

Jornadas de Automática

Revisión del uso de IA en Entornos No Estructurados Transitables

Jiménez, Alberto^{a,*}, de la Escalera, Arturo^a, Iglesias, José Antonio^b

^aLaboratorio de Sistemas Inteligentes (LSI), Universidad Carlos III de Madrid, Av. de la Universidad 30, 28911, Leganés, España.

^bGrupo de Control, Aprendizaje y Optimización de Sistemas (CAOS), Universidad Carlos III de Madrid, Av. de la Universidad 30, 28911, Leganés, España.

To cite this article: Jiménez, Alberto, de la Escalera, Arturo, Iglesias, José Antonio. 2025. The use of AI in Traversable Unstructured Environments: A Review. *Jornadas de Automática*, 46.

<https://doi.org/10.17979/ja-cea.2025.46.12098>

Resumen

La navegación autónoma de UGVs supone un gran desafío cuando se efectúa en entornos 3D no estructurados. Las condiciones irregulares y altamente dinámicas de estas áreas dificulta el uso de métodos convencionales basados en reglas o modelos manuales, siendo necesario un análisis profundo de la transitabilidad. Este trabajo presenta una revisión exhaustiva del estado del arte sobre las técnicas de IA aplicadas en este campo. Se analizan los diferentes paradigmas de aprendizaje y la evolución de diferentes arquitecturas, examinando sus avances, limitaciones y oportunidades para lograr una navegación autónoma robusta.

Palabras clave: Técnicas de Inteligencia Artificial, Aprendizaje Automático, Percepción y Sensorización, Fusión de Datos Sensoriales, Robots Móviles Autónomos, Vehículos Autónomos, Navegación Robótica.

The use of AI in Traversable Unstructured Environments: A Review

Abstract

Autonomous navigation of UGVs is a major challenge when performed in unstructured 3D environments. The irregular and highly dynamic conditions of these areas make it difficult to use conventional methods based on rules or manual models, being necessary a deep analysis of traversability. This paper presents an exhaustive review of the state of the art in AI techniques applied into this field. Different learning paradigms and progression of different architectures are analyzed, examining their advances, limitations and opportunities to achieve a robust autonomous navigation.

Keywords: Artificial Intelligence Techniques, Machine Learning, Perception and Sensing, Sensor Data Fusion, Autonomous Mobile Robots, Autonomous Vehicles, Robot Navigation.

1. Introducción

El desarrollo de vehículos terrestres no tripulados, conocidos como UGVs (del inglés *Unmanned Ground Vehicles*) capaces de operar de forma autónoma en entornos no estructurados presenta un desafío clave en el ámbito de la robótica móvil. A diferencia de los entornos estructurados como las ciudades, donde las zonas de tránsito siguen normas y superficies predecibles, los escenarios naturales presentan terrenos irregulares y obstáculos altamente variables, complicando las tareas de percepción y planificación de movimiento. En es-

tos entornos no estructurados, la capacidad de un UGV para estimar la transitabilidad del terreno es crucial para alcanzar una navegación autónoma robusta y segura. Tradicionalmente, la estimación de transitabilidad se ha basado en métodos geométricos o reglas estadísticas, con aproximaciones muy limitadas ante la variabilidad de características que presentan los entornos desestructurados. Además, estas técnicas no consideran los elementos dinámicos del escenario ni las restricciones móviles del propio robot, aumentando la imprecisión de sus estimaciones. Diferentes técnicas de Inteligencia Artificial (IA) han permitido crear modelos que superan las limita-

*Autor para correspondencia: albejime@pa.uc3m.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

ciones de los métodos tradicionales, abriendo nuevas vías para la percepción y navegación autónoma en entornos 3D complejos, a partir de una estimación precisa de la transitabilidad del terreno. Este trabajo presenta una revisión técnica y crítica de los enfoques basados en IA para estimar la transitabilidad en entornos no estructurados. Se analizarán los diferentes paradigmas de aprendizaje utilizados, así como la evolución desde arquitecturas modulares clásicas hasta los últimos enfoques extremo a extremo (*end-to-end*), los cuales están ganando protagonismo en las investigaciones más recientes. Con este objetivo, se presenta una revisión sistemática de la literatura para ofrecer una visión consolidada del estado actual, identificar los avances más efectivos, señalar los desafíos que aún quedan abiertos y aportar una perspectiva sobre las líneas futuras de investigación más prometedoras.

El resto del artículo se estructura de la siguiente manera: la sección 2 describe los entornos no estructurados y el problema de la transitabilidad, la sección 3 compara los métodos convencionales frente a los métodos basados en IA, la sección 4 analiza la estimación de transitabilidad mediante técnicas de IA, y la sección 5 presenta las conclusiones y perspectivas futuras.

