



Isdefe



Universidad de Jaén

Informes de Prospectiva 2024

Cátedra Isdefe/CETEDEX-UJA



RED HORIZONTES ISDEFE
Madrid, 18 de noviembre de 2024

TABLA DE CONTENIDOS

1. PROCESAMIENTO DEL LENGUAJE NATURAL – RECUPERACIÓN DE INFORMACIÓN AUMENTADA	3
2. SISTEMAS DE IDENTIFICACIÓN DE OBJETOS Y DETECCIÓN DE ANOMALÍAS MEDIANTE IMÁGENES DE SATÉLITE Y CENITALES	14
3. LOCALIZACIÓN SOBRE CARTOGRAFÍA EN ENTORNOS NO ESTRUCTURADOS Y CON GNSS DENEGADO	31
4. SISTEMAS DE IDENTIFICACIÓN Y CLASIFICACIÓN DE AMENAZAS DRON EN IMAGEN	41
5. TRANSMISIÓN DE ENERGÍA EN LA ATMÓSFERA USANDO LÁSERES DE ALTA POTENCIA	62
6. GENERACIÓN DE RUTAS TRANSITABLES POR ROBOTS A PARTIR DE MODELOS 3D EN ESCENARIOS NO ESTRUCTURADOS	81



Procesamiento del Lenguaje Natural – Recuperación de Información Aumentada

Informe de Prospectiva 2024



TABLA DE CONTENIDOS

1. INTRODUCCIÓN.....	5
2. PROCESAMIENTO DEL LENGUAJE NATURAL.....	5
2.1. Recuperación de Información Aumentada (RAG).....	8
3. ESCENARIO DE APLICACIÓN DE LA RECUPERACIÓN DE INFORMACIÓN AUMENTADA.....	9
4. CONCLUSIONES.....	11
5. ANEXOS.....	12
5.1. Referencias.....	12
5.2. Acrónimos.....	13

1. INTRODUCCIÓN

El objetivo del presente informe de prospectiva es el de exponer por un lado el potencial del área de conocimiento tras la inteligencia artificial generativa, el procesamiento del lenguaje natural, y por otro el de describir la tarea de recuperación de información aumentada, el cual constituye una de las aplicaciones más destacadas de los grandes modelos de lenguaje. Así mismo, se describirá un escenario de aplicación de esta tecnología asociado al proyecto de la cátedra Isdefe/CETEDEX-UJA.

2. PROCESAMIENTO DEL LENGUAJE NATURAL

El PLN es el área de la inteligencia artificial (IA) centrada en el estudio, diseño y desarrollo de metodologías y métodos computacionales orientados al entendimiento y generación de lenguaje humano [1]. El PLN cuenta con un amplio abanico de aplicaciones, que se podría resumir en todo aquel caso de uso en el que intervenga el lenguaje humano.

El PLN surge como una de las primeras aplicaciones de la IA, entendida esta simplemente como la automatización de tareas exclusivas humanas. Esta primera aplicación fue la de traducción automática, que surgió en el contexto de la Guerra Fría ante la necesidad de traducir textos escritos en ruso al inglés, objetivo en el que se trabajó en el proyecto Georgetown-IBM [2] y que se presentó en el año 1954. Desde entonces el PLN ha experimentado un progreso inconmensurable, en el que se identifican varias etapas: (1) centrado en el desarrollo de capas software para posibilitar interfaces en lenguaje natural para el acceso a bases de datos (años 70); (2) protagonismo de la lingüística (años 80); (3) una evolución complicada hacia una PLN basado en datos y probabilístico por la dificultad de la creación de recursos lingüísticos (años 90-2010) y (4) evolución en todas las tareas a través del potencial de la representación por *word embeddings* y de los métodos basados en *deep learning* (años 2010-2018).

Actualmente el PLN está viviendo una nueva época en la que está liderando y es el protagonista de todos los avances que se están produciendo en IA. Esta fase se podría considerar anunciada en 2016 por el CEO de Microsoft Satya Nadella cuando dijo: *human language is the new user interface*. Se podría pensar que era una vuelta al pasado, pero cuando antes solo se desarrollaron modelos de transformación de lenguaje natural para escenarios muy concretos de acceso a bases de datos, en este caso el fin que se pronosticaba sí era realmente permitir la comunicación hombre-máquina a través del lenguaje natural, capacitando a las máquinas para el entendimiento y la generación de lenguaje natural. Aunque en la habilidad para entender el lenguaje se había logrado grandes avances gracias a los modelos de *deep learning*, la generación de lenguaje totalmente independiente de una tarea concreta se consideraba aún una quimera o al menos una tarea muy complicada. La aparición de los primeros grandes modelos de lenguaje (LLM) o modelos generativos, como es el caso de GPT-1 en 2018 [3], comenzó a tornar en posible lo que parecía imposible unos años atrás. Desde 2018, los distintos LLMs que se han publicado han aumentado sus capacidades, siendo cada vez más patente su habilidad para entender lenguaje humano y para generarlo, llegando a convertir en dificultosa la distinción entre lenguaje generado automáticamente y el escrito por un humano. La figura 1 muestra la evolución de los LLMs y representa la incesante aparición de nuevos modelos con una cada vez mayor habilidad de comprensión y generación de lenguaje.

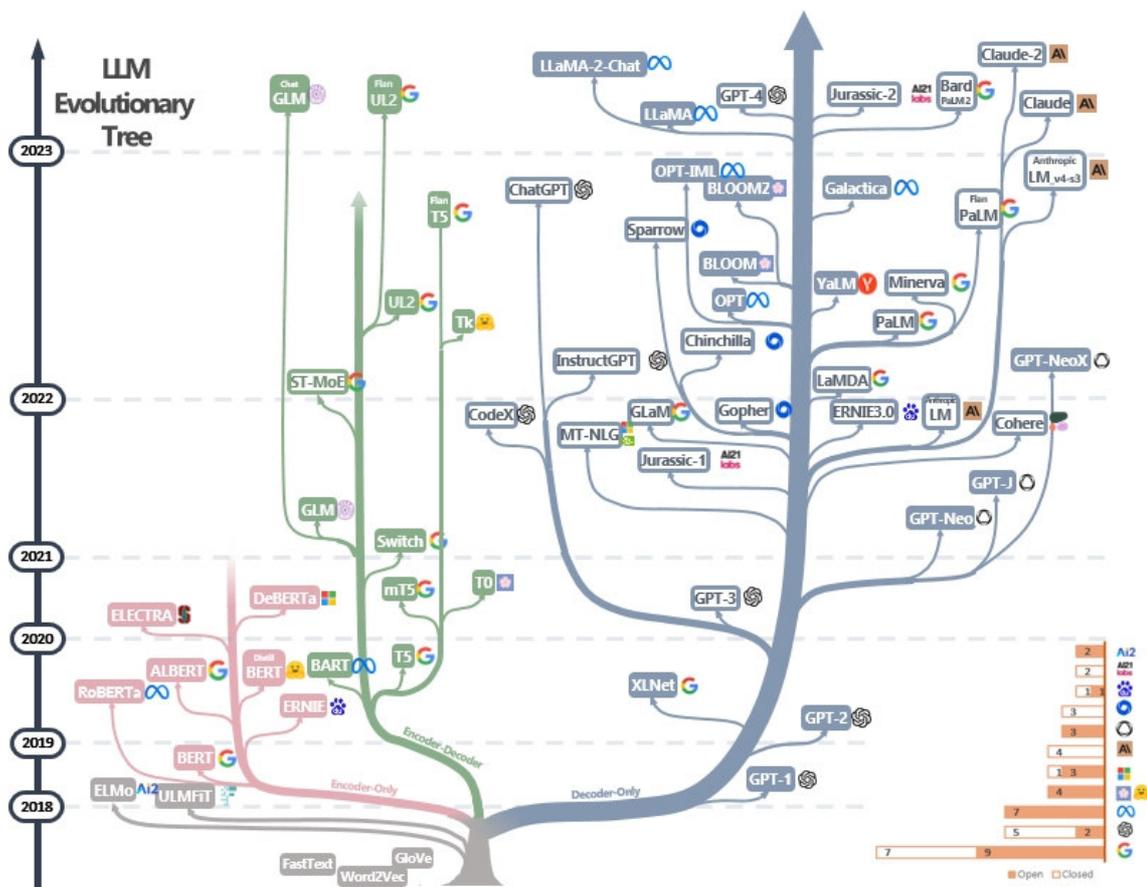


Figura 1: Representación de la evolución de los LLMs.

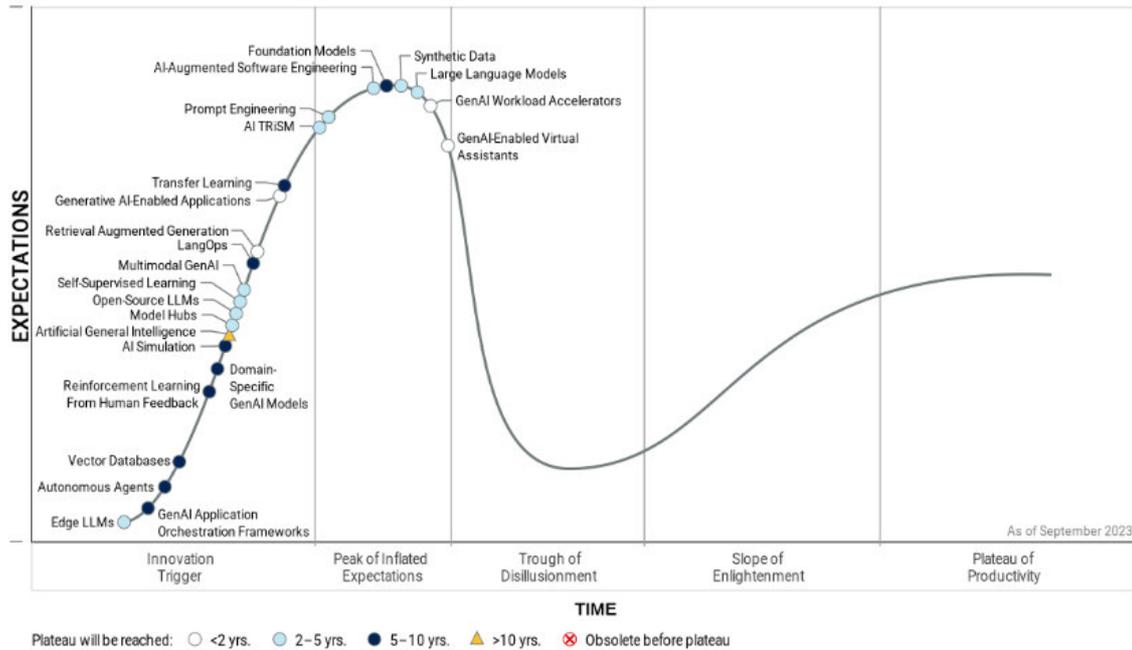
Los LLMs, y de un modo más general, los modelos fundacionales [4], son los responsables de la gran evolución de la IA, de que esta sea el principal avance tecnológico de los últimos años, y de que la IA haya traspasado los despachos académicos para convertirse en una tecnología más a emplear para el desarrollo humano. Este hecho es perceptible incluso en los análisis sobre las tecnologías disruptivas en los próximos años, las cuales estarán basadas en LLMs y modelos generativos. Uno de estos estudios es el de la consultora Gartner, la cual en su informe “Hype Cycle for Emerging Technologies” incluye a la IA generativa basada en LLMs y en modelos fundacionales, y al PLN como tecnologías disruptivas en los próximos años.¹ Gartner también afirmó el pasado octubre de 2023, que en 2026 el 80% de las compañías habrán usado algún sistema basado en modelos generativos. Así mismo, predice que los LLM serán la base del 60% de los sistemas de PLN en 2027, evidenciando el prometedor desarrollo del PLN y de los LLMs.² La figura 2 muestra la predicción en cuanto a interés innovador de las aplicaciones y tecnologías relacionadas con el PLN y con los modelos generativos. Se puede comprobar que los sistemas de recuperación de información aumentada (*retrieval augmented generation*, RAG) tiene aún camino por recorrer hasta llegar al máximo nivel de innovación.

La evolución del nivel de inversión en un área de investigación y en una tecnología es otro indicador del grado de desarrollo futuro de la misma. En septiembre de 2023, el portal de estudios de mercado Market and Markets publicó un análisis prospectivo sobre el mercado relacionado con el PLN. En concreto, se prevé que pase de un valor de 18,9 mil millones de dólares a un valor de 68,1 mil millones de dólares en

¹ <https://www.gartner.com/en/articles/what-s-new-in-the-2023-gartner-hype-cycle-for-emerging-technologies> [Consultado: 16/04/2024].

² <https://www.gartner.com/en/newsroom/press-releases/2023-10-11-gartner-says-more-than-80-percent-of-enterprises-will-have-used-generative-ai-apis-or-deployed-generative-ai-enabled-applications-by-2026#:~:text=Gartner%20predicts%20that%20by%202027,fewer%20t> [Consultado: 16/04/2024].

2028, es decir, un crecimiento de casi un 30% en cinco años. El mercado donde el PLN va a experimentar un mayor crecimiento es en el estadounidense (v. figura 3).



Gartner

Figura 2: Predicción de evolución desde el punto de vista de la innovación de los LLMs y otras tecnologías relacionadas con el PLN. Fuente: Gartner, octubre de 2023.

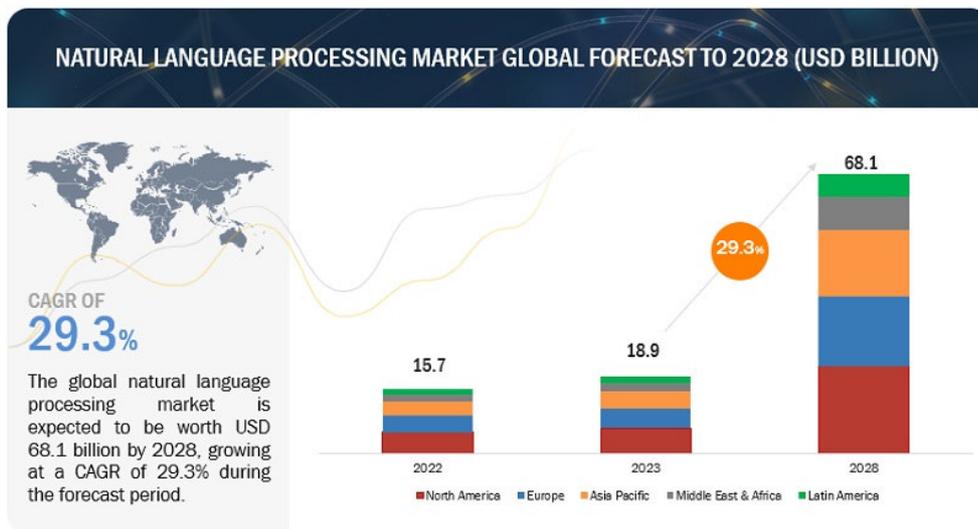


Figura 3: Predicción de la evolución del mercado relacionado con el PLN.

2.1. RECUPERACIÓN DE INFORMACIÓN AUMENTADA (RAG)

Al igual que el PLN, los sistemas RAG cuentan con un presente y con un futuro prometedor debido al amplio espectro de casos de uso en los que se pueden aplicar. Los RAG surgieron como una estrategia para aprovechar la capacidad de consulta de conocimiento de los LLMs y de reducir el número de errores por alucinación. Esto ha llevado a la propuesta de diferentes esquemas de RAG, que se muestran en la figura 4. Así mismo, todavía tienen que superar una serie de retos, lo que es un indicativo de su aún capacidad de innovación y progresión, y en particular son: (1) poder procesar contextos de búsqueda más amplios; (2) superar la dificultad de contar con información imprecisa, con el fin de que sean más robustos; (3) mejorar la precisión mediante el uso de *fine-tuning*; (4) aplicarlo en un mayor número de casos de uso; (5) mejorar la eficiencia a través de la reducción del tamaño de los LLMs base y (6) mejorar su despliegue en entornos de producción, debido principalmente a su alto coste computacional.

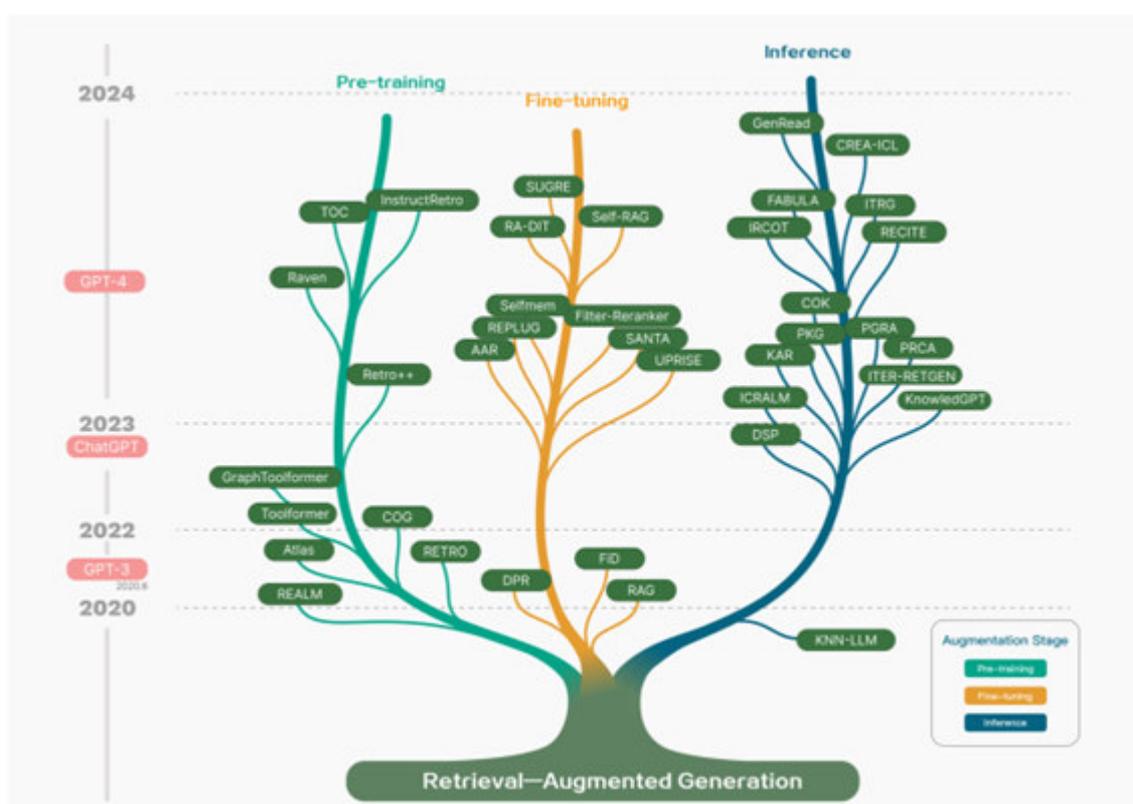


Figura 4: Representación de la evolución de la tecnología basada en RAG. Fuente [5].

El potencial de los sistemas basados en RAG se encuentra en su capacidad de ajustar los LLMs a un determinado dominio, o a una información específica. Esto permite su aplicación en una gran variedad de casos de uso, lo cual evidencia su poder aún de desarrollo e implantación en distintos sectores económicos, como, por ejemplo:

1. **Análisis financiero.** La habilidad de recuperación de información y generación de una respuesta ajustada de los RAGs será muy beneficiosa para este tipo de tarea en la que la información es clave para la toma de decisiones.
2. **Salud.** Los RAGs permitirán combinar de forma adecuada la información del paciente con casos previos, de forma que se ofrezca al médico información útil para facilitar sus tareas, como puede ser el diagnóstico de enfermedades.

3. **Derecho.** Facilitará a estos profesionales el acceso a información tanto legislativa como de sentencias pasadas con el fin de facilitar su tarea.
4. **Educación.** Los RAGs permiten el desarrollo de sistemas de asistencia o *bots* para los estudiantes, mediante la correcta combinación de libros de texto y otras fuentes de información de interés.
5. **Creación de contenidos.** El poder de adaptar el comportamiento de los LLMs a un determinado dominio, habilita a los RAGs como la tecnología más adecuada para la generación de contenido orientados a una determinada población.
6. **Servicio al consumidor y análisis de mercados.** Posibilitan el desarrollo de *bots* adaptados a un determinado tipo de cliente y a un específico conjunto de productos.

Cada uno de estos posibles casos de uso muestran la versatilidad de los RAGs, y su más que robusta capacidad de innovación, crecimiento y aplicación.

3. ESCENARIO DE APLICACIÓN DE LA RECUPERACIÓN DE INFORMACIÓN AUMENTADA

La arquitectura o sistemas basados en RAG se están convirtiendo en una solución factible a un amplio número de retos relacionados con el procesamiento del lenguaje. Un problema que en un principio no pareciera resolverse con una arquitectura de recuperación de información aumentada, como es la extracción de definiciones asociadas a un concepto dado y que ha sido afrontado en proyecto “Obtención de definiciones de términos relevantes encontrados en documentos en formato pdf”, de aquí en adelante DefRAG, de la cátedra Isdefe/CETEDEx-UJA, también se ha comprobado que puede encararse con una solución basada en RAG. No obstante, se han estudiado diversas alternativas hasta desarrollar la definitiva basada en recuperación de información aumentada.

La extracción de definiciones es una tarea compleja que ha atraído a la comunidad de investigación de PLN desde hace bastante tiempo [6], representando este alto interés la organización en 2020 de una competición específica de este tipo de sistemas en el foro de investigación SemEval 2020 [7]. En particular, la tarea se define como la identificación del extracto de texto que se corresponde con la explicación de un concepto. Como se ha indicado previamente, la respuesta al desafío no puede ceñirse a identificar las palabras alrededor de la mención del concepto objetivo, sino que tiene que ser aquel que presente el patrón sintáctico asociado a una definición.

La tarea suele abordarse como un problema de clasificación binaria, de forma que se estudia si un fragmento de texto puede o no ser una definición del concepto indicado. Las primeras aproximaciones estaban basadas en el uso de patrones léxicos y sintácticos, tratando de identificar los fragmentos de texto ligados al patrón “es” o “refiere a” [8, 9]. El siguiente hito en la evolución de la tarea estuvo conectado con la publicación de conjuntos de datos de conceptos con sus definiciones. Esto permitió el diseño y desarrollo de métodos de aprendizaje automático con la capacidad de identificar la estructura sintáctica de una definición, y así poder generalizar y encontrar definiciones de conceptos desconocidos. El primer conjunto de datos de estas características fue World-Class Latices [15], el cual está formado por definiciones enciclopédicas. Este conjunto de datos impulsó el progreso de la extracción inteligente de definiciones siguiendo estrategias de aprendizaje supervisado [10], semi-supervisado [11] y basadas en modelos de lenguaje [12].

El reto al que se enfrentan los sistemas de aprendizaje automático es el de la generalización, es decir, el de poder identificar definiciones de un dominio diferente del que está entrenado, o definiciones con un patrón distante sobre los que están entrenados. Este escenario es probable que pueda darse en el presente proyecto, debido a que: (1) los documentos proporcionados son artículos científicos de la plataforma web

ArXiv, (2) los conceptos de interés, aunque están relacionados con la ingeniería, no todos coinciden en la rama de ingeniería y (3) los conceptos están definidos en varios documentos, convirtiéndose el problema en multi-documento. Un enfoque supervisado obliga a la creación de un conjunto de entrenamiento, y limita la elaboración automática de una definición que aúne las explicaciones del concepto de interés en cada uno de los documentos en los que se describe.

Debido a las limitaciones del enfoque basado en clasificación, se ha optado por estudiar la resolución del problema como si se tratara de recuperación de información. Esta tarea tiene como fin la de encontrar la respuesta más adecuada que satisfaga la necesidad de información del usuario. Usualmente la necesidad de información se resuelve indicando las ubicaciones o enlaces donde está la información solicitada, siendo el ejemplo más palmario el buscador Google. Sin embargo, el objetivo es ofrecer una definición, y no el indicar, en este caso, los artículos científicos donde puede estar dicha definición. Por tanto, se precisa de un módulo de generación de lenguaje, que tras la recuperación oportuna de los documentos donde se define el concepto, tenga la capacidad de generar una respuesta en lenguaje natural que aglutine todas las definiciones encontradas.

Los grandes modelos de lenguaje (LLMs, por sus siglas en inglés) han demostrado una gran capacidad de generación de lenguaje natural [13]. A su vez, también han exhibido su habilidad en ser usados como recuperadores de información almacenada en bases de conocimiento [14]. Por tanto, se podrían usar un LLM para la consecución del objetivo del proyecto, ya que pueden buscar información y pueden generar lenguaje. Sin embargo, los LLMs sufren de alucinaciones, es decir, de generar respuestas plausibles desde el punto de vista lingüístico, pero que no está soportado con hechos o datos, o dicho de otro modo, los LLMs en ocasiones se inventan las respuestas. Una estrategia para evitar o reducir la probabilidad de alucinación consiste en ajustar la generación de lenguaje a un conjunto de textos indicados como entrada al LLM, de forma que al LLM se le proporciona los textos o la información precisa y oportuna a partir de la cual generar una respuesta a la necesidad de información planteada. Este modo de uso de los LLM recibe el nombre de Generación Aumentada por Recuperación (*retrieval-augmented generation*, RAG) [15].

El resultado del proyecto ha sido el extractor de definiciones DefRAG,³ cuya arquitectura basada en RAG está recogida en la figura 5. El sistema tiene tres funcionalidades derivadas del objetivo principal de recuperar la definición de un concepto en el dominio tecnológico de una colección de artículos científicos. La primera está asociada a la funcionalidad principal mencionada, la segunda permite aumentar la base de conocimiento inicial con documentos aportados por el usuario, y la tercera posibilita enriquecer la base de conocimiento con artículos procedentes de la plataforma de pre-publicación de artículos científicos ArXiv. El gran modelo de lenguaje tras DefRAG es Llama 3 8b, el cual ha demostrado no solo suficiencia en la generación de definiciones adecuadas, sino también a limitar la posibilidad de alucinación cuando se le pregunta por un concepto que no se menciona en la base de conocimiento.

