentes de la multitud. Pérez-Higueras et al. [2014] también utilizan IRL para la navegación social, empleando los costos para aprender políticas de ejecución local y proporcionar comandos de dirección al robot. Mientras tanto, Vasquez et al. [2014] comparan IRL y ajustes manuales para el aprendizaje de parámetros de la función de recompensa y propone métricas de evaluación para comparar estas técnicas, demostrando que los parámetros de recompensa aprendidos por IRL son superiores. El enfoque de entropía máxima se ha empleado para aprender la distribución conjunta de trayectorias de múltiples agentes en un entorno, mostrando una inferencia de alta calidad (Kretzschmar et al. [2016]).

En cuanto a la generación de trayectorias de robots en entornos de interacción humano-robot, Wang et al. [2022a] proponen el planificador NN-RRT\* y el marco NRTIRL, que utiliza rutas de demostración generadas por humanos para mejorar las rutas planeadas por el planificador. La Figura 2.16 proporciona una descripción general del marco. La red neuronal se optimiza para que las rutas planeadas sean más similares a las rutas proporcionadas por humanos, mejorando así la capacidad del planificador para generar rutas más naturales y coherentes.

Ramachandran and Amir [2007] proponen modelar el Aprendizaje por Reforzamiento Inverso (IRL) desde una perspectiva bayesiana (BIRL) y resolver el aprendizaje de recompensas utilizando un algoritmo modificado de Monte Carlo de Cadena de Markov (MCMC). La recompensa se modela como un vector de variable aleatoria que determina la distribución de estados y acciones expertas. Luego se infiere la distribución de las recompensas que mejor explica las trayectorias de los expertos. Por otro lado, Kim and Pineau [2016] utilizan BIRL para aprender una función de recompensa lineal sobre características extraídas de cámaras RGB-D en

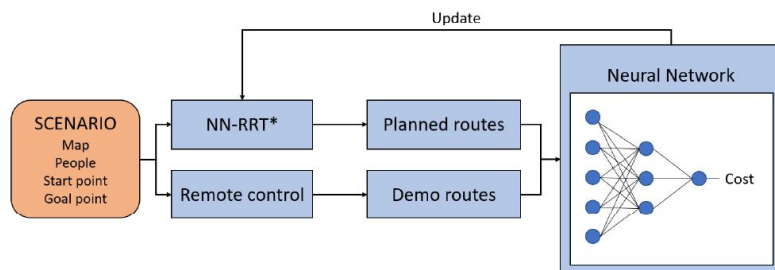


Figura 2.16: Descripción general de la NRTIRL. (imagen tomada de Wang et al. [2022a])

una silla de ruedas robótica. El marco propuesto consta de tres módulos: extracción de características, BIRL y planificación de rutas. El módulo de extracción de características extrae información de un sensor RGB-Depth, el módulo BIRL utiliza demostraciones de expertos para aprender una función de coste que considera variables sociales, y el módulo de planificación utiliza una arquitectura de tres capas para optimizar las rutas globales y locales evitando obstáculos. En otro enfoque, Okal and Arras [2016] proponen un nuevo método para modelar el comportamiento normativo social en robots utilizando Procesos de Decisión de Markov (MDP) y una versión modificada de BIRL. Se centran en los comportamientos espaciales de movimiento del robot y utilizan una representación basada en grafos para integrar restricciones específicas de la tarea en el MDP. El uso de esta representación basada en grafos permite a los autores instanciar planificadores globales como RRT o A\* utilizando las recompensas aprendidas para la navegación local.

En la tabla 2.8 podemos ver una comparación de los métodos descritos, así como que estudios realizan simulaciones o experimentos reales y cuales añaden alguna característica específica para mejorar el confort social.

Tabla 2.8: Métodos revisados para IRL

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Ziebart et al. [2008]	Aprendizaje Inverso de Reforzamiento de Entropía Máxima Aprendizaje inverso y aprendizaje por imitación	SI	NO	NO
Henry et al. [2010]	Aprendizaje Inverso de Reforzamiento con Procesos Gaussianos para el entorno	SI	NO	SI
Pérez-Higueras et al. [2014]	Aprendizaje inverso de refuerzo Planificador de trayectorias globales: algoritmo de Dijkstra	NO	SI	SI
Gerkey and Konolige [2008]	Aprendizaje DARPA aplicado a tierra Trayectorias globalmente óptimas en un mapa de costos	SI	NO	NO
Vasquez et al. [2014]	Comparar métodos de aprendizaje basados en IRL Planificación de movimiento GPU basado en cuadrícula	SI	NO	SI
Kretschmar et al. [2016]	Cadenas de Markov Monte Carlo (MCMC) hamiltonianas Aprender un modelo del comportamiento de navegación de agentes que cooperan como peatones Gráfico de Voronoi del entorno	SI	SI	SI
Wang et al. [2022a]	Árboles aleatorios de exploración rápida de redes neuronales Una función de costo basada en redes neuronales	SI	NO	SI
Ramachandran and Amir [2007]	BIRL bayesiano (BIRL) El aprendizaje de recompensas es una tarea de estimación Proceso de decisión de Markov Tarea de aprendizaje de aprendices	SI	NO	NO
Kim and Pineau [2016]	Módulo de planificación de trayectorias Aprendizaje inverso de refuerzo Marco para la planificación de trayectorias socialmente adaptativas en entornos dinámicos Generando trayectorias similares a las humanas	NO	SI	SI
Okal and Arras [2016]	Representación basada en gráficos de lo continuo Nueva extensión de BIRL	SI	SI	SI

## Experimentos

En los métodos de aprendizaje por refuerzo inverso la etapa de simulación tiene diferentes objetivos. En [Ziebart et al. \[2008\]](#), se usa para modelar las preferencias de enrutamiento del mundo real utilizando datos de GPS, mientras que [Henry et al. \[2010\]](#) demuestran el aprendizaje exitoso de rutas de navegación a partir de demostraciones utilizando un simulador de movimiento de multitudes. Por su parte, [Gerkey and Konolige \[2008\]](#) generan trayectorias de velocidad factibles que resultan en rutas suaves para la navegación de robots, mientras que [Vasquez et al. \[2014\]](#) presentan una plataforma de software con varias contribuciones, incluyendo algoritmos de aprendizaje basados en GPU y teleoperación.

[Kretzschmar et al. \[2016\]](#) evalúan la generalización de su enfoque a nuevas situaciones utilizando conjuntos de datos de peatones que interactúan, mientras que [Wang et al. \[2022a\]](#) recopilan datos para el algoritmo de planificación de trayectorias de un robot utilizando lidar y control remoto.

Por otro lado, [Ramachandran and Amir \[2007\]](#) utilizan el Aprendizaje por Reforzamiento Inverso Bayesiano para aprender funciones de recompensa para juegos de aventuras, y [Okal and Arras \[2016\]](#) demuestran la efectividad de su enfoque de aprendizaje al permitir que los robots aprendan comportamientos de navegación complejos con experimentos en un robot real y un simulador de peatones.

En aquellos estudios que realizan experimentos en robots reales nos encontramos con [Pérez-Higueras et al. \[2014\]](#) y [Kretzschmar et al. \[2016\]](#) que demuestran un comportamiento social exitoso para robots móviles en entornos concurridos. Mientras [Vasquez et al. \[2014\]](#) muestra nel potencial de los robots para brindar servicios útiles en espacios públicos. Por su parte, [Kim and Pineau \[2016\]](#) y [Okal and Arras \[2016\]](#) se centran en el comportamiento del robot similar al de los conductores humanos y en respetar los espacios personales, respectivamente. El planificador de IRL fue más rápido, pero más conservador, mientras que el robot en [Okal and Arras \[2016\]](#) mantuvo los espacios personales con la ayuda de un rastreador de relaciones sociales.

### Confort Social

Varios estudios tienen como objetivo desarrollar marcos de planificación de trayectorias socialmente compatibles para robots en entornos humanos. [Henry et al. \[2010\]](#) replican el comportamiento peatonal humano, mientras que [Pérez-Higueras et al. \[2014\]](#) imitan el comportamiento humano para movimientos socialmente compatibles. [Vasquez et al. \[2014\]](#) replican las interacciones humanas, y [Kretzschmar et al. \[2016\]](#) se centra en aprender el comportamiento de los peatones para predecir y navegar a través de ellos. Mientras tanto, [Wang et al. \[2022a\]](#), [Kim and Pineau \[2016\]](#), and [Okal and Arras \[2016\]](#) proponen enfoques que generan trayectorias socialmente adaptativas mediante el aprendizaje de trayectorias demostradas y teniendo en cuenta variables sociales.

#### 2.2.4. Enfoques de navegación de múltiples comportamientos

Cuando las personas se desplazan en un entorno concurrido, no es sencillo comportarse como un objeto rígido cuya única meta es llegar a un destino sin interactuar con los demás. A menudo, es necesario pedir permiso para pasar, a veces interrumpiendo conversaciones o indicando nuestras intenciones con gestos, e incluso tocando ligeramente a alguien para que se aparte y nos permita avanzar. Este escenario, complicado de trasladar a un agente robótico debido a la mezcla de funcionalidades distintas que implica, requiere integrar el sistema de navegación con otros módulos presentes en la arquitectura de software. En esta sección, se presentan algunos ejemplos de enfoques que combinan acciones asociadas a diferentes funcionalidades para alcanzar un objetivo de navegación (comportamientos multimodales). Dicha integración puede lograrse incorporando todas estas funcionalidades en el marco de navegación (Kamezaki et al. [2022]; Dugas et al. [2020]) o permitiendo que todas cooperen en una representación compartida del entorno (Vega-Magro et al. [2021]).

Permitir que un robot adapte su comportamiento según el contexto implica adentrarse en el campo de la autoadaptación. Según la propuesta de Chen et al. [2018b], después de estimar una trayectoria local para evitar obstáculos basada en las rutas previstas de agentes móviles, el robot puede elegir un modelo de viaje para la navegación según el estado del tráfico. Por otro lado, Freitas et al. [2020] proponen un marco que permite al robot ajustar su configuración de navegación según el contexto, como abortar una misión cuando el nivel de autonomía de energía es bajo y redirigir al robot a la estación de carga. Algunos de estos cambios de contexto están relacionados con la presencia de personas en el entorno. Sin embargo, este trabajo no se enfoca realmente en permitir que un robot navegue de manera natural y socialmente adecuada entre las personas. Utilizando el marco basado en el modelo MROS, Bozhinoski and Wijkhuizen [2021] presentan un enfoque similar que adapta la configuración del planificador local en tiempo de ejecución para cumplir con un conjunto de requisitos de calidad. Todos estos métodos no consideran otras habilidades de acción para el robot aparte de moverse en el entorno.

El enfoque IAN (Interaction Actions for Navigation) (Dugas et al. [2020]) se define como una planificación de alto nivel, consciente de la in-

teracción y con múltiples comportamientos para la navegación en entornos poblados por humanos y no estructurados. En resumen, el enfoque permite que el robot elija un comportamiento de navegación específico basado en el estado observado del entorno. Estos comportamientos combinan acciones asociadas a diferentes funcionalidades robóticas (comportamientos multimodales). El primer comportamiento considera un escenario estático o con poca dinámica y consiste en un planificador de movimiento basado en un campo de velocidad local, utilizando RVO para modelar agentes móviles. En el segundo comportamiento, el robot puede anunciar verbalmente su movimiento y señalar la dirección con la mano. El tercer comportamiento se utiliza para pasar muy cerca de las personas en entornos altamente poblados, utilizando el enfoque Dynamic Window (DWA) como planificador local. Cuando el DWA no puede encontrar una solución, el robot se mueve lentamente con el brazo extendido, llegando a su propio espacio y anunciando verbalmente que está pasando entre las personas.

El marco SNAPE (Vega-Magro et al. [2021]) enfatiza que un robot necesita comportamientos sociales y cooperación de los humanos para navegar socialmente. La base de la propuesta es la arquitectura de software CORTEX para robótica (Bustos et al. [2019]; Marfil et al. [2020]). Esta arquitectura utiliza un conjunto de agentes de software que rodean un modelo mundial basado en gráficos, organizados en cinco capas: percepción, social, navegación, interacción humano-robot y planificación de alto nivel. Mediante CORTEX, el marco SNAPE administra todo el flujo de información, desde la percepción del entorno hasta la planificación del comportamiento, coordinando la actividad en todas las capas. Por ejemplo, cuando el robot detecta que una persona bloquea su camino, puede acercarse, llamar la atención con un diálogo específico y pedir permiso para pasar.

Basándose en un modelo SFM inducible (i-SFM), Kamezaki et al. [2022] proponen un método de planificación de trayectorias reactivo, proactivo e inducible mediante puntos de paso fusionados (el enfoque de navegación de multitudes proximales (PCN)). El PCN considera la proximidad y el contacto físico para trazar las rutas, utilizando i-SFM para predecir los movimientos humanos. El PCN puede predecir el movimiento de las

personas en el entorno del robot, generar múltiples trayectorias que incluyen rutas de contacto físico mediante el método de puntos de paso y determinar la ruta considerando la eficiencia del movimiento y el grado de invasión de la multitud.

En la tabla 2.9 podemos ver una comparación de los métodos descritos, así como que estudios realizan simulaciones o experimentos reales y cuales añaden alguna característica específica para mejorar el confort social.

Tabla 2.9: Enfoques de navegación de múltiples comportamientos y enfoques de navegación de comportamiento multimodal

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Chen et al. [2018b]	Selección del modelo de viaje de acuerdo con el estado del tráfico	SI	SI	SI
Freitas et al. [2020]	Autoadaptación basada en métricas QoS Planificación codificada en árboles de comportamiento Arquitectura de software CORTEX	SI	NO	SI
Bozhinoski and Wijkhuizen [2021]	Autoadaptación basada en el marco MROS Modelos de calidad para adaptar la configuración del planificador local en tiempo de ejecución	SI	NO	NO
Kamezaki et al. [2022]	Enfoque de Navegación de Multitudes Próximas (PCN) (proximidad y contacto físico) SFM inducible (i-SFM) para predecir el movimiento humano	SI	SI	NO
Dugas et al. [2020]	El marco IAN Acciones de interacción (hablar, tocar y hacer gestos) para navegar en escenarios concurridos	SI	SI	SI
Vega-Magro et al. [2021]	El marco SNAPE Arquitectura de software cognitiva CORTEX	SI	NO	SI

## Experimentos

En esta sección, examinamos los experimentos que validan diversos métodos, explorando múltiples facetas en el ámbito de las simulaciones robóticas y sus objetivos particulares.

Las simulaciones ofrecen una visión profunda de cómo los robots se desenvuelven y se adaptan en distintos escenarios simulados. Desde evaluar modelos de conciencia social hasta la navegación proactiva en entornos complejos, estas simulaciones proveen información esencial para mejorar la interacción humano-robot en entornos del mundo real. Destaca la evaluación con participantes, como en el caso de [Vega-Magro et al. \[2021\]](#), añadiendo validez y relevancia a los resultados obtenidos en el entorno simulado.

Por un lado, algunas de estas simulaciones realizan comparaciones con otros métodos para exhibir las mejoras obtenidas. Es el caso de [Chen et al. \[2018b\]](#) se lleva a cabo una comparación detallada de dos casos de navegación utilizando el robot Patrobot. Además, la simulación se enfoca en la conciencia social, utilizando coordenadas de peatones enviadas al robot mediante sensores láser. Las trayectorias recopiladas de los peatones se emplean para entrenar un modelo, evaluando así el rendimiento del robot en situaciones complejas y dinámicas. [Dugas et al. \[2020\]](#) realizan una comparación entre los modelos de interacción probabilísticos simples y el planificador de banda elástica cronometrada (TEB) CADRL. La evaluación del marco de planificación multicomportamiento de la IAN destaca la eficacia del modelo propuesto en escenarios simulados complejos.

Por otro lado, [Freitas et al. \[2020\]](#) utilizan instantáneas del robot en movimiento para proporcionar una visión detallada de su comportamiento en un entorno simulado. Este enfoque ofrece una perspectiva valiosa sobre cómo el robot responde y se adapta a los diferentes elementos simulados. En contraste, [Bozhinoski and Wijkhuizen \[2021\]](#) se enfoca en examinar cómo los modelos de calidad contribuyen a mejorar la navegación en un marco de autoadaptación robótica, destacando la importancia de la calidad global en la planificación y ejecución de la navegación, con el objetivo de optimizar el rendimiento del robot en diversos entornos simulados.

Otro enfoque, presentado por [Kamezaki et al. \[2022\]](#), permite explorar

la capacidad del robot para navegar de manera proactiva y segura en entornos con multitudes, utilizando una simulación proactiva de navegación proximal de multitudes que involucra a un robot y de 4 a 8 humanos.

Finalmente, [Vega-Magro et al. \[2021\]](#) desarrollan una simulación en un apartamento de 65m<sup>2</sup> con dos habitaciones, un pasillo y un baño. En este entorno, un robot social con base omnidireccional interactúa con peatones aleatorios, algunos de los cuales bloquean su trayectoria. Esta simulación recrea un entorno doméstico y evalúa la capacidad del robot para navegar e interactuar de manera efectiva en un espacio residencial.

Los experimentos llevados a cabo en robots reales proporcionan una perspectiva práctica sobre la capacidad de los robots para interactuar en entornos del mundo real. Desde la consideración de trayectorias humanas hasta la libre circulación en presencia de múltiples personas, estos estudios abordan desafíos prácticos en la implementación de robots en entornos sociales y compartidos. La variedad de configuraciones, desde oficinas hasta salas universitarias, subraya la importancia de evaluar la adaptabilidad y el comportamiento del robot en diversos contextos.

Entre aquellos que realizan estos experimentos se encuentran: [Chen et al. \[2018b\]](#) se enfoca en demostrar los beneficios de integrar la trayectoria humana en la planificación del robot. La investigación destaca cómo el robot, al explorar trayectorias aleatorias para desviar a los peatones, puede mejorar la interacción y la navegación en entornos compartidos. Este enfoque resalta la importancia de considerar no solo el comportamiento del robot, sino también las dinámicas de movimiento humano para una interacción más segura y eficiente. Mientras que el experimento llevado a cabo por [Kamezaki et al. \[2022\]](#) busca comprender cómo un robot puede interactuar en entornos dinámicos y poblados. Al permitir que el robot se mueva libremente entre grupos de 4 a 7 personas, se explora la capacidad del robot para navegar de manera segura y adaptarse a diferentes configuraciones sociales. Este estudio proporciona información valiosa sobre la interacción en situaciones realistas y congestionadas. Finalmente [Dugas et al. \[2020\]](#) usan una plataforma de robot humanoide, involucrando participantes y transeúntes en entornos de oficina (también presentes en la simulación) y salas universitarias. Al replicar condiciones tanto simuladas como reales, se busca validar la capacidad del robot para interactuar en

entornos comunes y dinámicos. La inclusión de participantes y transeúntes agrega complejidad al estudio, permitiendo observar cómo el robot se comporta en presencia de individuos en un entorno cotidiano.

### Confort Social

Los estudios referenciados abordan aspectos cruciales de la interacción humano-robot, resaltando diferentes enfoques y mejoras significativas en el comportamiento de los robots.

La inclusión de la conciencia social, mejorando la capacidad del robot para comprender y responder de manera más natural a las señales sociales humanas, se evidencia en [Chen et al. \[2018b\]](#), donde se adapta el comportamiento del robot a las normas sociales, y en [Vega-Magro et al. \[2021\]](#), que utilizan el marco SNAPE para navegar e interactuar siguiendo las convenciones sociales.