2. Los entornos no estructurados y el problema de la transitabilidad

Tradicionalmente, los avances en navegación autónoma se han consolidado principalmente en entornos estructurados. Estos entornos presentan una organización del escenario regular, con estructuras físicas bien definidas y por lo general patrones repetitivos. Ejemplos de entornos estructurados son carreteras, pasillos interiores, calles urbanas, etc. Las superficies de un entorno estructurado son mayoritariamente planas, con delimitaciones bien marcadas que favorecen a las tareas de percepción, localización y mapeo de los sistemas robóticos autónomos. Además, los elementos del escenario suelen tener posiciones permanentes y dimensiones fijas, facilitando operaciones de detección y evasión de obstáculos.

Los entornos no estructurados, a diferencia de los estructurados, carecen de regularidad geométrica y semántica, con superficies irregulares, obstáculos impredecibles y condiciones cambiantes en tiempo (Beycimen et al., 2023; Wijayathunga et al., 2023). Ejemplos de entornos no estructurados son bosques, zonas de desastre, terrenos rocosos, tierras agrícolas, etc. La naturaleza dinámica de los entornos no estructurados los convierte en escenarios altamente cambiantes, impredecibles e inestables, donde no es posible establecer una organización clara ni reglas evidentes de localización y navegación (Wijayathunga et al., 2023). En el contexto de la navegación 3D de vehículos autónomos terrestres, estos entornos suponen una serie de desafíos difíciles de superar con las arquitecturas convencionalmente desarrolladas (Shu et al., 2024; Borges et al., 2022), detallados a continuación:

- Percepción compleja: el reconocimiento del terreno transitable es complejo por la falta de patrones regulares y la presencia de obstáculos variables que pueden confundir a los sistemas de percepción (Guastella and Muscato, 2020; Wijayathunga et al., 2023).

- Localización compleja: la carencia de referencias estructurales persistentes y la escasa cobertura satelital en estas zo-

nas limitan la localización de los robots a partir de métodos clásicos como SLAM (Wijayathunga et al., 2023).

- Planificación compleja: los espacios transitables son muy dinámicos, requiriendo planificadores capaces de operar en tiempo real y en ausencia de mapas delimitados, generando rutas adaptativas a partir de una evaluación local del terreno (Zhu et al., 2020; Huang et al., 2024).

- Movilidad del robot difícil: las superficies de los entornos no estructurados son muy irregulares e inestables, suponiendo un reto para la tracción del vehículo autónomo, su equilibrio y locomoción (Papadakis, 2013). El riesgo de atasco o vuelco del robot es significativamente mayor, por lo que es necesario estrechar la integración entre la percepción del terreno y el control de los actuadores.

- Coste computacional elevado: navegar por estos entornos requiere grandes volúmenes de datos sensoriales multimodales, así como modelos complejos de IA, lo que conlleva un incremento significativo del coste computacional. Esto impone altas exigencias sobre el hardware embarcado y afecta a la eficiencia del software autónomo (Huang et al., 2024).

- Falta de datos etiquetados: el entrenamiento y validación de los modelos de IA están limitados por la variabilidad de estos escenarios, con una baja disponibilidad de datos etiquetados representativos (Sharma et al., 2022). La recolección de datos en entornos no estructurados es costosa y generalmente poco escalable.

En este contexto, el término transitabilidad, comúnmente mencionado en inglés como “*traversability*”, se refiere a la capacidad de un sistema para evaluar, de forma autónoma, las regiones del entorno desestructurado que pueden ser atravesadas de forma segura por el robot (Papadakis, 2013). La estimación de transitabilidad consiste en deducir las diferentes características del terreno, tales como la pendiente, rugosidad, nivel de obstáculos o deformabilidad a partir de la información sensorial captada por numerosos sensores, generalmente interpretada como nubes de puntos, imágenes segmentadas, mapas de elevación o mapas de ocupación (Shu et al., 2024). Estimar la transitabilidad en un entorno no estructurado no consiste solo en considerar la geometría del terreno, sino también las limitaciones físicas y dinámicas del propio robot, tales como su masa, tamaño, sistemas de locomoción, etc. (Arena et al., 2021). Para ello, además de evaluar la información fusionada de los diferentes sensores, es necesario aplicar técnicas avanzadas como modelados de superficie, Aprendizaje Automático o Redes Neuronales Artificiales que clasifiquen el escenario (Guastella and Muscato, 2020). La interpretación de la topología debe realizarse desde muchas perspectivas, teniendo siempre en cuenta el tipo de robot autónomo y sus sistemas de percepción y movilidad. Algunos robots con locomoción no tradicional requieren incluso considerar la interacción entre sus puntos de contacto y las propiedades físicas del terreno, haciendo aún más compleja la estimación de transitabilidad (Zhang et al., 2024b).

Los desafíos que presentan los entornos no estructurados y la alta complejidad de estimar su transitabilidad, han motivado la exploración de distintas soluciones adaptativas y basadas en IA, con un aprendizaje que permita la generalización a escenarios desconocidos (Yoon et al., 2024), manejando la ambigüedad sensorial y analizando el escenario más allá de reglas fijas o mapas predefinidos. Numerosos estudios destacan

la necesidad de combinar múltiples fuentes de información, como visión, LiDAR, IMU o GNSS para obtener representaciones más complejas y fieles con la realidad del entorno (Xu et al., 2023). En este sentido, la integración de datos en representaciones 3D densas o semánticas (Dabbiru et al., 2021) se ha convertido en un paso previo clave para facilitar la evaluación de transitabilidad en tiempo real.