³ <https://cetdex.ujaen.es/defrag> [consultado 5/11/2024]

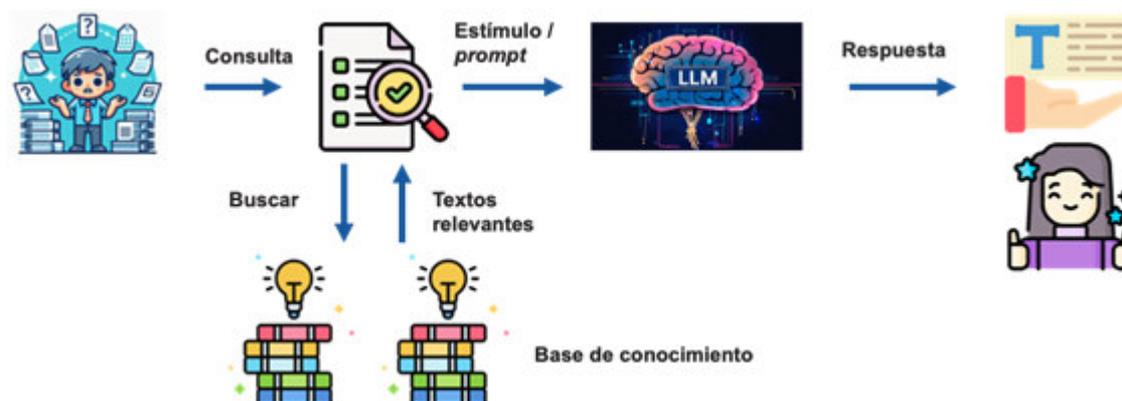


Figura 5: Arquitectura RAG base de DefRAG.

4. CONCLUSIONES

El presente y futuro del PLN, por tanto, es de líder de los avances científicos y tecnológicos de la IA. Esto obligatorio por tanto prestar atención a su evolución científica, y a apostar por participar en dicho progreso por medio de la investigación. Así mismo, los RAGs, son una estrategia sencilla de adaptar los LLMs a entornos de aplicación específicos, y, además, evitando tener que ajustar los modelos con grandes cantidades de datos mediante *fine-tuning*.

Por tanto, la investigación en el desarrollo de RAGs, y más general en PLN se convierte en perentoria, porque seguirán protagonizando los próximos avances disruptivos de la IA.

5. ANEXOS

5.1. REFERENCIAS

- [1] Indurkha, N., & Damerau, F. J. (2010). Handbook of natural language processing. Chapman and Hall/CRC.
- [2] Hutchins, W. J. (2004, September). The Georgetown-IBM experiment demonstrated in January 1954. In Conference of the Association for Machine Translation in the Americas (pp. 102-114). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [3] Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving language understanding with unsupervised learning.
- [4] Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... & Liang, P. (2021). On the opportunities and risks of foundation models. arXiv preprint arXiv:2108.07258.
- [5] Gao, Y., Xiong, Y., Gao, X., Jia, K., Pan, J., Bi, Y., ... & Wang, H. (2023). Retrieval-augmented generation for large language models: A survey. arXiv preprint arXiv:2312.10997.
- [6] Navigli, R., & Velardi, P. (2010, July). Learning word-class lattices for definition and hypernym extraction. In Proceedings of the 48th annual meeting of the association for computational linguistics (pp. 1318-1327).
- [7] Spala, S., Miller, N. A., Deroncourt, F., & Dockhorn, C. (2020). Semeval-2020 task 6: Definition extraction from free text with the defst corpus. arXiv preprint arXiv:2008.13694.
- [8] Hovy, E. H., Philpot, A., Klavans, J., Germann, U., Davis, P. T., & Popper, S. (2003). Extending metadata definitions by automatically extracting and organizing glossary definitions. In Proceedings of the 2003 Annual National Conference on Digital Government Research, DG. O 2003, 2003 (pp. 1-6). Digital Government Research Center.
- [9] Sierra, G., Alarcón, R., Aguilar, C., & Bach, C. (2008). Definitional verbal patterns for semantic relation extraction. Terminology. International Journal of Theoretical and Applied Issues in Specialized Communication, 14(1), 74-98.
- [10] Espinosa-Anke, L., & Saggion, H. (2014, June). Applying dependency relations to definition extraction. In International Conference on Applications of Natural Language to Data Bases/Information Systems (pp. 63-74). Cham: Springer International Publishing.
- [11] Anke, L. E., Saggion, H., & Ronzano, F. (2015, September). Weakly supervised definition extraction. In Proceedings of the International Conference Recent Advances in Natural Language Processing (pp. 176-185).
- [12] Veyseh, A., Deroncourt, F., Dou, D., & Nguyen, T. (2020, April). A joint model for definition extraction with syntactic connection and semantic consistency. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 34, No. 05, pp. 9098-9105).
- [13] Dathathri, S., Madotto, A., Lan, J., Hung, J., Frank, E., Molino, P., ... & Liu, R. (2020). Plug and play language models: A simple approach to controlled text generation. International Conference of Learning Representations.

[14] Petroni, F., Rocktäschel, T., Riedel, S., Lewis, P., Bakhtin, A., Wu, Y., & Miller, A. (2019, November). Language Models as Knowledge Bases?. In Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP) (pp. 2463-2473).

[15] Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., ... & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive nlp tasks. *Advances in Neural Information Processing Systems*, 33, 9459-9474.

5.2. ACRÓNIMOS

Descripción de los acrónimos utilizados a lo largo del informe. A continuación, se muestran algunos ejemplos:

IA	Inteligencia Artificial.
LLM	Large Language Models.
PLN	Procesamiento del Lenguaje Natural.
RAG	Recuperación de Información Aumentada, en inglés retrieval augmented generation.



Sistemas de identificación de objetos y detección de anomalías mediante imágenes de satélite y cenitales

Informe de Prospectiva 2024



1. INTRODUCCIÓN	16
1.1. Objetivo del informe	16
1.2. Contexto	16
2. FACTORES DE INFLUENCIA EN LA DETECCIÓN DE ANOMALÍAS Y RECONOCIMIENTO DE OBJETOS	19
3. IDENTIFICACIÓN DE TENDENCIAS	20
3.1. Tendencias actuales	20
3.2. Tendencias emergentes	22
4. ESCENARIOS FUTUROS	23
4.1. Escenario “Detección de objetos en vuelo”	23
4.1.1. Análisis del escenario “Detección de objetos en vuelo”	23
4.1.2. Probabilidad del escenario “Detección de objetos en vuelo”	23
4.1.3. Riesgos, oportunidades y medidas de mitigación del escenario “Detección de objetos en vuelo”	23
4.2. Escenario “Generación de conjuntos de datos sintéticos de objetos en vuelo”	24
4.2.1. Análisis del escenario “Generación de conjuntos de datos sintéticos de objetos en vuelo”	24
4.2.2. Probabilidad del escenario “Generación de conjuntos de datos sintéticos de objetos en vuelo”	24
4.2.3. Riesgos, oportunidades y medidas de mitigación del escenario “Generación de conjuntos de datos sintéticos de objetos en vuelo”	24
4.3. Escenario “Inteligencia Artificial Explicable”	24
4.3.1. Análisis del escenario “Inteligencia Artificial Explicable”	24
4.3.2. Probabilidad del escenario “Inteligencia Artificial Explicable”	25
4.3.3. Riesgos, oportunidades y medidas de mitigación del escenario “Inteligencia Artificial Explicable”	25
5. PROPUESTA DE ACCIONES	25
5.1. Acciones recomendadas	25
5.2. Plan de seguimiento	27
6. CONCLUSIONES	27
7. ANEXOS	28
7.1. Referencias	28
7.2. Acrónimos	30

1. INTRODUCCIÓN

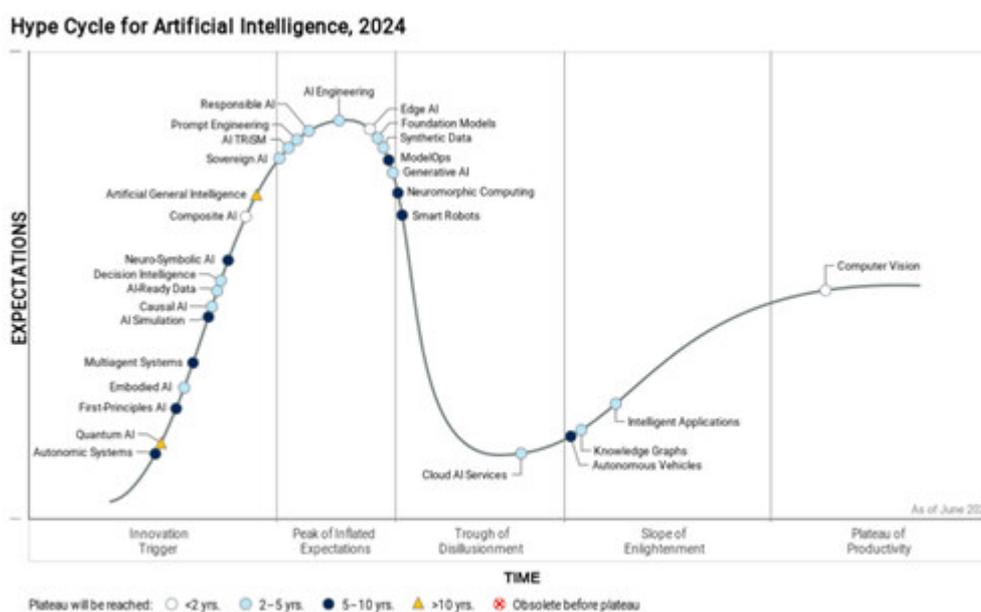
1.1. OBJETIVO DEL INFORME

Este informe de prospectiva forma parte de los trabajos realizados por el grupo de investigación de Sistemas Inteligentes y Minería de Datos (SIMIDAT) de la Universidad de Jaén en el desarrollo de la línea de trabajo “Sistemas de identificación de objetos y detección de anomalías mediante imágenes de satélite y cenitales” en la Cátedra ISDEFE/CETEDEx - UJAEN.

En este trabajo se analizan y desarrollan modelos de aprendizaje profundo para la detección e identificación de elementos de interés en imágenes, así como para el análisis de anomalías en mantenimiento predictivo. Por último, debido al especial interés en objetos en vuelo no tripulados se ha realizado un estudio prospectivo para reconocimiento de drones.

1.2. CONTEXTO

La Ciencia de Datos es un campo multidisciplinar que se encuadra dentro de la Inteligencia Artificial y se trabaja con conceptos relacionados con el *Smart Data* y el *Big Data* para procesar grandes cantidades de datos y que nos permite obtener resultados precisos en los reconocimientos e identificaciones. Una de las técnicas más empleadas dentro de estos campos se centra en los modelos de aprendizaje profundo (conocidos en inglés como *Deep Learning*) para detección e identificación de elementos de interés en imágenes, entre otros. En las Figuras 1 y 2 se puede observar el ciclo de las tecnologías más importantes en este año 2024 según Gartner. En ellas, destacan elementos como datos sintéticos, IA generativa, aprendizaje profundo e Inteligencia Artificial explicable en los que se incide en este estudio prospectivo.



Gartner

Figura 1: Ciclo de sobreexpectación (hype cycle) de Inteligencia Artificial en el año 2024. Fuente: Gartner



Figura 2: Ciclo de sobreexpectación (hype cycle) de Ciencia de Datos y Aprendizaje Automático (izquierda) e Inteligencia de Negocio (derecha) en el año 2024. Fuente: Gartner

Por otro lado, es importante destacar que los conflictos actuales tanto en Ucrania como en Gaza han demostrado la importancia de los drones en las operaciones militares actuales considerándose prioritaria la evolución en este campo de batalla por el Ministerio de Defensa, trabajando para extender su uso y estudio dentro de las Fuerzas Armadas. En este sentido, la detección de objetos en imágenes (verticales y/o cenitales) juega un papel clave para su detección ya que son las amenazas más importantes en la actualidad. Adicionalmente, los denominados enjambres de drones permiten que drones más pequeños y económicos conformen un ataque mucho más peligroso y menos costoso en las zonas de conflicto. Los enjambres de drones suponen uno de los vectores de amenaza más importantes para las Fuerzas Armadas de todo el mundo. Decenas de aeronaves no tripuladas dispuestas a ejecutar un ataque contra varias posiciones de forma coordinada supone un reto mayúsculo para las defensas antiaéreas. A pesar que España cuenta con algunos sistemas especializados, centrados en tecnologías electromagnéticas, sería interesante incorporar a los mismos otros sistemas inteligentes que sean capaces de detectar este tipo de objetos para evitar sus ataques coordinados.

En esta línea de trabajo, el Ministerio de Defensa está potenciando y dedicando importantes esfuerzos en el desarrollo de este tipo de sistemas de enjambre y sistemas que sean capaces de luchar contra ellos. Por ejemplo, se necesitan desarrollar nuevos demostradores que permitan a un experto enfocarse en la ejecución de la misión, no teniendo que comandar plataforma (drones) por separado, sino que tengan un alto grado de automatización de cada uno de los drones no tripulados que conforman un enjambre de cara a habilitar su funcionamiento individual. Para las Fuerzas Armadas es importante que se implementen comportamientos inteligentes en el funcionamiento conjunto y colaborativo de todos los vehículos aéreos no tripulados. Además, también se están analizando y estudiando la posibilidad de incorporar, al igual que otros países de la OTAN, otras medidas a los tradicionales de electromagnetismo para derribar estos enjambres.

Considerando este contexto, este estudio trabaja en dos líneas principales, por un lado detección e identificación de elementos de interés en imágenes de satélite y analizar la situación actual para el reconocimiento de drones en vuelo, y por otro lado, una segunda línea centrada en el análisis de anomalías en mantenimiento predictivo.

- **Estudio de métodos de aprendizaje profundo para la identificación de objetos en imágenes.**

El uso de técnicas de detección de objetos tiene una importancia crucial en la actualidad, ya que permite identificar y hacer seguimiento de elementos clave en escenarios socioeconómicos y

ambientales. El aprendizaje profundo [Goo16] ha demostrado resultados prometedores en el campo de la visión por computador. En este ámbito, entre los modelos profundos, destacan las redes neuronales convolucionales [Ben15], con una arquitectura basada en convoluciones y diseñada específicamente para extraer y analizar características específicas de las imágenes, lo que las hace especialmente eficaces para el procesamiento de imágenes y la detección de objetos de interés en un entorno tan variado como el terrestre. La Figura 3 representa el esquema general de una CNN adaptada para la clasificación de imágenes. Destacan por encima del resto las redes de la familia YOLO [Red16] y RCNN [Gir14].

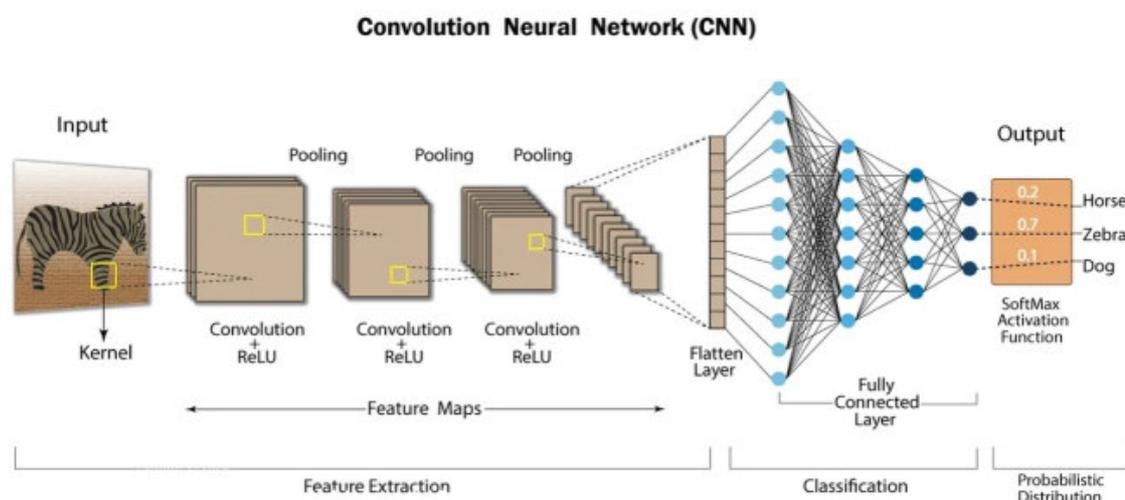


Figura 3: Esquema de una CNN. Fuente: [WhatCNN]

Uno de los campos clave dentro del área de la identificación de objetos es el ámbito militar, en el que la vigilancia y el reconocimiento de objetos juegan un papel esencial. Teniendo en cuenta la presencia de drones equipados con armas o el uso de estas aeronaves para tareas de espionaje su detección temprana es de vital importancia. Existen numerosas metodologías para la detección de drones, entre las que se incluye la detección por imágenes RGB [Kim23] o térmicas [Meb23], por señales de radar [Tor16], lidar [Dog22] o radiofrecuencia [Als19], por señales acústicas [Ber17] e incluso metodologías híbridas que combinan dos o más de estas técnicas [Sva20]. Cada método tiene asociados una serie de ventajas e inconvenientes [Ros24] que habrá que tener presentes a la hora de implementar soluciones en una situación real.

- **Sistemas inteligentes para mantenimiento predictivo.**

El mantenimiento predictivo es una herramienta esencial para optimizar la operación y la gestión de sistemas complejos. Se basa en la capacidad de predecir fallos o anomalías antes de que ocurran, minimizando así el tiempo de inactividad y maximizando la eficiencia operativa [Ran24]. Un componente crítico de este enfoque es la detección de anomalías en datos temporales. Estos eventos o patrones atípicos representan desviaciones notables del comportamiento normal de los datos [Agg17], y su detección permite no solo prevenir problemas futuros sino también extraer información valiosa que optimiza la toma de decisiones en tiempo real, tal y como se refleja en la Figura 4.

Para abordar este desafío, se han desarrollado diversas técnicas de análisis, desde métodos estadísticos clásicos hasta modelos avanzados de aprendizaje automático. Las técnicas tradicionales, como los modelos de autorregresión y de medias móviles, se fundamentan en principios estadísticos robustos y requieren un profundo conocimiento matemático [New83]. Estas

técnicas asumen que las series temporales siguen distribuciones de datos bien definidas, lo cual puede limitar su aplicabilidad en sistemas dinámicos o complejos.

Entre los enfoques modernos, el *Deep Learning* ha demostrado un potencial significativo [Mao19, Jia19, Wan19, Zha19]. Basado en redes neuronales artificiales complejas, el aprendizaje profundo puede captar y modelar relaciones temporales profundas y no lineales gracias al empleo de redes recurrentes. Este enfoque es particularmente útil para detectar anomalías en series temporales con dependencias de largo alcance, ya que las redes neuronales pueden identificar patrones intrincados que las técnicas tradicionales no capturan.

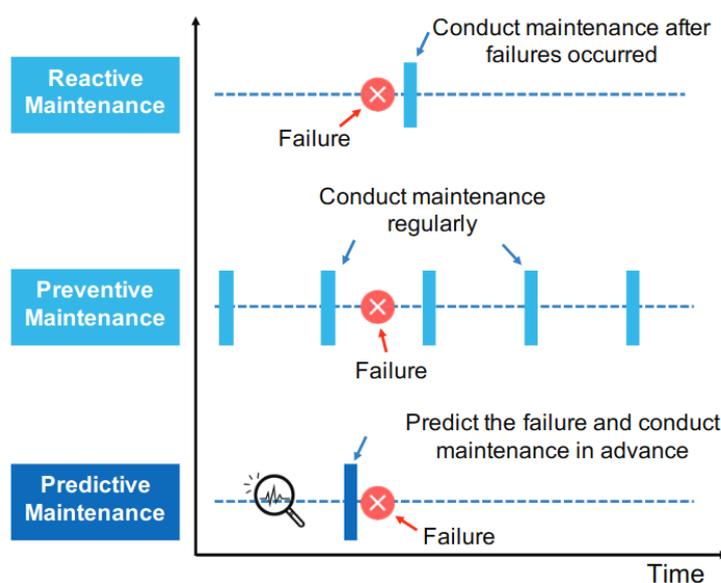


Figura 4: Aplicación del mantenimiento predictivo frente a otras técnicas de mantenimiento tradicionales como el mantenimiento reactivo o el preventivo. El mantenimiento predictivo predice cuándo va a ocurrir el fallo antes de ocurra, pudiendo evitarlo con el mantenimiento. Fuente: [Ran24].

2. FACTORES DE INFLUENCIA EN LA DETECCIÓN DE ANOMALÍAS Y RECONOCIMIENTO DE OBJETOS

Los factores de influencia más importantes en los problemas estudiados son:

- **Datos.** Se necesita:
 - Más calidad de datos. Mayor precisión, consistencia, completitud y relevancia de los datos utilizados para entrenar los modelos.
 - Más cantidad de datos. Si la cantidad de datos es limitada, puede dificultar el entrenamiento de modelos robustos y generalizables.
 - Más diversidad de los datos. La representatividad de los datos en términos de condiciones operativas, tipos de fallos y variabilidad en el comportamiento de los sistemas es esencial. Si los datos carecen de diversidad, puede llevar a modelos sobreajustados o con un bajo rendimiento en condiciones nuevas.
 - Más etiquetado de los mismos. Se necesita, para entrenar algunos modelos, determinar de antemano qué datos son anómalos.

- **Validación y evaluación del modelo.** Es fundamental determinar una estrategia de validación de la detección de anomalías del modelo, en especial en datos no etiquetados.
- **Disponibilidad de recursos computacionales.** La disponibilidad de infraestructura adecuada (como GPUs, almacenamiento y procesamiento en la nube) para entrenar modelos complejos de manera eficiente.
- **Adecuación del método de detección al contexto del problema.** Según las características del contenido, tanto para detección de anomalías como para el reconocimiento de objetos, habrá que escoger aquellas metodologías que, según sus ventajas e inconvenientes, sean óptimas para resolver el problema.

3. IDENTIFICACIÓN DE TENDENCIAS

3.1. TENDENCIAS ACTUALES

Entre las tendencias más destacadas actualmente para la detección de anomalías enfocadas a mantenimiento predictivo nos encontramos con la incorporación de tecnologías de gemelos digitales. Estas herramientas permiten crear simulaciones dinámicas en tiempo real y un análisis detallado de datos, lo que se traduce en una monitorización más precisa de los equipos y una capacidad mejorada para predecir fallos antes de que ocurran. Como resultado, se optimiza el rendimiento de los activos industriales y se minimiza el tiempo de inactividad no planificado, mejorando significativamente la eficiencia operativa [TFGS24].

Paralelamente, los modelos avanzados de aprendizaje automático y aprendizaje profundo han cobrado gran relevancia en este campo (Figura 5). Algoritmos complejos, como las redes neuronales profundas y el aprendizaje por refuerzo, están siendo adoptados para analizar grandes volúmenes de datos y predecir con mayor precisión las posibles fallas [TFGP24]. Estas técnicas no solo permiten identificar patrones complejos en los datos, sino que también proporcionan sistemas de mantenimiento más adaptativos y proactivos, ajustándose de manera dinámica a las condiciones cambiantes de los equipos (Figura 6).

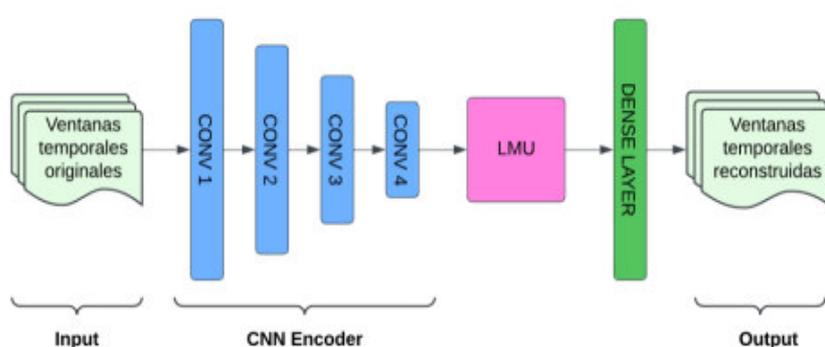


Figura 5: Modelo Deep Learning desarrollado para detección de anomalías en mantenimiento predictivo. Fuente: elaboración propia

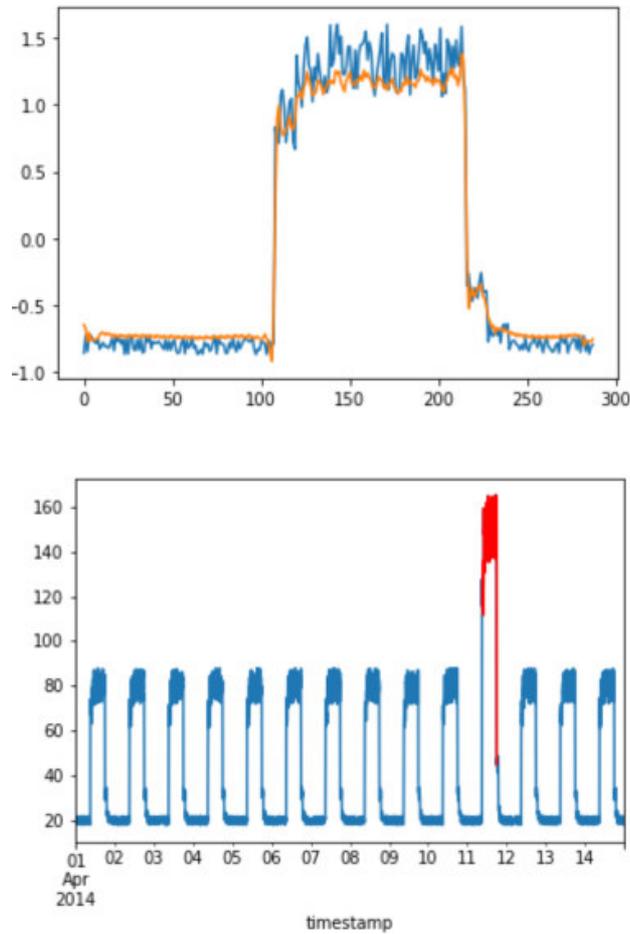


Figura 6: Ejemplo de reconstrucción del comportamiento normal y detección de anomalías del modelo desarrollado. Fuente: elaboración propia

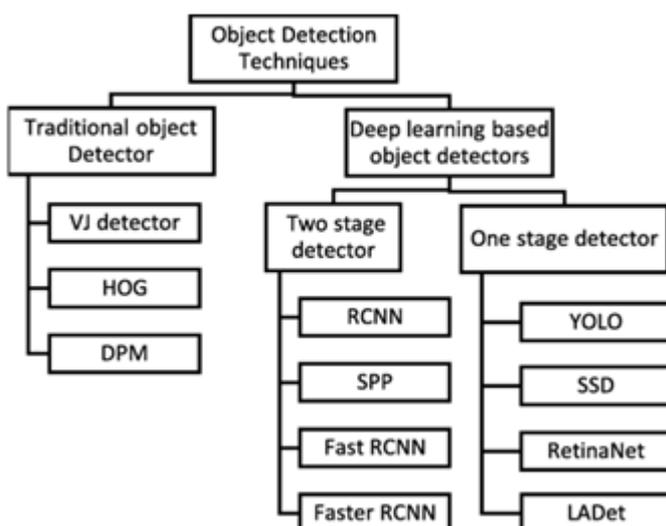


Figura 7: Clasificación de diversos modelos de detección de objetos. Fuente: [Kau22]



Figura 8: Imágenes con elementos identificados de YoloV8x en el conjunto de datos DIOR con 50 épocas. Fuente: elaboración propia

Para el problema de la detección de objetos se han propuesto modelos basados en aprendizaje profundo en una o dos etapas. La diferencia entre ambos reside en la manera en la que afrontan el problema. Los detectores de una etapa usan un único modelo profundo para la localización y clasificación de los objetos presentes en las imágenes destacando los modelos de la familia YOLO [TFGMA24]. En cambio, los detectores de dos etapas clasifican las imágenes en dos fases: una primera en la que se detectan las regiones en las que es probable que haya objetos interesantes y una segunda que, analizando exclusivamente las regiones interesantes, clasifica los elementos presentes en ellas. Como es lógico, los detectores en dos fases son más lentos, pero su tasa de acierto es mayor. La Figura 7 representa los algoritmos más destacados para la detección de objetos y la Figura 8 representa un ejemplo de detección de objetos mediante Yolo.