Por otro lado, [Freitas et al. \[2020\]](#) introducen la exploración de la autoadaptación del comportamiento de navegación de un robot. Este enfoque sugiere la capacidad del robot para ajustar su comportamiento de navegación de manera autónoma, mejorando su adaptabilidad a entornos cambiantes y su capacidad para cumplir con objetivos específicos. Además, [Dugas et al. \[2020\]](#) proponen el uso de acciones de interacción, como decir, tocar y gesticular, como parte integral del comportamiento del robot. Esta estrategia enriquece la comunicación y la interacción del robot con los humanos al incorporar modalidades más expresivas y comprensibles.

En conjunto, estos estudios resaltan la importancia de considerar la conciencia social en la interacción humano-robot. Ya sea mediante modelos mejorados, la capacidad de autoadaptación del robot, la inclusión de diversas acciones de interacción, o marcos específicos como SNAPE, estos enfoques buscan mejorar la calidad y naturalidad de la interacción robot-humano. La evaluación en entornos simulados, como en el caso de [Vega-Magro et al. \[2021\]](#), también subrayan la importancia de validar estas mejoras en condiciones controladas antes de su implementación en entornos del mundo real.

### 2.3. Navegación con Paralelización

Como se ha visto en este apartado una de las cuestiones que más se busca en navegación es la optimización del método y obtener los datos lo más rápido posible para que la reacción del robot sea en “tiempo real”. Por ello, con el desarrollo de las nuevas tecnologías se abre un nuevo camino, que es la optimización de estos métodos con la paralelización.

Para analizar los trabajos que se han ido desarrollando hasta la fecha se ha realizado una búsqueda en Web of Science con los siguientes parámetros TS=(robot) AND TS=parallelization AND TS= navigation, obteniendo 21 resultados. Como se observa en la gráfica 2.17 en los últimos años ha tenido más impacto este tipo de artículos.

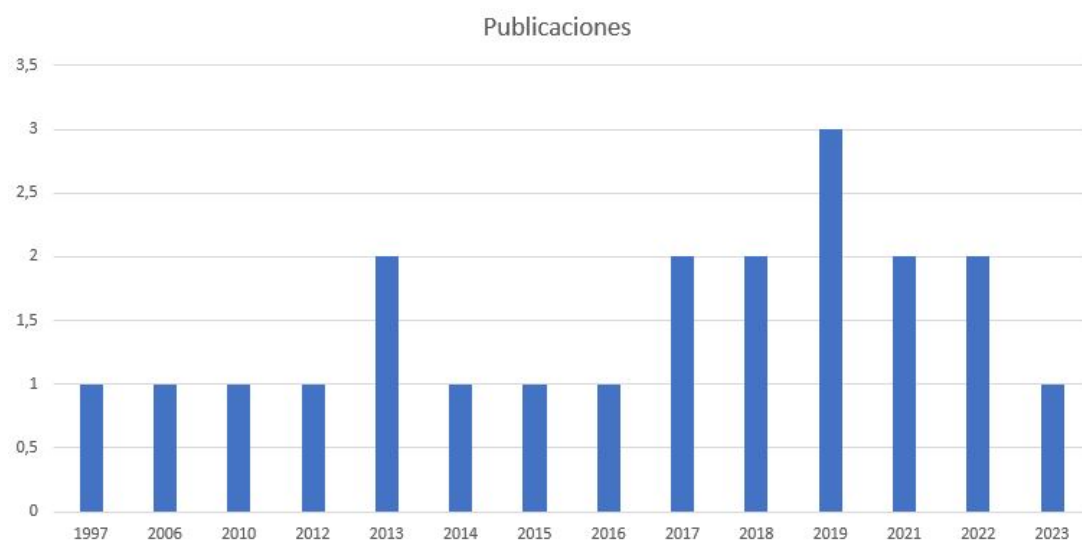


Figura 2.17: Artículos Paralelización Web of Science

Esta revisión literaria se ha enriquecido con la inclusión de otras fuentes consideradas de interés. Todos estos recursos han sido examinados en esta sección para ofrecer una visión de la evolución en este campo. El artículo [Henrich \[1997\]](#) fue excluido del análisis debido a su antigüedad, del año 1997, lo que lo hace obsoleto en la actualidad.

El primer artículo que nos encontramos referente a la paralelización

aplicada en los métodos de navegación en robots es [Vercelli et al. \[1994\]](#) presentando NAVNEX, un sistema híbrido que usa redes neuronales y algoritmos procedimentales para que un robot móvil se mueva en entornos desconocidos, aprendiendo y adaptándose en tiempo real durante la exploración. Emplea redes neuronales para entender obstáculos y mapas de espacio libre, y algoritmos procedimentales para analizarlos topológicamente y reconocer situaciones. Sin embargo, habría que esperar hasta 2006 para que la tecnología permitieran a [Kerrache and Drias \[2006\]](#) presentar HMALRTA\* (Aprendizaje heterogéneo de múltiples agentes en tiempo real A\*), una extensión de los métodos de búsqueda en tiempo real que permite a agentes con capacidades distintas resolver problemas de manera cooperativa.

El trabajo de [Prescott \[2008\]](#) introduce BRAHMS, una herramienta excepcional que se destaca por su habilidad para integrar componentes en diversos entornos computacionales, superando barreras entre escalas y disciplinas. Este sistema permite un desarrollo modular, siendo adaptable incluso en dispositivos con recursos limitados. Por otro lado [Otte and Correll \[2010\]](#) proponen un algoritmo Dynamic Team Any-Com ISS para planificar rutas de robots considerando integridad, resistencia.

A continuación, en el artículo [Furukawa et al. \[2010\]](#), la tecnología permite un nuevo avance permitiendo usar la GPU para paralelizar cálculos y acelerar la Estimación Bayesiana Recursiva (RBE), permitiendo el control en tiempo real de vehículos autónomos al reducir la carga computacional. En esta línea siguen [Häselich et al. \[2012\]](#) optimizando el rendimiento del sistema usando CPU y GPGPU (General-Purpose Graphics Processing Unit). Además se introduce la paralelización en la tarjeta gráfica que también probará [Kapadia et al. \[2012\]](#) y [Iguar et al. \[2013\]](#). Esta última propuesta por [Iguar et al. \[2013\]](#) realiza una implementación en DSP que permite el procesamiento en tiempo real de imágenes de alta resolución.

Por otro lado, el trabajo de [Lau et al. \[2013\]](#) ofrece algoritmos que reducen significativamente las visitas y el tiempo de cálculo, manteniendo altos niveles de precisión. Su algoritmo GVD aborda estructuras no convexas en entornos 3D, permitiendo representar mejores obstáculos usando Microsoft Kinect. En la tabla 2.10, se pueden observar los métodos usados para el primer grupo de artículos que van desde 1994 a 2013.

Tabla 2.10: Enfoques de navegación con Paralelización

Referencia	Métodos	Simulaciones	Exp. Reales
Vercelli et al. [1994]	Navegación y exploración neuronal (NAVEX)	SI	NO
Kerrache and Drias [2006]	Aprendizaje heterogéneo de múltiples agentes en tiempo real A* (HMALRTA*)	SI	NO
Prescott [2008]	BRAHMS es una herramienta para integrar módulos de procesos computacionales en un sistema computable viable	SI	NO
Otte and Correll [2010]	Dynamic Team Any-Com ISS, algoritmo de planificación de rutas de múltiples robots centralizado	NO	SI
Furukawa et al. [2010]	Paralelización de la Estimación Bayesiana Recursiva (RBE) basada en grid utilizando unidades de procesamiento gráfico (GPU)	SI	SI
Häselich et al. [2012]	Optimizar el rendimiento del sistema utilizando CPU multinúcleo y hardware GPGPU. Minimización de energía de campo aleatorio de Markov mediante muestreo de Gibbs. Optimizaciones de memoria: paralelizar la minimización de energía del terreno utilizando múltiples subprocesos de CPU. Paralelización en la tarjeta gráfica	SI	NO
Kapadia et al. [2012]	SteerBench Paralelización en la tarjeta gráfica	SI	NO
Lau et al. [2013]	Algoritmos de actualización incremental para DM y GVD	SI	SI
Igual et al. [2013]	Procesador de señal digital (DSP) multinúcleo Modelo de gradiente (McGM) en un DSP multinúcleo de baja potencia Paralelización en la tarjeta gráfica	SI	NO

Con la posibilidad de usar diferente número de procesadores [Ragab and Elkabbany \[2014\]](#) proponen una implementación paralela en 3 niveles mediante el el Filtro Kalman Extendido (EKF) mejorando el rendimiento de algoritmos de procesamiento de imágenes y visión por computadora para la ubicación de robots móviles. Por otro lado, [Krupke et al. \[2015\]](#) presentan un enfoque distribuido y sin autoridad central para organizar robots, logrando máxima paralelización y complejidad lineal con el número de robots.

En otra línea de investigación para reducir la carga en la localización precisa de robots en interiores, [Konecny et al. \[2016\]](#) realizan la comparación entre un método implementado en C# y un modelo matemático en MATLAB evidencia la eficiencia superior de C# en demandas computacionales, permitiendo respuestas más rápidas en tiempo real y reduciendo las limitaciones en sistemas integrados de baja potencia.

Con el surgimiento de CUDA [Ouerghi et al. \[2017\]](#) presentan una solución basada en esta tecnología. La estrategia propuesta realiza iteraciones RANSAC en paralelo, optimizando el rendimiento mediante diversos niveles de paralelismo, y se destaca por su aplicabilidad en problemas diversos, especialmente en navegación autónoma. Otras de las tecnologías que se abren paso para la paralelización es el uso de las FPGAs como la que proponen [Nahar et al. \[2017\]](#). Presenta una arquitectura para segmentación de imágenes en tiempo real en FPGA, enfrentando desafíos de rendimiento y consumo de energía en sistemas robóticos con recursos limitados, esenciales para aplicaciones como compresión, imágenes médicas, cartografía y navegación autónoma.

Otros trabajos se centran más en mejorar diferentes aspectos del rendimiento en la navegación de diferentes robots como [Palossi et al. \[2017\]](#) que demuestran un logro significativo al conseguir vuelo estacionario en UAV nano sin sensores barométricos mediante odometría visual. Y [Chou et al. \[2017\]](#) presentan un enfoque para generar trayectorias de navegación suaves y naturales en robots móviles basada en líneas de flujo con método de función potencial armónica.

En la tabla 2.11 se pueden observar los métodos usados para el grupo de artículos que van desde 2019 a 2017.

Tabla 2.11: Enfoques de navegación con Paralelización II

Referencia	Métodos	Simulaciones	Exp. Reales
Ragab and Elkabbany [2014]	Filtro Kalman Extendido (EKF) Implementación paralela en 3 niveles (1º a nivel cámara, 2º procesador coopera con la cámara, 3º bucle/extracción)	SI	NO
Krupke et al. [2015]	Método distribuido	SI	NO
Konecny et al. [2016]	Algoritmo de coincidencia de escaneo láser del punto más cercano iterativo (ICP) MATLAB y lenguaje C#. LiDAR	SI	NO
Ouerghi et al. [2017]	Modelo de programación de CUDA Versión básica de Gröbner del algoritmo de 5 puntos, complementada con una estimación robusta Iteraciones RANSAC requeridas en paralelo	SI	NO
Palossi et al. [2017]	Arquitectura paralela de clase MCU de consumo ultrabajo y optimizando la implementación del software	SI	NO
Nahar et al. [2017]	Tres arquitecturas novedosas de segmentación de imágenes implementadas en Virtex UltraScale XCVU190-2FLGC2104EES9847 FPGA	SI	NO
Chou et al. [2017]	Iteración de Jacobi, la iteración de Gauss-Seidel y la iteración SOR Implementación paralela en GPU Ecuación de Laplace con BC de Dirichlet o Neumann	SI	NO

El término SLAM (Simultaneous Localization and Mapping) se refiere a un proceso utilizado en robótica y sistemas autónomos para permitir que un robot o dispositivo móvil cree un mapa de un entorno desconocido mientras simultáneamente se localiza en dicho entorno. Un ejemplo de esta tecnología es [Vespa et al. \[2018\]](#) utilizan Octree para representar eficientemente el entorno, permitiendo funciones de SLAM y planificación sin necesidad de paralelización intensiva en GPU. Otro ejemplo de ello es

el que propone [Ma et al. \[2021\]](#) que presentan un método de paralelización basado en hardware integrado con GPU para acelerar el procesamiento visual frontal del algoritmo Visual SLAM.

Una variante del SLAM es RatSLAM un sistema de localización y mapeo simultáneo (SLAM) bioinspirado. [Muñoz et al. \[2019\]](#) presentan una implementación de RatSlam que es más rápida que RatSlam estándar, lo que la hace idónea para aplicaciones en tiempo real debido a su menor tiempo de procesamiento.

Los sensores Lidar son frecuentemente usados con SLAM para construir mapas del entorno. Por ello [Sinyukov and Padir \[2018\]](#) presentan un algoritmo paralelizado de LiDAR 3D SLAM para robots aéreos autónomos, mostrando mejoras de ejecución del 26 % con el uso de 4 CPU frente a la ejecución en serie. Además, resalta el marco de navegación NoVeLTI, que proporciona libertad de navegación para el usuario y flexibilidad al adaptarse y personalizarse para diversas necesidades. En esta misma línea, [A V and Kanna \[2021\]](#) emplean técnicas como FPFH y el algoritmo ICP para mejorar la precisión en la alineación de datos LiDAR, generando mapas 3D más detallados y precisos. Además, la optimización del gráfico de pose 3D reduce la deriva en la trayectoria estimada, mejorando la precisión y confiabilidad en la navegación del robot aéreo.

Otra aportación para los robots aéreos es presentada por [Torres et al. \[2020\]](#) proponen una arquitectura eficiente para procesar imágenes en vuelo, crucial en vigilancia forestal y navegación visual con alta velocidad y bajo consumo energético. Utiliza una arquitectura WNS y FPGA para procesamiento simultáneo en UAV, permitiendo paralelización avanzada, manipulación de grandes imágenes y simplificación de circuitos con funciones booleanas. Esta arquitectura escalable FPGA ofrece integración de sistemas neuronales que detectan incendios, áreas quemadas e invasión de áreas protegidas, abriendo múltiples usos y aplicaciones para esta tecnología.

Siguiendo con la aplicación de navegación autónoma en UAV [He et al. \[2021\]](#) proponen dividir la aplicación PNI en clústeres para maximizar la ejecución en paralelo, minimizando la comunicación entre ellos y equilibrando las cargas de trabajo. Este enfoque busca reducir la energía de comunicación y congestión en NoC mediante algoritmos de procesamien-

to conscientes de la energía, equilibrio de carga y asignación optimizada de tareas. Se validó con simulaciones en navegación de drones.

Tabla 2.12: Enfoques de navegación con Paralelización III

Referencia	Métodos	Simulaciones	Exp. Reales
Vespa et al. [2018]	Sistema SLAM denso basado en Octree eficiente Mapeo TSDF Planificación de movimiento en línea -Informed RRT	SI	NO
Sinyukov and Padr [2018]	Algoritmo LiDAR 3D SLAM paralelizado	SI	SI
Thompson and Guihen [2018]	Marco de planificación de misiones para AMV Mejora del algoritmo DStPSO con la modificación de desintegración del enjambre	SI	SI
Azevedo [2018]	ViTruDe (Vine Trunks and Masts Detector), un algoritmo de percepción visual para detectar una alta densidad de elementos naturales del viñedo	SI	NO
Azevedo et al. [2019]	ViTruDe en GPU utilizando Compute Unified Device Architecture (CUDA) y CPU Sistema Global de Navegación por Satélite (GNSS)	SI	NO
Muñoz et al. [2019]	Implementación del algoritmo RatSlam como una biblioteca C++	SI	NO
Torres et al. [2020]	Arquitectura de red neuronal ingrúvida	SI	SI
He et al. [2021]	Código de percepción e inteligencia de navegación (PNI) Analizador IR LLVM para construir el DDG ( gráfico de dependencia de datos ) Aplicación de navegación autónoma de UAV Paralelización arquitectura Networkon-chip (NoC).	SI	NO
A V and Kanna [2021]	LiDAR 3D SLAM paralelizado	SI	NO
Ma et al. [2021]	El SLAM visual basado en GPU integrada		

En otro enfoque, [Azevedo \[2018\]](#) introduce ViTruDe, un algoritmo optimizado en GPU que mejora significativamente el reconocimiento en viñedos, aumentando la eficiencia del robot AgRob V16 en tareas agrícolas en terrenos inclinados. Este algoritmo aprovecha la GPU con programación CUDA para acelerar el procesamiento de imágenes en tiempo real, mejorando el rendimiento del robot en viñedos. En [Azevedo et al. \[2019\]](#) presentan una alternativa con la implementación en GPU con CUDA que acelera el detector ViTruDe, logrando más de 80 veces la velocidad de procesamiento comparada con la CPU. Esto permite operaciones en tiempo real para seguimiento y cosecha en viñedos en pendientes pronunciadas, ofreciendo precisión de localización independiente de la señal satelital y superando las limitaciones de GNSS y terreno para entornos de viñedos. Además, sugiere propuestas de desarrollo futuro, como la combinación CUDA-OpenACC y la exploración de cámaras y bibliotecas optimizadas para GPU .

En la tabla 2.12 se pueden observar los métodos usados para el último grupo de artículos que van desde 2019 a 2023.

Un algoritmo masivamente paralelizado (MPLP) es introducido por [Mukherjee et al. \[2021\]](#) que aprovechan subprocesos múltiples para búsquedas y evaluaciones asincrónicas en paralelo, mejorando drásticamente el tiempo de planificación. Se destaca su superioridad sobre algoritmos existentes en dominios de planificación con cuellos de botella en evaluaciones de bordes. En el procesamiento de imágenes, [Mohan and Kurian \[2022\]](#) destacan por su capacidad para lograr rendimiento en tiempo real al procesar imágenes a alta velocidad usando Verilog para módulos personalizados, paralelización, canalización y optimización de memoria en la Lógica Programable. Combina la distancia del centroide y la transformada rápida de Fourier para obtener descriptores de características de forma rápida y ligera, lo que lo hace escalable e invariante a la rotación. Además, utiliza buses de interfaz estándar AXI para la rápida conexión y transferencia de datos entre unidades, lo que facilita la configuración de diferentes módulos del sistema.

Para la aplicación específica de diferentes tipos de robots surgen las siguientes implementaciones con paralelización. Para los AGV (Vehículos Terrestres Autónomos) [Yu et al. \[2022\]](#) introducen un método codicioso

para asignar trabajos según prioridades, mejorando la eficiencia en la distribución de tareas. Utiliza un modelo de programación mixta para rutas y un método de bloqueo de recursos para prevenir colisiones entre AGV, garantizando seguridad y flujo continuo. Las simulaciones confirman la eficiencia y robustez del algoritmo, mostrando reducción en el tiempo promedio por tarea y estabilidad en costos de CPU y memoria para la escalabilidad del sistema. Otra propuesta para la mejora de navegación para vehículos autónomos es desarrollada por [Stevenson and Fox \[2022\]](#) en una versión acelerada por GPU del software del hipocampo basado en el filtro unitario de partículas coherentes (UCPF) para modelar funciones del hipocampo humano.