3. Métodos convencionales frente a métodos basados en Inteligencia Artificial

La estimación de transitabilidad ha sido una tarea clave para la navegación autónoma desde sus inicios, específicamente en entornos no estructurados (Papadakis, 2013). Las condiciones en estos escenarios pueden variar de forma repentina y abrupta, requiriendo métodos alternativos que puedan solventar todos los problemas que presentan.

Tradicionalmente, estos métodos se han basado en reglas explícitas, heurísticas geométricas y análisis físicos del terreno, directamente a partir de datos sensoriales. Estas técnicas no incorporaban información adicional, como puede ser la dinámica del robot o un aprendizaje basado en la experiencia previa (Papadakis, 2013). Los métodos convencionales se apoyaban principalmente en un análisis de características del terreno y una serie de criterios predefinidos para la pendiente, rugosidad, curvatura o irregularidad de la superficie, determinando la viabilidad de atravesar cada zona. Estas técnicas presentan limitaciones ante escenarios dinámicos, donde la complejidad es mayor y la incertidumbre elevada. Como consecuencia, no son capaces de generalizar ante situaciones nuevas o ambiguas, ni tampoco pueden adaptarse a diferentes condiciones del entorno o morfologías distintas del robot móvil. No obstante, los métodos tradicionales han demostrado su utilidad en escenarios controlados, donde ciertos umbrales y funciones específicas establecidas minuciosamente han permitido la movilidad autónoma de plataformas móviles robotizadas. Estos métodos se clasifican generalmente en cuatro grandes grupos según sus enfoques para estimar la transitabilidad (Papadakis, 2013):

- Análisis propioceptivos: estos métodos se basan en la información directa proporcionada por varios sensores internos del robot, comúnmente acelerómetros, giroscopios o sensores de corriente. A partir de esta información sensorial, se deduce la dificultad de navegar cada región, infiriendo el comportamiento dinámico del vehículo. Generalmente, se interpretan como superficies no transitables aquellas donde las aceleraciones verticales, vibraciones o consumo de energía son elevados (Papadakis, 2013; Borges et al., 2022). Estos métodos son útiles para modelar la dificultad de tránsito del terreno bajo el vehículo, pero no permiten predecir información sobre zonas aún no exploradas, impidiendo una planificación proactiva.

- Análisis basados en geometría: estos métodos evalúan la transitabilidad del terreno calculando sus características geométricas, como la pendiente, rugosidad o presencia de obstáculos, a partir de información espacial de sensores LiDAR o cámaras estéreo. Partiendo de estas características, se elabora un mapa de costes para identificar qué zonas son accesibles o transitables por el vehículo, permitiendo la planificación de rutas eficientes y seguras, y evitando obstáculos y

terrenos difíciles de atravesar. Para ello, se utilizan herramientas matemáticas que transforman los datos del entorno a una representación más estructurada, destacando el algoritmo Normal Distributions Transform (NDT) (Ahtiainen et al., 2017). La mayoría de las metodologías tradicionales se basan en este tipo de análisis geométricos, y aunque pueden ofrecer una representación objetiva del entorno que rodea al robot, suelen requerir umbrales definidos manualmente y entornos poco deformables (Ahtiainen et al., 2017; Borges et al., 2022).

- Análisis basados en apariencia: estos métodos utilizan imágenes, generalmente de cámaras RGB o infrarrojas, para inferir la transitabilidad del terreno en función de patrones visuales, diferencia de texturas o incluso el color (Papadakis, 2013). Estos análisis proyectan el problema hacia el ámbito del procesamiento y clasificación de imágenes, evaluando un conjunto discreto de clases de terreno, en lugar de aplicar una regresión, como es común en otros enfoques. Los análisis basados en apariencia pueden ser eficaces en entornos estructurados o con cierta homogeneidad, pero son muy susceptibles a condiciones de iluminación variables. Además, en entornos donde el aspecto visual del terreno no esté directamente relacionado con su transitabilidad, estos métodos son muy inefficientes.

- Enfoques híbridos: como se ha analizado, los enfoques anteriores presentan grandes limitaciones individuales, pero estas pueden ser mitigadas combinándolos entre ellos. Varios estudios han explotado una buena complementariedad entre los sensores LiDAR y de visión, aumentando la robustez del sistema y mejorando su anticipación a obstáculos blandos o deformables. A pesar de que estos enfoques pueden mejorar la estimación general de transitabilidad en diferentes condiciones de funcionamiento, siguen dependiendo en gran medida de una definición manual de reglas y umbrales, y no aprenden de manera autónoma (Papadakis, 2013; Borges et al., 2022).