3.2. TENDENCIAS EMERGENTES

En lo que respecta a tendencias emergentes en la **detección de anomalías**, se observa un cambio hacia enfoques más holísticos, transparentes e integrados en el mantenimiento predictivo, aprovechando una hibridación de inteligencia humana y de aprendizaje automático para crear sistemas adaptables, resistentes y explicables. En concreto, en lugar de enfoques exclusivamente automatizados y centrados en aprendizaje automático, la nueva tendencia se enfoca en una colaboración armoniosa entre humanos y tecnologías avanzadas. Este cambio subraya la importancia del bienestar humano, la sostenibilidad y la adaptabilidad, integrando a las personas en el proceso de toma de decisiones.

Otra tendencia significativa es el desarrollo de modelos híbridos de mantenimiento predictivo, que combinan métodos tradicionales con técnicas avanzadas de aprendizaje automático. Esta integración permite mejorar la precisión de las predicciones mediante el uso de principios físicos que describen el comportamiento de la maquinaria, complementados por el análisis de datos en tiempo real. Al abordar las limitaciones de los enfoques basados únicamente en datos o en modelos teóricos, estos modelos híbridos ofrecen soluciones más robustas y fiables, adaptándose mejor a la complejidad de los sistemas industriales modernos.

Finalmente, la necesidad de explicabilidad en los sistemas inteligentes está ganando relevancia. A medida que las técnicas de aprendizaje profundo se vuelven fundamentales para las predicciones en mantenimiento, surge la demanda de herramientas que puedan interpretar y explicar las decisiones tomadas por estos modelos (Inteligencia Artificial eXplicable - XAI) [Sam17][Bar20]. La investigación en explicabilidad se está enfocando en desarrollar métodos que permitan una comprensión clara de las predicciones, algo crucial en sectores críticos donde la transparencia es esencial para garantizar la seguridad y la confianza en estas tecnologías.

En lo que respecta al **reconocimiento de objetos** en imágenes de satélite, y según [Zha23], hoy en día se pueden identificar las siguientes tendencias: detección de objetos multiescala, detección de objetos girados, detección de objetos débiles, detección de objetos diminutos y detección de objetos con supervisión limitada. En este mismo campo destacan el uso de arquitecturas avanzadas como YOLO, y está siendo de gran relevancia el uso de modelos específicos como YOLOv5 y YOLOv8, junto con la red convolucional Faster R-CNN. Estos modelos aportan relevancia en el campo de la visión por computador y tienen gran capacidad para realizar detecciones de alta precisión en tiempo real.

- YOLOv5 es una opción robusta en términos de velocidad, siendo capaz de realizar detecciones rápidas en imágenes con objetos de diferentes tamaños. Sin embargo, su desempeño en términos de precisión no destaca.
- YOLOv8 es la versión más reciente de la familia y tiene un avance significativo en comparación con versiones anteriores.
- Faster R-CNN no es tan rápido como los modelos YOLO pero obtiene buenas precisiones para la detección de objetos en escenarios donde la velocidad no es crítica.

Sobre el **reconocimiento de objetos en vuelo**, existen numerosas técnicas de detección según el tipo de información que el sistema tome de entrada: información visual, por señales de radiofrecuencia, acústicas,

etc. La tendencia más destacada actualmente es el uso de metodologías híbridas que combinen dos o más de estas técnicas, ya que potencia los beneficios individuales de cada una a la vez que reduce, o incluso elimina, las desventajas [Ros24].

4. ESCENARIOS FUTUROS

Dentro de esta línea de trabajo se presentan tres escenarios futuros relacionados con la creación de conjuntos de datos sintéticos de objetos en vuelo, la detección de los mismos y la Inteligencia Artificial Explicable como escenarios que pueden ser de interés para análisis futuros.

4.1. ESCENARIO “DETECCIÓN DE OBJETOS EN VUELO”

Avanzar en la detección de objetos mediante imágenes cenitales y verticales puede ser uno de los escenarios más prometedores para trabajar en sistemas de apoyo que permitan detectar por ejemplo objetos en vuelo no tripulados.

4.1.1. ANÁLISIS DEL ESCENARIO “DETECCIÓN DE OBJETOS EN VUELO”

La detección de objetos en vuelo mediante algoritmos avanzados de aprendizaje profundo es una línea de trabajo que puede ser de especial interés para las amenazas actuales en las zonas de conflicto. Este tipo de algoritmos inteligentes se pueden incorporar en sistemas de seguimiento y estaciones de observación en zonas de conflicto y pueden complementar a los sistemas actuales. En concreto, es necesario profundizar en el estudio de nuevos algoritmos y el diseño de algoritmos convolucionales y recurrentes, entre otros, para la detección de objetos en vuelo no tripulados (tanto aislados como en enjambre).

4.1.2. PROBABILIDAD DEL ESCENARIO “DETECCIÓN DE OBJETOS EN VUELO”

Este escenario tiene una probabilidad muy alta debido al rápido avance en los últimos años en el desarrollo e implementación de algoritmos cada vez más complejos dentro del aprendizaje profundo. Los grupos de investigación y empresas tecnológicas más importantes de todo el mundo están trabajando en estas líneas y se pueden obtener resultados prometedores a corto y medio plazo. Por otro lado, es importante destacar que este escenario tiene una gran dependencia con la inversión público/privada para desarrollar algoritmos eficaces y eficientes, y con la dificultad de incorporarlos en los sistemas de seguimiento actuales con capacidad para funcionar en tiempo real.

4.1.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO “DETECCIÓN DE OBJETOS EN VUELO”

Riesgos: El principal riesgo de este escenario es la ausencia de conjuntos de datos relevantes, de gran cardinalidad y complejidad, que nos permitan entrenar de forma eficiente y correcta a los algoritmos inteligentes. Además, una vez entrenados los modelos es importante realizar la validación de los mismos en estaciones de seguimiento que se encuentren en zona de conflicto, o al menos en zonas de simulación, que nos permitan comprobar su eficacia.

Oportunidades: Posicionarse en la vanguardia de la detección de objetos en vuelo puede proporcionar una gran ventaja de cara a incorporar este tipo de algoritmos en estaciones de seguimiento en zonas de conflicto actualmente, o incluso en zonas especiales o con necesidad de alta protección en nuestro país como pueden ser edificios públicos, zonas restringidas, etc.

Medidas de mitigación: La principal medida de mitigación de los riesgos y debilidades de este escenario se complementa con el escenario que planteamos a continuación. Tenemos la necesidad de construir un sistema de generación de conjuntos de datos sintéticos de objetos en vuelo.

4.2. ESCENARIO “GENERACIÓN DE CONJUNTOS DE DATOS SINTÉTICOS DE OBJETOS EN VUELO”

A día de hoy, los algoritmos avanzados de reconocimiento de objetos en vuelo se encuentran con un problema muy importante, y es que no existen conjuntos de datos públicos con los que poder entrenar a los algoritmos para que obtengan resultados elevados de acierto.

4.2.1. ANÁLISIS DEL ESCENARIO “GENERACIÓN DE CONJUNTOS DE DATOS SINTÉTICOS DE OBJETOS EN VUELO”

En la literatura y los repositorios públicos no existen conjuntos de datos con objetos de vuelo no tripulados. Además, los objetos de vuelo no tripulados están constantemente actualizándose, por ejemplo, con cambio de formas, tamaños, colores, etc. Esta característica dificulta mucho la capacidad de entrenamiento de los algoritmos de reconocimiento de objetos en vuelo ya que los conjuntos de datos son escasos y están centrados en solo unos cuantos tipos de drones.

4.2.2. PROBABILIDAD DEL ESCENARIO “GENERACIÓN DE CONJUNTOS DE DATOS SINTÉTICOS DE OBJETOS EN VUELO”

La probabilidad de que se de este escenario es muy elevada ya que tenemos la necesidad de construir este sistema inteligente para la generación de los conjuntos de datos sintéticos de objetos en vuelo, tanto objetos aislados como vuelos en enjambre. Sin estos conjuntos de datos los algoritmos de detección no serán capaces de tener un buen funcionamiento.

4.2.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO “GENERACIÓN DE CONJUNTOS DE DATOS SINTÉTICOS DE OBJETOS EN VUELO”

Riesgos: El principal riesgo de este escenario viene determinado por la construcción en sí de una batería de imágenes asociada a un dron o enjambre de los mismos. En primer lugar, es importante tener bien identificado el objeto sobre el que queremos construir el conjunto de datos, y en segundo lugar, es importante establecer si la generación la vamos a realizar sobre una localización concreta o múltiples localizaciones. Por otro lado, para poder validar los algoritmos es importante contar con conjuntos de datos reales sobre los que validar los generadores de imágenes inteligentes.

Oportunidades: Este escenario es muy prometedor porque sin estos conjuntos no será posible que los algoritmos funcionen correctamente.

Medidas de mitigación: Es importante trabajar de forma coordinada con los responsables del Centro de Desarrollo Experimental de Jaén para poder contar con conjuntos de datos de objetos en vuelo sobre los que poder validar.

4.3. ESCENARIO “INTELIGENCIA ARTIFICIAL EXPLICABLE”

El uso de algoritmos de aprendizaje profundo está muy extendido dentro de la IA. Sin embargo, estos algoritmos se denominan cajas negras porque no se sabe exactamente cómo funcionan sus procesos internos ni qué aspectos influyen en la generación de la salida, y esto dificulta la confianza del usuario en el sistema en procesos de toma de decisiones.

4.3.1. ANÁLISIS DEL ESCENARIO “INTELIGENCIA ARTIFICIAL EXPLICABLE”

Recientemente, la normativa sobre IA de la Unión Europea establece una serie de pilares fundamentales sobre los que se debe sustentar un sistema inteligente [IAFiable]: ética, legalidad y robustez. Esto se conoce

dentro de la literatura como Inteligencia Artificial Fiable (o Confiable), y en ella, la Inteligencia Artificial explicable (XAI)[Gun19] juega un papel primordial. A día de hoy, los diseños y desarrollos de la mayoría de los sistemas inteligentes están basados en aprendizaje profundo que carecen de explicabilidad y no tenemos una forma directa de comprender porqué toman sus decisiones. Trabajar en el diseño de modelos que permitan explicar *ad hoc* o a la misma vez que hacen sus predicciones es una línea de trabajo de especial interés. Se han aplicado muchos esfuerzos para definir explicabilidad en aprendizaje automático centrándose especialmente en el rol que tiene la audiencia particular para la que se generan las explicaciones.

4.3.2. **PROBABILIDAD DEL ESCENARIO “INTELIGENCIA ARTIFICIAL EXPLICABLE”**

Este escenario tiene una probabilidad muy elevada ya que acaba de entrar en vigor la nueva normativa relacionada con la IA Fiable en la Unión Europea [LeyIAUE]. En este sentido, es necesario que todos los desarrollos de sistemas inteligentes que se implementen o usen en territorio europeo deben cumplir con la misma en función del nivel de riesgo que representen. Adicionalmente, para incorporar los modelos inteligentes en el proceso de toma de decisiones es necesario tener información que avale o explique la misma, fundamentalmente con información causal.

4.3.3. **RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO “INTELIGENCIA ARTIFICIAL EXPLICABLE”**

Riesgos: El principal riesgo de este escenario viene determinado por la complejidad en sí de los modelos de aprendizaje profundo. Incorporar explicabilidad a estos sistemas es un problema de gran complejidad. Pero la incorporación de explicabilidad incrementaría la confianza en el proceso de toma de decisiones y es una herramienta de soporte para la auditoría de los modelos IA. En la actualidad, podemos encontrar un amplio número de investigadores que se encuentran trabajando en esta línea, primordialmente en dos variantes: 1) procesos *ad hoc* que analicen las predicciones realizadas por los modelos y que muestren las partes y/o capas de las redes neuronales más relevantes para hacer esas predicciones, y 2) mecanismos (de atención, por ejemplo) que se incorporen en los modelos para explicar sus predicciones a la misma vez que las hacen.

Oportunidades: Este escenario es muy prometedor ya que es necesario cumplir con la nueva normativa y trabajar en esta línea de investigación puede proporcionar un importante avance en todos los desarrollos que se realicen.

Medidas de mitigación: La principal medida se debe centrar en buscar colaboraciones, como por ejemplo dentro de nuestro propio Instituto Interuniversitario, para optimizar los procesos de su incorporación en nuestros sistemas inteligentes.

5. PROPUESTA DE ACCIONES

5.1. ACCIONES RECOMENDADAS

A continuación, se describen las acciones recomendadas en relación con los escenarios futuros planteados en la sección anterior.

Con respecto al escenario “Detección de objetos en vuelo”, se recomienda el estudio del estado del arte en el área de la detección de drones. En la literatura científica se pueden encontrar numerosos artículos centrados en la detección de vehículos no tripulados agrupados en siete categorías: detección con imágenes RGB (detección visual), por imágenes térmicas (detección térmica), por señales de radar, por señales LiDAR, por señales de radiofrecuencia, por señales acústicas y por métodos híbridos en los que se combinan dos o más técnicas de detección. En estas propuestas, un gran porcentaje de las propuestas

emplea técnicas de inteligencia artificial con diferentes objetivos, ya sea para clasificar de forma automática las muestras recogidas por los dispositivos de captura o para aumentar la cantidad de datos de entrenamiento con técnicas de *data augmentation*, resaltando la utilidad de este campo de la informática para la tarea de detección de objetos. El estudio profundo de propuestas ya existentes posibilita la implementación de soluciones de calidad adaptadas a los problemas específicos a los que nos enfrentamos.

Ligado a esta acción, es interesante el análisis de ventajas e inconvenientes de cada tipo de método de detección que encontramos en la literatura científica. Como es lógico, cada técnica tiene asociadas una serie de ventajas y limitaciones, resumidas en la Tabla 1.

Técnica	Coste	Tipo de detección	Rango	Sensibilidad a meteorología
Visual	Bajo	Pasiva	Bajo	Alta
Térmica	Bajo	Pasiva	Bajo	Media
Radar	Alto	Activa	Alto	Baja
Lidar	Alto	Activa	Medio	Media
Radiofrecuencia	Medio	Pasiva	Medio	Baja
Acústica	Bajo	Pasiva	Bajo	Media

Tabla 1: Resumen de las ventajas e inconvenientes más destacables de cada técnica de detección. Se incluye el coste de la implementación, el tipo de detección que permite, el rango de visión, y la sensibilidad ante las condiciones meteorológicas adversas. Fuente: elaboración propia.

El estudio de los factores resumidos en la Tabla 1, en la que se indica el coste de la solución, el tipo de detección, el rango del sistema y la sensibilidad a condiciones meteorológica adversas, y el análisis del contexto de la situación real en la que se aplicarán las técnicas de detección de objetos, permitirá escoger aquella metodología más adecuada, posibilitando una clasificación óptima.

En este aspecto, y también relacionado con el escenario 2 “Generación de conjuntos de datos sintéticos de objetos en vuelo”, aparece la necesidad de contar con un conjunto de datos etiquetado de calidad con el que entrenar los modelos inteligentes. Muchos autores, al detectar la falta de conjuntos de datos públicos, han recopilado y etiquetado conjuntos de datos privados. El estudio de artículos que traten este tema, junto al estudio de técnicas para la generación de datos sintéticos, facilitará la creación de un conjunto de datos de calidad con el que entrenar y evaluar los modelos de detección.

El escenario 3 “Inteligencia Artificial Explicable” es importante hacer una revisión profunda de la bibliografía XAI en el ámbito de Defensa en los cuatro ejes de la explicabilidad: explicabilidad de los datos (que ayudará a supervisar robustez, representatividad y sesgo de los mismos), explicabilidad del modelo (que contribuirá a entender cómo funciona), explicabilidad post-hoc (aportando información sobre las salidas aportadas) y evaluación de las explicaciones. El estudio del estado del arte en el ámbito de Defensa permitirá conocer las líneas futuras más relevantes a abordar, entre ellas: a) gestión de las interacciones de usuarios en XAI para mejorar el rendimiento de los modelos IA; b) desarrollo de modelos explicativos adaptativos que proporcionen explicaciones relativas al contexto, c) diseños explicables en escenarios de aprendizaje dinámicos, afrontando por ejemplo aprendizaje continuo o flujos de datos continuos; d) estudios sobre la evaluación de robustez tanto del modelo IA como de las explicaciones que aporta; e) análisis de explicabilidad en modelos de IA generativa y en particular en modelos fundacionales.

5.2. PLAN DE SEGUIMIENTO

El plan de seguimiento es una de las partes fundamentales para garantizar el éxito del desarrollo e implementación de modelos avanzados inteligentes para la detección y generación de objetos no tripulados en vuelo.

En este sentido se plantean principalmente tres acciones:

1. Revisión periódica del estado del arte. Se debe de revisar de manera periódica las publicaciones académicas y los avances tecnológicos en el campo de la detección y generación sintética de objetos no tripulados. Nos centraremos en el análisis de nuevos modelos de aprendizaje profundo como redes convoluciones y generativas.
2. Informes periódicos sobre los nuevos modelos encontrados. Los informes deben reflejar el resultado de la revisión periódica llevada a cabo en el apartado anterior. En concreto, deben presentar un análisis detallado de las características principales de los mismos, sus ventajas e inconvenientes y su posible aplicabilidad al contexto específico de la detección y generación de objetos no tripulados en vuelo.
3. Estudios comparativos de los nuevos modelos con respecto al estado del arte. Se comparan los modelos analizados mediante pruebas experimentales para determinar la validez de los modelos estudiados. Este análisis determinará en gran medida la viabilidad de los desarrollos para su implementación en un sistema real.

6. CONCLUSIONES

En este trabajo se estudian algoritmos de aprendizaje profundo para mantenimiento predictivo y reconocimiento de objetos en imágenes cenitales y verticales. Esta disciplina se encuadra dentro del área de aprendizaje automático, una de las subáreas más destacadas dentro de la Inteligencia Artificial en la actualidad.

Más concretamente, el trabajo realizado por el equipo de investigación del grupo Sistemas Inteligentes y Minería de Datos se ha centrado en:

- Mantenimiento predictivo [TFGS24, TFGP24]: Se ha realizado una revisión de propuestas para la detección de anomalías en series temporales, y se han desarrollado tanto un algoritmo híbrido de aprendizaje profundo como una interfaz intuitiva que permita a un operador realizar estudios con algoritmos de la literatura de una forma sencilla.
- Reconocimiento de objetos: Se ha trabajado en imágenes cenitales mediante los algoritmos de la familia YOLO que nos ha permitido presentar la capacidad de estos algoritmos a día de hoy [TFGMA24].
- Reconocimiento de objetos en vuelo: Se ha realizado un estudio prospectivo [Ros24] sobre la detección de drones donde se ha construido una taxonomía basada en el tipo de técnica que se emplea para su detección, así como el coste de implementarla, tipo de detección, rango y la sensibilidad a la meteorología.

El estudio prospectivo pone de manifiesto una de las necesidades más importantes para el reconocimiento de objetos en vuelo (aislados y en enjambre): la construcción de conjuntos de datos tanto reales como sintéticos que nos permitan entrenar de forma eficiente y eficaz a los algoritmos avanzados.

7. ANEXOS

7.1. REFERENCIAS

[Agg17] C.C. Aggarwal, *Outlier Analysis*, Springer, New York, 2017.

[Ali23] S. Ali, T. Abuhmed, S. El-Sappagh, K. Muhammad, J.M. Alonso-Moral, R. Confalonieri, R. Guidotti, J. Del Ser, N. Díaz-Rodríguez, F. Herrera, "Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence," *Information Fusion*, vol. 99, 2023, p. 101805. doi: <https://doi.org/10.1016/j.inffus.2023.101805>.

[Als19] M.F. Al-Sa'd, A. Al-Ali, A. Mohamed, T. Khattab, and A. Erbad, "RF-based drone detection and identification using deep learning approaches: An initiative towards a large open-source drone database," *Future Generation Computer Systems*, vol. 100, pp. 86–97, 2019. doi: 10.1016/j.future.2019.05.007.

[New83] P. Newbold, "ARIMA model building and the time series analysis approach to forecasting," *Journal of Forecasting*, vol. 2, no. 1, pp. 23–35, 1983.

[Bar20] A. Barredo et al., "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI," *Information Fusion*, vol. 58, 2020.

[Ben15] Y. Bengio, Y. LeCun, and G. Hinton, "Deep Learning," *Nature*, vol. 521, pp. 436–444, 2015.

[Ber17] A. Bernardini, F. Mangiatordi, E. Pallotti, and L. Capodiferro, "Drone detection by acoustic signature identification," *Electronic Imaging*, vol. 29, no. 10, pp. 60–60, 2017. doi: 10.2352/ISSN.24701173.2017.10.IMAWM-168.

[Dog22] S. Dogru and L. Marques, "Drone detection using sparse lidar measurements," *IEEE Robotics and Automation Letters*, vol. 7, no. 2, pp. 3062–3069, 2022. doi: 10.1109/LRA.2022.3145498.

[Gir14] R.B. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proc. CVPR*, 2014.

[Goo16] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, The MIT Press, 2016.

[Gun19] D. Gunning and D. Aha, "DARPA's Explainable Artificial Intelligence (XAI) program," *AI Magazine*, vol. 40, no. 2, pp. 44–58, 2019.

[IAFiable] "Directrices éticas IA Fiable." Disponible: <https://op.europa.eu/es/publication-detail/-/publication/d3988569-0434-11ea-8c1f-01aa75ed71a1>.

[Jia19] W. Jiang, Y. Hong, B. Zhou, X. He, and C. Cheng, "A GAN-based anomaly detection approach for imbalanced industrial time series," *IEEE Access*, vol. 7, pp. 143608–143619, 2019.

[Kau22] J. Kaur and W. Singh, "Tools, techniques, datasets and application areas for object detection in an image: a review," *Multimedia Tools and Applications*, vol. 81, no. 27, pp. 38297–38351, 2022. doi: 10.1007/s11042-022-13153-y. Disponible: <https://doi.org/10.1007/s11042-022-13153-y>.

[Kim23] J.-H. Kim, N. Kim, and C.S. Won, "High-Speed Drone Detection Based on YOLO-V8," en *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Rhodes Island, Grecia, 4-10 junio, 2023, pp. 1–2. doi: 10.1109/ICASSP49357.2023.10095516.

- [Lei1AUE] "Ley de Inteligencia Artificial de la Unión Europea." Disponible: [https://www.europarl.europa.eu/thinktank/es/document/EPRS_BRI\(2021\)698792](https://www.europarl.europa.eu/thinktank/es/document/EPRS_BRI(2021)698792).
- [Mao19] W. Mao, J. Chen, X. Liang, and X. Zhang, "A new online detection approach for rolling bearing incipient fault via self-adaptive deep feature matching," *IEEE Transactions on Instrumentation and Measurement*, 2019.
- [Meb23] N.E.D. Mebtouche and N. Baha, "Robust UAV detection based on saliency cues and magnified features on thermal images," *Multimedia Tools and Applications*, vol. 82, no. 13, pp. 20039–20058, 2023. doi: 10.1007/s11042-022-14271-3.
- [Ran24] Y. Ran, X. Zhou, P. Lin, Y. Wen, and R. Deng, "A survey of predictive maintenance: Systems, purposes and approaches," *arXiv:1912.07383*, pp. 1–36, 2024.
- [Red16] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," en *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Los Alamitos, CA, EE.UU., 27-30 junio, 2016, pp. 779–788. IEEE Computer Society. doi: 10.1109/CVPR.2016.91.
- [Ros24] D. de la Rosa, C.J. Carmona, M.J. del Jesus, and F. Charte, "Detección automática de drones. Estudio prospectivo," 2024. [Última revisión: 07/11/2024]. Disponible: <https://simidat.ujaen.es/en/estudio-drones>.
- [Sam17] W. Samek, T. Wiegand, and K.-R. Müller, "Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models," *arXiv:1708.08296*, 2017.
- [Sva20] F. Svanstrom, C. Englund, and F. Alonso-Fernandez, "Real-time drone detection and tracking with visible, thermal and acoustic sensors," en *2020 25th International Conference on Pattern Recognition (ICPR)*, 2021, pp. 7265–7272. doi: 10.1109/ICPR48806.2021.9413241.
- [TFGMA24] M. Á. López Reyes, *Métodos de aprendizaje profundo para la identificación de objetos en imágenes por satélite*, Trabajo de Fin de Grado, Grado en Ingeniería en Informática, Universidad de Jaén, 2024. Directores: A.J. Rivera Rivas y M.D. Pérez Godoy. Disponible: <https://crea.ujaen.es/handle/10953.1/25377>.
- [TFGMP24] P. Ruiz-Muñoz, "Desarrollo de una aplicación de métodos deep learning para detección de anomalías," Trabajo de Fin de Grado, Grado en Ingeniería Informática, Universidad de Jaén, 2024. Directores: A.M. García-Vico y M.J. del Jesus. Disponible: <https://crea.ujaen.es/handle/10953.1/325>.
- [TFGS24] S. Montejo-Fernández, "Análisis de métodos deep learning para detección de anomalías," Trabajo de Fin de Grado, Grado en Ingeniería Informática, Universidad de Jaén, 2024. Directores: A.M. García-Vico y M.J. del Jesus. Disponible: <https://crea.ujaen.es/handle/10953.1/25399>.
- [Tor16] B. Torvik, K.E. Olsen, and H. Griffiths, "Classification of birds and UAVs based on radar polarimetry," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, no. 9, pp. 1305–1309, 2016. doi: 10.1109/LGRS.2016.2582538.
- [Wan19] J. Wang, Z. Mo, H. Zhang, and Q. Miao, "A deep learning method for bearing fault diagnosis based on time-frequency image," *IEEE Access*, vol. 7, pp. 42373–42383, 2019.
- [WhatCNN] N. Shahriar, "What convolutional neural network (CNN) deep learning," *LinkedIn Pulse*, [Online]. Disponible: <https://www.linkedin.com/pulse/what-convolutional-neural-network-cnn-deep-learning-nafiz-shahriar/>.