Combinando los métodos de aprendizaje en la navegación de robots y la paralelización aparecen la propuesta por [Wang et al. \[2022b\]](#) mejoran del algoritmo IW-IES en Aprendizaje por Refuerzo en tareas desafiantes como navegación de robots y locomoción en entornos dinámicos. Este método pondera la novedad y calidad de las instancias, adaptándose rápidamente a entornos cambiantes, lo que lo hace relevante para desafíos futuros en dominios complejos y cambiantes. Y [Liu et al. \[2022\]](#) que proponen arquitectura de acelerador de hardware en FPGA para aumentar drásticamente la velocidad de cálculo del algoritmo Q-learning, logrando una mejora significativa en comparación con la ejecución en una CPU estándar. El diseño optimizado maximiza el uso de los recursos de la FPGA, resultando en un menor consumo y mayor eficiencia, siendo ideal para aplicaciones en tiempo real como la planificación de rutas en el control de robots.

Finalmente, encontramos una propuesta muy reciente por [Wei et al. \[2023\]](#) que presentan un método que emplea ecuaciones de difusión y Poisson para mejorar la navegación en entornos dinámicos, corrigiendo campos potenciales erróneos y permitiendo una navegación precisa con corrección de rutas, especialmente en áreas como estacionamientos. Prioriza regiones locales, mejorando la precisión y eficiencia de la navegación, y emplea la paralelización de ecuaciones lineales de calor para acelerar la resolución de problemas. Además, los análisis matemáticos y simulaciones respaldan la eficacia del método en condiciones específicas ver

En la tabla 2.13 se pueden observar los métodos usados para el último

grupo de artículos que van desde 2022 a 2023.

Tabla 2.13: Enfoques de navegación con Paralelización IV

Referencia	Métodos	Simulaciones	Exp. Reales
Mukherjee et al. [2021]	MPLP, un algoritmo de búsqueda diferida masivamente paralelizado	SI	NO
Yu et al. [2022]	Algoritmo paralelo para sistemas multi-AGV Algoritmo A/* mejorado	SI	NO
Stevenson and Fox [2022]	La GPU (Unidad de Procesamiento Gráfico) del software del hipocampo Mejora UCPF: creación de perfiles, optimización y refactorización basada. en pruebas para potenciar su rendimiento y funcionalidad	SI	NO
Wang et al. [2022b]	Estrategias de Evolución (ES) Aprendizaje por Refuerzo (RL) Estrategias de Evolución Incremental Ponderada por Instancias (IW-IES)	SI	NO
Mohan and Kurian [2022]	Módulos personalizados desarrollados en Verilog Procesador ARM Escribir datos en el Block RAM (BRAM) Máquina de Estados Finitos (FSM) en la Lógica Programable(PL) Buses de interfaz extensible avanzada (AXI) Estudio en Matlab	SI	NO
Liu et al. [2022]	Arquitectura de acelerador de hardware basado en FPGA para acelerar Q learning	SI	NO
Wei et al. [2023]	Ecuación de difusión, el método variacional y la ecuación de Poisson para concluir el proceso de navegación de manera simple y efectiva.	SI	NO
Mochurad et al. [2023]	2D y 3D LiDAR sensores	SI	NO

## Experimentos

En esta sección, se analizan una serie de experimentos destinados a validar diferentes métodos mediante simulaciones, con el propósito de mostrar su rendimiento y efectividad.

Para evaluar el rendimiento, se han empleado distintos recursos computacionales. Por ejemplo, [Prescott \[2008\]](#) utilizó un modelo de presas y depredadores en un procesador Intel Core 2. En otro caso, [Furukawa et al. \[2010\]](#) logró resultados en tiempo real combinando una Nvidia 880 y un procesador Intel Core 2 Duo. Más adelante, [Lau et al. \[2013\]](#) realizaron simulaciones con un procesador Intel Core i7 y Kinect para obtener mapas 3D del entorno, mientras que [Häselich et al. \[2012\]](#) emplearon un procesador Intel Core i7 para recopilar datos de sensores en diferentes contextos. Además, [Kapadia et al. \[2012\]](#) introdujeron peatones en su simulación como parte de su marco de trabajo.

En lo referente a las mejoras y optimizaciones, se destacan trabajos como el de [Iguar et al. \[2013\]](#), que aportaron mejoras sustanciales, y el análisis comparativo entre el tiempo secuencial y paralelo realizado por [Ragab and Elkabbany \[2014\]](#). Asimismo, [Krupke et al. \[2015\]](#) demostraron la capacidad de realizar simulaciones con enjambres de robots de diversos tamaños. Por otro lado, [Palossi et al. \[2017\]](#) introdujeron el simulador PULP, mientras que [Nahar et al. \[2017\]](#) abordaron mejoras en Vivado Power.

Se observó un incremento significativo en la capacidad de memoria RAM, pasando de 8 GB a 16 GB, tal como se evidencia en los trabajos de [Vespa et al. \[2018\]](#) y [Nahar et al. \[2017\]](#), en contraste con la configuración previa utilizada por [Häselich et al. \[2012\]](#) de 8 GB.

Con relación al hardware utilizado, [Azevedo \[2018\]](#) empleó un procesador i7-4700HQ con dos GPU NVIDIA diferentes, mientras que [Azevedo et al. \[2019\]](#) usaron un i7-4700HQ con una GPU NVIDIA 1050TI. Además, [Thompson and Guihen \[2018\]](#) describieron el uso de la plataforma REMORA para investigaciones en ambientes acuáticos.

Las comparaciones detalladas sobre el consumo de energía fueron realizadas por [He et al. \[2021\]](#) y [Nahar et al. \[2017\]](#). Por otro lado, [Ma et al. \[2021\]](#) llevaron a cabo pruebas de eficiencia utilizando una CPU con 6

núcleos, mientras que [Stevenson and Fox \[2022\]](#) se centraron en la eficiencia y robustez de un algoritmo paralelo, identificando cuellos de botella para mejorarlos mediante estrategias de paralelización. En un ámbito similar, [Wang et al. \[2022b\]](#) evaluaron la navegación en entornos dinámicos tras implementar técnicas de paralelización. Por último, [Mukherjee et al. \[2021\]](#) modelaron un robot PR2 y realizaron una exhaustiva evaluación de colisiones en un entorno interior.

Entre aquellos que realizaron pruebas en robots reales se encuentran: [Furukawa et al. \[2010\]](#) realizaron una búsqueda cooperativa utilizando UGV. Por otro lado, [Lau et al. \[2013\]](#) utilizaron un robot pioneer equipado con un telémetro láser en entornos dinámicos, capturando el movimiento humano. [Otte and Correll \[2010\]](#), por su parte, emplearon una plataforma robótica Prairiedog para llevar a cabo varios experimentos, tanto en una oficina como en un entorno real, con un total de 4 robots. Además, [Sinyukov and Padır \[2018\]](#) adaptaron el control compartido a una silla de ruedas robótica, realizando más de 250 experimentos.

En última instancia, dentro de este grupo, [Thompson and Guihen \[2018\]](#) consideran la plataforma de robots submarinos denominada Robótica Modular Reconfigurable para ambientes acuáticos (REMORA). Este estudio probó la eficacia del planificador de rutas con el modelo de control de REMORA AMV, demostrando su capacidad para estabilizar y rastrear de manera rápida la ruta generada. Por otro lado, [Torres et al. \[2020\]](#) emplean imágenes capturadas durante el vuelo de un UAV, mientras que [Mochurad et al. \[2023\]](#) llevan a cabo experimentos variando las posiciones de los sensores.

Además, [Mukherjee et al. \[2021\]](#) utilizan un robot Pr2 y calcula trayectorias libres de colisiones mediante el uso de NVIDIA Isaac Gym.

## 2.4. Navegación con Jetson Nano

La introducción de la Jetson Nano en 2019 ha representado un avance significativo en la paralelización de algoritmos, lo que ha permitido lograr mejoras notables en los resultados obtenidos. Diseñada por NVIDIA con un enfoque en aplicaciones de inteligencia artificial y aprendizaje automático en dispositivos embebidos, esta placa de desarrollo destaca por su equilibrio entre rendimiento, eficiencia energética y accesibilidad. La Jetson Nano está equipada con un procesador ARM Cortex-A57 de cuatro núcleos y un GPU NVIDIA Maxwell con 128 núcleos CUDA. Además, está compuesta por 4 GB de RAM LPDDR4 y una variedad de puertos de conectividad, como USB, Ethernet, HDMI y GPIO, resultando adecuada para proyectos que abarcan desde reconocimiento de objetos hasta seguimiento de personas, entre otras aplicaciones relacionadas.

Por consiguiente, se ha llevado a cabo una revisión sistemática para evaluar los trabajos más influyentes realizados hasta la fecha utilizando esta tecnología. Para analizar los trabajos desarrollados hasta la fecha, se realizaron dos búsquedas en Web of Science con los siguientes parámetros:  $TS=(robot) AND TS=jetson\ nano$  AND  $TS=social$  obteniendo 1 resultado y  $TS=(robot) AND TS=jetson\ nano$  AND  $TS=navigation$ , obteniendo 13 resultados. En esta última búsqueda, fue necesario eliminar la palabra clave “social” ya que no se obtuvieron resultados. Como se muestra en la figura 2.18, esta tecnología es relativamente nueva y no se encuentran artículos influyentes de años anteriores a 2020.

En primer lugar, hay varios trabajos que se enfocan en la detección de objetos para la identificación, localización y mejora en la navegación de los robots. En esta línea destacan los trabajos de [Pinto de Aguiar et al. \[2020\]](#), que se enfocan en la navegación en viñedos, donde la detección precisa de troncos de vid es crucial para la localización y el mapeo de robots. Compara el rendimiento de dos dispositivos, la Jetson Nano de NVIDIA y el USB Accelerator de Google, utilizando *Deep Learning* para identificar troncos de vid en tiempo real. Otra aplicación agrícola es la que proponen [Chen et al. \[2023\]](#) que consiste en un robot móvil autónomo basado en inteligencia artificial de cosas (AIoT) para abordar la escasez de mano de obra en la agricultura. Utiliza la placa NVIDIA Jetson Nano

y combina el algoritmo SLAM con reconocimiento de objetos para la recolección de pitahayas.




Figura 2.18: Artículos Jetson Web of Science

Con el enfoque de mejorar la navegación de robots mediante la identificación y clasificación de objetos [Ramôa et al. \[2020\]](#) proponen métodos innovadores de clasificación de puertas para mejorar la navegación de robots en entornos interiores. Estos métodos operan offline en computadoras de bajo consumo como la Jetson Nano, permitiendo la distinción en tiempo real entre puertas abiertas, cerradas y semiabiertas. Evolucionando en [Ramôa et al. \[2021\]](#) introduciendo tres métodos para clasificar el estado de las puertas, con el propósito de mejorar la navegación de robots en espacios interiores y aplicarlos en varios entornos.

Siguiendo la detección de objetos 3D el estudio de [Choe et al. \[2021\]](#) se enfoca en la detección de objetos en 3D para la navegación de robots y drones, evaluando varios marcos de detección de objetos en placas Jetson de NVIDIA. Y avanza en [Choe et al. \[2023\]](#) evaluando el desempeño de las plataformas NVIDIA Jetson al ejecutar frameworks de detección de

objetos 3D basados en aprendizaje profundo.

Otros enfoques para aplicar esta tecnología implementan un marco operativo para el robot sTetro ([Ramalingam et al. \[2021\]](#)), orientado a la limpieza de escaleras en edificios. Utiliza un Sistema de Percepción Ambiental (EPS) basado en visión, especialmente el modelo SSD MobileNet, para identificar y moverse en escaleras, obstáculos y desechos durante la limpieza. Y [Melo and Barros \[2023\]](#) proponen un enfoque de visión monocular para la detección de objetos y estimación de posiciones en el campo de fútbol de la Liga Small Size (SSL) de RoboCup, utilizando un NVIDIA Jetson Nano y la red SSD MobileNet v2. Este enfoque se centra en la detección de pelotas, robots y porterías, asumiendo que los objetos están en el suelo y la cámara del robot tiene una posición fija.

Por otro lado, tenemos otros trabajos centrados en mejorar la navegación autónoma de los robots. En el desarrollo de robots móviles, [Newman et al. \[2020\]](#) implementan un vehículo con capacidades de navegación autónoma en entornos desafiantes, prescindiendo de señales GPS. El sistema está basado en ROS Y SLAM usando la NVIDIA Jetson Nano y una cámara de profundidad Intel RealSense D435i para procesar imágenes estéreo y lograr la navegación mediante el procesamiento de información visual. Y [Dosoftei et al. \[2021\]](#) desarrollaron un robot móvil omnidireccional para entornos logísticos dinámicos, para ello emplea nodos de planificación de rutas con Matlab-Simulink para lograr la navegación autónoma en almacenes, validando la solución en la NVIDIA Jetson Nano integrada en el robot.

Para la navegación autónoma en entornos agrícolas [Yu et al. \[2023\]](#) proponen explorar usando Jetson Nano cinco métodos de visión por computadora basados en aprendizaje profundo para la extracción de líneas de navegación en campos, destacando las diferencias en precisión y velocidad entre las redes neuronales. Enfocado en vehículos aéreos no tripulados (UAVs) [Azevedo et al. \[2021\]](#) buscan resolver desafíos de navegación y evasión de obstáculos presenta un enfoque reactivo de evasión de colisiones que emplea un volumen de seguridad cilíndrico para detectar obstáculos y determinar rutas de escape en espiral. Finalmente, [Giovagnola et al. \[2023\]](#) presentan AirLoop, un simulador de vuelo basado en AirSim para validar algoritmos de fusión de sensores en la navegación autónoma de drones.

AirLoop amplía las capacidades de AirSim con un modelo de simulación de RADAR FMCW, demostrando su utilidad en la adquisición de datos sintéticos y en diversas tareas de navegación autónoma. Su integración con NVIDIA Jetson Nano y la ejecución de simulaciones HITL y SITL destacan su potencial para validar algoritmos de navegación autónoma.

Estos estudios resaltan la eficacia y el potencial de las plataformas Jetson Nano de NVIDIA, ofreciendo avances significativos en la navegación autónoma abarcando desde aplicaciones agrícolas como hasta robótica interior y exterior o en la validación de algoritmos para drones.

Además, encontramos otros estudios relevantes enfocados a robots sociales: [Kameli and Khan \[2022\]](#) se centran en mejorar la navegación de robots sociales, específicamente el robot Pepper, en entornos de hogares de ancianos. Para facilitar la navegación del robot hacia los residentes, se equipó a Pepper con un detector LiDAR y un NVIDIA Jetson Nano, superando las limitaciones de los sensores existentes. Y [Menon et al. \[2020\]](#) se enfocan en optimizar la síntesis de voz en tiempo real en dispositivos perimetrales, como el NVIDIA Jetson Nano, mediante algoritmos de redes neuronales adaptados para estos dispositivos. Se desarrolló una biblioteca de algoritmos con una interfaz unificada para experimentar con redes neuronales en un mismo conjunto de datos, sin generar nuevos algoritmos, sino adaptando los existentes para funcionar eficientemente en dispositivos como el Jetson Nano.

En la tabla 2.14 podemos ver un resumen de los métodos y los experimentos realizados.

## Experimentos

Los experimentos son una parte importante de la validación de los métodos analizados. Dado que los trabajos se encuentran validando la tecnología la mayoría de ellos no ha realizado la integración en un robot real.

Para realizar los experimentos [Pinto de Aguiar et al. \[2020\]](#) usaron una plataforma robótica AgRob V16 para elaborar el dataset. Se entrenaron e implementaron siete modelos en dos dispositivos, evaluando su rendimiento en términos de AP y tiempo de ejecución: la Jetson Nano

de NVIDIA admitió una gama más amplia de arquitecturas y modelos, mientras que el acelerador USB de Google destacó en modelos basados en SSD, ofreciendo un AP más alto y mejor rendimiento en tiempo de ejecución. [Chen et al. \[2023\]](#) también usaron una plataforma móvil para validar su sistema, los resultados experimentales confirman que el sistema de robot de recolección propuesto en este artículo puede realizar con éxito mapeos 2-D en un entorno cuasi-experimental.

Otro de los estudios que integra la Jetson Nano en un robot es [Rama-lingam et al. \[2021\]](#) implementándolo en un robot STetro destaca la fusión de datos de profundidad para mejorar la precisión y la efectividad del algoritmo de detección de contornos, capaz de identificar el primer escalón incluso con variaciones estructurales. Se planea optimizar las capas CNN y ampliar las clases de obstáculos y desechos para mejorar la seguridad y la eficiencia en futuras tareas de limpieza y navegación en escaleras.

Los experimentos llevados a cabo por [Ramôa et al. \[2020\]](#) y [Ramôa et al. \[2021\]](#) no usaron un robot y en ellos se realizaron comparaciones de los métodos propuestos entre sí. Por un lado, [Ramôa et al. \[2020\]](#) entrenaron los algoritmos en una máquina de mayor potencia y luego probados en la Jetson Nano, mostrando que es factible ejecutar estos métodos en dispositivos de baja potencia. Y [Ramôa et al. \[2021\]](#) entrenaron los modelos en máquinas de alto rendimiento y se prueban en una Jetson Nano equipada con una cámara 3D Realsense D435. Por otro lado, [Melo and Barros \[2023\]](#) realizaron experimentos de evaluación que utilizan hitos y patrones de tablero de ajedrez como referencias para comparar y analizar cualitativa y cuantitativamente la precisión y comportamiento del método propuesto.

En los experimentos simulados por [Choe et al. \[2021\]](#) y [Choe et al. \[2023\]](#) se busca validar que placas Jetson obtienen el mejor rendimiento. [Choe et al. \[2021\]](#) realizan los experimentos con Jetson AGX Xavier y Nano usando Complex-YOLOv3 y v4 respectivamente. Los resultados de referencia muestran que Complex-YOLOv4 tiene una precisión (mAP) más alta que v3, pero consume más recursos computacionales, lo que incluye el uso de CPU, GPU, RAM y consumo de energía.

Tabla 2.14: Enfoques de navegación con Jetson Nano

Referencia	Métodos	Simulaciones	Exp. Reales	Confort Social
Pinto de Aguiar et al. [2020]	Jetson Nano de NVIDIA USB Accelerator de Google Deep Learning	SI	SI	NO
Ramôa et al. [2020]	Jetson Nano Clasificación de objetos 3D PointNet Algoritmos de segmentación semántica en tiempo real (FastFCN y FC-HarDNet)	SI	NO	NO
Newman et al. [2020]	NVIDIA Jetson Nano Cámara de profundidad Intel RealSense D435i ROS (Sistema operativo de robot) Algoritmos SLAM	SI	NO	NO
Menon et al. [2020]	NVIDIA Jetson Nano Redes neuronales	SI	NO	SI
Ramôa et al. [2021]	Jetson Nano Algoritmos de segmentación semántica en tiempo real Conjunto de datos en 3D y RGB	SI	NO	NO
Ramalingam et al. [2021]	Robot sTetro Sistema de Percepción Ambiental (EPS) Modelo SSD MobileNet	SI	SI	NO
Choe et al. [2021]	Detección de objetos en 3D Jetson AGX Xavier y Nano Aprendizaje profundo como Complex-YOLOv3 y v4.	SI	NO	
Dosoftei et al. [2021]	Planificación de rutas con Matlab-Simulink NVIDIA Jetson Nano	SI	NO	NO
Azevedo et al. [2021]	Jetson Nano Octomaps en CPU y GPU-Voxels	SI	NO	NO
Kameli and Khan [2022]	NVIDIA Jetson Nano Detector LiDAR	SI	SI	SI
Melo and Barros [2023]	NVIDIA Jetson Nano Red SSD MobileNet v2	SI	NO	NO
Giovagnola et al. [2023]	Jetson Nano AirLoop	SI	NO	NO
Yu et al. [2023]	Jetson Nano Visión por computadora basados en aprendizaje profundo	SI	NO	NO
Choe et al. [2023]	Jetson Nano Jetson TX2 Jetson AGX Xavier Jetson Xavier NX TensorRT Detección objetos 3D	SI	NO	NO
Chen et al. [2023]	Inteligencia artificial de cosas (AIoT) NVIDIA Jetson Nano Algoritmo SLAM	SI	SI	NO

Aunque Complex-YOLOv3-tiny muestra la inferencia más rápida en ambas plataformas Jetson, Jetson Nano tiene limitaciones en el rendimiento con valores de FPS insuficientes para algoritmos como Complex-YOLOv3 y v4. Finalmente [Choe et al. \[2023\]](#) comparan las placas Jetson Nano, TX2, Xavier NX y AGX Xavier. La investigación revela que todas las placas Jetson consumen en promedio más del 80 % de los recursos de la GPU, y destaca el impacto positivo de TensorRT en la optimización de modelos de aprendizaje profundo. Este estudio proporciona fundamentos sólidos para sistemas robóticos que requieran detección de objetos en tiempo real y capacidades de navegación eficientes utilizando plataformas Jetson.