En contraste, los enfoques basados en Inteligencia Artificial permiten que los sistemas aprendan patrones de transitabilidad directamente de los datos, adaptándose mejor a la variabilidad del entorno y reduciendo la necesidad de intervención humana (Guastella and Muscato, 2020). La irrupción de técnicas de Aprendizaje Automático, y más concretamente del Aprendizaje Profundo (Lecun et al., 2015), ha revolucionado el análisis de transitabilidad en los siguientes aspectos:

- Generalización y robustez: el entrenamiento de Redes Neuronales Profundas a partir de conjuntos variados de datos permite generalizar el análisis de transitabilidad a nuevas condiciones del terreno, iluminación o meteorología, creando sistemas autónomos más flexibles capaces de operar establemente en entornos dinámicos (Guastella and Muscato, 2020).

- Adaptación autónoma a nuevas condiciones: algunos enfoques, como el propuesto recientemente por Yoon et al. (2024), integran mecanismos de aprendizaje continuo en línea que permiten una adaptación del sistema rápida y totalmente autónoma ante cambios tanto operacionales como del escenario, sin necesidad de supervisión por un agente humano.

- Modelado del riesgo e incertidumbre: en lugar de crear un mapa de costes binario e identificar cada región como “transitable” o “no transitable”, los modelos actuales permiten generar distribuciones de probabilidad o medidas de riesgo (Triest et al., 2024; Arena et al., 2021), más adecuadas para

escenarios inciertos y dinámicos como los presentados en entornos altamente desestructurados.

- Independencia de sensores específicos: algunos modelos actuales han demostrado funcionar con diferentes tipos de sensores como entrada, individual o conjuntamente, permitiendo la combinación de diferentes tecnologías para mejorar el rendimiento y la robustez del sistema en escenarios reales y ante condiciones altamente cambiantes (Beycimen et al., 2023).

La evolución desde los métodos convencionales a los enfoques basados en IA ha transformado el paradigma de estimación de transitabilidad (Shu et al., 2024; Guastella and Muscato, 2020). Hoy en día, el uso de IA no solo ha mejorado la precisión y adaptabilidad del sistema, sino que ha permitido incorporar semántica, contexto y experiencia pasada, abriendo nuevas posibilidades en la navegación autónoma en entornos 3D. Actualmente, se está apostando por arquitecturas híbridas que combinan lo mejor de ambos mundos, empleando técnicas de IA para estimar la transitabilidad en tiempo real y de forma robusta en entornos no estructurados, integrándose con estrategias clásicas (mapas de costes, planificaciones locales, etc.) para mejorar la precisión de la estimación y aumentar la capacidad adaptativa del vehículo autónomo (Xu et al., 2023).

4. Estimación de transitabilidad mediante técnicas de Inteligencia Artificial

La transformación de algoritmos tradicionales en sistemas basados en IA tiene como pilares el Aprendizaje Automático, particularmente el Aprendizaje Profundo, junto con la disponibilidad de grandes datasets (Sharma et al., 2022; Triest et al., 2022) y entornos de simulación avanzados (Vecchio et al., 2024; Chavez-Garcia et al., 2018). Las técnicas basadas en IA relacionan los datos sensoriales capturados con contextos específicos, habilitando tareas como segmentación semántica (Dabbiru et al., 2021; Xu et al., 2023), predicción de riesgos (Triest et al., 2024; Arena et al., 2021; Zhang et al., 2024a; Triest et al., 2023) y planificación de rutas de forma dinámica y adaptable (Yoon et al., 2024; Wijayathunga et al., 2023). Estas aproximaciones mejoran la eficiencia de la estimación de transitabilidad en entornos desestructurados, gracias a nuevos paradigmas de Aprendizaje Automático con enfoques supervisados, no supervisados, por refuerzo inverso y métodos híbridos, sirviendo de base para sistemas modulares o *end-to-end*.

El Aprendizaje Supervisado ha sido el paradigma para entrenar modelos de estimación a partir de datos etiquetados (Shu et al., 2024; Guastella and Muscato, 2020; Sevastopoulos and Konstantopoulos, 2022). La información para el entrenamiento proviene principalmente de nubes de puntos LiDAR (Ahtiainen et al., 2017; Ruetz et al., 2024) o imágenes RBB/RGB-D (Castro et al., 2022; Triest et al., 2024; Visca et al., 2021). Estos modelos se basan en su entrenamiento previo para identificar características geométricas del terreno y generar mapas de transitabilidad binarios o probabilísticos. Algunos trabajos recientes, incluyen tareas de clasificación semántica para identificar diferentes tipos de objeto en el entorno, y así valorar mejor la transitabilidad sobre estos (Dabbiru et al., 2021; Xu et al., 2023). En este contexto, son comunes las Redes Neuronales Convolucionales (CNNs, del inglés *Convolutional Neural Networks*), con trabajos como