[Zha23] X. Zhang et al., "Remote Sensing Object Detection Meets Deep Learning: A metareview of challenges and advances," *IEEE Geoscience and Remote Sensing Magazine*, vol. 11, no. 4, pp. 8–44, Dec. 2023. doi: 10.1109/MGRS.2023.3312347.

[Zha19] K. Zhao and H. Shao, "Intelligent fault diagnosis of rolling bearing using adaptive deep gated recurrent unit," *Neural Processing Letters*, pp. 1–20, 2019.

7.2. ACRÓNIMOS

CNN	Red Neuronal Convocional
DL	Deep Learning
IA	Inteligencia Artificial
RCNN	Red Neuronal Convocional Recurrente
RNN	Red Neuronal Recurrente
XAI	Inteligencia Artificial eXplicable



Localización sobre cartografía en entornos no estructurados y con GNSS denegado

“LocalízaTe sin GPS”

Informe de Prospectiva 2024



1. INTRODUCCIÓN.....	33
1.1. Objetivo del informe	33
1.2. Contexto	33
2. FACTORES DE INFLUENCIA: LA VISIÓN DEL SISTEMA	33
3. IDENTIFICACIÓN DE TENDENCIAS	34
3.1. Datos e infraestructuras de datos espaciales	34
3.2. Sensores	35
3.2.1. Sensores formados de imagen	36
3.2.2. Sensores IMU	36
3.2.3. Sensores de gravedad	36
3.2.4. Sensores magnéticos	37
3.3. Procesado	37
4. ESCENARIOS FUTUROS	37
4.1. Escenario relativo a la disponibilidad universal de datos LiDAR	37
4.2. Escenario relativo a los sistemas de posicionamiento visual (VPS)	38
4.3. Escenario relativo a la odometría visual	38
5. CONCLUSIONES	38
6. ANEXOS	40
6.1. Referencias	40
6.2. Acrónimos.....	40

1. INTRODUCCIÓN

1.1. OBJETIVO DEL INFORME

El objetivo de este informe es presentar una prospección sobre los principales elementos en los que se basa el proyecto LocalizaTeSinGPS, y que pueden tener relevancia respecto a su desarrollo futuro. Se establece un alcance temporal de corto y medio plazo (entre 3 y 10 años).

El ámbito de este documento se restringe al conjunto de elementos que conforman la base de la solución sobre la que se está trabajando, en concreto: datos MDT y sensores (fotográficos, inerciales, magnéticos) y técnicas de procesado.

Este informe de prospectiva forma parte de los trabajos a través de la Cátedra Isdefe-UJA (Universidad de Jaén).

1.2. CONTEXTO

El proyecto titulado LOCALIZACIÓN SOBRE CARTOGRAFÍA EN ENTORNOS NO ESTRUCTURADOS Y CON GNSS DENEGADO (LocalizaTeSinGPS) tiene como objetivo desarrollar un sistema de posicionamiento de última milla para vehículos autónomos (VA), en desplazamiento “on road”, tal que, en un entorno GNSS denegado y por medio de sensores pasivos y datos geoespaciales permita establecer una posición fiable del vehículo.

El proyecto LOCALIZACIÓN SOBRE CARTOGRAFÍA EN ENTORNOS NO ESTRUCTURADOS Y CON GNSS DENEGADO incluye la utilización de cualquier tipología de datos geoespaciales existente en los catálogos de datos disponibles. Desde esta perspectiva, la utilización de los MDT es una opción a considerar dado que ha sido utilizado con éxito en métodos de “map-matching” (p.ej. TERCOM, TERPROM, DSCMAC, LINS, etc.), si bien en un entorno de aplicación distinto.

En este proyecto se está analizando la viabilidad de realizar el posicionamiento de última milla por medio de la correlación entre un MDT generado por el VA al vuelo, por técnicas fotogramétricas, y un MDT previo disponible de la zona.

2. FACTORES DE INFLUENCIA: LA VISIÓN DEL SISTEMA

Para considerar adecuadamente los factores de influencia se va a proceder a describir, de forma resumida, el sistema que se pretende alcanzar en su fase operativa final.

Se considera un sistema de posicionamiento/orientación que debería funcionar tal como lo haría un explorador en un entorno geográfico de dimensiones restringidas, pero sin conocimiento de su posición exacta. De esta forma, desplazándose a un lugar con cierta predominancia visual, apoyado en una cartografía del lugar y de alguna(s) indicacio(nes) de punto(s) singular(es), el explorador debería ser capaz de deducir su posición.

Para afrontar el reto indicado anteriormente, se considera un sistema complejo que aúna datos espaciales disponibles, sensórica y procesamiento (fotogramétrico, IA, etc.). Los elementos básicos que intervienen en el sistema son los que se indican en la Figura 1. Se trata de un proyecto de amplio recorrido que en su primera anualidad (septiembre de 2023 a noviembre de 2024) han centrado su foco en analizar la utilización

de los MDE (modelos digitales de elevaciones) como posible signatura posicional. La hipótesis base sobre la que se basa esta actividad consiste en considerar que dados dos conjuntos de datos MDT de una misma zona (CD1 y CD2), debe existir una alta correlación entre ellos. De esta manera, si uno de los conjuntos está georreferenciado de manera adecuada, al otro conjunto se le podrá asignar un posicionamiento compatible con aquel.

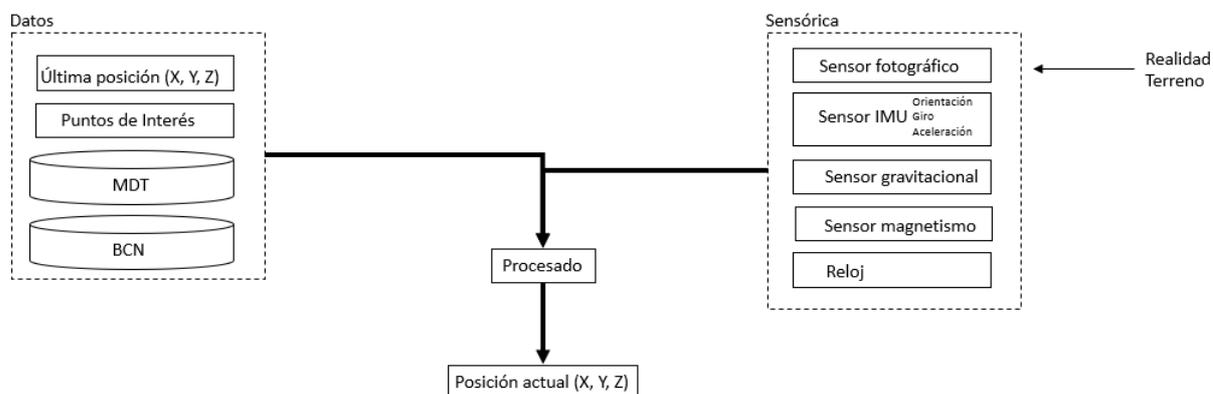


Figura 1: Visión general del sistema para la localización en entornos denegados.

Según lo indicado en la Figura 1 consideramos que los principales factores de influencia son los siguientes:

- Datos e infraestructuras de datos espaciales. Los datos espaciales son la base del conocimiento geográfico experto que dispondrá el sistema, son relevantes las tipologías de datos y los servicios avanzados que se puedan desarrollar sobre ellos.
- Sensores. El sistema a desarrollar debe basarse en sensores pasivos para no generar ningún tipo de huella detectable. También debe tratarse de sensores difícilmente perturbables. En este sentido, todo tipo de sensor que cumpla las condiciones anteriores debería ser analizado en cuanto a su aportación al sistema.
- Capacidad de procesamiento. La capacidad de procesamiento es clave para convertir los rasgos del terreno aportados por los datos espaciales y detectados por los sensores en una posición fiable del VA tanto en estático como en dinámico.

3. TENDENCIAS

En este apartado se realiza una breve prospectiva, en el corto y medio plazo, de elementos que intervienen o pueden intervenir en el sistema.

3.1. DATOS E INFRAESTRUCTURAS DE DATOS ESPACIALES

En relación a los datos, dado que el desarrollo de LocalizaTeSinGPS se enmarca en España, es relevante revisar el entorno específico en el que nos encontramos. Por un lado, en octubre pasado se lanzó el proceso de revisión de la directiva Inspire, en el que se desea incorporar una componente más aplicada. Por otra parte, existe una clara tendencia en los organismos productores de cartografía oficial a dar el paso a la incorporación de datos BIM y la conformación de gemelos digitales. Otra gran tendencia es la incorporación de la componente geográfica en los organismos productores de datos estadísticos y búsqueda de la interoperabilidad.

En relación a las bases cartográficas numéricas (BCN), la disponibilidad de mayor número de satélites, de sistemas LiDAR y de proyectos de aplicación de la IA para la detección de objetos en las imágenes, permite esperar que, en pocos años, los procesos de actualización sean más rápidos y automatizados.

En relación a los datos MDT cabe esperar que, gracias a las constelaciones de satélites disponibles y a vuelos LiDAR de mayor densidad de puntos, se disponga de modelos con mayor densidad de información y más actualizados. La IA está permitiendo la obtención de mejoras de productos MDT por medio de la fusión parcial de datos de más densidad y calidad.

En general, para un plazo medio se considera una clara consolidación de la tendencia en el incremento de la disponibilidad de datos, tanto en cantidad como en calidad, como en su tipología, generalmente ofrecidos por medio de servicios.

Una tecnología emergente en este campo son los sistemas de posicionamiento visual (Visual Positioning System). VPS utiliza técnicas de visión por computador e IA para determinar la posición y orientación en el mundo físico por medio de la correlación entre una imagen tomada en la posición de interés con las imágenes georreferenciadas almacenadas en una base de datos. Esta tecnología requiere de una infraestructura de gemelo digital de la realidad conformada por el fotografiado previo de la realidad. Otra técnica con posibilidades es la odometría visual (Visual Odometry), que permite extraer la posición a partir del análisis de secuencias de imágenes que incluyen elementos comunes de referencia.

3.2. SENSORES

Los sensores son una parte fundamental del sistema que se propone. Por un lado, se pueden considerar la existencia de unas tendencias generales y por otro de unas tendencias específicas para cada tipología. A continuación, se presentan las tendencias generales y, posteriormente, en subapartados independientes, las propias de cada tipología que interviene en el sistema.

Las principales tendencias generales son:

- Exactitud. Mejora de la exactitud y precisión en todas las gamas.
- Miniaturización. Menor tamaño, más compactos, menor peso, menor consumo.
- Eficiencia energética. Mejor aprovechamiento de la energía con consumos notablemente menores.
- Cosecha energética. Los sensores incorporarán técnicas de cosecha energética (p.ej. vibraciones, calor, radio frecuencias, etc.) para alimentarse.
- Autonomía. Alimentación de energía integrada y conexión Wireless a gran distancia permitirán una mayor autonomía.
- Autoaprendizaje. A lo largo de la vida del sensor sin necesidad de mantenimiento, modificaciones o calibraciones.
- Biosensores (espejos resonantes). Esta tecnología está cerca de su punto de madurez y posee gran interés en los campos industrial y de la salud.
- Fusión. Integración de múltiples sensores en un mismo dispositivo eliminando interfaces y robusteciendo los resultados.
- Inteligencia. Sensores con inteligencia embebida aplicada tanto a la captura como a las respuestas.
- Cuánticos. Sensores basados en la mecánica cuántica que permitirán alcanzar mayores precisiones y sensibilidad.

3.2.1. *SENSORES FORMADORES DE IMAGEN*

- Junto a las tendencias generales indicadas anteriormente, son tendencias particulares de los sensores formadores de imagen las siguientes:
- Imágenes basadas en eventos. Los píxeles incorporan sello temporal y responden a los cambios de intensidad
- Espectrómetros. Inclusión de espectrómetros para la mejora de los datos capturados.
- Hiperespectral. Incremento de las aplicaciones basadas en estos sensores.
- Nuevos materiales. Disponibilidad de nuevos materiales para la construcción (perovskite, semiconductores orgánicos, cuánticos, etc.) ofreciendo mayor sensibilidad, reducción ruido, menores consumos.
- Mejor resolución. Seguirá la reducción del tamaño del pixel ofreciendo más resolución en formatos de sensores más pequeños.
- Estabilización. Las técnicas IBIS (In-Body image stabilization) serán superadas para compensar mejor el movimiento de la cámara y permitir imágenes más nítidas, especialmente en condiciones de disparo difíciles.
- Rango dinámico. Mejora de la capacidad de capturar detalle en las zonas brillantes y oscuras gracias a la mejora de sensores y algoritmos.
- Baja iluminación. Mejora de la capacidad de realizar tomas en condiciones de baja iluminación.

3.2.2. *SENSORES IMU*

Junto a las tendencias generales, son tendencias particulares de los sensores inerciales las siguientes:

- Fusión. Mejoras en la fusión entre los sensores que suelen incorporar (acelerómetros, giróscopos, magnetómetros) y con otros sensores como GNSS, y con técnicas como la odometría visual.
- Robustez y fiabilidad. Mejoras para conseguir dispositivos más resistentes y fiables en entornos comprometidos (temperatura, vibración, golpes, etc.).
- Nuevas tecnologías de sensor. Las mejoras en el conocimiento de materiales, la física y miniaturización están permitiendo el desarrollo de nuevas tecnologías como los giróscopos basados en la resonancia magnética nuclear, sensores inerciales basados en átomos fríos, sensores basados en sistemas micro-opto-electro-mecánicos (MOEMS), Sensores inerciales de velocimetría de imágenes de partículas, etc.

3.2.3. *SENSORES DE GRAVEDAD*

Las anomalías de la gravedad pueden representar un método de posicionamiento para los sistemas de navegación con apoyo a los IMU (Tian y otros, 2019). Desde este punto de vista, las anomalías de la gravedad, más allá de ser usadas para las correcciones altimétricas en los modelos de geoide, presentan particularidades que pueden ser útiles para la navegación en entornos con GNSS denegado:

- Mejora continua en la determinación de las anomalías. Debido a la necesidad de modelos de geoide y a la determinación de la gravedad de una manera precisa tanto para la navegación GNSS convencional como para el control orbital correcto, existe una continua mejora en la precisión de los modelos de anomalías terrestres, lo que permitirá una mejor aproximación de la posición basada en esta metodología.
- Miniaturización y mejora de la sensibilidad instrumental. La miniaturización de los dispositivos para la medida de la anomalía de la gravedad, junto con el aumento de su sensibilidad relativa permiten su uso en plataformas más pequeñas e incluso móviles.

- Los algoritmos de ML y la fusión de la información de anomalías de diversas fuentes facilitarán la creación de mapas precisos a nivel local para mejorar la precisión de la navegación.

3.2.4. *SENSORES DE MAGNÉTICOS*

Más allá del uso de los sensores magnéticos de manera integrada en los sensores inerciales se han desarrollado tecnologías de navegación basadas en las anomalías magnéticas del campo terrestre (Canciani, 2016 y Canciani y Raquet, 2016 y 2020). Son tendencias en este aspecto las siguientes:

- Mejoras en las capturas de la anomalía magnética. Los nuevos sistemas de capturas para las anomalías magnéticas permiten una mejora sustancial del posicionamiento pudiendo alcanzar en algunos casos la precisión de un sistema GNSS.
- Uso de ML e IA para la mejora del posicionamiento mediante anomalías magnéticas permite una mayor aproximación de la solución absoluta.

3.3. PROCESADO

El proceso de la información multifuente y multisensor ha permitido hasta la actualidad una cierta aproximación a la solución del posicionamiento en entornos GNSS denegados. Todas las mejoras anteriormente indicadas, de forma individual, pueden permitir una mayor exactitud en el posicionamiento tanto absoluto como relativo, sin embargo, más allá de estas aproximaciones, se plantea que los desarrollos futuros pueden beneficiarse de:

- Mejor reconocimiento de objetos basados en IA. La mejora del reconocimiento de objetos puede permitir la correlación con otra información como anomalías magnéticas y/o gravitacionales que permita una mejora en la exactitud.
- Integración multiescala. La integración de información visual a gran escala junto con el reconocimiento de objetos lejanos permitirá el posicionamiento en diferentes mapas del terreno mejorando y facilitando el posicionamiento a diferentes resoluciones.
- Mejora del hardware y miniaturización. La constante mejora en velocidad de procesamiento del hardware permitirá un incremento en la velocidad de captura y procesamiento de la información y el consiguiente cálculo del posicionamiento permitiendo corregir posibles anomalías y errores. Además, la miniaturización permitirá el uso de sistemas redundantes que den una mayor robustez al posicionamiento.

4. ESCENARIOS FUTUROS

Las tendencias indicadas ofrecen de manera aislada y combinada un amplio conjunto de posibles escenarios. En principio, consideramos que todos ellos son favorables al desarrollo del sistema que se propone. A continuación, se presentan aquellos más relacionados con los datos espaciales por ser la base sobre la que concommitan el resto de elementos del sistema.

4.1. ESCENARIO RELATIVO A LA DISPONIBILIDAD UNIVERSAL DE DATOS LIDAR

Este escenario se refiere al incremento sustancial de la disponibilidad de datos LiDAR tanto en España como fuera de España. El boom de las técnicas de captura de datos LiDAR de alta y muy alta densidad espacial y de manera universal afectará positivamente al proyecto LocalizaTeSinGPS. Por un lado, el

disponer de datos LiDAR de mayor densidad consideramos permitirá ajustar mejor la signatura posicional extraída de un MDE. Por otra parte, la universalización de este tipo de datos, permitirá que la solución que se está desarrollando y que se ha definido considerando la disponibilidad actual en España de datos MDE y geoespaciales, también podrá ser válida en otros países.

Consideramos que este escenario tiene una probabilidad alta-muy alta y que no presenta riesgos, es una oportunidad perfectamente aprovechable.

4.2. ESCENARIO RELATIVO A LOS SISTEMAS DE POSICIONAMIENTO VISUAL (VPS)

Este escenario enlaza con el desarrollo de los gemelos digitales, fundamentalmente urbanos entendidos como una gran infraestructura de datos geoespaciales. La tecnología base VPS ya está disponible pero, debido a la escasez de datos, su grado de despliegue es muy reducido y, además, su escalado a nivel de todas las poblaciones (provincia, país, continente) supone grandes retos (captura de la información, procesado, almacenamiento, etc.). Su extensión al ámbito no urbano (red de carreteras, espacios naturales, etc.) no está en nada resuelta. Cabe esperar que el nivel de cobertura de esta infraestructura sobre las principales poblaciones se vaya consolidando, poco a poco, en el medio plazo. Cabe esperar un proceso semejante al que ocurrió con Street View de Google.

Este escenario ofrece aspectos de interés para el proyecto LocalizaTeSinGPS. Por un lado, viene a confirmar la viabilidad de la posibilidad de referenciación utilizando sensores formadores de imágenes a partir de datos geoespaciales disponibles en una infraestructura. Por otro lado, ofrece la posibilidad de extender la utilización de los VA a entornos urbanos.

En el marco temporal que se analiza, consideramos que este escenario tiene una probabilidad alta-muy alta de seguir desarrollándose y que no presenta riesgos, todo lo contrario, es una oportunidad perfectamente aprovechable y que facilita y posibilita la transferencia de tecnología hacia el proyecto LocalizaTeSinGPS.

4.3. ESCENARIO RELATIVO A LA ODOMETRÍA VISUAL

Este escenario se relaciona conceptualmente con el anterior, pero también se vincula con los sensores formadores de imagen y la capacidad de procesamiento, principalmente. La odometría visual se encuentra en completa efervescencia en cuanto a su integración con la IA, al desarrollo de métodos (p.ej. directos y semi-directos), soluciones en tiempo real y embebidas, integración con SLAM (híbridos VO-SLAM), etc.

Este escenario ofrece aspectos de interés para el proyecto LocalizaTeSinGPS y complementa a los escenarios anteriores. La llegada al mercado de cámaras con capacidades embebidas de odometría visual son un elemento a tener en consideración para las futuras actividades de este proyecto.

En el marco temporal que se analiza, consideramos que este escenario tiene una probabilidad alta-muy alta de seguir desarrollándose. Este escenario no presenta riesgos, todo lo contrario, ofrece una oportunidad perfectamente aprovechable y que facilita y posibilita la transferencia de tecnología hacia el proyecto LocalizaTeSinGPS.

5. CONCLUSIONES

En un medio plazo se va a disponer de mayor cantidad de datos, infraestructuras de datos, de sensores y técnicas de fusión de sensores que ayudarán a que el reto planteado en el proyecto LocalizaTe Sin GPS

sea mucho más sencillo de superar. A lo anterior hay que añadir una explosión inmensa y generalizada de las aplicaciones de la Inteligencia Artificial, incluidas las embebidas, tal que se dispondrá de sistemas que permitirán el reconocimiento efectivo y fiable de numerosos rasgos del terreno que podrán ser utilizados como puntos de interés para la orientación y posicionamiento. En cualquier caso, el propio terreno seguirá siendo el marco sobre el que todos los demás elementos deberán fusionarse y complementarse para alcanzar un posicionamiento con las exigencias de exactitud posicional adecuadas a la gestión de un vehículo autónomo.

6. ANEXOS

6.1. REFERENCIAS

Benser E.T. (2015). Trends in Inertial Sensors and Applications

Canciani, Aaron J., "Absolute Positioning Using the Earth's Magnetic Anomaly Field" (2016). Theses and Dissertations. 251. <https://scholar.afit.edu/etd/251>

Canciani, A., Raquet, J., Absolute Positioning Using the Earth's Magnetic Anomaly Field. Journal of Institute of Navigation, 63(3): 371 (2016). <https://onlinelibrary.wiley.com/doi/10.1002/navi.138>

Canciani, A., Raquet, J. Positioning Using Magnetic Fields en Position, Navigation, and Timing Technologies in the 21st Century: Integrated Satellite Navigation, Sensor Systems, and Civil Applications, Volume 2. Capítulo 48 (2020). ISBN:9781119458494. <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119458555.ch48>

El-Sheimy, N., Youssef, A. Inertial sensors technologies for navigation applications: state of the art and future trends. Satell Navig 1, 2 (2020). <https://doi.org/10.1186/s43020-019-0001-5>

Tian, D., Lingjuan, M., Haijun, S., Yongsheng, S., Solving Gravity Anomaly Matching Problem Under Large Initial Errors in Gravity Aided Navigation by Using an Affine Transformation Based Artificial Bee Colony Algorithm, Frontiers in Neurorobotics 13 (2019). <https://doi.org/10.3389/fnbot.2019.00019>

<https://e.sentech.nl/en/news/21-sensor-technology-future-trends>

<https://network-king.net/five-trends-in-sensor-technologies-for-iot/>

<https://www.geospatialworld.net/prime/business-and-industry-trends/what-is-visual-positioning-system-vps/>

<https://www.idtechex.com/en/research-report/emerging-image-sensor-technologies-2024-2034-applications-and-markets/965>

<https://www.electronicdesign.com/markets/automation/article/21145842/electronic-design-magnetic-field-navigation-as-an-alternative-gps>

6.2. ACRÓNIMOS

MDT	Modelo digital del terreno.
MDE	Modelo digital de elevaciones.
MDS	Modelo digital de superficies.
VA	Vehículo autónomo.
VPS	Visual Positioning System
UJA	Universidad de Jaén.
GNSS	Global Navigation Satellite System.



UNIVERSIDAD DE JAÉN

Sistemas de identificación y clasificación de amenazas dron en imagen

Informe de Prospectiva 2024



1. INTRODUCCIÓN.....	44
1.1. Objetivo del informe.....	44
1.2. Contexto	44
2. FACTORES DE INFLUENCIA.....	45
3. IDENTIFICACIÓN DE TENDENCIAS.....	46
3.1. Tendencias actuales	46
3.2. Tendencias emergentes	49
4. ESCENARIOS FUTUROS	51
4.1. Escenario #1: Implementación de técnicas basadas en el procesado de señales radar.....	51
4.1.1. Análisis del escenario #1	51
4.1.2. Probabilidad del escenario #1	51
4.1.3. Riesgos, oportunidades y medidas de mitigación del escenario #1.....	52
4.2. Escenario #2: Implementación de técnicas basadas en la adquisición y procesado de señales de radiofrecuencia	52
4.2.1. Análisis del escenario #2	52
4.2.2. Probabilidad del escenario #2	53
4.2.3. Riesgos, oportunidades y medidas de mitigación del escenario #2.....	53
4.3. Escenario #3: Implementación de técnicas basadas en el procesado de señales de audio	53
4.3.1. Análisis del escenario #3	54
4.3.2. Probabilidad del escenario #3	54
4.3.3. Riesgos, oportunidades y medidas de mitigación del escenario #3.....	54
4.4. Escenario #4: Implementación de técnicas avanzadas de adquisición y procesado de imágenes	55
4.4.1. Análisis del escenario #4	55
4.4.2. Probabilidad del escenario #4	55
4.4.3. Riesgos, oportunidades y medidas de mitigación del escenario #4.....	55
4.5. Escenario #5: FUSIÓN SENSORIAL.....	56
4.5.1. Análisis del escenario #5	56
4.5.2. Probabilidad del escenario #5	56
4.5.3. Riesgos, oportunidades y medidas de mitigación del escenario #5.....	56
5. PROPUESTA DE ACCIONES	56
5.1. Acciones recomendadas	56
5.2. Plan de seguimiento	56
6. CONCLUSIONES	58

TABLA DE CONTENIDOS

7. ANEXOS	59
7.1. Referencias.....	59

1. INTRODUCCIÓN

1.1. OBJETIVO DEL INFORME

El objetivo de este informe de prospectiva es anticipar y analizar las tendencias y posibles escenarios futuros en el ámbito de las tecnologías para la detección de amenazas por drones. Este documento pretende proporcionar una visión integral de las tecnologías actuales y emergentes que están modelando este campo y ofrecer recomendaciones que guíen las decisiones estratégicas en materia de defensa y seguridad. El informe se centra en identificar los retos y oportunidades de estas tecnologías con un alcance temporal de mediano a largo plazo (5-10 años), considerando tanto el contexto español como europeo.