En cuanto a los experimentos realizados por [Newman et al. \[2020\]](#) se logró integrar una cámara en ROS con éxito, aunque se encontraron algunos desafíos de memoria en la Jetson Nano durante pruebas intensivas que afectaron la generación de mapas SLAM. Sin embargo, se solucionó conectándola a una estación de trabajo externa vía Ethernet para transferir datos, aliviando la carga de memoria y mejorando el rendimiento. El estudio de [Dosoftai et al. \[2021\]](#) también realiza simulaciones para validar su desarrollo, incluyendo pruebas de control, adquisición de datos de sensores y generación de informes de rendimiento, evaluando la plataforma para aplicaciones logísticas

En otros experimentos se realizó la validación del sistema mediante la comparación con otros como es el caso de [Yu et al. \[2023\]](#). Comparando los efectos de varios modelos de segmentación semántica existentes, incluida la red de segmentación semántica clásica UNet, la red Deeplabv3 + de alta precisión y tres redes de segmentación semántica ligeras BiseNetv1, BiseNetv2 y ENet. Además, el experimento utilizó TensorRT como biblioteca de aceleración e implementó el modelo en el dispositivo informático de borde Jetson Nano.

Mientras, [Azevedo et al. \[2021\]](#) realizaron una validación con simulación Gazebo, logrando que el UAV navegara en un entorno complejo, manteniendo tiempos de procesamiento bajos tanto en una computadora portátil de alto rendimiento como en Jetson Nano. [Giovagnola et al. \[2023\]](#) realizaron experimentos como la adquisición de datos sintéticos, la detección de objetos y la navegación autónoma en un entorno descono-

cido. Y demostró la posibilidad de interconectar el motor de simulación propuesto con un controlador de vuelo COTS mediante una simulación de planificación de ruta asistida por GPS.

Finalmente, la evaluación de [Menon et al. \[2020\]](#) se centró en la calidad y velocidad de la síntesis de voz, resaltando la capacidad del Jetson Nano para ejecutar algoritmos en paralelo en la GPU. A pesar de lograr una síntesis de voz en tiempo real prometedora en dispositivos perimetrales, se identificaron limitaciones importantes. En las pruebas realizadas en [Kameli and Khan \[2022\]](#) se compararon los mapas generados por el robot utilizando el método propuesto con los mapas previamente creados, evidenciando una mejora significativa en la calidad y los detalles del mapa generado con la nueva configuración, lo que facilita la navegación precisa del robot. Además, se probaron tres casos de uso que demostraron la capacidad del robot para elegir rutas eficientes, evitar atascos en esquinas y reaccionar adecuadamente ante obstáculos inesperados en su camino.

### Confort Social

En cuanto al confort Social [Menon et al. \[2020\]](#) buscan mejorar la síntesis de voz en dispositivos perimetrales, con la intención de ofrecer soluciones más efectivas y personalizadas, especialmente en aplicaciones de voz para robots sociales y en interacciones humano-máquina. Y el desarrollo de [Kameli and Khan \[2022\]](#) permite al robot reaccionar de manera más inteligente ante situaciones inesperadas, mediante la adición de sensores y la integración del Jetson Nano aceleran el proceso de mapeo, mejorando la eficiencia general del robot en su interacción con los residentes.



UNIVERSIDAD  
DE MÁLAGA

## Resultados Experimentales

En esta sección, se presentarán los resultados obtenidos durante el desarrollo de esta tesis. Se describirá en detalle la arquitectura utilizada para implementar el sistema de navegación, junto con las herramientas empleadas y la aplicación informática responsable de calcular las trayectorias.

### 3.1. Simulador y robot

Para llevar a cabo nuestros experimentos, se ha utilizado un robot desarrollado en colaboración con la Universidad de Extremadura, como se muestra en la Figura 3.1. Este robot presenta una estructura cuadrada con cuatro ruedas, y está equipado con dos baterías recargables mediante una entrada de 220 VAC. Además, cuenta con un brazo robótico, aunque no fue utilizado en nuestros experimentos.

La programación de este robot se realizó utilizando el framework RoboComp, desarrollado por la misma universidad (Manso et al. [2010]). RoboComp es un marco de robótica de código abierto que simplifica la creación y modificación de componentes de software que se comunican a través de interfaces públicas. Emplea lenguajes de dominio específicos

como IDSL y CDSL para definir interfaces y especificar la interacción del componente con el entorno. Un generador de código produce fuentes en C++ y/o Python basadas en CMake, que pueden compilarse y ejecutarse sin dificultad. Además, los componentes pueden regenerarse fácilmente para adaptarse a cambios, preservando todo el código específico del usuario mediante un sencillo mecanismo de herencia (Manso [2023]).




Figura 3.1: Robot Completo

Para realizar pruebas con el robot, desarrollamos una aplicación MQTT utilizando este framework, lo que nos permitió controlar el movimiento del robot en el espacio tridimensional, realizar giros e incluso seguir trayectorias predefinidas. También implementamos la posibilidad de controlar el robot mediante un joystick. La Figura 3.2 muestra la interfaz de usuario de la aplicación para controlar el robot, mientras que la Figura 3.3 muestra el programa en ejecución.

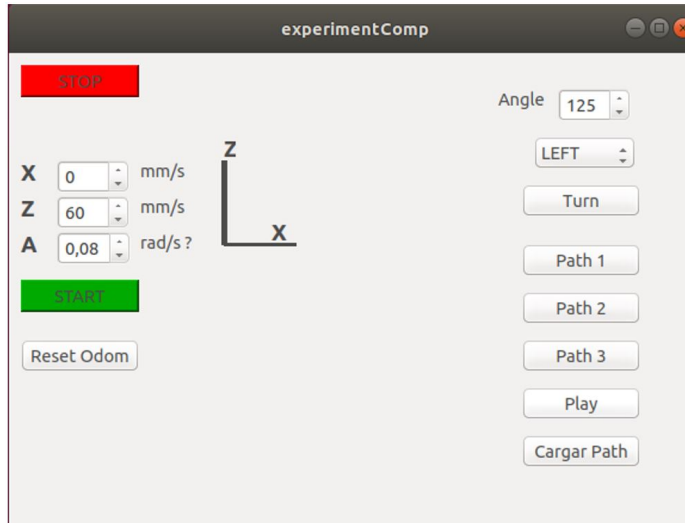


Figura 3.2: Control Remoto MQTT

También se llevó a cabo la implementación de un algoritmo de navegación, que permitiera obtener trayectorias mediante la creación de poblaciones de puntos. Para ello se estudiaron las técnicas de navegación descritas en capítulos anteriores, cómo se detalla en 5.2, 5.3 y 5.4. De forma resumida, el sistema de obtención de trayectorias propuesto consiste en una ecuación de *fitness*, que tiene diferentes factores para determinar qué caminos son más eficientes. Entre todos los que se calculan se eligen los mejores, acorde a una ecuación a la que se denominará de ahora en adelante como “fitness ” y que otorga al camino una puntuación en base a la seguridad, la suavidad de ángulos y la longitud. Así, cada factor es multiplicado por una variable que irá cambiando según los resultados que se obtengan.

$$fitness = 0,6 * security + (0,3/longitud) + (0,1/smoothness); \quad (3.1)$$

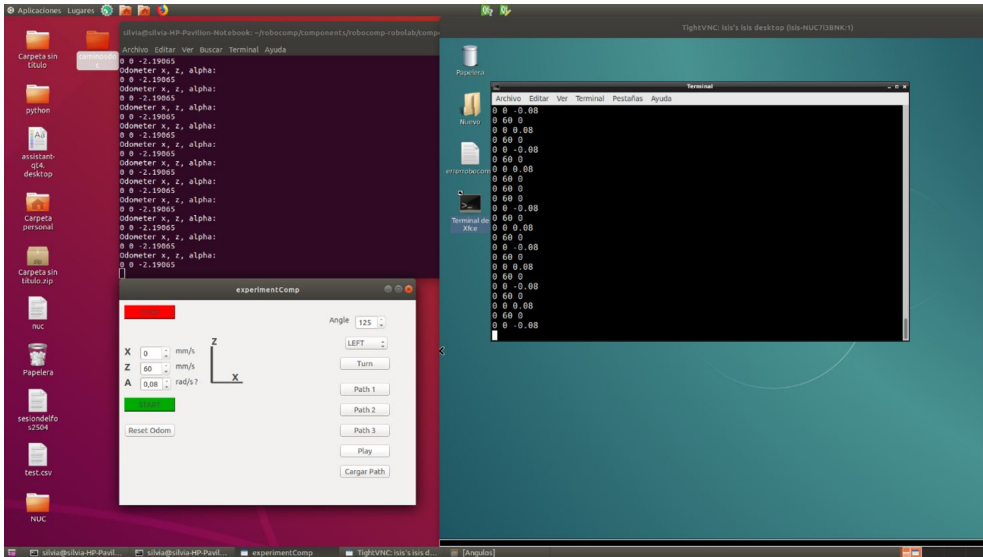


Figura 3.3: Control Remoto MQTT

Para probar este y otros algoritmos de generación de trayectorias, se ha creado en el marco de esta Tesis una aplicación en C para poder realizar simulaciones. Mediante esta aplicación se muestra un mapa donde la escala de grises indica la ocupación de cada celda, así como las poblaciones que se van creando. En el mapa se pueden ir viendo los diferentes puntos de cada población sobre el mapa. Este mapa simula un apartamento dividido en celdas, en el mapa se encuentran representados las paredes y los muebles del apartamento. Las paredes están representadas por celdas negras y los objetos por celdas grises. En el programa, las celdas negras representan una ocupación del 100% y no se pueden crear trayectorias que crucen estas celdas. Mientras que las celdas grises, representan una ocupación del 50%, estas celdas se deben de evitar, aunque si se podría pasar si fuese totalmente necesario. Finalmente, las celdas en blanco estarían totalmente libres 0% de ocupación.

Para generar las trayectorias, se colocan dos puntos sobre el mapa que van desde la esquina superior izquierda donde se coloca el punto rojo que es de partida y el destino que estaría en la esquina inferior derecha representado por un punto azul. El programa obtendrá una población de

puntos y calculará posibles trayectorias del robot para ir desde el punto de partida al punto de destino evitando las celdas negras y en la medida de lo posible las celdas grises. En la figura 3.4 se puede observar la interfaz de este programa.






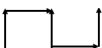



Figura 3.4: Aplicación con el mapa

### 3.1.1. Relación del factor de suavidad con el consumo de energía y la percepción social del movimiento del robot







La suavidad en las trayectorias (el factor *smoothness*) puede ser relevante para la percepción de las trayectorias del robot por parte de las personas en su entorno. Pero este factor también puede influir en el consumo de energía del robot. No se encontró en la literatura ningún estudio que abordara este último aspecto, por lo que se decidió realizarlo tal y como se detalla en 5.1. En esta contribución también se analiza la percepción social de las trayectorias según este factor, buscando trayectorias que optimicen tanto el consumo como la aceptabilidad.

Tabla 3.1: Consumo de batería: Sin caminos curvos.

Prueba	Ruta	Descripción	Movimientos	Consumo	Suavidad
SIERRA 15°		El robot sigue un camino en forma de sierra haciendo 15° con una velocidad constante	TURN -15 0.08 MOVE 70 60 Z TURN 30 0.08 MOVE 70 60 Z TURN -30 0.08	5.45 W	150°
SIERRA 30°		El robot sigue un camino en forma de sierra haciendo 30° con una velocidad constante	TURN -30 0.08 MOVE 70 60 Z TURN 60 0.08 MOVE 70 60 Z TURN -60 0.08	5.9 W	120°
SIERRA 45°		El robot sigue un camino en forma de sierra que hace 45° con una velocidad constante	TURN -45 0.08 MOVE 70 60 Z TURN 90 0.08 MOVE 70 60 Z TURN -90 0.08	6.14 W	90°
SIERRA 60°		El robot sigue un camino en forma de sierra que hace 45° con una velocidad constante	TURN -60 0.08 MOVE 70 60 Z TURN 120 0.08 MOVE 70 60 Z TURN -120 0.08	6.53 W	60°
SIERRA 75°		El robot sigue un camino en forma de sierra que hace 75° con una velocidad constante	TURN -75 0.08 MOVE 70 60 Z TURN 150 0.08 MOVE 70 60 Z TURN -150 0.08	8.93 W	30°
SIERRA (90)°		El robot sigue un camino en forma de sierra que hace 90° con una velocidad constante	TURN -90 0.08 MOVE 70 60 Z TURN 180 0.08 MOVE 70 60 Z TURN -180 0.08	10.12 W	90°
RECTO		El robot sigue un camino recto.		3.76 W	180°

A modo de síntesis de los resultados presentados en el artículo, las tablas 3.1 y 3.2 muestran el consumo de energía para trayectorias basadas en líneas rectas y líneas curvas, respectivamente. Cada fila de la tabla describe una determinada prueba, mostrando un borrador de la ruta seguida, una descripción de la prueba, los movimientos descritos en el archivo que se carga para esa ruta en la aplicación MQTT, el consumo de energía medido por el sistema Arduino y el valor promedio de suavidad (en estas trayectorias de prueba, todos los giros son iguales en cada prueba, por lo que la desviación estándar de suavidad es siempre 0).

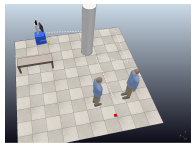
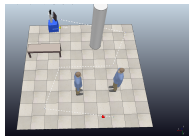
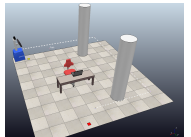

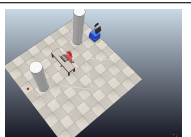
Tabla 3.2: Consumo de batería: Caminos curvos.

Prueba	Ruta	Descripción	Movimientos	Consumo	Suavidad
CURVA CON $V = 0.02$		El robot sigue una trayectoria curva con velocidad = $0,02$ rad/s y sus ruedas giran con un ángulo = $70^\circ$	TURN -45 0.08 ROTATION 70 60 Z 0.02 TURN 45 0.08 ROTATION 70 60 Z 0.02 TURN -90 0.08	5.2 W	34 cm
CURVA CON $V = 0.04$		El robot sigue una trayectoria curva con velocidad = $0,04$ rad/s y sus ruedas giran con un ángulo = $70^\circ$	TURN -45 0.08 ROTATION 70 60 Z 0.04 TURN 45 0.08 ROTATION 70 60 Z 0.04 TURN -90 0.08	4.9 W	36.25 cm
CURVA CON $V = 0.06$		El robot sigue una trayectoria curva con velocidad = $0,06$ rad/s y sus ruedas giran con un ángulo = $70^\circ$	TURN -45 0.08 ROTATION 70 60 Z 0.06 TURN 45 0.08 ROTATION 70 60 Z 0.06 TURN -90 0.08	4.6 W	38.45 cm
CURVA CON $V = 0.08$		El robot sigue una trayectoria curva con velocidad = $0,08$ rad/s y sus ruedas giran con un ángulo = $70^\circ$	TURN -45 0.08 ROTATION 70 60 Z 0.08 TURN 45 0.08 ROTATION 70 60 Z 0.08 TURN -90 0.08	4.49 W	45.57 cm
CURVA CON $V = 1.1$		El robot sigue una trayectoria curva con velocidad = $1,1$ rad/s y sus ruedas giran con un ángulo = $70^\circ$	TURN -45 0.08 ROTATION 55 60 Z 0.1 TURN 45 0.08 ROTATION 55 60 Z 0.1 TURN -90 0.08	1.92 W	58 cm
CURVA CON $V = 1.2$		El robot sigue una trayectoria curva con velocidad = $1,2$ rad/s y sus ruedas giran con un ángulo = $70^\circ$ .	TURN -45 0.08 ROTATION 45 60 Z 0.12 TURN 45 0.08 ROTATION 45 60 Z 0.12 TURN -90 0.08	1.8 W	74.35 cm

Además de evaluar el consumo de las baterías, este artículo busca medir la percepción social del proyecto. Para este fin, se diseñaron encuestas que se distribuyeron entre un grupo de participantes. Estas encuestas presentaban diversas situaciones simuladas utilizando VREP (también conocido como CoopeliaSim), un simulador que se basa en una arquitectura de control distribuido. En VREP, cada objeto o modelo puede ser controlado de manera individual a través de diversos métodos, como scripts incrustados en Python o Lua, complementos en C o C++, clientes API remotos en varios lenguajes, o soluciones personalizadas.

Durante el desarrollo de la tesis, se adquirió experiencia en el uso de este programa para realizar simulaciones y presentar diferentes escenarios a los encuestados. Se modeló un robot similar al utilizado en el laboratorio para recrear las trayectorias descritas en la tabla 3.3, donde se detallan cinco casos de uso, o “escenarios”, preparados en el simulador (CoppeliaRobotics [2023]).

Tabla 3.3: Escenarios.

Escenarios	Descripción	Situaciones	Imagen
1	El robot pasa del punto amarillo al punto rojo. La escena incluye una columna, una mesa y dos personas paradas una frente a la otra. El robot pasará entre ellos.	1.0/1.1/1.2/1.3/1.4	
2	El robot pasa del punto amarillo al punto rojo. La escena incluye una columna, una mesa y dos personas paradas una frente a la otra. El robot pasará alrededor de ellos.	2.1/2.2/2.3/2.4	
3	El robot pasa del punto amarillo al punto rojo. La escena incluye dos columnas y una mesa con una silla. El robot rodea todos los obstáculos.	3.1/3.2/3.3/3.4	
4	El robot va del punto amarillo al punto rojo. La escena incluye dos columnas, una mesa con una silla y una planta. El robot pasa entre los obstáculos.	4.1/4.2/4.3/4.4	
5	El robot pasa del punto amarillo al punto rojo. La escena incluye dos columnas y una mesa con una silla. El robot pasa entre los obstáculos.	5.1/5.2/5.3/5.4	

El análisis de las encuestas se detalla en el capítulo 5.1 de esta Tesis. De forma sintetizada, se puede destacar que las personas encuestadas perciben un comportamiento más natural y no amenazante cuando el robot mantiene una distancia de seguridad a los objetos y personas, y cuando dicha trayectoria se asemeja a la que seguiría una persona. En este caso, los encuestados entendieron que una persona debería tomar el camino más corto para llegar a la meta, y evitaría hacer cambios bruscos en su desplazamiento, tomando por tanto las trayectorias más suaves.