el de Visca et al. (2021) que abordan el problema de estimación de transitabilidad a través de clasificación de imágenes. Arquitecturas más complejas, emplean autoencoders en tareas de segmentación densa, prediciendo la transitabilidad para cada pixel o punto del entorno (Shu et al., 2024; Hirose et al., 2018). Por otro lado, las Redes Neuronales Gráficas (GNNS, del inglés *Graph Neural Networks*) han permitido procesar directamente nubes de puntos no estructuradas, preservando su información tridimensional sin necesidad de proyecciones que puedan implicar la pérdida de alguna información (Borges et al., 2022). Todos estos modelos cuyo aprendizaje es supervisado requieren de una gran cantidad de datos etiquetados. Esto es un problema en entornos 3D no estructurados, ya que su adquisición tiene un alto coste y complejidad, y es por esto que estudios recientes se basan en otras técnicas de aprendizaje más eficientes. Aun así, iniciativas como el dataset Tartan-Drive (Triest et al., 2022) o CaT (Sharma et al., 2022), presentan valiosas aportaciones que buscan mitigar esta limitación, proporcionando datos de alta calidad en entornos todoterreno.

Para reducir la dependencia de etiquetar manual y masivamente datos capturados en entornos desestructurados, otras aproximaciones han recurrido al Aprendizaje No Supervisado y Auto-Supervisado (Shu et al., 2024; Guastella and Muscato, 2020). En este caso, se utilizan métodos tradicionales, como el “clustering” o “autoencoders” para buscar correlaciones entre los datos sensoriales capturados y la transitabilidad del escenario, a partir de la identificación de patrones recurrentes en el terreno sin etiquetas explícitas (Shu et al., 2024; Sevastopoulos and Konstantopoulos, 2022). Los últimos enfoques con Aprendizaje Auto-Supervisado se basan en generar automáticamente las etiquetas directamente a partir de los datos de entrada, utilizando heurísticas o información espacio-temporal intrínseca. Por ejemplo, Yoon et al. (2024) han desarrollado un sistema adaptativo de estimación de transitabilidad basado en un aprendizaje continuo online y auto-supervisado, demostrando una gran adaptabilidad del robot en entornos no estructurados variables. Por otro lado, trabajos como el de Seo et al. (2023), con “ScaTE”, presentan marcos escalables de Aprendizaje Auto-Supervisado para la estimación de transitabilidad desde la experiencia de conducción real, específica al vehículo. Otro avance clave de estos enfoques no supervisados es la transferencia del conocimiento de dominios sintéticos (fácilmente etiquetables) a dominios reales, como demuestran Vecchio et al. (2024) usando datos sintéticos y Aprendizaje Auto-Supervisado. Saucedo et al. (2024) con EAT también apuntan a una adaptabilidad agnóstica al entorno.

El Aprendizaje por Refuerzo también ha emergido como una herramienta poderosa para la toma de decisiones en entornos altamente dinámicos e inciertos. En estos entornos, la transitabilidad no es una simple propiedad estática del terreno, sino que también puede depender de las propias acciones del sistema robótico y su interacción con el entorno (Guastella and Muscato, 2020; Zhu et al., 2020). Debido a esto, los enfoques de Aprendizaje por Refuerzo, en lugar de buscar una relación directa entre los datos sensoriales y la transitabilidad, aprenden diferentes estrategias de actuación para maximizar una señal de recompensa acumulada a lo largo del tiempo. Esta recompensa puede diseñarse para incentivar una navegación segura, eficiente y orientada a objetivos específicos. Zhu et al. (2020) utilizan Aprendizaje por Refuerzo Inverso para no

solo analizar la transitabilidad del terreno, sino también para planificar las trayectorias de tránsito más seguras en vehículos autónomos todoterreno. En este caso, el robot aprende la función de coste a partir de demostraciones previas. De forma similar, Triest et al. (2023) generan mapas de costes conscientes del riesgo de tránsito por cada región del escenario. Arena et al. (2021) también proponen modelos orientados al robot para crear mapas de transitabilidad mediados por el riesgo en terrenos 3D no estructurados. Estos enfoques permiten integrar la percepción de transitabilidad con el ciclo posterior de planificación y control, optimizando el comportamiento del sistema y avanzando en la arquitectura de navegación autónoma.

Sobre estos fundamentos, las técnicas basadas en IA para la estimación de transitabilidad pueden estructurarse de manera modular o mediante arquitecturas *end-to-end*. El enfoque modular ha sido tradicionalmente más adoptado en sistemas robóticos reales (Papadakis, 2013; Beycimen et al., 2023), debido a su mayor control y comprensibilidad. En estos sistemas, la estimación de transitabilidad es un bloque dentro de una arquitectura de navegación más larga que puede incluir percepción, segmentación, clasificación, planificación y decisión (Ruetz et al., 2024; Dabbiru et al., 2021). Por ejemplo, Dabbiru et al. (2021) realizan segmentación semántica antes de estimar la transitabilidad, donde la segmentación forma parte de un módulo anterior al de estimación. En otro estudio, Song and Jo (2015) emplean un método de “super-vóxelles” para la clasificación de transitabilidad, que también es una forma de pre-procesamiento modular. Por otro lado, Xu et al. (2023) fusionan características semánticas y geométricas, cuya implementación debe ser modular. La principal ventaja de los sistemas modulares radica en su interpretabilidad y en la posibilidad de optimizar cada componente de forma independiente. Esto facilita su integración con otros módulos de navegación clásicos como SLAM o controladores reactivos (Beycimen et al., 2023; Borges et al., 2022). Sin embargo, esta segmentación suele introducir errores de acoplamiento entre distintos bloques funcionales, limitando la capacidad del sistema y pudiendo sufrir propagación de errores entre módulos (Guastella and Muscato, 2020; Sevastopoulos and Konstantopoulos, 2022).