Para realizar este informe prospectivo hemos analizado el estado de la tecnología que aparece en la literatura científica reciente y bajo la hipótesis de que dichos estudios pueden servir de base para futuros proyectos que eleven su TRL y finalmente se traduzcan, a largo plazo, en prototipos industriales. En este análisis se han empleado diferentes bases de datos tales como WoS o Scopus, focalizando la búsqueda en artículos que versan sobre la detección y clasificación de amenazas drone de forma amplia.

Este informe de prospectiva forma parte del trabajo que el grupo de investigación TEP 237 - Robótica, Automática y Visión por Computador (GRAV) está realizando bajo el título “Sistemas de identificación y clasificación de amenazas dron en imagen” que tiene como objetivo principal la identificación automática y clasificación de drones para permitir una mejor actuación de contramedidas. El trabajo está articulado a través de la Cátedra ISDEFE/CETEDEX-UJA (Universidad de Jaén).

1.2. CONTEXTO

El uso de drones ha experimentado un crecimiento exponencial en la última década, abarcando aplicaciones que van desde la entrega de paquetes y la vigilancia hasta operaciones militares y actividades de espionaje. Este incremento en la utilización de drones ha suscitado preocupaciones respecto a su potencial uso malintencionado, lo que subraya la importancia de desarrollar y mejorar sistemas de detección confiables y eficientes.

Actualmente, las principales tecnologías de detección incluyen sistemas basados en radar, radiofrecuencia (RF), captación de audio y procesamiento de imágenes [1-2]. Cada una de estas técnicas presenta ventajas y limitaciones particulares. Por ejemplo, los sistemas de radar son reconocidos por su fiabilidad en condiciones meteorológicas adversas y su capacidad de detección a largo alcance, pero pueden verse limitados por la baja sección transversal de los drones más pequeños. Las tecnologías basadas en RF son eficaces en la captación de señales de comunicación, pero no pueden detectar drones autónomos que no emiten señales.

El procesamiento de audio se presenta como una opción accesible y de rápida implementación, aunque está sujeto a interferencias por ruido ambiental y limitaciones en el rango de detección. Por otro lado, las técnicas de procesamiento de imágenes, impulsadas por el aprendizaje profundo y la visión por computador, han mostrado avances notables en la identificación de drones a través de análisis visuales. No obstante, estas técnicas dependen de la calidad de las condiciones de luz y de la línea de visión.

Un enfoque cada vez más relevante es la fusión sensorial, que combina información de múltiples fuentes para superar las limitaciones inherentes a cada tecnología individual. La integración de datos provenientes de radar, RF, audio e imágenes promete aumentar la eficacia y precisión de los sistemas de detección, permitiendo una respuesta más completa y adaptada a diferentes escenarios operacionales. Este informe busca no solo identificar estas tecnologías y sus desarrollos más recientes, sino también analizar su impacto potencial en el panorama de seguridad actual y proponer acciones para fortalecer la posición de liderazgo en la investigación y aplicación de dichas tecnologías en el ámbito de la defensa y la seguridad civil.

2. FACTORES DE INFLUENCIA

FACTORES DE INFLUENCIA	
Factores normativos	<p>La evolución de la regulación sobre el espacio aéreo y el uso de drones es uno de los factores más determinantes en el desarrollo de tecnologías de detección. En los últimos años, la normativa ha avanzado para enfrentar los retos que representan los drones en entornos urbanos y en espacios restringidos. Las regulaciones internacionales, lideradas por organismos como la Organización de Aviación Civil Internacional (OACI) y la Agencia Europea de Seguridad Aérea (EASA), establecen los parámetros que condicionan la implementación de tecnologías de detección. Estas normativas buscan garantizar la seguridad y la privacidad, lo que puede representar tanto un impulso como una barrera para el desarrollo de nuevos sistemas. Las leyes que regulan el uso de drones también pueden incentivar la inversión en tecnologías de detección o, por el contrario, limitar su despliegue debido a preocupaciones legales y éticas.</p>
Factores geoestratégicos	<p>El entorno político global y las tensiones geoestratégicas juegan un papel fundamental en la adopción y desarrollo de tecnologías de detección de drones. Las amenazas de espionaje, sabotaje y ataques de drones en zonas de conflicto han acelerado la necesidad de soluciones de detección avanzadas. Las relaciones internacionales, así como la colaboración entre países para la defensa común, influyen directamente en las decisiones de desarrollo e implementación de estas tecnologías. Por ejemplo, la colaboración en programas de defensa conjunta entre la Unión Europea y la OTAN ha potenciado la investigación y el despliegue de sistemas avanzados para la detección de amenazas aéreas.</p>
Factores económicos	<p>El desarrollo de tecnologías para la detección de drones está vinculado a la disponibilidad de recursos financieros y a la inversión en investigación y desarrollo (I+D). Las economías más fuertes tienen mayores probabilidades de liderar la implementación de estas tecnologías debido a la capacidad de destinar fondos a proyectos de vanguardia. Sin embargo, el costo de las tecnologías de detección avanzadas, como los sistemas de radar de alta frecuencia y las cámaras de alta resolución, puede ser una barrera para algunos países o sectores con presupuestos limitados. Además, la demanda del mercado y las oportunidades de negocio relacionadas con la seguridad pública y privada influyen en el desarrollo y la adopción de estas tecnologías.</p>
Factores tecnológicos	<p>El rápido avance de la inteligencia artificial (IA) y el aprendizaje profundo ha permitido un progreso significativo en las capacidades de los sistemas de detección de drones. Los sensores de alta sensibilidad, junto con algoritmos de procesamiento de señales más complejos, permiten detectar y clasificar drones con mayor precisión y rapidez. Estos desarrollos están impulsando la integración de sistemas multimodales que pueden operar en diversos escenarios y condiciones. Las innovaciones tecnológicas también están reduciendo el tiempo de respuesta de los sistemas y mejorando la capacidad de análisis en tiempo real. Sin embargo, la dependencia de estas tecnologías de</p>

	fuentes de energía fiables y la necesidad de mantener una infraestructura tecnológica avanzada pueden representar un desafío para su aplicación en zonas con recursos limitados.
Factores políticos	La seguridad nacional y las políticas de defensa son impulsores clave en el desarrollo de tecnologías de detección de drones. Los gobiernos de todo el mundo están adoptando estrategias para fortalecer sus capacidades defensivas y proteger infraestructuras críticas contra potenciales ataques con drones. Estas políticas se reflejan en la asignación de recursos y en la promoción de investigaciones y desarrollos en el ámbito de la tecnología de detección.

Tabla 1: Factores de influencia.

3. IDENTIFICACIÓN DE TENDENCIAS

3.1. TENDENCIAS ACTUALES

Las referencias consultadas coinciden en que las tecnologías sobre las que se está investigando con el objetivo de optimizar sus tasas de éxito de identificación y discriminación son cuatro [1-2]: las técnicas basadas en **radar**, sistemas de detección basados en procesamiento de **señales de radiofrecuencia**, técnicas basadas en el procesamiento de **señales de audio** y tecnologías basadas en **adquisición y procesamiento de imágenes** sobre diferentes longitudes de onda.

Técnicas basadas en el procesamiento de señales radar

Es considerada como la tecnología de detección más confiable cuando se aborda la detección de vehículos aéreos no tripulados, ya que tradicionalmente se ha utilizado para la detección de aeronaves con fines militares y civiles (como la aviación). El radar es una tecnología electromagnética que emplea ondas de radio para detectar y localizar objetos cercanos. Cualquier sistema de radar funciona basándose en mediciones basadas en el eco y consta de un transmisor de radar que envía ondas electromagnéticas cortas en la banda de radio o microondas, antenas transmisoras y receptoras, un receptor de radar que recibe las señales reflejadas del objetivo y un procesador que identifica los atributos de los objetos. Por lo tanto, el radar puede obtener características tales como distancia, la velocidad, el azimut y la elevación. En cuanto a sus ventajas e inconvenientes:

- Ventajas: de largo alcance; rendimiento en todo tipo de climas; habilidad para reconocer vectores de características de tipo Micro-Doppler (MDS); medición de velocidad y dirección.
- Inconvenientes: capacidad de detección limitada debido a la baja sección transversal del radar (RCS); rendimiento limitado debido a bajas altitudes y velocidades; alto costo y complejidad de implementación.

Dentro de las diferentes tecnologías radar se encuentran en radar de largo alcance que opera en las bandas X y S [3], el radar de onda milimétrica [4], el radar pulsado Doppler [5], el radar de onda continua [6], el radar de onda continua modulada en frecuencia [7] y el radar de efecto micro-Doppler [8]. En los últimos años se ha visto un aumento significativo en la importancia de la detección y clasificación de vehículos aéreos no tripulados mediante el efecto **micro-Doppler** del radar. Debido a que las aspas giratorias de los drones modulan las ondas de radar incidentes, se sabe que los drones provocan cambios micro-Doppler en los ecos del radar. Partes específicas de un objeto que se mueven por separado del resto proporcionan una **huella digital micro-Doppler**. Estas huellas pueden ser producidas por drones simplemente girando las palas de sus hélices [9]. Además, los componentes móviles del dron, como los rotores o las alas, producen ecos de radar únicos. Al examinar estas huellas, los autores de [10] propusieron un enfoque

novedoso que se centra en desarrollar algunos patrones y características para identificar varios drones pequeños según los tipos de palas. En [11], los autores propusieron una técnica basada en el aprendizaje profundo para la detección y clasificación de huellas digitales micro-Doppler de radar de múltiples helicópteros. Se recopilaron imágenes de radar micro-Doppler de helicópteros de alas giratorias y varios otros objetos no giratorios utilizando un radar de onda continua (CW), y luego las **imágenes micro-Doppler** se etiquetaron y alimentaron a un **modelo CNN** entrenado. Las mediciones experimentales mostraron una precisión de reconocimiento del 99,4%. Como suele ocurrir cuando se construyen modelos basados en aprendizaje profundo, para conseguir altas tasas de éxito es necesario entrenar y testear los modelos con una gran cantidad de datos. Proyectos de investigación pueden ir alineados en este sentido.

Técnicas basadas en la adquisición y procesado de señales de radiofrecuencia

Estas técnicas parte del análisis de las señales de comunicación para la transmisión de datos de telemetría, multimedia y señales de control entre el controlador remoto o estación de control y los UAV. Dichas señales son capturadas por receptores de radio frecuencia y procesadas mediante algoritmos de detección de señales para la identificación del dron. Las ventajas e inconvenientes de dicha tecnología son:

- Ventajas: detección e identificación de largo alcance; resistencia a todas las condiciones climáticas; capacidad de capturar señales y espectros de comunicación del UAV y su operador; capacidad de distinguir diferentes tipos de vehículos aéreos no tripulados.
- Desventajas: incapaz de identificar drones autónomos; interferencia con otras fuentes de RF; vulnerable a los piratas informáticos.

Los estudios que tratan con la tecnología RF suelen trabajar con la misma metodología experimental: preprocesado de la señal RF para eliminar ruido, extracción de características y sintonización, parametrización y evaluación de algoritmos de clasificación. Un estudio reciente es el documentado en [12], en el que los autores probaron varios modelos de aprendizaje profundo y aprendizaje automático para tareas de clasificación y extracción de características de RF de drones. La solución de detección de drones propuesta comenzó con el preprocesamiento de datos sin procesar de señales de RF de drones del conjunto de datos DroneRF disponible públicamente [13]. Tras esto emplearon métodos fusionados para extraer características en el dominio del tiempo y la frecuencia. Para la clasificación emplearon diferentes propuestas. En la primera solución, las características extraídas se introdujeron en un clasificador de aprendizaje automático **XGBoost**, mientras que, en la segunda solución, tanto la extracción como la clasificación de características, se realizaron utilizando un **modelo de aprendizaje profundo 1D-CNN**; en la tercera solución, las características se extrajeron utilizando un modelo de aprendizaje profundo 1D-CNN y se clasificaron utilizando clasificadores de aprendizaje automático y viceversa. Para balancear las clases emplearon técnicas **de aprendizaje semisupervisado** con la generación de datos sintéticos en función de las características originales de la clase minoritaria, mejorando las tasas de acierto. El estudio consiguió una tasa de acierto superior al 99%.

Técnicas basadas en el procesado de señales de audio

Esta técnica consiste en la captación de señales de audio a través de sensores acústicos de alta sensibilidad (micrófonos) y posteriormente se procesa para crear un mapa de características.

- Ventajas: económico; no se requiere línea de visión (LoS); implementación rápida.
- Desventajas: ruido de fondo; rango de detección limitado; vulnerabilidad a las condiciones del viento.

Estudios publicados en los últimos años han demostrado que los métodos basados en audio son útiles para la identificación de drones. Debido a sus motores, palas de las hélices, características aerodinámicas, etc., los drones generan huellas digitales únicas, que pueden emplearse en tareas de detección. El audio que se emplea con mayor frecuencia es el sonido por las palas de las hélices, ya que tiene una ganancia

superior al resto. Diferentes trabajos de investigación han examinado el sonido producido por los drones, utilizando características como la frecuencia, amplitud, modulación y duración para identificar la existencia de los mismos. En [14] se propuso una metodología para la clasificación de sonido de UAVs multiclase **basada en CNN** con un conjunto de datos a gran escala: archivos de audio de 10 UAV distintos, desde drones de juguete hasta drones de Clase I, y cada archivo incluye una grabación de 5 segundos del sonido del dron. En la parte de extracción de características, los MFCC (coeficientes característicos de la señal de audio) se extrajeron de muestras de audio en dos pasos: primero, el audio se convirtió de la escala Hz a la escala Mel y luego al logaritmo de la escala Mel; a continuación, se realizaron transformaciones de magnitud logarítmica y de coseno discreto. La característica MFCC es una característica del formada a partir de las frecuencias de componen la señal de audio. Luego, las características extraídas se introdujeron en un modelo CNN simple para entrenar el sistema de clasificación de drones. Los resultados obtenidos mostraron una tasa de éxito en clasificación de alrededor del 97,7 %.

Técnicas basadas en adquisición y procesado de imágenes

Los sistemas basados en la captura y procesado de imágenes consisten en adquirir información visual del dron (imágenes o vídeos) mediante matrices de sensores ópticos sensibles a diferentes longitudes de onda y luego identificar el dron en la matriz digital producida a partir de algoritmos de detección de objetos, usando para ellas técnicas de visión por computador. El proceso de capturar datos visuales de objetos se llama adquisición de imágenes y consta de tres pasos principales: primero, la energía se refleja desde el objeto de interés; luego, es enfocado mediante un sistema óptico; y finalmente, la cantidad de energía se mide usando el sensor de la cámara. Algunas ventajas y limitaciones de la tecnología son las siguientes:

- Ventajas: confirmación visual; no intrusivo; económico.
- Desventajas: rango de detección limitado y requiere LoS; dependencia del clima y la iluminación.

Las metodologías de procesado de imágenes para la detección y clasificación de objetos se agrupan en dos grandes grupos: metodologías clásicas (basadas en técnicas de binarización y extracción de descriptores de regiones de interés) y **metodologías basadas en aprendizaje profundo**. Las últimas son las más utilizados en los estudios recientes [15-24]. El aprendizaje profundo para la detección de objetos con redes neuronales convolucionales (CNN) tiene dos enfoques: detección en una etapa y detección en dos etapas. Debido a su alta velocidad de inferencia, los detectores de una etapa, como los algoritmos de “You Only Look Once” (YOLO) y de “Single Shot Detector” (SSD), son muy rápidos. Por otro lado, los detectores de dos etapas son más precisos, lo que implica una mejor localización e identificación de objetos en la imagen. Este método busca proporcionar varios cuadros delimitadores para los objetos de la imagen. Los detectores de dos etapas más conocidos son la red neuronal convolucional basada en regiones (**R-CNN**). El diseño de arquitecturas de **redes convolucionales optimizadas** para el problema planteado unidas a la generación de una **base de datos lo suficientemente amplia** es sin duda objeto de interés para futuros proyectos de investigación.

Uno de los puntos críticos de la tecnología es el **tiempo de procesado de imágenes** de alta resolución. Para que las técnicas basadas en procesado de imágenes sean realmente útiles es necesario que los modelos arrojen resultados a la misma frecuencia de adquisición de imágenes del sensor. Trabajando este aspecto existen trabajos publicados a mediados del 2023 como el referenciado en [15]. En él los autores propusieron un modelo AD-YOLOv5s que modifica la arquitectura original YOLOv5. Empleando TensorRT consiguieron acelerar el modelo que ejecutaron en una Jetson Nano. Los resultados experimentales arrojaron tasas de acierto cercanas al 90% con velocidades de ejecución cercanas a los 30 frames por segundo.

Unida a la alta velocidad de procesado se encuentra otro aspecto clave, la **visión 360° de alta resolución**. Para ello, diferentes estudios como el publicado en [25] han tratado de robotizar sistemas de visión dotados de ópticas telescópicas. Dado que el tiempo de reacción es un parámetro crucial para una defensa exitosa frente a amenazas, es necesario mejorar aún más la distancia operativa del sistema de detección óptico.

Este estudio mencionado presenta el análisis, desarrollo y evaluación de un sistema de detección de UAV basado en telescopio. El sistema consta de una montura de alta precisión y un telescopio equipado con una cámara. Los UAV se detectan en los fotogramas de vídeo capturados mediante el algoritmo de aprendizaje profundo YOLOv4 utilizando una arquitectura modificada. El sistema propuesto, que utiliza un telescopio f/10 con una distancia focal de $f = 2540$ mm y una cámara equipada con un sensor de $7,3 \text{ mm} \times 4,1 \text{ mm}$, permite un aumento significativo en el rango de detección óptica detectando UAVs a más de 3 km de distancia y con diámetros de 30 cm, en condiciones de luz diurna y con suficiente contraste.

3.2. TENDENCIAS EMERGENTES

Fusión sensorial

El futuro inmediato para por la integración de todas o parte de las tecnologías mencionadas anteriormente dado que cada una de las modalidades de detección de drones tiene su propio conjunto de limitaciones, y un sistema anti-drones sólido puede complementarse integrando varias modalidades. En este sentido la comunidad científica y las empresas fabricantes de sistemas anti-dron han comenzado a prestar atención a los métodos de **fusión de sensores bimodales y multimodales**; sin embargo, estas metodologías aún se encuentran en las primeras etapas de desarrollo e implementación. Los sistemas de **fusión de sensores** pueden integrar características de audio y visuales de sensores acústicos y de imagen [26–28] o combinar sistemas de radar y de imágenes visuales [29,30]; sensores de imagen y RF [31]; sensores de radar, RF y cámara [32]; sensores ópticos de cámara, audio y radar [33]; así como sensores visibles, térmicos y de audio [34] para mejorar la identificación, el seguimiento y la clasificación de drones. Al integrar las capacidades de varias modalidades sensoriales, el método aumenta la solidez y precisión de los sistemas de detección. Las técnicas de fusión de sensores, como la fusión temprana y la fusión tardía, se pueden aplicar a los sistemas de detección de drones. Estos enfoques definen cuándo y cómo se combinan los datos de varios sensores durante la detección e identificación de drones.

La **fusión temprana** (a veces denominada fusión de "nivel de datos" o "nivel de características") implica integrar datos sin procesar o características extraídas de varios sensores antes de cualquier procesamiento o análisis adicional. El objetivo es integrar los datos lo antes posible, lo que da como resultado una representación más completa de la información.

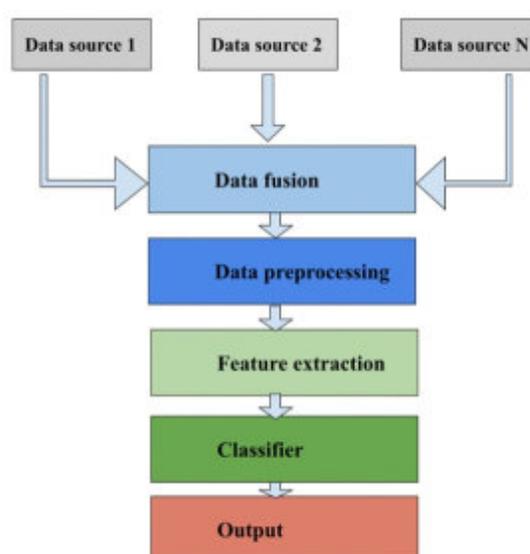


Ilustración 1: Fusión sensorial temprana

La **fusión tardía** (a veces denominada fusión de "nivel de decisión") es una aplicación de fusión de sensores en el que las decisiones o puntuaciones de confianza que indican la presencia del dron a partir de numerosos sensores separados se integran en una etapa posterior en la fase de procesamiento. Estas decisiones individuales o puntuaciones de confianza luego se agregan para formar una decisión final. Los sistemas de votación, los promedios ponderados, los enfoques bayesianos y los modelos de aprendizaje automático son algunos ejemplos de enfoques de agregación populares utilizados en la fusión tardía para la detección de drones.

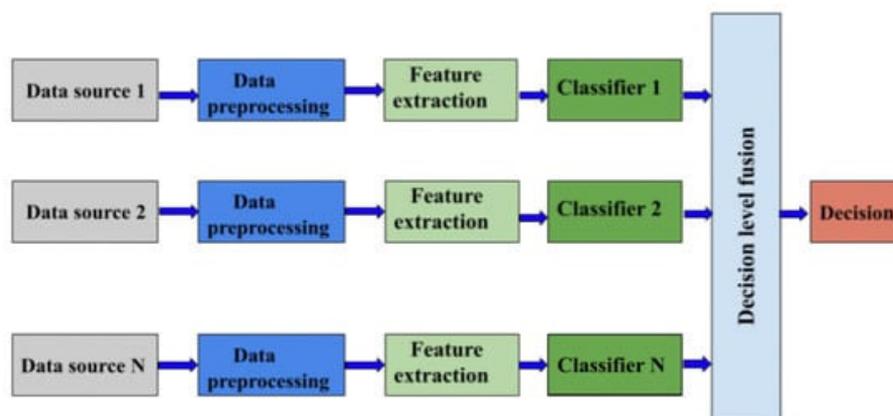


Ilustración 2: Fusión sensorial tardía

La fusión temprana y tardía se puede aplicar para integrar diferentes modalidades de sensores. Estos enfoques definen cuándo y cómo se combinan los datos de varios sensores durante la detección e identificación de drones. En la fusión temprana, los datos sin procesar o las características relevantes de varios sensores se combinan antes del modelo, que se entrena normalizando rangos de datos o concatenando los vectores de características. El principal beneficio de la fusión temprana es que permite que el sistema de detección utilice plenamente los datos combinados, lo que quizás dé como resultado resultados de detección y clasificación más precisos. La fusión temprana requiere que todos los datos de los sensores sean consistentes en términos de tamaño, resolución y alineación temporal. Por lo tanto, podría ser más intensivo desde el punto de vista computacional, ya que el conjunto de datos fusionados puede ser enorme y complicado. En la fusión tardía, las decisiones o puntuaciones de confianza que indican la presencia de un dron a partir de sensores individuales se combinan en la fase de detección.

Un estudio reciente publicado a finales del 2023 y referenciado en [35] obtuvo buenos resultados en la tarea de detección y clasificación de drones aplicando fusión sensorial tardía sobre tres fuentes sensoriales: imagen, audio y magnetismo. Para la parte del procesado de imagen desarrolló un detector óptico utilizando redes neuronales convencionales CNN y aprendizaje profundo DL para maximizar su rendimiento, encontrando limitaciones en escenas luminosas. Para la parte de audio desarrollaron un detector acústico utilizando máquinas de vectores de soporte SVM y aprendizaje automático ML para maximizar su rendimiento, estando este limitado por el ruido ambiente. Para resolver este último integraron un indicador de ambiente acústico. El detector de campo magnético que emplearon como tercer sensor se basó en una brújula y un magnetómetro. Para minimizar las limitaciones de cada sensor y aprovechar su rendimiento los autores emplearon inferencia bayesiana sobre el problema binario (drone o no drone). Aunque el estudio es prometedor, según la opinión del autor de este informe requiere ser validado de forma más extensa.