Desde el punto de eficiencia, la ruta más corta y la ruta en la que el robot no tiene una gran rotación tienen los mejores resultados sobre el consumo. Esto se debe a que cuando los robots hacen girar sus ruedas,

consumen energía para realizar estos movimientos. Como muestran los resultados para ambos factores, se podría decir que la suavidad es un factor importante que considerar si se quiere optimizar el consumo de baterías y maximizar la aceptación social.



UNIVERSIDAD  
DE MÁLAGA

## Conclusiones y trabajo futuro

Durante el desarrollo de esta tesis, se ha consolidado y ampliado el conocimiento en diversas áreas fundamentales para la robótica social. Concretamente se ha explorado minuciosamente el estado del arte en el ámbito de la navegación social en entornos cotidianos. Este proceso de investigación reveló una gama diversa de técnicas disponibles para resolver esta tarea, desencadenando la necesidad de clasificarlas para determinar su idoneidad según los objetivos planteados. Debido a la diversidad de técnicas y a los diferentes enfoques de cada autor, resulta complejo homogeneizar los datos para realizar comparaciones directas. Por tanto, se han seleccionado aquellas características que distinguen a cada técnica dentro de su conjunto. Este análisis pormenorizado culminó en la identificación, a partir del trabajo presentado en 5.2, de algoritmos altamente eficientes y productivos en entornos de robots sociales, principalmente aquellos relacionados con el aprendizaje y la predicción. La profundización en estos campos se llevó a cabo a través de los trabajos 5.4 y 5.3. Además, se adquirió una comprensión exhaustiva de diversas técnicas destinadas a mejorar la interacción humano-robot y a fomentar la sociabilidad, abarcando desde el reconocimiento facial hasta el desarrollo de habilidades de imitación y cooperación con seres humanos, aspectos que se revelaron

como especialmente fascinantes y relevantes.

En el ámbito experimental, se destacó la importancia de identificar las bases de datos públicas más adecuadas para la fase de entrenamiento, así como de descubrir las ideas aportadas por múltiples investigadores para llevar a cabo experimentos con robots reales, simplificando esta etapa. Sin embargo, la obtención de voluntarios adecuados, libres de influencias preconcebidas sobre las pruebas a realizar, y la consecución de una diversidad representativa en términos de género, edad y entorno, continúan siendo retos significativos. En este sentido, la propuesta de llevar a cabo pruebas en centros comerciales u otros espacios con estas características se destaca como una opción ideal para abordar estas necesidades de investigación.

Además, se exploró en detalle la técnica del “factor de suavidad” para mejorar el comportamiento social de los robots. Se notó una carencia de investigación en este aspecto específico, lo que motivó y dio origen al trabajo propuesto en 5.1. El presente estudio, evaluó cómo este factor influye tanto en el aspecto social como en el consumo de batería del robot, siendo este último un punto crítico y desafiante en el campo de la robótica.

Asimismo, se identificó un interés sustancial en el desarrollo de nuevas tecnologías de paralelización de algoritmos. La optimización del tiempo de computación para los algoritmos de navegación es una cuestión recurrente, y se reconoció la posibilidad de mejorarlo a través de estas técnicas. Sin embargo, el uso efectivo de la paralelización en algoritmos demanda equipos con requisitos técnicos difíciles de obtener. Por ello, la adquisición y el desarrollo con el equipo Jetson Nano se perfilan como una solución innovadora. Adicionalmente, se constató la escasez de trabajos publicados sobre paralelización y la utilización de estos equipos en el campo de la robótica social.

En consecuencia, se considera que, como trabajo futuro, se debe seguir explorando esta línea de investigación, adaptando los algoritmos desarrollados a este equipo y llevando a cabo pruebas para evaluar las mejoras en los tiempos y las potenciales ventajas que podríamos obtener. Por otra parte, se puede afirmar que la evolución de la navegación en la robótica social será de suma importancia. Esto se debe a que el aprovechamiento de la capacidad de paralelización en los entrenamientos, especialmente para las técnicas de aprendizaje y predicción, promete ser muy benefi-

ciosa, mejorando de forma significativa su rendimiento y apuntalando un futuro más sólido y eficiente para la interacción humano-robot.

## 4.1. Principales Aportaciones

Esta tesis ha contribuido significativamente a la consolidación y expansión del conocimiento en áreas fundamentales de la robótica social, particularmente en lo que respecta a la navegación social en entornos cotidianos. A continuación, se presentan los principales logros y hallazgos alcanzados:

- Se ha identificado una diversa gama de técnicas para resolver la navegación social, clasificándolas según sus objetivos y destacando algoritmos altamente eficientes en entornos de robots sociales, particularmente en el aprendizaje y la predicción.
- La investigación ha profundizado en técnicas para mejorar la interacción humano-robot y fomentar la sociabilidad, desde el reconocimiento facial hasta el desarrollo de habilidades de imitación y cooperación con seres humanos.
- Se ha explorado en detalle la técnica del “factor de suavidad” para mejorar el comportamiento social de los robots, abordando una carencia de investigación en este aspecto específico y evaluando su impacto en el aspecto social y en el consumo de energía.
- La tesis ha identificado un interés sustancial en el desarrollo de nuevas tecnologías de paralelización de algoritmos para mejorar el tiempo de computación en algoritmos de navegación, identificando la escasez de trabajos publicados sobre este tema en el campo de la robótica social.
- Se ha propuesto la adaptación de los algoritmos desarrollados a equipos específicos, como el equipo Jetson Nano, y la realización de pruebas para evaluar las mejoras en los tiempos y las potenciales ventajas que podrían obtenerse, destacando la importancia de seguir explorando esta línea de investigación para un futuro más sólido y eficiente en la interacción humano-robot.



UNIVERSIDAD  
DE MÁLAGA

## Copia de los trabajos

### 5.1. Measuring Smoothness as a Factor for Efficient and Socially Accepted Robot Motion

#### Referencia Bibliográfica:

Silvia Guillén Ruiz, Luis V. Calderita, Alejandro Hidalgo-Paniagua, and Juan P. Bandera Rubio. Measuring smoothness as a factor for efficient and socially accepted robot motion. *Sensors*, 20(23), 2020. ISSN 1424-8220. doi: 10.3390/s20236822. URL <https://www.mdpi.com/1424-8220/20/23/6822>

**Resumen:** Social robots, designed to interact and assist people in social daily life scenarios, require adequate path planning algorithms to navigate autonomously through these environments. These algorithms have not only to find feasible paths but also to consider other requirements, such as optimizing energy consumption or making the robot behave in a socially accepted way. Path planning can be tuned according to a set of factors, being the most common path length, safety, and smoothness. This last factor may have a strong relation with energy consumption and so-

cial acceptability of produced motion, but this possible relation has never been deeply studied. The current paper focuses on performing a double analysis through two experiments. One of them analyzes energy consumption in a real robot for trajectories that use different smoothness factors. The other analyzes social acceptance for different smoothness factors by presenting different simulated situations to different people and collecting their impressions. The results of these experiments show that, in general terms, smoother paths decrease energy consumption and increase acceptability, as far as other key factors, such as distance to people, are fulfilled.

**DOI:** 10.3390/S20236822

## 5.2. Evolution of socially-aware robot navigation

### Referencia Bibliográfica:

Silvia Guillén-Ruiz, Juan Pedro Bandera, Alejandro Hidalgo-Paniagua, and Antonio Bandera. Evolution of socially-aware robot navigation. *Electronics*, 12(7), 2023. ISSN 2079-9292. doi: 10.3390/electronics12071570. URL <https://www.mdpi.com/2079-9292/12/7/1570>.

**Resumen:** In recent years, commercial and research interest in service robots working in everyday environments has grown. These devices are expected to move autonomously in crowded environments, maximizing not only movement efficiency and safety parameters, but also social acceptability. Extending traditional path planning modules with socially aware criteria, while maintaining fast algorithms capable of reacting to human behavior without causing discomfort, can be a complex challenge. Solving this challenge has involved the development of proactive systems that take into account cooperation (and not only interaction) with the people around them, the determined incorporation of approaches based on Deep Learning, or the recent fusion with skills coming from the field of human-robot interaction (speech, touch). This review analyzes approaches to socially aware navigation and classifies them according to the strategies followed by the robot to manage interaction (or cooperation) with humans.

DOI: 10.3390/electronics12071570

### 5.3. Best Practices for Developing Socially-Aware Service Robots with Predictive Techniques to Enhance Social Comfort

#### Referencia Bibliográfica:

Silvia Guillén Ruiz, Juan P. Bandera Rubio, Alejandro Hidalgo-Paniagua, and Antonio Bandera. Best practices for developing socially-aware service robots with predictive techniques to enhance social comfort. In 2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME), pages 1–6, 2023b. doi: 10.1109/ICECCME57830.2023.10252708

**Resumen:** Over the last few years, there has been a growing interest in the development of service robots that can operate in everyday environments, both in commercial and research settings. These robots are designed to work autonomously in busy settings. They aim to move considering efficiency and safety criteria, but also social acceptance. Incorporating social awareness criteria into the conventional path planning modules, while maintaining speedy algorithms that can adjust to human behavior without causing discomfort, presents a significant challenge. To overcome this challenge, predictive methods have become increasingly relevant. It is also important to establish guidelines for developing methods that promote social acceptance. This includes considering factors such as cultural differences, ethical considerations, and user feedback to ensure that the robots are accepted and trusted by society. This paper compares different state-of-the-art predictive methods in the field of socially aware robot navigation. It also proposes guidelines to evaluate and train these methods, taking into account social acceptance as a key requisite to successfully deploy service robots in daily life settings.

DOI: 10.1109/ICECCME57830.2023.10252708

## 5.4. Exploring Learning Techniques for Developing Socially-Aware Service Robots: Best Practices for Social Comfort

### Referencia Bibliográfica:

Silvia Guillén Ruiz, Juan P. Bandera Rubio, Alejandro Hidalgo-Paniagua, and Antonio Bandera. Exploring Learning Techniques for Developing Socially-Aware Service Robots: Best Practices for Social Comfort, chapter Volume 375: Artificial Intelligence Research and Development. *Frontiers in Artificial Intelligence and Applications*, 2023a. doi: 10.3233/FAIA230692.

**Resumen:** In the past few years, there has been an increase in commercial and research focus on service robots operating in daily surroundings. These machines are anticipated to function independently in busy settings, enhancing movement efficiency and safety parameters, as well as social acceptance. Expanding conventional path planning modules to include socially aware criteria, while sustaining speedy algorithms that can adapt to human behavior without causing distress, presents a significant challenge. To address this challenge, learning methods have gained significant relevance. Among the various techniques, deep reinforcement learning, end-to-end, and inverse reinforcement learning have been the most promising. However, it is difficult to determine which techniques are superior, and sometimes, developers may obtain poor results due to inadequate data or experimental procedures during the learning stage. Therefore, it is essential to evaluate and discuss the best practices and options for an effective training stage that can improve results. As we are specifically referring to social robots, the evaluation of results should take into consideration social comfort as a key factor.

**DOI:** 10.3233/FAIA230692

## Bibliografía

- Shreyas Madhav A V and B Rajesh Kanna. Parallel fpfh slam for aerial vehicles. In *2021 IEEE Conference on Norbert Wiener in the 21st Century (21CW)*, pages 1–4, 2021. doi: 10.1109/21CW48944.2021.9532582.
- Martín Abadi, Paul Barham, Jianmin Chen, Zhifeng Chen, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Geoffrey Irving, Michael Isard, Manjunath Kudlur, Josh Levenberg, Rajat Monga, Sherry Moore, Derek Gordon Murray, Benoit Steiner, Paul A. Tucker, Vijay Vasudevan, Pete Warden, Martin Wicke, Yuan Yu, and Xiaoqiang Zhang. Tensorflow: A system for large-scale machine learning. *CoRR*, abs/1605.08695, 2016. URL <http://arxiv.org/abs/1605.08695>.
- J. Abdi et al. Scoping review on the use of socially assistive robot technology in elderly care. *S. BMJ Open.*, 8, 2018.
- Joshua Achiam, David Held, Aviv Tamar, and Pieter Abbeel. Constrained policy optimization. In *34th International Conference on Machine Learning (ICML)*, volume 70, page 22–31. JMLR.org, 2017.
- Faez Ahmed and Kalyanmoy Deb. Multi-objective optimal path planning using elitist non-dominated sorting genetic algorithms. *Soft Computing*,

- 17:1283–1299, 2013. ISSN 1433-7479. doi: 10.1007/s00500-012-0964-8. URL <https://doi.org/10.1007/s00500-012-0964-8>.
- Arash Ajoudani, Andrea Maria Zanchettin, Serena Ivaldi, Alin Albu-Schäffer, Kazuhiro Kosuge, and Oussama Khatib. Progress and prospects of the human-robot collaboration. *Autonomous Robots*, 42, 06 2018. doi: 10.1007/s10514-017-9677-2.
- Alexandre Alahi, Kratarth Goel, Vignesh Ramanathan, Alexandre Robicquet, Li Fei-Fei, and Silvio Savarese. Social lstm: Human trajectory prediction in crowded spaces. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 961–971, 2016. doi: 10.1109/CVPR.2016.110.
- Saleh Alarabi, Chaomin Luo, and Michael Santora. A prm approach to path planning with obstacle avoidance of an autonomous robot. In *2022 8th International Conference on Automation, Robotics and Applications (ICARA)*, pages 76–80, 2022. doi: 10.1109/ICARA55094.2022.9738559.
- Georges Aoude, Brandon Luders, Joshua Mason Joseph, Nicholas Roy, and Jonathan P. How. Probabilistically safe motion planning to avoid dynamic obstacles with uncertain motion patterns. *Autonomous Robots*, 35:51–76, 2013.
- Filipe Azevedo, Pranjali Shinde, Luís Santos, Jorge Mendes, Filipe N. Santos, and Hélio Mendonça. Parallelization of a vine trunk detection algorithm for a real time robot localization system. In *2019 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)*, pages 1–6, 2019. doi: 10.1109/ICARSC.2019.8733644.
- Filipe Alberto Sampaio Azevedo. *Paralelização de Algoritmos de Processamento de Imagem em Contexto de Vinha*. PhD thesis, FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO, 2018. URL <https://hdl.handle.net/10216/113979>.
- Fábio Azevedo, Jaime Cardoso, André Ferreira, Tiago Fernandes, Miguel Moreira, and Luis Campos. Efficient reactive obstacle avoidance using spirals for escape. *Drones*, 5, 06 2021. doi: 10.3390/drones5020051.

- Andrej Babinec, František Duchoň, Martin Dekan, Zuzana Mikulová, and Ladislav Jurišica. Vector field histogram\* with look-ahead tree extension dependent on time variable environment. *Transactions of the Institute of Measurement and Control*, 40(4):1250–1264, 2018. doi: 10.1177/0142331216678062.
- Bobak H. Baghi and Gregory Dudek. Sample efficient social navigation using inverse reinforcement learning. *CoRR*, abs/2106.10318, 2021. URL <https://arxiv.org/abs/2106.10318>.
- M. Bennewitz, W. Burgard, and S. Thrun. Learning motion patterns of persons for mobile service robots. In *2002 IEEE International Conference on Robotics and Automation (ICRA)*, volume 4, pages 3601–3606 vol.4, 2002. doi: 10.1109/ROBOT.2002.1014268.
- Aniket Bera, Sujeong Kim, Tanmay Randhavane, Srihari Pratapa, and Dinesh Manocha. Gimp- realtime pedestrian path prediction using global and local movement patterns. In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 5528–5535, 2016. doi: 10.1109/ICRA.2016.7487768.
- J. Borenstein and Y. Koren. The vector field histogram-fast obstacle avoidance for mobile robots. *IEEE Transactions on Robotics and Automation*, 7(3):278–288, 1991. doi: 10.1109/70.88137.
- Darko Bozhinoski and Jasper Wijkhuizen. Context-based navigation for ground mobile robot in semi-structured indoor environment. In *2021 Fifth IEEE International Conference on Robotic Computing (IRC)*, pages 82–86, 2021. doi: 10.1109/IRC52146.2021.00019.
- Pablo Bustos, Luis Jesús Manso, Antonio Bandera, Juan Pedro Bandera Rubio, Ismael García-Varea, and Jesus Martínez-Gómez. The CORTEX cognitive robotics architecture: Use cases. *Cogn. Syst. Res.*, 55:107–123, 2019.
- Luis Vicente Calderita, Luis J Manso, Pablo Bustos, Cristina Suárez-Mejías, Fernando Fernández, and Antonio Bandera. Therapist: Towards an autonomous socially interactive robot for motor and neurorehabilitation therapies for children. *JMIR Rehabil Assist Tech-*

- nol*, 1:e1, 10 2014. ISSN 2369-2529. doi: 10.2196/rehab.3151. URL <http://rehab.jmir.org/2014/1/e1/>.
- A. Castro-González, Masahiro Shiomi, Takayuki Kanda, M. A. Salichs, Hiroshi Ishiguro, and Norihiro Hagita. Position prediction in crossing behaviors. In *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 5430–5437, 2010. doi: 10.1109/IROS.2010.5651144.
- Konstantinos Charalampous, Ioannis Kostavelis, and Antonios Gasteratos. Recent trends in social aware robot navigation: A survey. *Robotics and Autonomous Systems*, 93:85–104, 2017. ISSN 0921-8890. doi: <https://doi.org/10.1016/j.robot.2017.03.002>. URL <https://www.sciencedirect.com/science/article/pii/S0921889016302287>.
- Changan Chen, Yuejiang Liu, Sven Kreiss, and Alexandre Alahi. Crowd-robot interaction: Crowd-aware robot navigation with attention-based deep reinforcement learning. In *2019 International Conference on Robotics and Automation (ICRA)*, pages 6015–6022, 2019. doi: 10.1109/ICRA.2019.8794134.
- Liang-Bi Chen, Xiang-Rui Huang, and Wei-Han Chen. Design and implementation of an artificial intelligence of things-based autonomous mobile robot system for pitaya harvesting. *IEEE Sensors Journal*, 23(12):13220–13235, 2023. doi: 10.1109/JSEN.2023.3270844.
- Pengzhan Chen, Xiaoyan Zhang, Xiaoyue Chen, and Mengchao Liu. Path planning strategy for vehicle navigation based on user habits. *Applied Sciences*, 8:407, 2018a. doi: 10.3390/app8030407.
- Yu Fan Chen, Michael Everett, Miao Liu, and Jonathan P. How. Socially aware motion planning with deep reinforcement learning. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 1343–1350, 2017a. doi: 10.1109/IROS.2017.8202312.
- Yu Fan Chen, Miao Liu, Michael Everett, and Jonathan P. How. Decentralized non-communicating multiagent collision avoidance with

- deep reinforcement learning. In *2017 IEEE International Conference on Robotics and Automation (ICRA)*, pages 285–292, 2017b. doi: 10.1109/ICRA.2017.7989037.
- Yujing Chen, Fenghua Zhao, and Yunjiang Lou. Interactive model predictive control for robot navigation in dense crowds. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(4):2289–2301, 2022. doi: 10.1109/TSMC.2020.3048964.
- Yuying Chen, Congcong Liu, Bertram E. Shi, and Ming Liu. Robot navigation in crowds by graph convolutional networks with attention learned from human gaze. *IEEE Robotics and Automation Letters*, 5(2): 2754–2761, 2020. doi: 10.1109/LRA.2020.2972868.
- Zhixian Chen, Chao Song, Yuanyuan Yang, Baoliang Zhao, Ying Hu, Shou Bin Liu, and Jianwei Zhang. Robot navigation based on human trajectory prediction and multiple travel modes. *Applied Sciences*, 8(11), 2018b. doi: 10.3390/app8112205.
- S.F. Chik, Yeong Fai, Eileen Su, T.Y. Lim, Yuvashini Subramaniam, and P.J.H. Chin. A review of social-aware navigation frameworks for service robots in dynamic human environments. *Journal of Telecommunication, Electronic and Computer Engineering*, 8:41–50, 01 2016.
- Chungjae Choe, Minjae Choe, and Sungwook Jung. Run your 3d object detector on nvidia jetson platforms:a benchmark analysis. *Sensors*, 23: 4005, 04 2023. doi: 10.3390/s23084005.
- Minjae Choe, Sukjun Lee, Nak-Myoung Sung, Sungwook Jung, and Chungjae Choe. Benchmark analysis of deep learning-based 3d object detectors on nvidia jetson platforms. In *2021 International Conference on Information and Communication Technology Convergence (ICTC)*, pages 10–12, 2021. doi: 10.1109/ICTC52510.2021.9621072.
- Jinyoung Choi, Christopher Dance, Jung-eun Kim, Kyung-sik Park, Jaehun Han, Joonho Seo, and Minsu Kim. Fast adaptation of deep reinforcement learning-based navigation skills to human preference. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pages 3363–3370, 2020. doi: 10.1109/ICRA40945.2020.9197159.