En respuesta a estas limitaciones, en los últimos años se ha tendido hacia arquitecturas *end-to-end*, en las que se entrena un único bloque capaz de inferir la transitabilidad, o incluso comandos de control del vehículo, directamente a partir de las entradas sensoriales en bruto, sin necesidad de preprocesarlas ni realizar una segmentación modular del modelo. Estos enfoques han demostrado un gran potencial gracias al auge de las Redes Neuronales Profundas, especialmente las arquitecturas Convolucionales y Recurrentes. Las Redes Profundas *end-to-end* permiten representar jerárquicamente las características de forma automática, eliminando o encapsulando los módulos intermedios tradicionales (Triest et al., 2024; Visca et al., 2021). Esto favorece a la optimización conjunta de todo el modelo, conduciendo a un rendimiento superior en escenarios complejos y altamente desestructurados, en los que las interacciones son muy impredecibles y prácticamente imposibles de modelar (Arena et al., 2021). Chavez-Garcia et al. (2018) exploran el aprendizaje de la transitabilidad del terreno a partir de simulaciones, un enfoque adecuado para arquitecturas *end-*

to-end ya que pueden ser entrenadas con grandes volúmenes de datos sintéticos y luego transferidas o adaptadas al mundo real, como también discuten Vecchio et al. (2024). El principal inconveniente de estos enfoques reside en su menor interpretabilidad y en el riesgo de sobreajuste, especialmente cuando los datos de entrenamiento no cubren suficientemente la diversidad del entorno. Debido a esto, la utilización de datos reales, provenientes de diversos sensores ricos en información, como LiDAR, cámaras estéreo o térmicas, es fundamental para el éxito de estos modelos.

En resumen, los enfoques basados en IA para la estimación de transitabilidad están configurando un nuevo paradigma en el ámbito de la navegación autónoma, superando muchas de las limitaciones de los métodos tradicionales. Si bien cada estrategia presenta ventajas e inconvenientes específicos, la tendencia actual se dirige hacia la integración de modelos multimodales, con la aparición de arquitecturas *end-to-end* que tienen una gran capacidad de generalización y adaptación. El desafío pendiente reside en garantizar la robustez, interpretabilidad y transferibilidad de estos modelos a entornos reales altamente variables, con condiciones adversas y considerando las restricciones computacionales de las plataformas actuales.

5. Conclusiones y perspectivas futuras

Este trabajo ha ofrecido una revisión exhaustiva sobre los avances en el problema de la estimación de transitabilidad en entornos 3D no estructurados, abarcando desde enfoques tradicionales hasta métodos modernos basados en técnicas avanzadas de Inteligencia Artificial. Estas técnicas de Aprendizaje Profundo han superado las limitaciones previas de los anteriores métodos, permitiendo una segmentación semántica del entorno y una mayor capacidad para generalizar a escenarios previamente desconocidos y altamente dinámicos. Con la aplicación de estos enfoques se ha observado un salto cualitativo en la capacidad de los sistemas autónomos para estimar regiones transitables de forma robusta, con paradigmas de entrenamiento cada vez más eficientes como el Aprendizaje por Refuerzo Inverso o el Auto-Supervisado.

Entre los enfoques actuales, las arquitecturas *end-to-end* han destacado por su capacidad para aprender directamente de los datos sensoriales en bruto, ofreciendo mejoras de rendimiento y adaptabilidad, con una estructura mucho menos compleja que elimina la necesidad de componentes intermedios explícitos. No obstante, la complejidad de interpretar estos modelos y la dificultad para obtener grandes volúmenes de datos de entrenamiento, aún presentan desafíos por superar.

Como líneas futuras de investigación, se propone profundizar en el desarrollo de sistemas *end-to-end* más interpretables. Una forma de aumentar su interpretabilidad podría ser mediante arquitecturas híbridas que puedan integrar algún módulo explícito dentro del flujo de procesamiento, con el objetivo de aumentar la transparencia en su toma de decisiones. Es necesario también buscar nuevas formas de entrenamiento que reduzcan la dependencia de grandes conjuntos de datos etiquetados, con técnicas como el Aprendizaje Auto-Supervisado o a través de simulaciones realistas. Siguiendo esta línea, la expansión de estos modelos hacia la percepción multimodal y su integración con el control activo del vehículo

es una vía prometedora para alcanzar una navegación robusta y eficiente en terrenos 3D no estructurados.