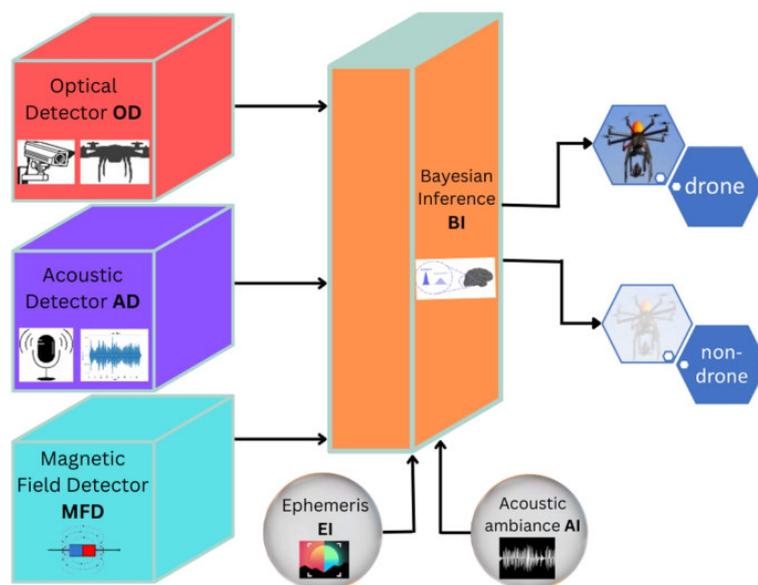


Ilustración 3: Inteferencia Bayesiana a partir de tres fuentes sensoriales

4. ESCENARIOS FUTUROS

4.1. ESCENARIO #1: IMPLEMENTACIÓN DE TÉCNICAS BASADAS EN EL PROCESADO DE SEÑALES RADAR

Este escenario contempla la implementación y optimización de técnicas basadas en señales radar para la detección y clasificación de drones. Considerada como una de las tecnologías de detección más confiables, el radar ha sido tradicionalmente empleado en la detección de aeronaves tanto en el ámbito militar como civil. El sistema radar utiliza ondas electromagnéticas para detectar y localizar objetos, midiendo la distancia, velocidad, azimut y elevación de los mismos mediante la emisión y recepción de ondas de radio reflejadas.

4.1.1. ANÁLISIS DEL ESCENARIO #1

La adopción de tecnologías basadas en radar ofrece ventajas significativas, como su capacidad de detección de largo alcance, operatividad en todo tipo de climas y la habilidad de reconocer características micro-Doppler, que son particularmente útiles para la identificación de drones. Los ecos micro-Doppler, generados por las palas y partes móviles de los drones, proporcionan una "huella digital" única que permite la identificación precisa de estos dispositivos. Sin embargo, esta tecnología también enfrenta desafíos, como la capacidad de detección limitada por la baja sección transversal del radar (RCS) y el rendimiento reducido en detecciones a bajas altitudes y velocidades.

Los estudios recientes han mostrado avances significativos en el uso de algoritmos de aprendizaje profundo para la clasificación de huellas micro-Doppler, alcanzando precisiones de hasta el 99,4%. Sin embargo, la implementación de estos modelos requiere un entrenamiento extenso con grandes volúmenes de datos para asegurar su efectividad.

4.1.2. PROBABILIDAD DEL ESCENARIO #1

La probabilidad de que este escenario se materialice es alta, considerando el creciente interés y los avances en tecnologías radar, especialmente en aplicaciones de defensa y seguridad. La capacidad de integrar

estas técnicas con algoritmos de IA y aprendizaje profundo facilita su adopción. No obstante, el alto costo y la complejidad de implementación pueden representar una barrera para algunos actores.

4.1.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #1

Riesgos:

- Costo elevado: Los sistemas radar son costosos y requieren una inversión significativa en infraestructura.
- Complejidad de implementación: La instalación y mantenimiento de estos sistemas pueden ser técnicamente complejos.
- Limitaciones en detección a bajas altitudes y velocidades: Dificultad para identificar drones pequeños y de baja altitud.

Oportunidades:

- Alta precisión de detección: La capacidad de detectar drones con características micro-Doppler permite una identificación detallada y precisa.
- Operatividad en todo tipo de climas: A diferencia de otras técnicas, los radares pueden funcionar eficazmente bajo diversas condiciones meteorológicas.
- Ampliación de aplicaciones de seguridad: Utilización en infraestructuras críticas, fronteras y zonas de alta seguridad.

Medidas de mitigación:

- Optimización de costos: Implementar soluciones de radar de menor escala y tecnologías complementarias para reducir gastos.
- Formación técnica: Capacitar al personal para gestionar y mantener los sistemas radar, asegurando su funcionamiento óptimo.
- Integración con otras tecnologías: Complementar el radar con otros métodos de detección (e.g., RF, imágenes) para superar limitaciones de alcance y altitud.

4.2. ESCENARIO #2: IMPLEMENTACIÓN DE TÉCNICAS BASADAS EN LA ADQUISICIÓN Y PROCESADO DE SEÑALES DE RADIOFRECUENCIA

Este escenario aborda el uso de técnicas de adquisición y procesamiento de señales de radiofrecuencia (RF) para la detección e identificación de drones. Estas técnicas se basan en el análisis de señales de comunicación utilizadas para la transmisión de datos de telemetría, multimedia y control entre los UAV y sus estaciones de control. Los receptores de RF capturan estas señales, que luego se procesan mediante algoritmos especializados para identificar y clasificar drones.

4.2.1. ANÁLISIS DEL ESCENARIO #2

Las técnicas basadas en RF ofrecen una serie de ventajas significativas, como la detección de largo alcance y la capacidad de operar en diversas condiciones climáticas. Pueden capturar tanto las señales del dron como las del operador, lo que facilita la identificación de diferentes tipos de vehículos aéreos no tripulados. Sin embargo, presentan limitaciones, como la incapacidad de identificar drones completamente autónomos que no emiten señales, y la posible interferencia con otras fuentes de RF, que puede afectar la precisión. Además, estos sistemas pueden ser vulnerables a ataques de piratería, lo que plantea preocupaciones de ciberseguridad.

Estudios recientes han avanzado en el uso de modelos de aprendizaje profundo y aprendizaje automático para mejorar la extracción y clasificación de características de señales RF. Por ejemplo, se ha demostrado que el uso de técnicas de preprocesamiento de datos y la aplicación de modelos como XGBoost y 1D-CNN pueden lograr tasas de acierto superiores al 99% en la detección de drones. La generación de datos sintéticos para equilibrar las clases también ha contribuido a mejorar la precisión de estos sistemas.

4.2.2. PROBABILIDAD DEL ESCENARIO #2

La probabilidad de que este escenario se haga realidad es alta, debido a la capacidad de las técnicas RF de operar en condiciones diversas y a su eficacia demostrada en estudios recientes. Sin embargo, la adopción de estas técnicas puede verse afectada por la necesidad de proteger los sistemas contra interferencias y ciberataques, y por la dificultad de detectar drones autónomos sin emisión de señales.

4.2.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #2

Riesgos:

- Interferencia con otras señales: Las señales RF pueden ser vulnerables a la interferencia de fuentes externas, lo que puede comprometer la precisión de la detección.
- Ciberseguridad: La posibilidad de ataques de piratería que comprometan la efectividad del sistema.
- Limitaciones con drones autónomos: Los drones que no emiten señales son más difíciles de detectar con estas técnicas.

Oportunidades:

- Detección de largo alcance: Capacidad para identificar drones a grandes distancias, lo cual es ventajoso en operaciones de vigilancia y defensa.
- Ampliación del alcance operativo: Integración con otras técnicas para mejorar la cobertura y la precisión.
- Eficiencia en condiciones adversas: Operatividad en cualquier condición climática, lo que aumenta la versatilidad del sistema.

Medidas de mitigación:

- Desarrollo de sistemas de filtrado avanzado: Implementar algoritmos de filtrado para minimizar la interferencia de otras fuentes de RF.
- Fortalecimiento de la ciberseguridad: Adoptar medidas de seguridad robustas para proteger los sistemas de ataques externos.
- Complemento con otras tecnologías: Integrar las técnicas de RF con otros sistemas de detección, como radar o procesamiento de imágenes, para compensar las limitaciones en la detección de drones autónomos.

4.3. ESCENARIO #3: IMPLEMENTACIÓN DE TÉCNICAS BASADAS EN EL PROCESADO DE SEÑALES DE AUDIO

Este escenario aborda la utilización de técnicas de procesamiento de señales de audio para la detección de drones. Estas técnicas captan señales acústicas mediante sensores de alta sensibilidad, como micrófonos, y procesan los datos para identificar patrones característicos del sonido de los drones. Las huellas digitales acústicas se utilizan para detectar y clasificar drones en diferentes entornos operativos, aprovechando el sonido generado por motores y hélices.

4.3.1. ANÁLISIS DEL ESCENARIO #3

El procesado de señales de audio se ha demostrado eficaz para la detección de drones debido a la singularidad de los sonidos que generan. Estos métodos permiten una implementación rápida y no requieren línea de visión (LoS), lo que los hace útiles en áreas donde otros métodos pueden verse limitados. Sin embargo, estas técnicas enfrentan desafíos relacionados con el ruido de fondo, el rango de detección y las condiciones del viento, que pueden afectar la precisión de la detección. Los estudios han demostrado que la extracción de características de audio, como los coeficientes MFCC, y su análisis mediante modelos de redes neuronales convolucionales (CNN) pueden alcanzar tasas de éxito cercanas al 97,7 % en la clasificación de drones.

4.3.2. PROBABILIDAD DEL ESCENARIO #3

Este escenario tiene una probabilidad moderada de materializarse como un componente complementario de los sistemas de detección de drones. La viabilidad de las técnicas basadas en audio es alta debido a su bajo coste y facilidad de implementación. No obstante, las limitaciones inherentes relacionadas con el ruido ambiental y las condiciones climáticas pueden afectar su adopción en escenarios donde se necesita una alta precisión y confiabilidad.

4.3.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #3

Riesgos:

- Sensibilidad al ruido de fondo: La precisión de la detección puede verse afectada en entornos con altos niveles de ruido no relacionado.
- Rango de detección limitado: Estas técnicas suelen tener un alcance más reducido comparado con otras tecnologías.
- Dependencia de las condiciones meteorológicas: El viento y otros factores climáticos pueden distorsionar las señales acústicas.

Oportunidades:

- Bajo coste de implementación: Las técnicas basadas en audio son más económicas y accesibles en comparación con otras tecnologías de detección.
- No requiere línea de visión: Puede ser eficaz en áreas donde los métodos ópticos fallan debido a obstáculos físicos.
- Desarrollo de métodos híbridos: Integrar audio con otras técnicas (e.g., RF, radar) para crear sistemas de detección multimodales y más robustos.

Medidas de mitigación:

- Filtrado de ruido: Desarrollar algoritmos avanzados de cancelación de ruido para mejorar la precisión en entornos ruidosos.
- Combinación con otras tecnologías: Utilizar el procesado de audio como parte de un sistema de detección híbrido que compense sus limitaciones.
- Optimización de sensores: Implementar micrófonos especializados y algoritmos de preprocesamiento que mitiguen el impacto de las condiciones climáticas adversas.

4.4. ESCENARIO #4: IMPLEMENTACIÓN DE TÉCNICAS AVANZADAS DE ADQUISICIÓN Y PROCESADO DE IMÁGENES

Este escenario se centra en la adopción y evolución de técnicas avanzadas basadas en la adquisición y el procesamiento de imágenes para la detección de drones. Estas técnicas utilizan sensores ópticos que capturan imágenes o vídeos a diferentes longitudes de onda, y algoritmos de visión por computador para identificar y clasificar drones. Este proceso implica la reflexión de energía desde el dron, el enfoque mediante un sistema óptico y la medición de la energía con un sensor de cámara.

4.4.1. ANÁLISIS DEL ESCENARIO #4

El desarrollo de técnicas de adquisición y procesamiento de imágenes implica la integración de algoritmos de aprendizaje profundo, como las redes neuronales convolucionales (CNN), que permiten una detección más rápida y precisa. Las metodologías pueden clasificarse en enfoques de detección en una etapa, como YOLO y SSD, que ofrecen alta velocidad, y en dos etapas, como R-CNN, que proporcionan mayor precisión en la localización de drones. Sin embargo, uno de los desafíos clave es mantener la velocidad de procesamiento en imágenes de alta resolución para que los resultados coincidan con la frecuencia de adquisición de los sensores. Estudios recientes han mostrado avances significativos, como el uso de modelos optimizados que logran tasas de acierto cercanas al 90% con velocidades de 30 frames por segundo.

Además, la implementación de visiones 360° con sistemas robotizados y ópticas telescópicas ha demostrado extender el alcance de detección a más de 3 km en condiciones de luz diurna, lo cual es crucial para la detección temprana y la respuesta eficiente ante amenazas.

4.4.2. PROBABILIDAD DEL ESCENARIO #4

Este escenario tiene una alta probabilidad de materializarse, dado el interés continuo en la mejora de sistemas de seguridad mediante tecnologías visuales y los avances en hardware y software de procesamiento de imágenes. La capacidad de integración de algoritmos de aprendizaje profundo y mejoras en dispositivos como cámaras de alta resolución y plataformas de procesamiento en tiempo real apoyan la viabilidad de este escenario.

4.4.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #4

Riesgos:

- Dependencia de las condiciones ambientales: Las técnicas de procesamiento de imágenes son sensibles a factores como la iluminación y el clima.
- Rango de detección limitado: La efectividad de estas tecnologías puede verse reducida en condiciones adversas o cuando la línea de visión (LoS) es obstruida.
- Consumo de recursos: La necesidad de procesamiento de imágenes de alta resolución puede requerir una infraestructura robusta y un uso intensivo de recursos.

Oportunidades:

- Confirmación visual precisa: Estas técnicas permiten verificar visualmente la presencia de drones, reduciendo el riesgo de falsas alarmas.
- Evolución de la IA: La mejora constante en algoritmos de aprendizaje profundo y hardware optimizado puede aumentar la eficiencia de los sistemas de detección.
- Aplicaciones de seguridad ampliadas: La detección visual puede adaptarse a múltiples escenarios de seguridad, tanto civiles como militares.

Medidas de mitigación:

- Optimización de algoritmos: Desarrollar modelos de aprendizaje profundo que mantengan alta eficiencia en condiciones de baja iluminación y climas adversos.
- Redundancia sensorial: Integrar estas técnicas con otros métodos de detección (como radar y RF) para superar las limitaciones de LoS y condiciones ambientales.
- Actualización y mantenimiento: Implementar programas de mejora continua en los sistemas de cámaras y algoritmos de procesamiento para asegurar el rendimiento óptimo.

4.5. ESCENARIO #5: FUSIÓN SENSORIAL

Este escenario plantea la integración de múltiples tecnologías de detección en un sistema de fusión sensorial avanzado. Esta combinación implica el uso de sensores de radar, RF, audio e imágenes para aumentar la precisión y robustez en la detección de drones. La fusión sensorial, tanto temprana como tardía, se convierte en un pilar fundamental para superar las limitaciones de cada tecnología individual y ofrecer un sistema de detección más completo y efectivo.

4.5.1. ANÁLISIS DEL ESCENARIO #5

La implementación de la fusión sensorial avanzada tiene implicaciones significativas. Al integrar datos de múltiples modalidades, los sistemas pueden lograr una mayor precisión en la detección y clasificación de drones, reduciendo las falsas alarmas y mejorando la capacidad de respuesta ante amenazas. La fusión temprana permite un procesamiento exhaustivo de los datos sin procesar, mientras que la fusión tardía optimiza las decisiones basadas en la información obtenida de diferentes sensores. Esto representa una mejora notable en la seguridad y la eficiencia operativa.

4.5.2. PROBABILIDAD DEL ESCENARIO #5

La probabilidad de que este escenario se materialice es alta, dado el interés creciente de la comunidad científica y las industrias en mejorar la robustez de los sistemas de detección mediante la fusión de tecnologías. Los avances recientes en inteligencia artificial y en modelos de aprendizaje profundo apoyan esta tendencia, facilitando la integración de múltiples fuentes sensoriales. Sin embargo, la complejidad de la implementación y los costes asociados pueden ralentizar la adopción completa a corto plazo.

4.5.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #5

Riesgos:

- Complejidad de integración: La fusión de múltiples sensores requiere una infraestructura avanzada y sincronización precisa, lo que aumenta la complejidad del sistema.
- Costos elevados: La implementación y mantenimiento de sistemas de fusión sensorial pueden resultar costosos, limitando su adopción en áreas con menos recursos.
- Dependencia tecnológica: La eficacia de estos sistemas depende de avances continuos en IA y procesamiento de datos, lo que los hace vulnerables a cambios en la tecnología.

Oportunidades:

- Mayor precisión en la detección: La capacidad de combinar datos de múltiples fuentes puede aumentar significativamente la precisión y reducir los errores.
- Desarrollo de sistemas adaptativos: La integración sensorial permite el desarrollo de sistemas que se ajustan a diferentes entornos y condiciones.

- Liderazgo tecnológico: Las organizaciones que adopten esta tecnología tempranamente pueden posicionarse como líderes en seguridad y defensa.

Medidas de mitigación:

- Colaboración internacional: Promover alianzas con instituciones y empresas para compartir conocimientos y costes de desarrollo.
- Desarrollo de estándares: Establecer estándares de interoperabilidad para facilitar la integración de sensores.
- Formación especializada: Capacitar a los equipos en el manejo y mantenimiento de sistemas de fusión sensorial para maximizar su eficacia.

5. PROPUESTA DE ACCIONES

5.1. ACCIONES RECOMENDADAS

Algunas acciones podrían ser las siguientes:

- Implementación de proyectos piloto:
 - Pruebas de campo y validación: Realizar proyectos piloto que permitan evaluar la eficacia de las tecnologías en condiciones reales. Esto ayudará a identificar las fortalezas y debilidades de cada sistema y a hacer ajustes antes de una implementación más amplia.
 - Despliegue gradual de tecnologías: Adoptar un enfoque escalonado para la implementación de tecnologías, empezando por aquellas de menor costo y más accesibles, como el procesado de audio, y luego avanzando hacia tecnologías más complejas como el radar y la fusión sensorial.
- Desarrollo de estándares de interoperabilidad:
 - Normativas de integración: Crear estándares para garantizar la interoperabilidad entre diferentes tipos de sensores y sistemas, facilitando así la implementación de enfoques multimodales.
 - Protocolos de seguridad y ciberseguridad: Asegurar que las nuevas tecnologías incluyan protocolos robustos para proteger contra posibles interferencias y ataques cibernéticos, especialmente en sistemas de RF y radar.
- Integración de tecnologías complementarias:
 - Enfoques híbridos: Desarrollar y desplegar sistemas de detección que combinen múltiples técnicas (por ejemplo, radar y procesado de imágenes) para compensar las limitaciones de cada una y maximizar la eficacia de la detección.
 - Optimización del uso de la IA: Utilizar algoritmos de aprendizaje profundo para integrar y procesar datos de diferentes fuentes, asegurando un análisis eficiente y en tiempo real.

5.2. PLAN DE SEGUIMIENTO

- Monitoreo de avances tecnológicos: Establecer un sistema de vigilancia tecnológica para identificar nuevos desarrollos y tendencias en la detección de drones.
- Evaluación de desempeño: Implementar mecanismos de evaluación periódica para revisar la eficacia de los sistemas desplegados y realizar mejoras continuas.

6. CONCLUSIONES

En resumen, la detección y clasificación de drones mediante tecnologías avanzadas es un campo en constante evolución que se enfrenta a múltiples retos y oportunidades. Los escenarios planteados demuestran que, aunque cada técnica tiene sus ventajas y limitaciones, la combinación de enfoques como el procesado de imágenes, señales de audio, RF y radar, junto con métodos de fusión sensorial, ofrece una solución integral para mejorar la precisión y eficacia de los sistemas de detección. Estos avances tecnológicos, potenciados por el uso de la inteligencia artificial y el aprendizaje profundo, están posicionando a la industria de la defensa y la seguridad en un nuevo nivel de sofisticación y capacidad operativa.

Para maximizar el impacto de estas tecnologías, es crucial que se lleven a cabo acciones estratégicas, como la inversión en I+D, la realización de proyectos piloto y el desarrollo de estándares de interoperabilidad y ciberseguridad. Además, la capacitación continua de los operadores y la implementación de sistemas híbridos y escalables asegurarán que las tecnologías se adapten a un entorno cambiante y a las crecientes amenazas que representan los drones. La combinación de estas medidas garantizará una respuesta efectiva, resiliente y proactiva frente a las futuras necesidades de seguridad y vigilancia.

7. ANEXOS

7.1. REFERENCIAS

- [1] Özkaner, A., & Akça, Y. (2024). Mini/Micro UAV detection in the presence of ISM or spurious signals and an experimental application on an SDR. *Engineering Science and Technology, an International Journal*, 49, 101591. <https://doi.org/10.1016/J.JESTCH.2023.101591>
- [2] Seidaliyeva, U., Ilipbayeva, L., Taissariyeva, K., Smailov, N., & Matson, E. T. (2023). Advances and Challenges in Drone Detection and Classification Techniques: A State-of-the-Art Review. *Sensors* 2024, Vol. 24, Page 125, 24(1), 125. <https://doi.org/10.3390/S24010125>
- [3] Liu, J.; Xu, Q.; Chen, W. Classification of Bird and Drone Targets Based on Motion Characteristics and Random Forest Model Using Surveillance Radar Data. *IEEE Access* 2021, 9, 160135–160144.
- [4] Fu, R.; Al-Absi, M.A.; Kim, K.-H.; Lee, Y.-S.; Al-Absi, A.A.; Lee, H.-J. Deep Learning-Based Drone Classification Using Radar Cross Section Signatures at mmWave Frequencies. *IEEE Access* 2021, 9, 161431–161444.
- [5] Wang, C.; JTian, J.; Cao, J.; XWang, X. Deep Learning-Based UAV Detection in Pulse-Doppler Radar. *IEEE Trans. Geosci. Remote Sens.* 2022, 60, 1–12.
- [6] Li, S.; Chai, Y.; Guo, M.; Liu, Y. Research on Detection Method of UAV Based on micro-Doppler Effect. In *Proceedings of the 39th Chinese Control Conference (CCC)*, Shenyang, China, 27–29 July 2020; pp. 3118–3122.
- [7] Khan, M.A.; Menouar, H.; Eldeeb, A.; Abu-Dayya, A.; Salim, F.D. On the Detection of Unauthorized Drones—Techniques and Future Perspectives: A Review.
- [8] Li, S.; Chai, Y.; Guo, M.; Liu, Y. Research on Detection Method of UAV Based on micro-Doppler Effect. In *Proceedings of the 39th Chinese Control Conference (CCC)*, Shenyang, China, 27–29 July 2020
- [9] Raval, D.; Hunter, E.; Hudson, S.; Damini, A.; Balaji, B. Convolutional Neural Networks for Classification of Drones Using Radars. *Drones* 2021, 5, 149.
- [10] Yan, J.; Hu, H.; Gong, J.; Kong, D.; Li, D. Exploring Radar Micro-Doppler Signatures for Recognition of Drone Types. *Drones* 2023, 7, 280.
- [11] Samuell, G.; Maurer, P.; Hassan, A.; Frangenberg, M. A Deep Learning Approach for Multi-copter Detection using mm-Wave Radar Sensors: Application of Deep Learning for Multi-copter detection using radar micro-Doppler signatures. In *Proceedings of the ICRAI 2021: 2021 7th International Conference on Robotics and Artificial Intelligence*, Guangzhou, China, 19–22 November 2021.
- [12] Inani, K.N.; Sangwan, K.S. Machine Learning based framework for Drone Detection and Identification using RF signals. In *Proceedings of the 2023 4th International Conference on Innovative Trends in Information Technology (ICITIIT)*, Kottayam, India, 11–12 February 2023; pp. 1–8.
- [13] Allahham, M.S.; Al-Sa'd, M.F.; Al-Ali, A.; Mohamed, A.; Khattab, T.; Erbad, A. DroneRF dataset: A dataset of drones for RF-based detection, classification and identification. *Data Brief* 2019, 26, 104313.
- [14] Wang, Y.; Chu, Z.; Ku, I.; Smith, E.C.; Matson, E.T. A Large-Scale UAV Audio Dataset and Audio-Based UAV Classification Using CNN. In *Proceedings of the 2022 Sixth IEEE International Conference on Robotic Computing (IRC)*, Naples, Italy, 5–7 December 2022; pp. 186–189.

- [15] Shang, Y.; Liu, C.; Qiu, D.; Zhao, Z.; Wu, R.; Tang, S. AD-YOLOv5s-based UAV detection for low-altitude security. *Int. J. Micro Air Veh.* 2023, 15.
- [16] Kabir, M.S.; Ndukwe, I.K.; Awan, E.Z.S. Deep Learning Inspired Vision based Frameworks for Drone Detection. In *Proceedings of the 2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, Kuala Lumpur, Malaysia, 12–13 June 2021; pp. 1–5.
- [17] Delleji, T.; Chtourou, Z. An Improved YOLOv5 for Real-time Mini-UAV Detection in No-Fly Zones. In *Proceedings of the 2nd International Conference on Image Processing and Vision Engineering*, Online, 22–24 April 2022; pp. 174–181.
- [18] Selvi, S.S.; Pavithraa, S.; Dharini, R.; Chaitra, E. Deep Learning Approach to Classify Drones and Birds. In *Proceedings of the 2022 IEEE 2nd Mysore Sub Section International Conference (MysuruCon)*, Mysuru, India, 16–17 October 2022; pp. 1–5.
- [19] Al-Qubaydhi, N.; Alenezi, A.; Alanazi, T.; Senyor, A.; Alanezi, N.; Alotaibi, B.; Alotaibi, M.; Razaque, A.; Abdelhamid, A.A.; Alotaibi, A. Detection of Unauthorized Unmanned Aerial Vehicles Using YOLOv5 and Transfer Learning. *Electronics* 2022, 11, 2669.
- [20] Pansare, A.; Sabu, N.; Kushwaha, H.; Srivastava, V.; Thakur, N.; Jamgaonkar, K.; Faiz, M.Z. Drone Detection using YOLO and SSD A Comparative Study. In *Proceedings of the 2022 International Conference on Signal and Information Processing (IConSIP)*, Pune, India, 26–27 August 2022; pp. 1–6.
- [21] Singha, S.; Aydin, B. Automated Drone Detection Using YOLOv4. *Drones* 2021, 5, 95.
- [22] Aydin, B.; Singha, S. Drone Detection Using YOLOv5. *Eng* 2023, 4, 416–433.
- [23] Zhao, J.; Zhang, J.; Li, D.; Wang, D. Vision-Based Anti-UAV Detection and Tracking. *IEEE Trans. Intell. Transp. Syst.* 2022, 23, 25323–25334.
- [24] Mubarak, A.S.; Vubangsi, M.; Al-Turjman, F.; Ameen, Z.S.; Mahfudh, A.S.; Alturjman, S. Computer Vision-Based Drone Detection Using Mask R-CNN. In *Proceedings of the 2022 International Conference on Artificial Intelligence in Everything (AIE)*, Lefkosa, Cyprus, 2–4 August 2022; pp. 540–543.
- [25] Ojdanic, D., Sinn, A., Naverschnigg, C., & Schitter, G. (2023). Feasibility Analysis of Optical UAV Detection Over Long Distances Using Robotic Telescopes. *IEEE Transactions on Aerospace and Electronic Systems*, 59(5), 5148–5157. <https://doi.org/10.1109/TAES.2023.3248560>
- [26] Jamil, S.; Fawad; Rahman, M.; Ullah, A.; Badnava, S.; Forsat, M.; Mirjavadi, S.S. Malicious UAV Detection Using Integrated Audio and Visual Features for Public Safety Applications. *Sensors* 2020, 20, 3923.
- [27] Kim, J.; Lee, D.; Kim, Y.; Shin, H.; Heo, Y.; Wang, Y.; Matson, E.T. Deep Learning Based Malicious Drone Detection Using Acoustic and Image Data. In *Proceedings of the 2022 Sixth IEEE International Conference on Robotic Computing (IRC)*, Naples, Italy, 5–7 December 2022; pp. 91–92.
- [28] Liu, H.; Wei, Z.; Chen, Y.; Pan, J.; Lin, L.; Ren, Y. Drone Detection Based on an Audio-Assisted Camera Array. In *Proceedings of the 2017 IEEE Third International Conference on Multimedia Big Data (BigMM)*, Laguna Hills, CA, USA, 19–21 April 2017; pp. 402–406.
- [29] Abdelsamad, S.E.; Abdelteef, M.A.; Elsheikh, O.Y.; Ali, Y.A.; Elsonni, T.; Abdelhaq, M.; Alsaqour, R.; Saeed, R.A. Vision-Based Support for the Detection and Recognition of Drones with Small Radar Cross Sections. *Electronics* 2023, 12, 2235.