- Han-Jung Chou, Pei-Li Kuo, and Jing-Sin Liu. Numerical streamline path planning based on log-space harmonic potential function: A simulation study. In *2017 IEEE International Conference on Real-time Computing and Robotics (RCAR)*, pages 535–542, 2017. doi: 10.1109/RCAR.2017.8311918.
- Lorenzo Cominelli, Nicola Carbonaro, Daniele Mazzei, Roberto Garofalo, Alessandro Tognetti, and Danilo de rossi. A multimodal perception framework for users emotional state assessment in social robotics. *Future Internet*, 9:42, 08 2017. doi: 10.3390/fi9030042.
- CoppeliaRobotics. Robot simulator coppeliasim. Technical report, CoppeliaRobotics, 2023. URL <https://coppeliarobotics.com>.
- Sean Curtis, Stephen J. Guy, Basim Zafar, and Dinesh Manocha. Virtual tawaf: A velocity-space-based solution for simulating heterogeneous behavior in dense crowds. In *Modeling, Simulation and Visual Analysis of Crowds*, volume 11 of *The International Series in Video Computing*, pages 181–209. Springer, 2013.
- Kerstin Dautenhahn, Michael L Walters, Sarah Woods, Kheng Lee Koay, Chrystopher L Nehaniv, Emrah Akin Sisbot, Rachid Alami, and Thierry Siméon. How may i serve you?: a robot companion approaching a seated person in a helping context. In Michael A Goodrich, Alan C Schultz, and David J Bruemmer, editors, *Proceedings of the 1st {ACM} {SIGCHI/SIGART} Conference on Human-Robot Interaction*, pages 172–179. ACM, 2006. doi: 10.1145/1121241.1121272. URL <https://doi.org/10.1145/1121241.1121272>.
- K Deb, A Pratap, S Agarwal, and T Meyarivan. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, 6:182–197, 2002. doi: 10.1109/4235.996017.
- C. Dosoftei, Alexandru Popovici, Sacaleanu Petru Razvan, Paul-Marcelin Gherghel, and Cristina Budaciu. Hardware in the loop topology for an omnidirectional mobile robot using matlab in a robot operating system environment. *Symmetry*, 13:969, 05 2021. doi: 10.3390/sym13060969.

- Daniel Drake, Scott Koziol, and Eugene Chabot. Mobile robot path planning with a moving goal. *IEEE Access*, 6:12800–12814, 2018. ISSN 2169-3536.
- Noel E. Du Toit and Joel W. Burdick. Robot motion planning in dynamic, uncertain environments. *IEEE Transactions on Robotics*, 28(1):101–115, 2012. doi: 10.1109/TRO.2011.2166435.
- Daniel Dugas, Juan Nieto, Roland Siegwart, and Jen Jen Chung. Ian: Multi-behavior navigation planning for robots in real, crowded environments. In *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 11368–11375, 2020. doi: 10.1109/IROS45743.2020.9341457.
- Daniel Dugas, Juan Nieto, Roland Siegwart, and Jen Jen Chung. Navrep: Unsupervised representations for reinforcement learning of robot navigation in dynamic human environments. In *2021 IEEE International Conference on Robotics and Automation (ICRA)*, pages 7829–7835, 2021. doi: 10.1109/ICRA48506.2021.9560951.
- Michael Everett, Yu Fan Chen, and Jonathan P. How. Motion planning among dynamic, decision-making agents with deep reinforcement learning. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3052–3059, 2018. doi: 10.1109/IROS.2018.8593871.
- Tingxiang Fan, Xinjing Cheng, Jia Pan, Dinesh Manocha, and Ruigang Yang. Crowdmove: Autonomous mapless navigation in crowded scenarios. *CoRR*, abs/1807.07870, 2018. URL <http://arxiv.org/abs/1807.07870>.
- Francesco Farina, Daniele Fontanelli, Andrea Garulli, Antonio Giannitrapani, and Domenico Prattichizzo. When helbing meets laumond: The headed social force model. In *2016 IEEE 55th Conference on Decision and Control (CDC)*, pages 3548–3553, 2016. doi: 10.1109/CDC.2016.7798802.

- Gonzalo Ferrer and A. Sanfeliu. Bayesian human motion intentionality prediction in urban environments. *Pattern Recognition Letters*, 44: 134–140, 07 2014a. doi: 10.1016/j.patrec.2013.08.013.
- Gonzalo Ferrer and A. Sanfeliu. Proactive kinodynamic planning using the extended social force model and human motion prediction in urban environments. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 09 2014b. doi: 10.1109/IROS.2014.6942788.
- Gonzalo Ferrer and Alberto Sanfeliu. Comparative analysis of human motion trajectory prediction using minimum variance curvature. In *2011 6th ACM/IEEE International Conference on Human-Robot Interaction (HRI)*, pages 135–136, 2011. doi: 10.1145/1957656.1957698.
- Gonzalo Ferrer, Anaís Garrell, and Alberto Sanfeliu. Social-aware robot navigation in urban environments. In *2013 European Conference on Mobile Robots (ECMR)*, pages 331–336, 2013a. doi: 10.1109/ECMR.2013.6698863.
- Gonzalo Ferrer, Anaís Garrell, and Alberto Sanfeliu. Robot companion: A social-force based approach with human awareness-navigation in crowded environments. In *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 1688–1694, 2013b. doi: 10.1109/IROS.2013.6696576.
- Gonzalo Ferrer, Anaís Zulueta, Fernando Cotarelo, and A. Sanfeliu. Robot social-aware navigation framework to accompany people walking side-by-side. *Autonomous Robots*, 41, 04 2017. doi: 10.1007/s10514-016-9584-y.
- P. Fiorini and Z. Shiller. Motion planning in dynamic environments using the relative velocity paradigm. In *1993 IEEE International Conference on Robotics and Automation (ICRA)*, pages 560–565 vol.1, 1993. doi: 10.1109/ROBOT.1993.292038.
- A. Foka and P. Trahanias. Probabilistic autonomous robot navigation in dynamic environments with human motion prediction. *I. J. Soc. Robot.*, 2:79–94, 2010. doi: 10.1007/s12369-009-0037-z.

- Anthony Francis, Aleksandra Faust, Hao-Tien Lewis Chiang, Jasmine Hsu, J. Chase Kew, Marek Fiser, and Tsang-Wei Edward Lee. Long-range indoor navigation with prm-rl. *IEEE Transactions on Robotics*, 36(4):1115–1134, 2020. doi: 10.1109/TRO.2020.2975428.
- Renan Salles De Freitas, Adrián Romero-Garcés, Rebeca Marfil, Cristina Vicente-Chicote, Jesus Martinez Cruz, Juan F. Inglés-Romero, and Antonio Bandera. *QoS Metrics-in-the-Loop for Better Robot Navigation*, volume 1285 of *Advances in Intelligent Systems and Computing*, pages 94–108. Springer, 2020.
- Chiara Fulgenzi, Anne Spalanzani, and Christian Laugier. Dynamic obstacle avoidance in uncertain environment combining pvos and occupancy grid. In *2007 IEEE International Conference on Robotics and Automation (ICRA)*, pages 1610–1616, 2007. doi: 10.1109/ROBOT.2007.363554.
- Tomonari Furukawa, Benjamin Lavis, and Hugh F. Durrant-Whyte. Parallel grid-based recursive bayesian estimation using gpu for real-time autonomous navigation. In *2010 IEEE International Conference on Robotics and Automation*, pages 316–321, 2010. doi: 10.1109/ROBOT.2010.5509396.
- Jorge Gallego Pérez, Manja Lohse, and Vanessa Evers. Robots for the psychological wellbeing of the elderly. In *EventHRI 2014 Workshop on Socially Assistive Robots for the Aging Population: Are we trapped in Stereotypes?*, March 2014. HRI 2014 Workshop on Socially Assistive Robots for the Aging Population : Are we trapped in Stereotypes? ; Conference date: 03-03-2014 Through 03-03-2014.
- Wei Gao, David Hsu, Wee Sun Lee, Shengmei Shen, and Karthikk Subramanian. Intention-net: Integrating planning and deep learning for goal-directed autonomous navigation. In *Conference on Robot Learning*, 2017.
- Xingyuan Gao, Shiyong Sun, Xiaoguang Zhao, and Min Tan. Learning to navigate in human environments via deep reinforcement learning. In

- Tom Gedeon, Kok Wai Wong, and Minhoo Lee, editors, *Neural Information Processing*, pages 418–429, Cham, 2019. Springer International Publishing.
- Yuxiang Gao and Chien-Ming Huang. Evaluation of socially-aware robot navigation. *Frontiers in Robotics and AI*, 8, 2022. ISSN 2296-9144. doi: 10.3389/frobt.2021.721317. URL <https://www.frontiersin.org/articles/10.3389/frobt.2021.721317>.
- S Geetha, G M Chitra, and V Jayalakshmi. Multi objective mobile robot path planning based on hybrid algorithm. In *2011 3rd International Conference on Electronics Computer Technology*, volume 6, pages 251–255. IEEE, 2011. ISBN 9781424486786.
- Brian Gerkey and Kurt Konolige. Planning and control in unstructured terrain. *Computer Science*, 01 2008.
- Oscar Gil, Anaís Garrell, and Alberto Sanfeliu. Social robot navigation tasks: Combining machine learning techniques and social force model. *Sensors*, 21(21), 2021. ISSN 1424-8220. doi: 10.3390/s21217087. URL <https://www.mdpi.com/1424-8220/21/21/7087>.
- Jessica Giovagnola, Juan B. Moro Megías, Miguel Molina Fernández, Manuel Pegalajar Cuéllar, and Diego P. Morales Santos. Airloop: A simulation framework for testing of uav services. *IEEE Access*, 11:23309–23325, 2023. doi: 10.1109/ACCESS.2023.3253788.
- Matthew Gladden. Who will be the members of society 5.0? towards an anthropology of technologically posthumanized future societies. *Society 5.0: Innovation, Uncertainty and Social Sciences*, 05 2019. doi: 10.3390/socsci8050148.
- Wenyong Gong, Xiaohua Xie, and Yong-Jin Liu. Human experience-inspired path planning for robots. *International Journal of Advanced Robotic Systems*, 15, 2018. ISSN 17298806.
- Martin Gromniak and Jonas Stenzel. Deep reinforcement learning for mobile robot navigation. In *2019 4th Asia-Pacific Conference on Intelligent Robot Systems (ACIRS)*, pages 68–73, 2019. doi: 10.1109/ACIRS.2019.8935944.

- Feng Guo, Hongrui Wang, and Yantao Tian. Multi-objective path planning for unrestricted mobile. In *2009 IEEE International Conference on Automation and Logistics*, pages 1046–1051. IEEE, 2009. ISBN 9781424447947.
- Jingyu He, Yao Xiao, Corina Bogdan, Shahin Nazarian, and Paul Bogdan. A design methodology for energy-aware processing in unmanned aerial vehicles. *ACM Trans. Des. Autom. Electron. Syst.*, 27(1), sep 2021. ISSN 1084-4309. doi: 10.1145/3470451. URL <https://doi.org/10.1145/3470451>.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 770–778, 2016. doi: 10.1109/CVPR.2016.90.
- Dirk Helbing and Peter Molnar. Social force model for pedestrian dynamics. *Physical Review E*, 51, 05 1995. doi: 10.1103/PhysRevE.51.4282.
- Dominik Henrich. Fast motion planning by parallel processing - a review. *JOURNAL OF INTELLIGENT AND ROBOTIC SYSTEMS*, 1997. URL <https://nbn-resolving.de/urn:nbn:de:hbz:386-kluedo-9642>.
- Peter Henry, Christian Vollmer, Brian Ferris, and Dieter Fox. Learning to navigate through crowded environments. In *2010 IEEE International Conference on Robotics and Automation (ICRA)*, pages 981–986, 2010. doi: 10.1109/ROBOT.2010.5509772.
- A Hidalgo-Paniagua, M A Vega-Rodríguez, J Ferruz, and N Pavón. Mosfla-mrpp: Multi-objectiveshuffled frog-leapingalgorithm. *Pavn Solving the multiobjective path planning problem in mobile Soft Computing*, pages 122–136, 2015. doi: <https://doi.org/10.1016/j.engappai.2015.05.011>. [Original String]:A. Hidalgo-Paniagua, M. A. Vega-Rodríguez, J. Ferruz and N. Pavón, "Solving the multi-objective path planning problem in mobile,"*Soft Computing*, 2015.
- A Hidalgo-Paniagua, M A Vega-Rodríguez, and J Ferruz. Applying the movns (multi-objective variable neighborhood search) algorithm to sol-

- ve the path planning problem in mobile robotics. *Expert Systems With Applications*, pages 20–35, 2016. doi: <https://doi.org/10.1016/j.eswa.2016.03.035>. [Original String]:A. Hidalgo-Paniagua, M. A. Vega-Rodríguez and J. Ferruz, .^Applying the MOVNS (multi-objective variable neighborhood search) algorithm to solve the path planning problem in mobile robotics,.<sup>Ex</sup>pert Systems With Applications, pp. 20-35, 2016.
- Alejandro Hidalgo-Paniagua, Miguel A. Vega-Rodríguez, Joaquín Ferruz, and Nieves Pavón. Solving the multi-objective path planning problem in mobile robotics with a firefly-based approach. *Soft Computing*, 21:949–964, 2017. ISSN 14337479. doi: 10.1007/s00500-015-1825-z. [Original String]:A. Hidalgo-Paniagua, M. A. Vega-Rodríguez, N. Pavón and J. Ferruz, .^ Comparative Study of Parallel RANSAC Implementations in 3D Space, *International Journal of Parallel Programming*, 2014.
- Zhengxi Hu, Yingli Zhao, Sen Zhang, Lei Zhou, and Jingtai Liu. Crowd-comfort robot navigation among dynamic environment based on social-stressed deep reinforcement learning. *International Journal of Social Robotics*, 14, 06 2022. doi: 10.1007/s12369-021-00838-x.
- Marcel Häselich, Simon Eggert, and Dietrich Paulus. Parallelized energy minimization for real-time markov random field terrain classification in natural environments. In *2012 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pages 1823–1828, 2012. doi: 10.1109/ROBIO.2012.6491233.
- A. Iglesias, R. Viciano, J.M. Pérez-Lorenzo, K. Lan Hing Ting, A. Tudela, R. Marfil, Á. Dueñas, and J.P. Bandera. Towards long term acceptance of socially assistive robots in retirement houses: use case definition. In *2020 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)*, pages 134–139, 2020.
- Francisco Igual, Guillermo Botella, Carlos Garcia, Manuel Prieto Matias, and Francisco Tirado. Robust motion estimation on a low-power multi-core dsp. *EURASIP Journal on Advances in Signal Processing*, 2013, 12 2013. doi: 10.1186/1687-6180-2013-99.
- Tetsushi Ikeda, Yoshihiro Chigodo, Daniel Rea, Francesco Zanlungo, Masahiro Shiomi, and Takayuki Kanda. Modeling and prediction of pe-

- destrian behavior based on the sub-goal concept. In *Robotics: Science and Systems VIII*, 01 2013. doi: 10.15607/RSS.2012.VIII.018.
- B. Ilijoski, N. Ackovska, T. Zorcec, and Z Popeska. Extending robot therapy for children with autism using mobile and web application. *Sensors*, 2022.
- Welcome to the *IFR Press Conference*, 2020. International Federation of Robotics. URL [https://ifr.org/downloads/press2018/Presentation\\_WR\\_2020.pdf](https://ifr.org/downloads/press2018/Presentation_WR_2020.pdf).
- Joshua Mason Joseph, Finale Doshi-Velez, Albert S. Huang, and Nicholas Roy. A bayesian nonparametric approach to modeling motion patterns. *Autonomous Robots*, 31:383–400, 2011.
- Hu Jun and Zhu Qingbao. Multi-objective mobile robot path planning based on improved genetic algorithm. In *2010 International Conference on Intelligent Computation Technology and Automation*, volume 2, pages 752–756. IEEE, 2010. ISBN 9781424472796.
- Maria Kabtoul, Anne Spalanzani, and Philippe Martinet. Towards proactive navigation: A pedestrian-vehicle cooperation based behavioral model. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pages 6958–6964, 2020. doi: 10.1109/ICRA40945.2020.9196669.
- Maria Kabtoul, Anne Spalanzani, and Philippe Martinet. Proactive and smooth maneuvering for navigation around pedestrians. In *2022 International Conference on Robotics and Automation (ICRA)*, pages 4723–4729, 2022. doi: 10.1109/ICRA46639.2022.9812255.
- T. Kameli, M. Zuraes and A. Khan. Improved navigation for social robots through process offloading. In *International Conference on Computational Science and Computational Intelligence (CSCI)*, 2022.
- Mitsuhiro Kamezaki, Yusuke Tsuburaya, Taichi Kanada, Michiaki Hirayama, and Shigeki Sugano. Reactive, proactive, and inducible proximal crowd robot navigation method based on inducible social force model. *IEEE Robotics and Automation Letters*, 7(2):3922–3929, 2022. doi: 10.1109/LRA.2022.3148451.

- Y Kanayama and B I Hartman. Smooth local path planning for autonomous vehicles. In *Proceedings, 1989 International Conference on Robotics and Automation*, volume 3, pages 1265–1270 vol.3. IEEE Comput. Soc. Press, 1989. ISBN 0818619384.
- Mubbasir Kapadia, Shawn Singh, William Hewlett, Glenn Reinman, and Petros Faloutsos. Parallelized egocentric fields for autonomous navigation. *The Visual Computer*, 28, 12 2012. doi: 10.1007/s00371-011-0669-5.
- Mustapha Derras Karine Lan Hing Ting and Dimitri Voilmy. Designing human-robot interaction for dependent elderlies: a living lab approach. In *Proceedings of the 32nd International BCS Human Computer Interaction Conference (HCI)*, 2018.
- Samuel Karlsson, Anton Koval, Christoforos Kanellakis, Ali-akbar Aghamohammadi, and George Nikolakopoulos.  $D^*_{+s}$ : A generic platform-agnostic and risk-aware path planing framework with an expandable grid. *CoRR*, abs/2112.05563, 2021. URL <https://arxiv.org/abs/2112.05563>.
- Richelle Keizer, Lex van Velsen, Mathieu Moncharmont, Brigitte Riche, Nadir Ammour, Susanna del Signore, Gianluca Zia, Hermie Hermens, and Aurèle N’Dja. Using socially assistive robots for monitoring and preventing frailty among older adults: a study on usability and user experience challenges. *Health and Technology*, 9, 04 2019. doi: 10.1007/s12553-019-00320-9.
- J Kennedy and R Eberhart. Particle swarm optimization. In *Proceedings of ICNN’95 - International Conference on Neural Networks*, volume 4, pages 1942–1948 vol.4, 11 1995. doi: 10.1109/ICNN.1995.488968.
- Said Kerrache and Habiba Drias. Extending real-time heuristic search part ii: Heterogeneous multi-agent systems. *Multiagent Grid Syst.*, 2 (3):289–298, may 2006. ISSN 1574-1702.
- Harmish Khambhaita and Rachid Alami. A human-robot cooperative navigation planner. In *2017 ACM/IEEE International Conference*, pages 161–162, 03 2017. doi: 10.1145/3029798.3038374.