Agradecimientos

Este trabajo ha sido realizado parcialmente gracias al apoyo de las subvenciones PID2021-124335OB-C21 y PID2022-140554OB-C32 financiadas por MCI-N/AEI/10.13039/501100011033, los proyectos TEC-2024/ECO-277 y TEC-2024/TEC-102 financiados por la Comunidad de Madrid y el Programa de Investigación Predocoral en Formación en Inteligencia Artificial (PIPF-IA) de la Universidad Carlos III de Madrid.

Referencias

- Ahtiainen, J., Stoyanov, T., Saarinen, J., 5 2017. Normal Distributions Transform Traversability Maps: LIDAR-Only Approach for Traversability Mapping in Outdoor Environments. *Journal of Field Robotics* 34 (3), 600–621. DOI: 10.1002/ROB.21657
- Arena, P., Patanè, L., Taffara, S., 10 2021. Learning risk-mediated traversability maps in unstructured terrains navigation through robot-oriented models. *Information Sciences* 576, 1–23. DOI: 10.1016/J.INS.2021.06.007
- Beycimen, S., Ignat'yev, D., Zolotas, A., 11 2023. A comprehensive survey of unmanned ground vehicle terrain traversability for unstructured environments and sensor technology insights. *Engineering Science and Technology, an International Journal* 47, 101457. DOI: 10.1016/J.JESTCH.2023.101457
- Borges, P. V. K., Peynot, T., Liang, S., Arain, B., Wildie, M., Minareci, M. G., Lichman, S., Samvedi, G., Sa, I., Hudson, N., Milford, M., Moghadam, P., Corke, P., 2022. A Survey on Terrain Traversability Analysis for Autonomous Ground Vehicles: Methods, Sensors, and Challenges. DOI: 10.55417/fr.2022049
- Castro, M. G., Triest, S., Wang, W., Gregory, J. M., Sanchez, F., Rogers, J. G., Scherer, S., 9 2022. How Does It Feel? Self-Supervised Costmap Learning for Off-Road Vehicle Traversability. *Proceedings - IEEE International Conference on Robotics and Automation 2023-May*, 931–938. DOI: 10.1109/ICRA48891.2023.10160856
- Chavez-Garcia, R. O., Guzzi, J., Gambardella, L. M., Giusti, A., 7 2018. Learning Ground Traversability from Simulations. *IEEE Robotics and Automation Letters* 3 (3), 1695–1702. DOI: 10.1109/LRA.2018.2801794
- Dabbiru, L., Sharma, S., Goodin, C., Ozier, S., Hudson, C. R., Carruth, D. W., Doude, M., Mason, G., Ball, J. E., 4 2021. Traversability mapping in off-road environment using semantic segmentation. <https://doi.org/10.1117/12.2587661> 11748, 78–83. DOI: 10.1117/12.2587661
- Guastella, D. C., Muscato, G., 12 2020. Learning-Based Methods of Perception and Navigation for Ground Vehicles in Unstructured Environments: A Review. *Sensors* 2021, Vol. 21, Page 73 21 (1), 73. DOI: 10.3390/S21010073
- Hirose, N., Sadeghian, A., Vazquez, M., Goebel, P., Savarese, S., 2018. GO-Net: A Semi-Supervised Deep Learning Approach for Traversability Estimation. *IEEE International Conference on Intelligent Robots and Systems*, 3044–3051. DOI: 10.1109/IROS.2018.8594031
- Huang, T., Wang, G., Liu, H., Luo, J., Wu, L., Zhu, T., Pu, H., Wang, S., 2024. A Framework for Real-time Generation of Multi-directional Traversability Maps in Unstructured Environments. *Proceedings - IEEE International Conference on Robotics and Automation*, 18370–18376. DOI: 10.1109/ICRA57147.2024.10610312
- Lecun, Y., Bengio, Y., Hinton, G., 5 2015. Deep learning. *Nature* 521 (7553), 436–444. DOI: 10.1038/NATURE14539
- Papadakis, P., 4 2013. Terrain traversability analysis methods for unmanned ground vehicles: A survey. *Engineering Applications of Artificial Intelligence* 26 (4), 1373–1385. DOI: 10.1016/J.ENGAPPAI.2013.01.006
- Ruetz, F. A., Lawrence, N., Hernández, E., Borges, P. V., Peynot, T., 2024. ForestTrav: 3D LiDAR-Only Forest Traversability Estimation for Autonomous Ground Vehicles. *IEEE Access* 12, 37192–37206. DOI: 10.1109/ACCESS.2024.3373004
- Saucedo, M. A., Patel, A., Kanellakis, C., Nikolakopoulos, G., 6 2024. EAT: Environment Agnostic Traversability for reactive navigation. *Expert Systems with Applications* 244, 122919. DOI: 10.1016/J.ESWA.2023.122919