- [30] Mehta, V.; Dadboud, F.; Bolic, M.; Mantegh, I. A Deep Learning Approach for Drone Detection and Classification Using Radar and Camera Sensor Fusion. In Proceedings of the 2023 IEEE Sensors Applications Symposium (SAS), Ottawa, ON, Canada, 18–20 July 2023; pp. 1–6.
- [31] Aledhari, M.; Razzak, R.; Parizi, R.M.; Srivastava, G. Sensor Fusion for Drone Detection. In Proceedings of the 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring), Helsinki, Finland, 25–28 April 2021; pp. 1–7.
- [32] Vidyasagar, P.M.; Shoaib, S.; Shiva, P.M.; Kashyap, S.R.; Lethan, M.N. Detection and Surveillance of UAVs Based on RF and Radar Technology. *Int. Res. J. Eng. Technol. (IRJET)* 2021, 08, 4463–4466.
- [33] Lee, H.; Han, S.; Byeon, J.I.; Han, S.; Myung, R.; Joung, J.; Choi, J. CNN-Based UAV Detection and Classification Using Sensor Fusion. *IEEE Access* 2023, 11, 68791–68808.
- [34] Svanström, F.; Englund, C.; Alonso-Fernandez, F. Real-Time Drone Detection and Tracking with Visible, Thermal and Acoustic Sensors. In Proceedings of the 2020 25th International Conference on Pattern Recognition (ICPR), Milan, Italy, 10–15 January 2021; pp. 7265–7272.
- [35] Saadaoui, F. Z., Cheggaga, N., & Djabri, N. E. H. (2023). Multi-sensory system for UAVs detection using Bayesian inference. *Applied Intelligence*, 53(24), 29818–29844. <https://doi.org/10.1007/S10489-023-05027-Z/TABLES/4>



Universidad de Jaén

Transmisión de energía en la atmósfera usando láseres de alta potencia

Informe de Prospectiva 2024



TABLA DE CONTENIDOS

1. INTRODUCCIÓN.....	64
1.1. Objetivo del informe.....	64
1.2. Contexto	64
2. FACTORES DE INFLUENCIA.....	65
3. IDENTIFICACIÓN DE TENDENCIAS.....	65
3.1. Tendencias actuales	65
3.2. Tendencias emergentes	66
4. ESCENARIOS FUTUROS	67
4.1. Escenario #1: Optimista	67
4.1.1. Descripción y análisis del escenario #1	67
4.1.2. Probabilidad del escenario #1	67
4.1.3. Riesgos, oportunidades y medidas de mitigación del escenario #1.....	67
4.2. Escenario #2: Pesimista	68
4.2.1. Descripción y análisis del escenario #2	68
4.2.2. Probabilidad del escenario #2	68
4.2.3. Riesgos, oportunidades y medidas de mitigación del escenario #2.....	68
5. PROPUESTA DE ACCIONES	69
5.1. Acciones recomendadas	69
5.2. Plan de seguimiento	69
6. CONCLUSIONES	70
7. ANEXOS	71
7.1. Descripción general de los componentes de los sistemas HPOT	71
7.2. Tipos de láseres	71
7.3. Convertidores ópticos fotovoltaicos	73
7.4. Propagación de energía en la atmósfera.....	74
7.5. Referencias.....	77
7.6. Acrónimos.....	80

1. INTRODUCCIÓN

1.1. OBJETIVO DEL INFORME

El objetivo de este informe de prospectiva es anticipar y analizar las posibilidades y desafíos de la transmisión de energía óptica de alta potencia mediante láseres, principalmente en aplicaciones atmosféricas, con un enfoque en el sector militar y espacial. Este informe busca ofrecer un marco que ayude a tomar decisiones estratégicas en el desarrollo y uso de esta tecnología a medio plazo.

Este informe de prospectiva forma parte de los trabajos realizados por el grupo de investigación Advances in Photovoltaic Technology (AdPVTech), dentro de los proyectos impulsados por la Cátedra Isdefe/CETEDEX-UJA (Universidad de Jaén) en el marco de la Red de Horizontes Isdefe.

1.2. CONTEXTO

En la actualidad existen numerosas situaciones en las que el uso de energía eléctrica para alimentar equipos electrónicos resulta inconveniente, costoso, peligroso o directamente inviable. El suministro de energía en entornos hostiles, como el espacio exterior y las profundidades oceánicas, o en condiciones estrictas de seguridad debido al alto riesgo de incendio o explosión (refinerías, minas, plantas nucleares, tanques de combustible en el espacio, etc.), así como a través de grandes distancias aéreas hacia objetivos móviles remotos, representa un desafío complejo. Con el fin de superar las limitaciones asociadas con la transferencia de energía mediante cables convencionales, ha surgido recientemente la tecnología basada en la transmisión inalámbrica de energía (*wireless power transmission*, WPT), que permite el envío de energía sin la necesidad de interconexiones físicas. Actualmente, esta tecnología es reconocida a nivel internacional como uno de los avances más innovadores y revolucionarios en el ámbito de la transmisión de energía, destinada a transformar el paradigma de transmisión de energía tradicional. El aumento del interés y su incipiente comercialización, principalmente en los sectores domésticos, industriales y militares, han elevado su tamaño de mercado a cifras que alcanzan los miles de millones de dólares [1,2].

Además de ofrecer varios beneficios sobre el cableado eléctrico tradicional, como una mayor adaptabilidad, aislamiento eléctrico, facilidad de uso y durabilidad, la tecnología WPT abarca un amplio espectro de posibles aplicaciones, tanto de corto como de largo alcance. Entre los métodos de transmisión de corto alcance se encuentran la inducción electromagnética, la resonancia magnética y el acoplamiento eléctrico. En lo que respecta a los de largo alcance, engloba la transmisión óptica (ej. láseres) y de radiofrecuencia (ej. microondas) [3].

Dado que las tecnologías de corta distancia están alcanzando la madurez en su desarrollo y, por lo tanto, se acercan a los límites de sus capacidades, se observa una creciente preferencia hacia la investigación de las de larga distancia. Entre estas últimas, la transmisión de energía mediante láser destaca por sus notables ventajas, entre las cuales se incluye disponer de equipos altamente portátiles, una excelente direccionalidad y proporcionar una elevada densidad de potencia. Estas características garantizan una transmisión de potencia de alta eficiencia a lo largo de largas distancias, especialmente útil para su uso en recargas rápidas o en la alimentación remota de dispositivos electrónicos.

De este modo, la transmisión de energía óptica de alta potencia (*high-power optical transmission*, HPOT) surge como una opción prometedora dentro de las tecnologías WPT, ya que ofrece la posibilidad de transferir energía de forma continua del orden de cientos o miles de vatios a lo largo de varios kilómetros, demostrando una mayor densidad de energía y versatilidad en comparación con otras tecnologías de largo alcance, ej. radiofrecuencia. Algunos objetivos de los sistemas HPOT son dispositivos electrónicos móviles remotos, como pequeñas aeronaves o vehículos aéreos no tripulados (UAV), robots, satélites, vehículos submarinos autónomos, e incluso para el despliegue de una red virtual en el espacio que conecte, por ejemplo, hábitats remotos o instalaciones de aterrizaje, y que transfiera energía solar ininterrumpida desde estaciones solares espaciales hasta la Tierra. Asimismo, resulta especialmente relevante que el uso de la

luz como tecnología permite la transmisión tanto de energía como de datos con un alto nivel de seguridad, lo que representa un gran potencial para su aplicación en operaciones relacionadas con el suministro de energía y conexión a larga distancia para equipos militares [4].

2. FACTORES DE INFLUENCIA

Los principales factores que afectan a la tecnología HPOT se presentan a continuación:

Factores tecnológicos: El desarrollo de los sistemas HPOT (ver sección 7.1 para obtener una descripción general de los sistemas) depende de dos componentes clave: las fuentes de luz láser y los convertidores ópticos fotovoltaicos (OPC). La eficiencia del sistema es determinada por las características de la fuente láser (su longitud de onda, potencia y eficiencia; ver sección 7.2 para más información sobre los diferentes tipos de láseres más utilizados en sistemas HPOT) y la capacidad del convertidor fotovoltaico para transformar la luz en energía eléctrica (ver sección 7.3 para más información sobre los OPCs). Además, la propagación de la energía en la atmósfera se ve afectada por fenómenos como la atenuación, la turbulencia y la dispersión térmica, que pueden reducir significativamente la eficiencia total del sistema (ver sección 7.4). Las investigaciones actuales buscan mejorar el desempeño de estos elementos y la eficiencia de la transmisión de la energía a través de la atmósfera para minimizar las pérdidas.

Factores económicos: El costo de desarrollar, probar e implementar sistemas HPOT es elevado, ya que involucra tecnología de punta tanto en el subsistema emisor (fuente láser) como en el receptor (OPCs). Sin embargo, el retorno de la inversión podría ser considerable, especialmente si se logra aplicar esta tecnología en sectores críticos de nivel nacional como en Defensa, donde la transmisión segura de energía es crucial, principalmente en ambientes inhóspitos. También existe la posibilidad de que los costos se reduzcan a medida que las tecnologías que forman parte del sistema maduren y se comience su fabricación y comercialización a mayor escala.

Factores normativos: El uso de láseres de alta potencia está estrictamente regulado por acuerdos internacionales (norma IEC 60825:2024 SER). La necesidad de cumplir con estándares internacionales de seguridad es una barrera clave que afecta el desarrollo y despliegue de la tecnología.

Factores político-sociales: La implementación de sistemas HPOT en localizaciones cercanas a núcleos de población puede despertar preocupación, e incluso rechazo, sobre el uso de esta tecnología, puesto que la utilización de láseres de alta potencia puede ser percibido como un peligro por la ciudadanía. Por lo tanto, es necesario que se informe debidamente desde las instituciones gubernamentales sobre la seguridad de esta tecnología, facilitando así su inclusión en el sistema energético actual y su aceptación social. Por otro lado, la creación de redes virtuales de energía significaría un cambio de paradigma en la distribución de energía, logrando suministrar la energía necesaria en núcleos poblacionales aislados que no tengan una fácil conexión a la red eléctrica, o incluso en operaciones de rescate en áreas afectadas por desastres naturales. Estas aplicaciones hacen esta tecnología más atractiva para el apoyo ciudadano, puesto que se beneficiarían de forma directa.

3. IDENTIFICACIÓN DE TENDENCIAS

3.1. TENDENCIAS ACTUALES

La transmisión de energía inalámbrica mediante láser se encuentra en una etapa de crecimiento e investigación, impulsada principalmente por su aplicación en sectores militares, espaciales y energéticos. Comenzando por sus aplicaciones militares, una de las principales tendencias actuales es el desarrollo de sistemas HPOT para alimentar dispositivos móviles remotos, como drones, vehículos aéreos no tripulados (UAVs) o rovers, eliminando la necesidad de baterías pesadas o conexiones físicas a la red eléctrica. Esto

no solo mejora la movilidad de estos dispositivos, sino que también permite extender su autonomía de forma considerable, puesto que no es necesario que interrumpan su actividad durante la recarga, mejorando las capacidades tácticas y logísticas de los ejércitos modernos. Se contempla esta aplicación en medidas de seguridad en zonas fronterizas, en las que se puede lograr una vigilancia ininterrumpida de zonas de conflicto.

Otra aplicación de los sistemas HPOT en el ámbito militar es la capacidad de operar de manera discreta y eficiente en entornos de combate, donde el suministro de energía puede estar comprometido. La energía enviada a través de láseres puede alimentar sistemas de defensa y comunicación críticos sin necesidad de exponer cables o infraestructuras que podrían ser destruidas o interrumpidas por fuerzas enemigas. Por otro lado, dado que estos sistemas también pueden transmitir simultáneamente datos y energía, las comunicaciones cifradas a través de láseres ofrecen un alto nivel de seguridad, ya que los haces de luz no son fácilmente interceptables sin interrumpir la señal. Esto es particularmente relevante en el contexto de defensa cibernética y seguridad, en el que la transmisión de datos sensibles de forma segura es esencial.

En las tendencias dentro del sector energético, los sistemas HPOT están siendo desarrollados para poder alimentar cualquier tipo de sistema receptor, desde en centrales energéticas o refinerías para conectar sensores o sistemas de monitorización, en las que la utilización de cableado eléctrico es desaconsejada por el alto riesgo de explosión, hasta su utilización en operaciones de rescate en ubicaciones gravemente afectadas por desastres naturales en las que la infraestructura eléctrica suele estar comprometida, y la capacidad de enviar energía a larga distancia sin cables puede ser crucial para alimentar equipos médicos y de comunicación esenciales para las operaciones de salvamento. Además, la tecnología HPOT es ideal para su uso en **redes de ciudades inteligentes**, donde la transmisión de energía sin cables podría integrarse en la infraestructura urbana para alimentar dispositivos y sensores IoT (Internet de las cosas), reduciendo la necesidad de una infraestructura eléctrica densa y costosa.

En el ámbito espacial, la tendencia de desarrollo de la tecnología HPOT se encamina por el suministro de energía a satélites. Ya se han realizado experimentos de transmisión de energía mediante láser en el espacio con éxito [5]. Además, la tecnología HPOT es adecuada para la transmisión de energía en misiones de exploración espacial, como en la Luna o Marte, en situaciones en las que el acceso a fuentes tradicionales de energía (como el sol) es inexistente o limitado, como sucede en la cara oculta de la Luna o en alguno de sus cráteres. La capacidad de transmitir energía sin depender de una línea directa de luz solar abre la puerta a una nueva era de misiones espaciales ininterrumpidas y sistemas de soporte vital en estaciones espaciales permanentes.

La tendencia común de los sectores energético y espacial es la creación de redes energéticas globales que puedan transmitir energía a través de largas distancias sin la necesidad de infraestructura física; es decir, desplegar redes virtuales de energía, tanto en la Tierra como en el espacio, mediante la conexión inalámbrica de satélites capaces de recibir y transmitir energía dónde y cuándo sea necesario sin interrupciones.

3.2. TENDENCIAS EMERGENTES

Más allá de las aplicaciones que han sido más desarrolladas en la actualidad, una tendencia emergente es la transmisión de potencia a través de medios acuáticos. Alimentar dispositivos localizados en el fondo submarino es una ardua tarea debido al difícil acceso a este tipo de áreas y a los problemas asociados a las conexiones eléctricas en el mar. La transmisión de energía mediante luz, tanto a través de fibra óptica como del agua (a cortas distancias), puede ayudar a solventar importantes inconvenientes, permitiendo la recarga de baterías de dispositivos submarinos, tales como sensores o vehículos acuáticos no tripulados, evitando el desplazamiento de los mismos a la superficie del mar para reabastecer sus depósitos energéticos. Se están llevando a cabo investigaciones para la utilización de láseres con longitudes de onda apropiadas para la transmisión a través del agua y materiales fotovoltaicos adecuados para la eficiente conversión de la energía óptica a eléctrica.

4. ESCENARIOS FUTUROS

A continuación, se presentan el análisis cualitativo de algunos escenarios de desarrollo de la tecnología HPOT en el futuro.

4.1. ESCENARIO #1: OPTIMISTA

4.1.1. DESCRIPCIÓN Y ANÁLISIS DEL ESCENARIO #1

En este escenario, los avances tecnológicos en la transmisión de energía mediante láseres de alta potencia permiten su adopción masiva en sectores como Defensa y la exploración espacial. Los láseres se han optimizado para transmitir grandes cantidades de energía a largas distancias sin pérdidas significativas, y los convertidores fotovoltaicos utilizados para recibir y transformar esta energía en electricidad han alcanzado una elevada eficiencia a altas potencias. Gracias a estos avances, los sistemas HPOT se utilizan ampliamente para alimentar drones, satélites y estaciones espaciales, eliminando la necesidad de baterías o infraestructuras eléctricas físicas.

En el ámbito militar, la HPOT permite recargar drones en pleno vuelo, lo que aumenta su autonomía y reduce los tiempos de inactividad operativa. Los soldados en el campo de batalla pueden utilizar dispositivos alimentados de manera remota sin necesidad de transportar fuentes de energía pesadas. Además, la tecnología se ha implementado en bases militares remotas, donde la infraestructura eléctrica tradicional es inviable, utilizando láseres para enviar energía a largas distancias sin interrupciones.

En el sector espacial, la HPOT se utiliza para alimentar estaciones espaciales y satélites en órbita, incluso en áreas donde la luz solar no está disponible de manera continua. La energía recolectada por estaciones solares espaciales se transmite de manera eficiente en las redes virtuales de energía, proporcionando una fuente de energía constante y renovable. Este avance reduce la dependencia de combustibles fósiles y mejora la sostenibilidad de la energía global.

4.1.2. PROBABILIDAD DEL ESCENARIO #1

La probabilidad de este escenario es alta debido a los rápidos avances en tecnología láser y en convertidores fotovoltaicos, cuya eficiencia ronda el 70% en la actualidad. Los laboratorios de investigación en todo el mundo están logrando eficiencias cada vez mayores en la conversión de energía luminosa a eléctrica, y las pruebas en condiciones atmosféricas han demostrado que es posible transmitir energía a distancias de varios kilómetros con una pérdida mínima de potencia. Sin embargo, este escenario también depende de la capacidad de las empresas y gobiernos para invertir en esta tecnología y desarrollar las regulaciones necesarias para su uso seguro en el ámbito civil y militar.

4.1.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #1

Riesgos: Uno de los mayores riesgos en este escenario es la interferencia atmosférica. Aunque los avances han permitido reducir la pérdida de energía debido a la turbulencia y la dispersión térmica, condiciones ambientales adversos como la lluvia, la niebla o el polvo en el aire todavía pueden afectar la eficacia de la transmisión de energía. También existe el riesgo de que la tecnología HPOT sea utilizada de manera indebida en aplicaciones militares, lo que podría generar tensiones internacionales o conflictos.

Oportunidades: Las oportunidades en este escenario son vastas. En el sector energético, la capacidad de transmitir energía eficientemente de forma ininterrumpida y en cualquier localización pueden resolver el problema de la intermitencia inherente a las fuentes de energía renovable. Además, la adopción de HPOT en las infraestructuras militares y de defensa mejoraría la seguridad energética, reduciendo la necesidad de convoyes de suministro de energía, que a menudo son vulnerables en zonas de conflicto, junto a la mejora de la vigilancia en zonas fronterizas conflictivas, aumentando la seguridad nacional.

Medidas de mitigación: Para mitigar los riesgos asociados con este escenario, es necesario continuar invirtiendo en la investigación y desarrollo de sistemas HPOT que sean resistentes a condiciones atmosféricas adversas. Además, deben implantarse estándares internacionales que promuevan el uso de láseres de alta potencia siguiendo las pertinentes directrices éticas, evitando así su uso indebido o inmoral. También sería útil explorar la combinación de HPOT con otras tecnologías de energía inalámbrica para garantizar que se puedan mantener operaciones críticas incluso en condiciones climáticas adversas.

4.2. ESCENARIO #2: PESIMISTA

4.2.1. DESCRIPCIÓN Y ANÁLISIS DEL ESCENARIO #2

En este escenario, los avances en la transmisión de energía mediante láseres se ven obstaculizados por varios factores. A pesar de algunos progresos, los sistemas HPOT siguen enfrentando problemas de eficiencia en la conversión de energía y de transmisión a larga distancia. Las pérdidas de energía debido a la dispersión térmica y la turbulencia atmosférica no se han resuelto completamente, lo que limita la viabilidad de utilizar HPOT en aplicaciones prácticas que requieran grandes cantidades de energía.

Además, las preocupaciones sobre la seguridad y las posibles interferencias con otras tecnologías han llevado a los reguladores internacionales a imponer restricciones estrictas al uso de láseres de alta potencia. Esto ha impedido la implementación de HPOT en muchas aplicaciones civiles y militares. Como resultado, la tecnología sigue siendo experimental y solo se utiliza en entornos muy controlados, como laboratorios y pruebas a pequeña escala.

4.2.2. PROBABILIDAD DEL ESCENARIO #2

La probabilidad de este escenario es moderada. Aunque se han logrado algunos avances en la tecnología HPOT, los desafíos técnicos relacionados con la propagación de energía a través de la atmósfera y las regulaciones internacionales estrictas han frenado su adopción a gran escala. Las pruebas en condiciones reales han demostrado que la tecnología aún no está lista para implementarse de manera inmediata, lo que ha llevado a una disminución en la inversión por parte de gobiernos y empresas privadas.

4.2.3. RIESGOS, OPORTUNIDADES Y MEDIDAS DE MITIGACIÓN DEL ESCENARIO #2

Riesgos: El principal riesgo en este escenario es la pérdida de interés e inversión en la tecnología debido a los resultados limitados en las pruebas prácticas. Si no se logran avances significativos en la eficiencia de los sistemas HPOT, existe el riesgo de que la tecnología quede relegada a un segundo plano, perdiendo su impulso innovador. Además, la falta de marcos regulatorios claros para su uso podría generar incertidumbre en el sector empresarial, dificultando la colaboración internacional.

Oportunidades: A pesar de los desafíos, todavía existen oportunidades para que HPOT se desarrolle a largo plazo. Las investigaciones proponen alternativas novedosas para superar los obstáculos vigentes, como variaciones en la arquitectura de los OPCs o fuentes de luz cuasi-monocromáticas, podrían eventualmente mejorar la eficiencia de la transmisión de energía. Además, si se logra superar las barreras normativas, HPOT podría encontrar aplicaciones específicas en sectores donde la transmisión inalámbrica de energía es la única opción viable, como en zonas de desastres naturales o en operaciones espaciales.

Medidas de mitigación: Para mitigar los riesgos en este escenario, es crucial que se continúen las investigaciones en las áreas más prometedoras de HPOT, como el desarrollo de nuevos materiales para mejorar la conversión de energía y la exploración de fuentes láser más eficientes. También es necesario fomentar una mayor colaboración entre los gobiernos y las empresas privadas para crear marcos regulatorios flexibles que permitan la experimentación y el desarrollo de la tecnología. Asimismo, considerar la posibilidad de combinar HPOT con otras tecnologías de energía inalámbrica para mejorar su rendimiento en condiciones adversas puede ser una opción aconsejable.

5. PROPUESTA DE ACCIONES

5.1. ACCIONES RECOMENDADAS

De cara impulsar esta prometedora tecnología, en esta sección se proponen acciones que potencien su desarrollo.

Incrementar la inversión en I+D: Es fundamental aumentar la financiación para mejorar las fuentes láser y los OPCs. Se deben explotar nuevas y existentes tecnologías, como los láseres alcalinos bombeados por diodo y los convertidores verticales multi-unión, que prometen mayor eficiencia y mejor rendimiento en distancias largas y altas potencias.

Colaboración internacional: Establecer marcos colaborativos entre países y agencias espaciales para acelerar el desarrollo y la regulación de sistemas HPOT. Este tipo de colaboración puede facilitar la creación de estándares que permitan la adopción masiva de la tecnología sin comprometer la seguridad.

Implementar pruebas a gran escala: Realizar más pruebas de sistemas HPOT en condiciones reales. Se recomienda probar la tecnología en drones y satélites en órbita para evaluar la eficacia en diferentes entornos y bajo diversas condiciones atmosféricas.

Plan de reducción de costos: Desarrollar estrategias para reducir los costos de fabricación de componentes críticos, como los convertidores fotovoltaicos y las fuentes láser. Una producción a mayor escala y la investigación en materiales más económicos podrían ayudar a que la tecnología sea más accesible para aplicaciones civiles. También se propone como medida más inmediata el apoyo económico por parte de organismos estatales.

5.2. PLAN DE SEGUIMIENTO

Establecer un plan de seguimiento es fundamental para garantizar el éxito del desarrollo y la implementación de la tecnología HPOT. El primer paso clave es llevar a cabo un **monitoreo tecnológico** continuo, con pruebas periódicas tanto en entornos controlados como en escenarios reales. Estas pruebas deben evaluar la eficiencia de los sistemas HPOT, especialmente la capacidad de los láseres y los OPCs para transmitir y convertir energía bajo diferentes condiciones atmosféricas, como altas turbulencias o presencia de polvo. Este monitoreo permitirá detectar fallos y realizar ajustes tecnológicos que mejoren la fiabilidad y eficiencia de la tecnología en distintos contextos operativos.

Además, es esencial realizar **evaluaciones regulatorias** de forma periódica. Dado que los sistemas HPOT utilizan láseres de alta potencia, es necesario garantizar que el desarrollo cumpla con las normativas internacionales de seguridad. Estas regulaciones deben ser revisadas periódicamente para asegurar que estén alineadas con los avances tecnológicos y no impidan la innovación, sin comprometer la seguridad pública. La flexibilidad en el marco regulatorio permitirá la adopción segura de HPOT en aplicaciones cada vez más amplias, tanto en sectores civiles como militares.