- O. Khatib. Real-time obstacle avoidance for manipulators and mobile robots. In *1985 IEEE International Conference on Robotics and Automation (ICRA)*, volume 2, pages 500–505, 1985. doi: 10.1109/ROBOT.1985.1087247.
- Beomjoon Kim and Joelle Pineau. Socially adaptive path planning in human environments using inverse reinforcement learning. *International Journal of Social Robotics*, 8:51–66, 01 2016. doi: 10.1007/s12369-015-0310-2.
- Sujeong Kim, Stephen J. Guy, Wenxi Liu, David Wilkie, Rynson W.H. Lau, Ming C. Lin, and Dinesh Manocha. Brvo: Predicting pedestrian trajectories using velocity-space reasoning. *The International Journal of Robotics Research*, 34(2):201–217, 2015. doi: 10.1177/0278364914555543.
- B. Kluge and E. Prassler. Reflective navigation: individual behaviors and group behaviors. In *2004 IEEE International Conference on Robotics and Automation (ICRA)*, volume 4, pages 4172–4177 Vol.4, 2004. doi: 10.1109/ROBOT.2004.1308926.
- Jaromir Konecny, Michal Prauzek, and Jakub Hlavica. Icp algorithm in mobile robot navigation: Analysis of computational demands in embedded solutions\*\*this work was supported by the project sp2016/162, development of algorithms and systems for control, measurement and safety applications ii of student grant system, vsb-tu ostrava. *IFAC-PapersOnLine*, 49(25):396–400, 2016. ISSN 2405-8963. doi: <https://doi.org/10.1016/j.ifacol.2016.12.079>. URL <https://www.sciencedirect.com/science/article/pii/S2405896316327173>. 14th IFAC Conference on Programmable Devices and Embedded Systems PDES 2016.
- I. Kotseruba and J.K. Tsotsos. 40 years of cognitive architectures: core cognitive abilities and practical applications. In *Artif Intell Rev* 53, 2020.
- Henrik Kretschmar, Markus Spies, Christoph Sprunk, and Wolfram Burgard. Socially compliant mobile robot navigation via inverse reinforcement learning. *The International Journal of Robotics Research*, 35(11): 1289–1307, 2016. doi: 10.1177/0278364915619772.

- Dominik Krupke, Michael Hemmer, James McLurkin, Yu Zhou, and Sandor Fekete. A parallel distributed strategy for arraying a scattered robot swarm. In *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 2795–2802, 09 2015. doi: 10.1109/IROS.2015.7353761.
- Thibault Kruse, Amit Kumar Pandey, Rachid Alami, and Alexandra Kirsch. Human-aware robot navigation: A survey. *Robotics and Autonomous Systems*, 61(12):1726–1743, 2013. ISSN 0921-8890. doi: <https://doi.org/10.1016/j.robot.2013.05.007>. URL <https://www.sciencedirect.com/science/article/pii/S0921889013001048>.
- M. Kuderer, H. Kretzschmar, C. Sprunk, and W. Burgard. Feature-based prediction of trajectories for socially compliant navigation. In *Robotics: Science and Systems VIII*, 2013. doi: 10.15607/RSS.2012.VIII.025.
- Frédéric Large, Dizan Vasquez, Thierry Fraichard, and Christian Laugier. Avoiding cars and pedestrians using velocity obstacles and motion prediction. In *2004 IEEE Intelligent Vehicles Symposium*, pages 375–379, 2004.
- Boris Lau, Christoph Sprunk, and Wolfram Burgard. Efficient grid-based spatial representations for robot navigation in dynamic environments. *Robotics and Autonomous Systems*, 61:1116–1130, 10 2013. doi: 10.1016/j.robot.2012.08.010.
- Alexander Lavin. Optimized mission planning for planetary exploration rovers. *CoRR*, abs/1511.0, 2015a. URL <http://arxiv.org/abs/1511.00195>.
- Alexander Lavin. A pareto optimal d\* search algorithm for multiobjective path planning. *CORR*, 2015b.
- Alexander Lavin. A pareto front-based multiobjective path planning algorithm. *CORR*, 2015c. URL <http://arxiv.org/abs/1505.05947>.
- Jaedong Lee, Jungdam Won, and Jehee Lee. Crowd simulation by deep reinforcement learning. In *11th ACM SIGGRAPH Conference on Motion, Interaction and Games, MIG '18*, New York, NY, USA, 2018.

- Association for Computing Machinery. ISBN 9781450360159. doi: 10.1145/3274247.3274510. URL <https://doi.org/10.1145/3274247.3274510>.
- Min-Fan Ricky Lee and Sharfiden Hassen Yusuf. Mobile robot navigation using deep reinforcement learning. *Processes*, 10(12), 2022. ISSN 2227-9717. doi: 10.3390/pr10122748. URL <https://www.mdpi.com/2227-9717/10/12/2748>.
- J Li and L Fu K. Huang. Human-oriented navigation for service providing in home environment. In *IEEE*, pages 1892–1897. IEEE, 2010. ISBN 978-4-907764-36-4 SRC - BaiduScholar FG - 0. [Original String]:K. H. J. L. and L. F. , "Human-Oriented Navigation for Service Providing in Home Environment,in SICE Annual Conference, 2010.
- Mingming Li, Rui Jiang, Shuzhi Ge, and Tong Lee. Role playing learning for socially concomitant mobile robot navigation. *CAAI Transactions on Intelligence Technology*, 3, 05 2018. doi: 10.1049/trit.2018.0008.
- Shidong Li, Huihua Zhou, Jia Hu, Qing Ai, and Chao Cai. A fast path planning approach for unmanned aerial vehicles. *Concurrency and Computation: Practice and Experience*, 27:3446–3460, 2015. ISSN 1532-0626.
- Lucia Liu, Daniel Dugas, Gianluca Cesari, Roland Siegwart, and Renaud Dubé. Robot navigation in crowded environments using deep reinforcement learning. In *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 5671–5677, 2020. doi: 10.1109/IROS45743.2020.9341540.
- Xiaojuan Liu, Jietao Diao, and Nan Li. A fpga based accelerator implementation for path planning using q learning algorithm. *Journal of Physics: Conference Series*, 2245(1):012014, apr 2022. doi: 10.1088/1742-6596/2245/1/012014.
- Pinxin Long, Tingxiang Fan, Xinyi Liao, Wenxi Liu, Hao Zhang, and Jia Pan. Towards optimally decentralized multi-robot collision avoidance via deep reinforcement learning. In *2018 IEEE International Conference*

- on Robotics and Automation (ICRA)*, pages 6252–6259, 2018. doi: 10.1109/ICRA.2018.8461113.
- Matthias Luber, Gian Diego Tipaldi, and Kai Arras. Place-dependent people tracking. *I. J. Robot Res.*, 30:280–293, 02 2011. doi: 10.1177/0278364910393538.
- Carlos Lucas, Daniel Hernandez-Sosa, and Rui Caldeira. Multi-objective four-dimensional glider path planning using nsga-ii. In *2018 IEEE/OES Autonomous Underwater Vehicle Workshop (AUV)*, pages 1–5. IEEE, 2018. ISBN 9781728102535.
- Carlos Lucas, Daniel Hernández-Sosa, David Greiner, Aleš Zamuda, and Rui Caldeira. An approach to multi-objective path planning optimization for underwater gliders. *Sensors (Basel, Switzerland)*, 19, 2019. ISSN 1424-8220.
- Yuanfu Luo, Panpan Cai, Aniket Bera, David Hsu, Wee Sun Lee, and Dinesh Manocha. Porca: Modeling and planning for autonomous driving among many pedestrians. *IEEE Robotics and Automation Letters*, 3(4): 3418–3425, 2018. doi: 10.1109/LRA.2018.2852793.
- Tianji Ma, Nanyang Bai, Wentao Shi, Lutao Wang, and Tao Wu. *Research and Application of Visual SLAM Based on Embedded GPU*, pages 3–21. Wireless Communications and Mobile Computing, 06 2021. ISBN 978-3-030-77568-1. doi: 10.1007/978-3-030-77569-8\_1.
- Tt Mac, C Copot, Dt Tran, and R De Keyser. A hierarchical global path planning approach for mobile robots based on multi-objective particle swarm optimization. *Applied Soft Computing*, 59:68–76, 2017. ISSN 1568-4946.
- Luis Manso. Robocomp. Technical report, Universidad de Extremadura, 2023. URL <https://github.com/robocomp>.
- Luis Manso, Pilar Bachiller, Pablo Bustos, Pedro Núñez, Ramón Cintas, and Luis Calderita. Robocomp: A tool-based robotics framework. In *Simulation, Modeling, and Programming for Autonomous Robots - Second International Conference, SIMPAR 2010, Darmstadt*,

- Germany, November 15-18, 2010. *Proceedings*, volume 6472 of *Lecture Notes in Computer Science*, pages 251–262. Springer, 2010. doi: 10.1007/978-3-642-17319-6\\_25. URL [https://doi.org/10.1007/978-3-642-17319-6\\_25](https://doi.org/10.1007/978-3-642-17319-6_25).
- Rebeca Marfil, Adrián Romero-Garcés, Juan Pedro Bandera Rubio, Luis J. Manso, Luis V. Calderita, Pablo Bustos, Antonio Bandera, Javier García-Polo, Fernando Fernández, and Dimitri Voilmy. Perceptions or actions? grounding how agents interact within a software architecture for cognitive robotics. *Cogn. Comput.*, 12(2):479–497, 2020.
- Yeganeh Marghi, Farzad Towhidkhah, and Shahriar Gharibzadeh. Human brain function in path planning: a task study. *Cognitive Computation*, 9:136–149, 2017. ISSN 1866-9956.
- Ellips Masehian and Davoud Sedighizadeh. A multi-objective pso-based algorithm for robot path planning. In *Proceedings of the IEEE International Conference on Industrial Technology*, pages 465–470. IEEE, 2010. ISBN 9781424456970. doi: 10.1109/ICIT.2010.5472755.
- Maja J. Matarić. Socially assistive robotics: Human augmentation versus automation. *Science Robotics*, 2(4):eaam5410, 2017. doi: 10.1126/scirobotics.aam5410. URL <https://www.science.org/doi/abs/10.1126/scirobotics.aam5410>.
- S. Mohammad Mavadati, Haunghao Feng, Michelle Salvador, Sophia Silver, Anibal Gutierrez, and Mohammad H. Mahoor. Robot-based therapeutic protocol for training children with autism. In *2016 25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*, pages 855–860, 2016. doi: 10.1109/ROMAN.2016.7745219.
- Ross Mead and Maja J. Mataric. A probabilistic framework for autonomous proxemic control in situated and mobile human-robot interaction. In *Proceedings of the Seventh Annual ACM/IEEE International Conference on Human-Robot Interaction, HRI '12*, page 193–194, New York, NY, USA, 2012. Association for Computing Machinery. ISBN 9781450310635. doi: 10.1145/2157689.2157751. URL <https://doi.org/10.1145/2157689.2157751>.

- Ross Mead, Amin Atrash, and Maja J. Matarić. Proxemic feature recognition for interactive robots: Automating metrics from the social sciences. In *International Conference on Software Reuse*, 2011.
- João G. Melo and Edna Barros. An embedded monocular vision approach for ground-aware objects detection and position estimation. In *RoboCup 2022:: Robot World Cup XXV*, page 100–111, 2023.
- Sujeendran Menon, Pawel Zarzycki, Maria Ganzha, and Marcin Paprzycki. Development of a neural network library for resource constrained speech synthesis. In *2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*, pages 1–8, 2020. doi: 10.1109/ICRAIE51050.2020.9358310.
- Vu Trieu Minh and John Punwa. Feasible path planning for autonomous vehicles. *Mathematical Problems in Engineering*, 2014: 1–12, 2014. ISSN 1024-123X. URL <https://doaj.org/article/23fd970f5a464c42acafa12cbf98288f>.
- Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin A. Riedmiller, Andreas Fidjeland, Georg Ostrovski, Stig Petersen, Charlie Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dhharshan Kumaran, Daan Wierstra, Shane Legg, and Demis Hassabis. Human-level control through deep reinforcement learning. *Nature*, 518:529–533, 2015.
- Lesia Mochurad, Yaroslav Hladun, and Roman Tkachenko. An obstacle-finding approach for autonomous mobile robots using 2d lidar data. *Big Data and Cognitive Computing*, 7:43, 03 2023. doi: 10.3390/bdcc7010043.
- Navya Mohan and James Kurian. Design and implementation of shape-based feature extraction engine for vision systems using zynq soc. *International journal of electrical and computer engineering systems*, 13: 109–117, 02 2022. doi: 10.32985/ijeces.13.2.3.
- Shohin Mukherjee, Sandip Aine, and Maxim Likhachev. Mplp: Massively parallelized lazy planning. *IEEE Robotics and Automation Let-*

ters, 7:6067–6074, 2021. URL <https://api.semanticscholar.org/CorpusID:235755510>.

Mauro Muñoz, Matheus Menezes, Edison Pignaton de Freitas, Sen Cheng, Areolino Neto, Alexandre Oliveira, and Paulo Ribeiro. *A Parallel RatSlam C++ Library Implementation*, pages 173–183. Computational neuroscience, 11 2019. ISBN 978-3-030-36635-3. doi: 10.1007/978-3-030-36636-0\_13.

Roopal Nahar, Akanksha Baranwal, and K. Madhava Krishna. Fpga based parallelized architecture of efficient graph based image segmentation algorithm. In *2017 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pages 98–103, 2017. doi: 10.1109/ROBIO.2017.8324401.

Thaker Nayl, Mohammed Q Mohammed, and Saif Q Muhamed. Obstacles avoidance for an articulated robot using modified smooth path planning. In *2017 International Conference on Computer and Applications (ICCA)*, pages 185–189. IEEE, 2017. ISBN 9781538627525.

Andrew Newman, Guojun Yang, Boyang Wang, David Arnold, and Jafar Saniie. Embedded mobile ros platform for slam application with rgb-d cameras. In *2020 IEEE International Conference on Electro Information Technology (EIT)*, pages 449–453, 2020. doi: 10.1109/EIT48999.2020.9208310.

Pedro Núñez, Luis Manso, Pablo Bustos, Paulo Drews-Jr, and Douglas Macharet. Towards a new semantic social navigation paradigm for autonomous robots using cortex. In *RO-MAN Conference - BAILAR2016 Workshop*, 08 2016. doi: 10.13140/RG.2.2.20740.53122.

Billy Okal and Kai O. Arras. Learning socially normative robot navigation behaviors with bayesian inverse reinforcement learning. In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 2889–2895, 2016. doi: 10.1109/ICRA.2016.7487452.

Michael Otte and Nikolaus Correll. Any-com multi-robot path-planning: Maximizing collaboration for variable bandwidth. *Springer Tracts in Advanced Robotics*, 83, 01 2010. doi: 10.1007/978-3-642-32723-0\_12.

- Safa Ouerghi, Rémi Boutteau, Xavier Savatier, and Fethi Tlili. Cuda accelerated visual egomotion estimation for robotic navigation. In *In Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2017)*, pages 107–114, 01 2017. doi: 10.5220/0006171501070114.
- Rainer Palm and Dimiter Driankov. Velocity potentials and fuzzy modeling of fluid streamlines for obstacle avoidance of mobile robots. In *2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pages 1–8, 2015. doi: 10.1109/FUZZ-IEEE.2015.7337800.
- Rainer Palm, Ravi Chadalavada, and Achim J. Lilienthal. Recognition of human-robot motion intentions by trajectory observation. In *2016 9th International Conference on Human System Interactions (HSI)*, pages 229–235, 2016. doi: 10.1109/HSI.2016.7529636.
- Daniele Palossi, Andrea Marongiu, and Luca Benini. Ultra low-power visual odometry for nano-scale unmanned aerial vehicles. In *Design, Automation and Test in Europe Conference and Exhibition (DATE), 2017*, pages 1647–1650, 2017. doi: 10.23919/DATE.2017.7927257.
- Jong-Hun Park and Uk-Youl Huh. Path planning for autonomous mobile robot based on safe space. *Journal of Electrical Engineering Technology*, 11:1441–1448, 2016. ISSN 1975-0102.
- Jong Jin Park and Benjamin Kuipers. A smooth control law for graceful motion of differential wheeled mobile robots in 2d environment. In *2011 IEEE International Conference on Robotics and Automation (ICRA)*, pages 4896–4902, 2011. doi: 10.1109/ICRA.2011.5980167.
- Jong Jin Park, Collin Johnson, and Benjamin Kuipers. Robot navigation with model predictive equilibrium point control. In *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 4945–4952, 2012. doi: 10.1109/IROS.2012.6386195.
- C Petres, Y Pailhas, P Patron, Y Petillot, J Evans, and D Lane. Path planning for autonomous underwater vehicles. *IEEE Transactions on Robotics*, 23:331–341, 2007. ISSN 1552-3098.