- Seo, J., Kim, T., Kwak, K., Min, J., Shim, I., 2 2023. ScaTE: A Scalable Framework for Self-Supervised Traversability Estimation in Unstructured Environments. *IEEE Robotics and Automation Letters* 8 (2), 888–895. DOI: 10.1109/LRA.2023.3234768
- Sebastopoulos, C., Konstantopoulos, S., 2022. A Survey of Traversability Estimation for Mobile Robots. *IEEE Access* 10, 96331–96347. DOI: 10.1109/ACCESS.2022.3202545
- Sharma, S., Dabbiru, L., Hannis, T., Mason, G., Carruth, D. W., Doude, M., Goodin, C., Hudson, C., Ozier, S., Ball, J. E., Tang, B., 2022. CaT: CAVS Traversability Dataset for Off-Road Autonomous Driving. *IEEE Access* 10, 24759–24768. DOI: 10.1109/ACCESS.2022.3154419
- Shu, Y., Dong, L., Liu, J., Liu, C., Wei, W., 2024. Overview of Terrain Traversability Evaluation for Autonomous Robots. *Journal of Field Robotics*. DOI: 10.1002/ROB.22461; WGROUP:STRING:PUBLICATION
- Song, S., Jo, S., 2015. Traversability Classification Using Super-voxel Method in Unstructured Terrain. *Advances in Intelligent Systems and Computing* 345, 595–604. DOI: 10.1007/978-3-319-16841-8_53
- Triest, S., Castro, M. G., Maheshwari, P., Sivaprakasam, M., Wang, W., Scherer, S., 1 2023. Learning Risk-Aware Costmaps via Inverse Reinforcement Learning for Off-Road Navigation. *Proceedings - IEEE International Conference on Robotics and Automation 2023-May*, 924–930. DOI: 10.1109/ICRA48891.2023.10161268
- Triest, S., Sivaprakasam, M., Aich, S., Fan, D. D., Wang, W., Scherer, S., 2024. Velociraptor: Leveraging Visual Foundation Models for Label-Free, Risk-Aware Off-Road Navigation.
- Triest, S., Sivaprakasam, M., Wang, S. J., Wang, W., Johnson, A. M., Scherer, S., 5 2022. TartanDrive: A Large-Scale Dataset for Learning Off-Road Dynamics Models. *Proceedings - IEEE International Conference on Robotics and Automation*, 2546–2552. DOI: 10.1109/ICRA46639.2022.9811648
- Vecchio, G., Palazzo, S., Guastella, D. C., Giordano, D., Muscato, G., Spampinato, C., 4 2024. Terrain traversability prediction through self-supervised learning and unsupervised domain adaptation on synthetic data. *Autonomous Robots* 48 (2), 1–19. DOI: 10.1007/S10514-024-10158-4/FIGURES/14
- Visca, M., Kuutti, S., Powell, R., Gao, Y., Fallah, S., 5 2021. Deep Learning Traversability Estimator for Mobile Robots in Unstructured Environments. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 13054 LNAI, 203–213. DOI: 10.1007/978-3-030-89177-0_22
- Wijayathunga, L., Rassau, A., Chai, D., 8 2023. Challenges and Solutions for Autonomous Ground Robot Scene Understanding and Navigation in Unstructured Outdoor Environments: A Review. *Applied Sciences* 2023, Vol. 13, Page 9877 13 (17), 9877. DOI: 10.3390/APP13179877
- Xu, C., Zhang, B., Qiu, J., He, Z., 2023. An Unstructured Terrain Traversability Mapping Method Fusing Semantic and Geometric Features. *Proceedings of 2023 IEEE International Conference on Unmanned Systems, ICUS 2023*, 1142–1147. DOI: 10.1109/ICUS58632.2023.10318412
- Yoon, H. S., Hwang, J. H., Kim, C., Son, E. I., Yoo, S. W., Seo, S. W., 6 2024. Adaptive Robot Traversability Estimation Based on Self-Supervised Online Continual Learning in Unstructured Environments. *IEEE Robotics and Automation Letters* 9 (6), 4902–4909. DOI: 10.1109/LRA.2024.3386451
- Zhang, B., Li, G., Zhang, J., Bai, X., 12 2024a. A reliable traversability learning method based on human-demonstrated risk cost mapping for mobile robots over uneven terrain. *Engineering Applications of Artificial Intelligence* 138, 109339. DOI: 10.1016/J.ENGAPPAL.2024.109339
- Zhang, H., Li, Z., Zeng, X., Smith, L., Stachowicz, K., Shah, D., Yue, L., Song, Z., Xia, W., Levine, S., Sreenath, K., Liu, Y.-h., 10 2024b. Traversability-Aware Legged Navigation by Learning from Real-World Visual Data.
- Zhu, Z., Li, N., Sun, R., Xu, D., Zhao, H., 2020. Off-road Autonomous Vehicles Traversability Analysis and Trajectory Planning Based on Deep Inverse Reinforcement Learning. *IEEE Intelligent Vehicles Symposium, Proceedings*, 971–977. DOI: 10.1109/IV47402.2020.9304721