- Mark Pfeiffer, Michael Schaeuble, Juan Nieto, Roland Siegwart, and Cesar Cadena. From perception to decision: A data-driven approach to end-to-end motion planning for autonomous ground robots. In *IEEE International Conference on Robotics and Automation (ICRA)*, page 1527–1533. IEEE, 2017.
- Mark Pfeiffer, Samarth Shukla, Matteo Turchetta, Cesar Cadena, Andreas Krause, Roland Siegwart, and Juan Nieto. Reinforced imitation: Sample efficient deep reinforcement learning for mapless navigation by leveraging prior demonstrations. *IEEE Robotics and Automation Letters*, 3(4):4423–4430, 2018. doi: 10.1109/LRA.2018.2869644.
- André Silva Pinto de Aguiar, Filipe Baptista Neves dos Santos, Luís Carlos Feliz dos Santos, Vitor Manuel de Jesus Filipe, and Armando Jorge Miranda de Sousa. Vineyard trunk detection using deep learning – an experimental device benchmark. *Computers and Electronics in Agriculture*, 175:105535, 2020. ISSN 0168-1699. doi: <https://doi.org/10.1016/j.compag.2020.105535>. URL <https://www.sciencedirect.com/science/article/pii/S0168169920304555>.
- Ashwini Pogle, Roberto Martín-Martín, Patrick Goebel, Vincent Chow, Hans M. Ewald, Junwei Yang, Zhenkai Wang, Amir Sadeghian, Dorsa Sadigh, Silvio Savarese, and Marynel Vázquez. Deep local trajectory replanning and control for robot navigation. In *2019 International Conference on Robotics and Automation (ICRA)*, pages 5815–5822, 2019. doi: 10.1109/ICRA.2019.8794062.
- Tony Prescott. Brahms: Novel middleware for integrated systems computation. *Frontiers in Neuroinformatics*, 2, 01 2008. doi: 10.3389/conf.neuro.11.2008.01.051.
- Claudia Pérez-D’Arpino, Can Liu, Patrick Goebel, Roberto Martín-Martín, and Silvio Savarese. Robot navigation in constrained pedestrian environments using reinforcement learning. In *2021 IEEE International Conference on Robotics and Automation (ICRA)*, pages 1140–1146, 2021. doi: 10.1109/ICRA48506.2021.9560893.
- Noé Pérez-Higueras, Rafael Ramón-Vigo, Fernando Caballero, and Luis Merino. Robot local navigation with learned social cost functions. In

- 2014 *11th International Conference on Informatics in Control, Automation and Robotics (ICINCO)*, volume 02, pages 618–625, 2014. doi: 10.5220/0005120806180625.
- Mohammad Ragab and Ghada Elkabbany. A parallel implementation of multiple non-overlapping cameras for robot pose estimation. *KSII Transactions on Internet and Information Systems*, 8:4103–4117, 11 2014. doi: 10.3837/tiis.2014.11.025.
- Deepak Ramachandran and Eyal Amir. Bayesian inverse reinforcement learning. In *20th International Joint Conference on Artificial Intelligence (IJCAI)*, pages 2586–2591, Hyderabad, India, 01 2007.
- Balakrishnan Ramalingam, Rajesh Elara Mohan, Selvasundari Balakrishnan, Karthikeyan Elangovan, Braulio Gómez, Thejus Pathmakumar, Manojkumar Devarassu, Madan Rayguru, and Chanthini Baskar. stetro- deep learning powered staircase cleaning and maintenance reconfigurable robot. *Sensors*, 21:6279, 09 2021. doi: 10.3390/s21186279.
- João Ramôa, Vasco Lopes, Luis Alexandre, and S Mogo. Real-time 2d–3d door detection and state classification on a low-power device. In *SN Applied Sciences*, 2021. doi: <https://doi.org/10.1007/s42452-021-04588-3>.
- João Gaspar Ramôa, Luís A. Alexandre, and S. Mogo. Real-time 3d door detection and classification on a low-power device. In *2020 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)*, pages 96–101, 2020. doi: 10.1109/ICARSC49921.2020.9096155.
- Photchara Ratsamee, Yasushi Mae, Kenichi Ohara, Tomohito Takubo, and Takero Arai. Human-robot collision avoidance using a modified social force model with body pose and face orientation. *International Journal of Humanoid Robotics*, 10, 04 2013. doi: 10.1142/S0219843613500084.
- A.K. Reddy, V. Malviya, and R. Kala. Social cues in the autonomous navigation of indoor mobile robots. *Int J of Soc Robotics*, 13:1335–1358, 2021. doi: 10.1007/s12369-020-00721-1.

- A. Rios-Martinez, A. Spalanzani, and C. Laugier. From proxemics theory to socially-aware navigation: A survey. *International Journal of Social Robotics*, 7(2):137–153, 2014.
- J. Rios-Martinez, A. Spalanzani, and C. Laugier. From proxemics theory to socially-aware navigation: A survey. *Int. J. of Soc. Robotics*, 7:137–153, 2015. doi: 10.1007/s12369-014-0251-1.
- Jorge Rios-Martinez, Anne Spalanzani, and Christian Laugier. Understanding human interaction for probabilistic autonomous navigation using risk-rrt approach. In *2011 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 2014–2019, 2011. doi: 10.1109/IROS.2011.6094496.
- Universal Robots. Why cobots? Technical report, Universal Robots, 2023. URL <https://www.universal-robots.com/products/collaborative-robots-cobots-benefits/>.
- Alessandra Rossi, Kerstin Dautenhahn, Kheng Lee Koay, and Michael L. Walters. How social robots influence people’s trust in critical situations. In *2020 29th IEEE International Conference on Robot and Human Interactive Communication (RO-MAN)*, pages 1020–1025, 2020. doi: 10.1109/RO-MAN47096.2020.9223471.
- Andrey Rudenko, Luigi Palmieri, and Kai O. Arras. Joint long-term prediction of human motion using a planning-based social force approach. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pages 4571–4577, 2018. doi: 10.1109/ICRA.2018.8460527.
- S. M. Bhagya P. Samarakoon, M. A. Viraj J. Muthugala, and A. G. Buddhika P. Jayasekara. A review on human–robot proxemics. *Electronics*, 11(16), 2022. ISSN 2079-9292. doi: 10.3390/electronics11162490. URL <https://www.mdpi.com/2079-9292/11/16/2490>.
- Sunil Srivatsav Samsani and Mannan Saeed Muhammad. Socially compliant robot navigation in crowded environment by human behavior resemblance using deep reinforcement learning. *IEEE Robotics and Automation Letters*, 6(3):5223–5230, 2021. doi: 10.1109/LRA.2021.3071954.

- Giulio Sandini, Alessandra Sciutti, and David Vernon. Cognitive robotics. In *Encyclopedia of Robotics*, 2021.
- John Schulman, Filip Wolski, Prafulla Dhariwal, Alec Radford, and Oleg Klimov. Proximal policy optimization algorithms. *CoRR*, abs/1707.06347, 2017. URL <http://arxiv.org/abs/1707.06347>.
- Alessandra Sciutti, Pablo Barros, Ginevra Castellano, and Yuki Nagai. Editorial: Affective shared perception. *Frontiers in Integrative Neuroscience*, 16, 09 2022. doi: 10.3389/fnint.2022.1024267.
- D Sedighzadeh and E Masehian. Multi-objective pso- and npso-based algorithms for robot path planning. *Advances in Electrical and Computer Engineering*, 10:69–76, 2010. ISSN 1582-7445. URL <https://doaj.org/article/b82f7a40a1734b0bb68d56bc55c071ad>.
- Johanna Seibt, Malene Damholdt, and Christina Vestergaard. Integrative social robotics, value-driven design, and transdisciplinarity. *Interaction Studies*, 21:111–144, 01 2020. doi: 10.1075/is.18061.sei.
- Haobin Shi, Lin Shi, Meng Xu, and Kao-Shing Hwang. End-to-end navigation strategy with deep reinforcement learning for mobile robots. *IEEE Transactions on Industrial Informatics*, 16(4):2393–2402, 2020. doi: 10.1109/TII.2019.2936167.
- Z. Shiller, F. Large, and S. Sekhavat. Motion planning in dynamic environments: obstacles moving along arbitrary trajectories. *Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation (Cat. No.01CH37164)*, 4:3716–3721 vol.4, 2001. URL <https://api.semanticscholar.org/CorpusID:17639079>.
- Masahiro Shiomi, Francesco Zanlungo, Kotaro Hayashi, and Takayuki Kanda. Towards a socially acceptable collision avoidance for a mobile robot navigating among pedestrians using a pedestrian model. *International Journal of Social Robotics*, 6:443–455, 08 2014. doi: 10.1007/s12369-014-0238-y.
- Dmitry A. Sinyukov and Taşkın Padır. A novel shared position control method for robot navigation via low throughput human-machine inter-

- faces. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3913–3920, 2018. doi: 10.1109/IROS.2018.8593921.
- Emrah Akin Sisbot, Luis F. Marin-Urias, Rachid Alami, and Thierry Simeon. A human aware mobile robot motion planner. *IEEE Transactions on Robotics*, 23(5):874–883, 2007. doi: 10.1109/TRO.2007.904911.
- Jamie Snape, Jur van den Berg, Stephen J. Guy, and Dinesh Manocha. The hybrid reciprocal velocity obstacle. *IEEE Transactions on Robotics*, 27(4):696–706, 2011. doi: 10.1109/TRO.2011.2120810.
- SPARC. Robotics 2020 multi-annual roadmap for robotics in europe. Technical report, SPARC: The Partnership for Robotics in Europe, eu-Robotics Aisbl: Brussels, Belgium, 2015.
- Jack Stevenson and Charles Fox. *Scaling a Hippocampus Model with GPU Parallelisation and Test-Driven Refactoring*, pages 44–53. 11th International Conference on Biomimetic and Biohybrid Systems (Living Machines), 12 2022. ISBN 978-3-031-20469-2. doi: 10.1007/978-3-031-20470-8\_5.
- Mikael Svenstrup, Soren Tranberg, Hans Jorgen Andersen, and Thomas Bak. Pose estimation and adaptive robot behaviour for human-robot interaction. In *2009 IEEE International Conference on Robotics and Automation (ICRA)*, pages 3571–3576, 2009. doi: 10.1109/ROBOT.2009.5152690.
- Mikael Svenstrup, Thomas Bak, and Hans Jørgen Andersen. Trajectory planning for robots in dynamic human environments. In *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 4293–4298, 2010. doi: 10.1109/IROS.2010.5651531.
- Lei Tai, Giuseppe Paolo, and Ming Liu. Virtual-to-real deep reinforcement learning: Continuous control of mobile robots for mapless navigation. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 31–36, 2017. doi: 10.1109/IROS.2017.8202134.
- A.L. Thomaz and Maya Cakmak. Social learning mechanisms for robots. *Proceedings of the 14th International Symposium of Robotics Research*,

2009. [Original String]:A. T. and M. C. , "Social Learning Mechanisms for Robots,in Proceedings of the 14th International Symposium of Robotics Research, 2009.SRC - BaiduScholarFG - 0.
- Fletcher Thompson and Damien Guihen. Review of mission planning for autonomous marine vehicle fleets. *Journal of Field Robotics*, 36, 09 2018. doi: 10.1002/rob.21819.
- Simon Thompson, Takehiro Horiuchi, and Satoshi Kagami. A probabilistic model of human motion and navigation intent for mobile robot path planning. In *2009 4th International Conference on Autonomous Robots and Agents*, pages 663–668, 2009.
- Karine Lan Hing Ting, Mustapha Derras, and Dimitri Voilmy. Designing human-robot interaction for dependent elderlies: A living lab approach. In *Proceedings of the 32nd International BCS Human Computer Interaction Conference*, HCI '18, Swindon, GBR, 2018. BCS Learning & Development Ltd. doi: 10.14236/ewic/HCI2018.142. URL <https://doi.org/10.14236/ewic/HCI2018.142>.
- Vitor A.M.F. Torres, Brayan R.A. Jaimes, Eduardo S. Ribeiro, Mateus T. Braga, Elcio H. Shiguemori, Haroldo F.C. Velho, Luiz C.B. Torres, and Antonio P. Braga. Combined weightless neural network fpga architecture for deforestation surveillance and visual navigation of uavs. *Engineering Applications of Artificial Intelligence*, 87:103227, 2020. ISSN 0952-1976. doi: <https://doi.org/10.1016/j.engappai.2019.08.021>. URL <https://www.sciencedirect.com/science/article/pii/S095219761930212X>.
- Manuel Toscano-Moreno, Anthony Mandow, Maria Alcázar Martínez, and Alfonso Garcia-Cerezo. Velocity-based heuristic evaluation for path planning and vehicle routing for victim assistance in disaster scenarios. In *Robot 2019: Fourth Iberian Robotics Conference - Advances in Robotics*, volume 1093, pages 109–121. Springer, 2019. URL [https://doi.org/10.1007/978-3-030-36150-1\\_10](https://doi.org/10.1007/978-3-030-36150-1_10).
- Pete Trautman and Andreas Krause. Unfreezing the robot: Navigation in dense, interacting crowds. In *2010 IEEE/RSJ International Conference*

- on Intelligent Robots and Systems (IROS)*, pages 797–803, 09 2010. doi: 10.1109/IROS.2010.5654369.
- Pete Trautman, Jeremy Ma, Richard M. Murray, and Andreas Krause. Robot navigation in dense human crowds: Statistical models and experimental studies of human–robot cooperation. *The International Journal of Robotics Research*, 34(3):335–356, 2015. doi: 10.1177/0278364914557874.
- Xuan-Tung Truong and Trung Dung Ngo. Toward socially aware robot navigation in dynamic and crowded environments: A proactive social motion model. *IEEE Transactions on Automation Science and Engineering*, 14(4):1743–1760, 2017. doi: 10.1109/TASE.2017.2731371.
- Jur van den Berg, Ming Lin, and Dinesh Manocha. Reciprocal velocity obstacles for real-time multi-agent navigation. In *2008 IEEE International Conference on Robotics and Automation (ICRA)*, pages 1928–1935, 2008. doi: 10.1109/ROBOT.2008.4543489.
- Jur van den Berg, Stephen J. Guy, Ming Lin, and Dinesh Manocha. *Reciprocal n-Body Collision Avoidance*, volume 70, pages 3–19. Springer, 04 2011. ISBN 978-3-642-19456-6. doi: 10.1007/978-3-642-19457-3\_1.
- Tijs Vandemeulebroucke, Bernadette Dierckx de Casterlé, and Chris Gastmans. Ethics of socially assistive robots in aged-care settings: A socio-historical contextualisation. *Journal of Medical Ethics*, 46: medethics–2019, 12 2019. doi: 10.1136/medethics-2019-105615.
- Dizan Vasquez, Billy Okal, and Kai O. Arras. Inverse reinforcement learning algorithms and features for robot navigation in crowds: An experimental comparison. In *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 1341–1346, 2014. doi: 10.1109/IROS.2014.6942731.
- Araceli Vega, Luis J Manso, Douglas G Macharet, Pablo Bustos, and Pedro Núñez. Socially aware robot navigation system in human-populated and interactive environments based on an adaptive spatial density function and space affordances. *Pattern Recognition Letters*, 118:72–84, 2019. ISSN 01678655.

- A. Vega-Magro, R. Gondkar, L.J. Manso, and P. Núñez. Towards efficient human-robot cooperation for socially-aware robot navigation in human-populated environments: the snape framework. In *2021 IEEE International Conference on Robotics and Automation (ICRA)*, pages 3169–3174, 2021. doi: 10.1109/ICRA48506.2021.9561448.
- Jasmin Velagic, Dada Delimustafic, and Dinko Osmankovic. Mobile robot navigation system based on probabilistic road map (prm) with halton sampling of configuration space. *IEEE International Symposium on Industrial Electronics*, 06 2014. doi: 10.1109/ISIE.2014.6864789.
- Anirudh Vemula, Katharina Muelling, and Jean Oh. Social attention: Modeling attention in human crowds. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pages 4601–4607, 2018. doi: 10.1109/ICRA.2018.8460504.
- G. Vercelli, F. Giuffrida, A. Rolla, R. Toracca, and P. Morasso. Navnex: an hybrid system which learns navigation situations in real time. In *Proceedings Sixth International Conference on Tools with Artificial Intelligence. TAI 94*, pages 832–835, 1994. doi: 10.1109/TAI.1994.346390.
- Emanuele Vespa, Nikolay Nikolov, Marius Grimm, Luigi Nardi, Paul H. J. Kelly, and Stefan Leutenegger. Efficient octree-based volumetric slam supporting signed-distance and occupancy mapping. *IEEE Robotics and Automation Letters*, 3(2):1144–1151, 2018. doi: 10.1109/LRA.2018.2792537.
- D. Voilmy et al. CLARC: A cognitive robot for helping geriatric doctors in real scenarios. In *ROBOT (1)*, volume 693 of *Advances in Intelligent Systems and Computing*, pages 403–414. Springer, 2017.
- Chen Wang, Yanan Li, Shuzhi Sam Ge, and Tong Heng Lee. Adaptive control for robot navigation in human environments based on social force model. In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 5690–5695, 2016. doi: 10.1109/ICRA.2016.7487791.
- Yao Wang, Yuqi Kong, Zhiyu Ding, Wenzheng Chi, and Lining Sun. Nr-tirl based nn-rrt\* path planner in human-robot interaction environ-

- ment. In Filippo Cavallo, John-John Cabibihan, Laura Fiorini, Alessandra Sorrentino, Hongsheng He, Xiaorui Liu, Yoshio Matsumoto, and Shuzhi Sam Ge, editors, *Social Robotics*, pages 496–508, Cham, 2022a. Springer Nature Switzerland. ISBN 978-3-031-24667-8.
- Zhi Wang, Chunlin Chen, and Daoyi Dong. Instance weighted incremental evolution strategies for reinforcement learning in dynamic environments. *IEEE Transactions on Neural Networks and Learning Systems*, pages 1–15, 2022b. doi: 10.1109/TNNLS.2022.3160173.
- Wei Wei, Qiao Ke, Adam Zielonka, Mariusz Pleszczyński, and Marcin Woźniak. Vehicle parking navigation based on edge computing with diffusion model and information potential field. *IEEE Transactions on Services Computing*, 16(5):3827–3836, 2023. doi: 10.1109/TSC.2023.3286332.
- Mingliang Xu, Xiaozheng Xie, Pei Lv, Jianwei Niu, Hua Wang, Chaochao Li, Ruijie Zhu, Zhigang Deng, and Bing Zhou. Crowd behavior simulation with emotional contagion in unexpected multihazard situations. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 51(3): 1567–1581, 2021. doi: 10.1109/TSMC.2019.2899047.
- Q. Yao, Z. Zheng, L. Qi, H. Yuan, X. Guo, M. Zhao, Z. Liu, and T. Yang. Path planning method with improved artificial potential field—a reinforcement learning perspective. *IEEE Access*, 8:135513–135523, 2020.
- Dingding Yu, Xianliang Hu, Kewei Liang, and Jun Ying. A parallel algorithm for multi-agv systems. *Journal of Ambient Intelligence and Humanized Computing*, 13, 04 2022. doi: 10.1007/s12652-021-02987-3.
- Jiya Yu, Jiye Zhang, Aijing Shu, Yujie Chen, Jianneng Chen, Yongjie Yang, Wei Tang, and Yanchao Zhang. Study of convolutional neural network-based semantic segmentation methods on edge intelligence devices for field agricultural robot navigation line extraction. *Computers and Electronics in Agriculture*, 209:107811, 2023. ISSN 0168-1699. doi: <https://doi.org/10.1016/j.compag.2023.107811>. URL <https://www.sciencedirect.com/science/article/pii/S0168169923001990>.

- F. Zanlungo, Tetsushi Ikeda, and Takayuki Kanda. Social force model with explicit collision prediction. *EPL (Europhysics Letters)*, 93:68005, 03 2011. doi: 10.1209/0295-5075/93/68005.
- Shuwen Zhang, M Simkani, and M H Zadeh. Automatic vehicle parallel parking design using fifth degree polynomial path planning. In *2011 IEEE Vehicular Technology Conference (VTC Fall)*, pages 1–4. IEEE, 2011. ISBN 9781424483280.
- Yong Zhang, Dun-Wei Gong, and Jian-Hua Zhang. Robot path planning in uncertain environment using multi-objective particle swarm optimization. *Neurocomputing*, 103:172–185, 2013. ISSN 09252312.
- Zhiyun Zheng, Guanglei Zhu, Zhenhao Sun, Zhenfei Wang, and Lun Li. Improved social force model based on emotional contagion and evacuation assistant. *IEEE Access*, 8:195989–196001, 2020. doi: 10.1109/ACCESS.2020.3034348.
- Kai Zhu and Tao Zhang. Deep reinforcement learning based mobile robot navigation: A review. *Tsinghua Science and Technology*, 26(5):674–691, 2021. doi: 10.26599/TST.2021.9010012.
- Brian D. Ziebart, Andrew L. Maas, J. Andrew Bagnell, and Anind K. Dey. Maximum entropy inverse reinforcement learning. In *AAAI Conference on Artificial Intelligence*, 2008.
- Brian D. Ziebart, Nathan Ratliff, Garratt Gallagher, Christoph Mertz, Kevin Peterson, J. Andrew Bagnell, Martial Hebert, Anind K. Dey, and Siddhartha Srinivasa. Planning-based prediction for pedestrians. In *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3931–3936, 2009. doi: 10.1109/IROS.2009.5354147.