Cuando la tecnología haya alcanzado un estado de desarrollo aceptable, se comenzarán a realizar **pruebas a gran escala** para evaluar la viabilidad operativa de HPOT en condiciones reales. Este tipo de pruebas permitirá verificar el rendimiento de la tecnología en aplicaciones como la recarga de drones en vuelo o el suministro de energía a satélites en órbita. Los resultados de estas pruebas proporcionarán información valiosa para optimizar los sistemas y ajustar las estrategias de desarrollo.

Asimismo, el **análisis de costos y viabilidad** es un elemento crucial del plan de seguimiento. A medida que la tecnología avanza, es fundamental realizar un seguimiento de los costos de desarrollo y producción de los sistemas HPOT, especialmente los asociados con los láseres y los OPCs. El objetivo es garantizar

que la tecnología sea económicamente viable a largo plazo y escalable para diferentes aplicaciones, incluyendo usos civiles y comerciales, más allá de su uso inicial en el sector militar.

Por último, se deben generar **informes periódicos** de resultados para mantener informados a los actores clave. Estos informes proporcionarán una visión clara de los avances logrados, los desafíos identificados y las áreas donde es necesario realizar mejoras. Estos reportes ayudarán a coordinar las próximas fases de desarrollo y a tomar decisiones estratégicas basadas en los datos recopilados durante las pruebas y evaluaciones.

En resumen, el plan de seguimiento debe incluir un monitoreo tecnológico constante, evaluaciones regulatorias periódicas, pruebas a gran escala y un análisis económico detallado. Estas acciones asegurarán que el desarrollo de la tecnología HPOT se lleve a cabo de manera eficiente, segura y económicamente viable.

6. CONCLUSIONES

El análisis prospectivo sobre la transmisión de energía mediante láseres de alta potencia (HPOT) destaca el potencial disruptivo de esta tecnología, especialmente en sectores como el militar, espacial y energético. La capacidad de transmitir energía de manera eficiente a largas distancias sin necesidad de infraestructura física podría revolucionar tanto operaciones en entornos hostiles como la generación y distribución de energía en ubicaciones remotas.

Los principales hallazgos del informe subrayan que, si bien la tecnología HPOT aún enfrenta desafíos técnicos importantes, como la pérdida de energía en la propagación a través de la atmósfera y la eficiencia de los convertidores ópticos fotovoltaicos (OPC), los avances recientes en investigación y desarrollo están acercando esta tecnología a una fase de adopción práctica. Las tendencias actuales apuntan a su uso creciente en aplicaciones militares para alimentar drones y otros dispositivos electrónicos en campo de batalla, así como en misiones espaciales donde la transmisión inalámbrica de energía puede solventar la falta de acceso a fuentes tradicionales como la energía solar directa.

Por otro lado, se identifican riesgos significativos, como la propagación a través de la atmósfera y el costo elevado de implementación. La necesidad de normativas internacionales claras y la posible reticencia pública a la adopción de láseres de alta potencia cerca de núcleos poblacionales también son factores que podrían retrasar el despliegue de esta tecnología.

En cuanto a los escenarios futuros, el informe describe un escenario optimista en el que las mejoras tecnológicas permiten la adopción generalizada de sistemas HPOT, mientras que el escenario pesimista prevé que los obstáculos técnicos y regulatorios frenen su desarrollo a gran escala, limitándolo a aplicaciones experimentales o en situaciones controladas. Para mitigar estos riesgos, el informe recomienda incrementar las inversiones en investigación y desarrollo, promover la colaboración internacional y establecer pruebas a gran escala para evaluar la viabilidad operativa de los sistemas HPOT en condiciones reales y actuar en consecuencia.

En resumen, la transmisión de energía mediante láseres de alta potencia tiene el potencial de transformar sectores clave, pero su éxito dependerá de avances técnicos, de la superación de barreras regulatorias y de la aceptación social de esta tecnología emergente.

7. ANEXOS

7.1. DESCRIPCIÓN GENERAL DE LOS COMPONENTES DE LOS SISTEMAS HPOT

El funcionamiento de los sistemas HPOT consiste en la transmisión de energía a un equipo remoto utilizando una fuente de luz monocromática (o cuasi-monocromática). Se componen fundamentalmente de los siguientes elementos (**Figura 6**):

Subsistema emisor: Formado por una fuente generadora de luz monocromática (láser o LED) y de los elementos ópticos (lentes, espejos) que garanticen una correcta emisión del haz, tanto en calidad (colimación y uniformidad) como en dirección.

Subsistema receptor: Constituido por los elementos ópticos que reciben el rayo de luz y el dispositivo encargado de convertir la energía luminosa en energía eléctrica (célula solar o fotodiodo). Como se comentó anteriormente, estas células fotovoltaicas son denominadas convertidores ópticos fotovoltaicos (OPC), y son una parte esencial del sistema.

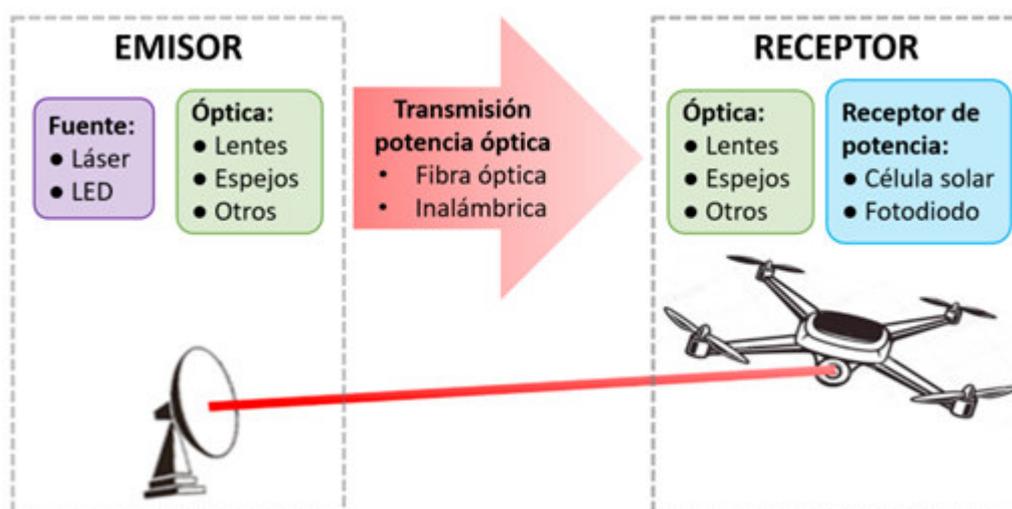


Figura 6: Esquema de los componentes de un sistema HPOT.

Cabe destacar que, tal y como se muestra en la **Figura 6**, la transmisión de la energía óptica puede ser a través de fibra óptica o realizarse de forma inalámbrica a través de diferentes medios, como aire, agua o el vacío (espacio).

7.2. TIPOS DE LÁSERES

Los principales tipos de láseres que se consideran apropiados para sistemas HPOT se presentan y describen a continuación:

Diodos láser (*laser diodes*, LDs): Los LDs son láseres semiconductor alimentados mediante electricidad. Aunque técnicamente deberían clasificarse como dispositivos de estado sólido, convencionalmente se consideran una rama aparte dentro de las tecnologías láser debido a las diferencias en los principios de funcionamiento para crear inversión de población. Los LDs destacan por su alta eficiencia eléctrico-óptica (típicamente alrededor del 50%), compactibilidad, requisitos de refrigeración aceptables y coste relativamente bajo. Además, presentan una modularidad excepcional; es común ensamblarlos en hileras para aumentar la potencia de salida [6–9]. A esto cabe añadir que los LDs pueden emitir en una amplia

gama de longitudes de onda, abarcando todo el espectro solar y extendiéndose al infrarrojo, lo que los hace compatibles con cualquier material fotovoltaico. Actualmente existen LDs de alta potencia disponibles para su compra en varias empresas (QPC Laser, AeroDiode, Laserline), alcanzando los 45 kW. Sin embargo, el brillo de los LDs suele ser bajo, por lo que serían necesarios importantes esfuerzos adicionales para implementar un sistema óptico que compense esta carencia, siempre que sea viable. Existen algunos métodos para minimizar este problema, como la combinación espectral de haces, pero el nivel de potencia alcanzable es considerablemente inferior. Cabe destacar que esta técnica no se limita a los LDs. Con todo, los LDs pueden ser una fuente útil para la transmisión de energía a través de distancias en el rango de unos pocos kilómetros [8].

Láseres de Estado Sólido Bombeados por Diodo (*Diode-Pumped Solid-State Lasers*, DPSSLs): Este tipo de láseres incluye aquellos basados en un medio activo de estado sólido, como cristales, vidrios o materiales cerámicos, dopadas con iones de tierras raras o metales de transición, generalmente neodimio (Nd), erbio (Er), cromo (Cr) y titanio (Ti), y bombeados ópticamente mediante LDs. Los DPSSLs se caracterizan por su diseño compacto, larga vida útil, alta eficiencia, calidad del haz alta y estable, y potencias excepcionalmente altas. Las longitudes de onda de emisión abarcan típicamente desde 0.7 hasta 3 μm [6]. Sin embargo, si se utilizan materiales no lineales, es posible generar segundos armónicos, produciendo el fenómeno conocido como “duplicación de frecuencia” [10]. Este método permite alcanzar longitudes de onda aún más cortas mediante la división de la longitud de onda fundamental a la mitad [11–13].

Entre los diferentes láseres de estado sólido existentes, destacan especialmente los **láseres de fibra**. Esta forma especial de láser de estado sólido se basa en el uso de una fibra dopada con iones de tierras raras como medio activo, en lugar de una barra o bloque. Los láseres de fibra presentan eficiencias superiores, alcanzando actualmente hasta el 50%, en comparación con aproximadamente el 30% de los láseres de estado sólido generales. Sin embargo, requieren diodos de bombeo con una mayor calidad de haz. Además, ofrecen una calidad de haz superior a potencias de salida más elevadas gracias a sus excelentes propiedades termo-ópticas. También poseen un mayor ancho de banda de ganancia y bandas de absorción más amplias, lo que proporciona mayor flexibilidad espectral en el infrarrojo cercano y hace que la longitud de onda de bombeo sea menos crítica. Los láseres de fibra no se ven afectados por desalineamientos, y muestran una excelente robustez y estabilidad a largo plazo [7]. Actualmente, ya se encuentran disponibles comercialmente láseres de fibra de 120 kW con eficiencias de más del 40% [14]. Estas características convierten a los láseres de fibra en una de las alternativas más atractivas para aplicaciones que requieran de alta potencia.

Otro tipo interesante de DPSSLs son los **láseres de disco**. Estos láseres se caracterizan por tener un medio activo con una delgada geometría circular. Los láseres de disco proporcionan altas potencias, con 24 kW y una calidad de haz aceptable ya disponibles en el mercado [15], y mejor flexibilidad y modularidad en comparación con los láseres de fibra, lo que permite escalar la potencia con mayor facilidad [6,16,17]. Dependiendo de las restricciones particulares del caso, los láseres de disco podrían ser una alternativa adecuada.

Láseres Alcalinos Bombeados por Diodo (*Diode-Pumped Alkali Lasers*, DPALs): Los DPALs son una nueva clase dentro de los láseres de gas introducida recientemente. Su principio de operación se basa en la excitación de vapores alcalinos atómicos como potasio (K), rubidio (Rb) y cesio (Cs); es decir, se utiliza vapor metálico como medio activo [18,19]. Las características principales de los DPALs son su excelente calidad óptica del haz, escasos problemas térmicos y una excepcional escalabilidad de la potencia [20–22]. En 2015, el Laboratorio Lawrence Livermore logró producir 13 kW, y se planificaron demostraciones de hasta 30 kW [23,24]. Estudios teóricos indican que se pueden obtener DPALs del orden de 100 kW con calidad del haz cercana al límite de difracción y una excelente relación peso-potencia (≈ 7 kg/kW), exhibiendo eficiencias que podrían superar las de los DPSSLs. Esto permitiría que los DPALs fueran competidores viables para ser usados en aplicaciones que requieren fuentes de luz continua de alta

potencia [18,19,25]. Además, las longitudes de onda disponibles de los DPALs coinciden con las bandas óptimas de absorción de las tecnologías fotovoltaicas, lo que convierte a esta tecnología láser en una opción prometedora para aplicaciones de transferencia de potencia láser una vez se complete su desarrollo.

7.3. CONVERTIDORES ÓPTICOS FOTOVOLTAICOS

En esta sección se presenta el subsistema receptor, encargado de recibir y transformar la energía transmitida en forma de luz en electricidad, y está centrada en la descripción de su componente principal: los convertidores fotovoltaicos. Los OPCs son, fundamentalmente, células solares optimizadas para la absorción de un haz de luz monocromático concreto o una estrecha banda espectral. En la **Figura 7** pueden verse imágenes de OPCs de materiales y diseños diferentes. Para asegurar una eficiencia final satisfactoria, los OPCs deberán de cumplir con los siguientes requisitos [1]:

- Brecha de energía del material semiconductor acorde a la fuente disponible y las características del medio. Entiéndase esto como un proceso simultáneo, es decir, que la fuente y el receptor deben escogerse en sintonía.
- Voltaje y potencia de salidas suficientemente altas para cumplir con las especificaciones del sistema objetivo. Además, deberá añadirse un convertidor DC/DC con un controlador del punto de máxima potencia incorporado, puesto que el OPC trabaja con cargas variables. Es probable que para voltajes inferiores a 0.8 V sea imposible su aplicación con dispositivos reales.
- Suficiente eficiencia para que la transmisión de energía sea exitosa.
- El tamaño y la geometría debe adecuarse a la situación. Por ejemplo, al perfil del láser, o a la superficie del dispositivo receptor en la que se acople el OPC.
- Capacidades operativas que soporten las condiciones del entorno a las que será sometido, como la temperatura, tiempo de vida, resistencia al clima u otras condiciones adversas, y restricciones específicas como peso, coste, etc.

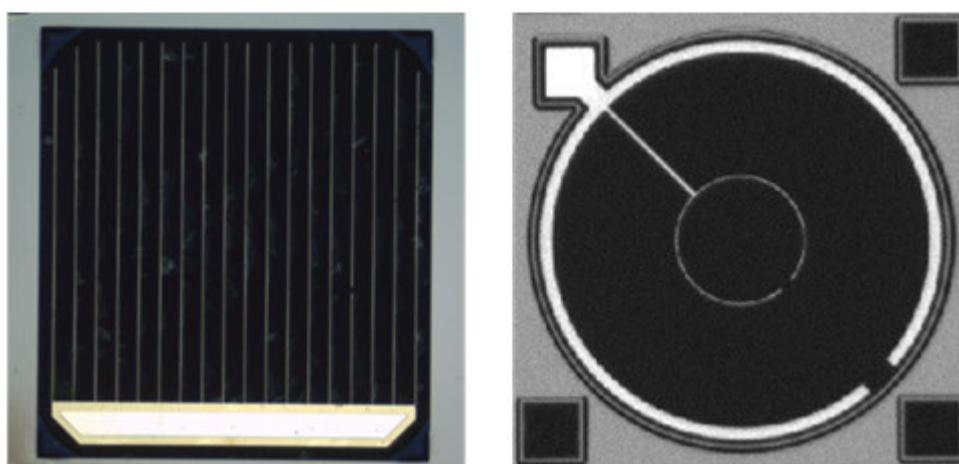


Figura 7: Vista en planta de convertidores fotovoltaicos de GaInP (izquierda) y GaAs (derecha).

Actualmente, las células solares más empleadas para la fabricación de OPCs están formadas por GaAs (arseniuro de galio), puesto que es un material conocido y estudiado en profundidad, además de poseer la eficiencia récord bajo iluminación del espectro solar para células de una unión, y también la mayor eficiencia alcanzada hasta la fecha en OPCs medidos en condiciones de laboratorio, 68.9% a 11.4 Wcm^{-2} [26,27]. En la **Tabla 1** se presentan ejemplos de convertidores utilizados en experimentos de sistemas HPOT. Como es apreciable, la mayoría de los OPCs son de GaAs y derivados, exhibiendo notables eficiencias que llegan a rozar el 60%. Sin embargo, las densidades de potencia que se utilizan son, en general, bajas. En este

sentido, algunos estudios teóricos sugieren que existen materiales más adecuados para la conversión de luz monocromática a altas potencias ($\sim 1000 \text{ Wcm}^{-2}$) [28,29]. Por ende, es justificada la investigación de nuevos materiales semiconductores que presenten propiedades más adecuadas para utilizar en sistemas HPOT.

Tabla 1: OPCs utilizados en sistemas HPOT presentes en la literatura.

Material	Densidad Potencia (Wcm^{-2})	Eficiencia fotovoltaica (%)	Año	Referencia
GaInP	0.3-0.7	40	2004	[30]
Si	0.056	17.7	2005	[31]
Si	0.075	11.9	2006	[32]
GaAs	0.42	14.0	2007	[33]
Si	25	35	2010	[34]
GaAs	4.4	16.5	2010	[35]
GaAs	0.312	21.9	2011	[36]
InGaAsP	0.1	44.6	2013	[37]
GaAs	6	40.4	2014	[38]
GaAs	0.047	37.5	2019	[39]
GaAs	14	57.5	2022	[40]
GaInP	53.5	37.2	2022	[41]

Pese a que suelen ser dispositivos mucho más eficientes que los módulos fotovoltaicos comerciales, las importantes pérdidas tanto intrínsecas como extrínsecas limitan el incremento todavía más su rendimiento.

7.4. PROPAGACIÓN DE ENERGÍA EN LA ATMÓSFERA

La transmisión de energía a través de la atmósfera no es trivial, especialmente cuando los niveles de potencia son elevados. Dependiendo de las características del medio, los fotones que forman el haz de luz pueden ser fuertemente influenciados por una amplia variedad de fenómenos en el momento que son emitidos desde la fuente de luz, influyendo tanto en la cantidad como la calidad de la energía transferida. El impacto es tan crítico que puede comprometer gravemente la viabilidad de todo el sistema. Por lo tanto, comprender las características del entorno para abordar este asunto correctamente es de suma importancia.

En esta sección se presentan los procesos físicos más relevantes involucrados en la propagación de alta potencia a través de luz, incluyendo aquellos relacionados con la absorción, dispersión, turbulencia, dispersión térmica y divergencia. Dado el estado todavía prematuro de la tecnología, la información proporcionada en este informe se centra principalmente en transmisiones en la atmósfera, ya que es el entorno más conveniente para empezar, antes de pasar a escenarios más desafiantes, como los fondos oceánicos o el espacio exterior. No obstante, es importante señalar que en las aplicaciones espaciales se asume que los siguientes fenómenos no aplican, o tienen un impacto mucho más reducido. Esto se debe a que el espacio es considerado la aproximación más similar al vacío absoluto, en el cual la radiación puede propagarse grandes distancias sin sufrir dispersión, aunque es posible que exista atenuación [42,43].

Atenuación. La propagación láser a través de un medio que no sea vacío está influenciada por la presencia de átomos, moléculas y aerosoles que absorben y dispersan la energía [44]. Estos procesos físicos reducen la potencia emitida por la fuente en la dirección de transmisión. Además, a altas potencias ($\geq 100 \text{ kW}$ en

atmósfera), la energía que es absorbida por las partículas calienta el medio circundante, causando un fenómeno adicional llamado dispersión térmica, que se discute en profundidad más adelante [45].

Los perfiles de atenuación varían significativamente entre diferentes medios, como se muestra en la **Figura 8**. Las pérdidas por atenuación en el agua, no solo en aguas oceánicas sino también en agua pura, son varios órdenes de magnitud más severas en comparación con las de la atmósfera. Además, dentro de la atmósfera podemos encontrar diferentes niveles de atenuación dependiendo de las propiedades particulares en las que nos encontremos, como la humedad y la contaminación, o incluso puede depender de condiciones meteorológicas como la niebla o la lluvia [6,28]. Por ejemplo, debido al impacto sustancial de los aerosoles en la atenuación de la luz, las atmósferas más difusas generalmente experimentan una atenuación considerablemente mayor, véase la **Figura 8**. Existen técnicas capaces de reducir la absorción de aerosoles en determinadas situaciones, como la vaporización de la trayectoria de propagación, es decir, eliminar las partículas suspendidas en el medio. En consecuencia, el efecto asociado de dispersión térmica también se minimizaría [45].

Es importante señalar que los mecanismos de atenuación son fuertemente dependientes de la longitud de onda de la fuente, lo cual es fundamental a la hora de diseñar sistemas HPOT adecuados. Según la **Figura 8**, el rango de longitudes de onda de propagación óptimas en el agua está entre los 300 y los 500 nm, mientras que en la atmósfera es recomendable evitar valores alrededor de 950, 1150 y 1400 nm, por ejemplo.

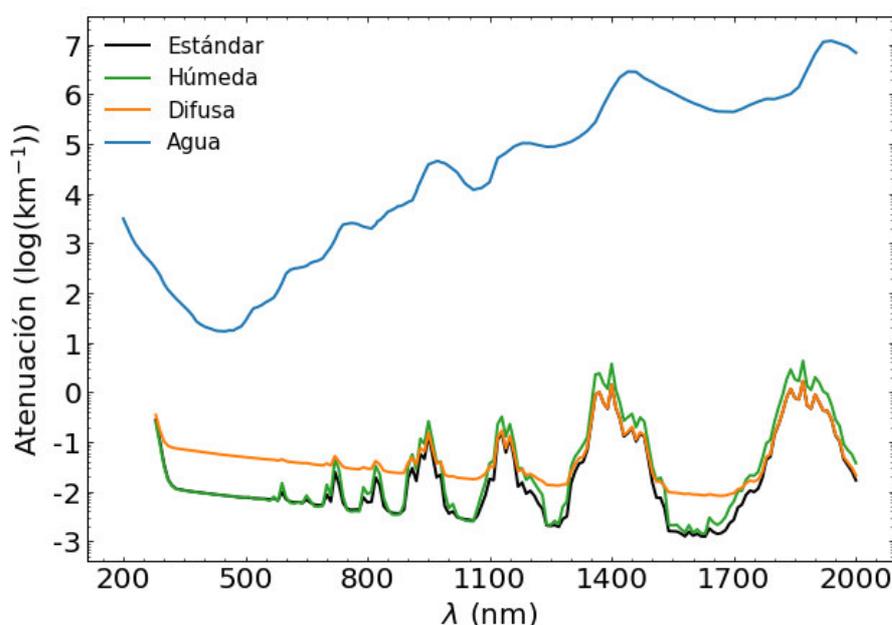


Figura 8: Atenuación en función de la longitud de onda del agua y de tres tipos de atmósfera: estándar (usada como referencia en el campo de la fotovoltaica), húmeda (ambientes con gran concentración de humedad), y difusa (referido a las zonas con valores extremos de aerosoles).

Turbulencia. La turbulencia es un fenómeno físico producido por fluctuaciones aparentemente aleatorias de los índices de refracción del medio que tienen lugar alrededor de la trayectoria de propagación del haz. En general, estas variaciones son causadas por corrientes convectivas producidas por gradientes de temperatura, y, en el caso del agua marina, también de la salinidad y la velocidad de disipación [6,46,47].

La turbulencia impacta significativamente la forma e intensidad del haz transmitido. Uno de los efectos más comunes es el centelleo, que produce fluctuaciones rápidas en la intensidad del haz a lo largo de su perfil espacial [47]. Un ejemplo típico de centelleo es el parpadeo de la luz de las estrellas que se puede observar en el cielo nocturno.

Otras consecuencias importantes son el *wandering* y la dispersión del haz. El *wandering* se define como el desplazamiento aleatorio (en primera aproximación) del centro del haz en el plano receptor respecto a su posición hipotética en ausencia de turbulencia. Este efecto es producido por remolinos de un tamaño mayor al diámetro del haz, los cuales desvían y hacen deambular el centro del haz en el tiempo debido a corrientes laterales.

Existen varios métodos para mitigar el impacto de la turbulencia, que, en regímenes fuertes, puede tener un efecto notoriamente perjudicial. Una de las técnicas se basa en el promedio de la apertura, el cual utiliza una apertura óptica suficientemente grande para promediar las fluctuaciones de intensidad recibidas, reduciendo así el centelleo [6,47]. Otra técnica interesante consiste en el uso de ópticas adaptables, en las cuales se puede ajustar la dirección del frente de onda transmitido, compensando los efectos de *wandering*. Otros sistemas más sofisticados también son capaces de detectar y modificar adecuadamente las distorsiones del frente de onda, logrando un mejor enfoque del haz en el objetivo. Las técnicas mencionadas pueden aplicarse a láseres de modo único, mejorando su eficiencia, pero no tendrían un gran efecto en los láseres multimodo.

Dispersión térmica. La dispersión térmica (*thermal blooming*) surge de una interacción no lineal entre una irradiancia monocromática intensa con el medio de propagación, el cual se calienta debido a la absorción de una parte de la energía transmitida [44,48].

Cuando un haz láser de alta potencia se propaga a través de un medio, las partículas por las que está constituido, como moléculas y aerosoles (en el caso de la atmósfera), absorben parte de la energía. Si es lo suficientemente potente, la irradiancia absorbida calienta el medio, aumentando considerablemente la temperatura y, por ende, induce un cambio en el índice de refracción debido a los cambios de densidad en las proximidades de la trayectoria de transmisión. Esta distorsión provoca un efecto óptico de desenfoque, haciendo que el haz se expanda y se reduzca así su irradiancia máxima. Además, la existencia de un flujo transversal de aire o agua en entornos atmosféricos o marinos, respectivamente, provoca un desplazamiento adicional del haz fuera del objetivo y en la dirección opuesta a el flujo externo. Finalmente, cuando se alcanzan condiciones de estado estacionario, es decir, hay un equilibrio en el proceso de intercambio de calor y el índice de refracción se estabiliza, el spot recibido muestra un patrón de media luna [44,48–50].

Este fenómeno puede comprometer en gran medida el éxito de las transmisiones de alta potencia. Por ejemplo, en la atmósfera, la dispersión térmica se convierte en una grave inconveniente en transmisiones con distancias del orden de kilómetros y niveles de potencia en el rango de cientos de kilovatios [45]. Para aplicaciones submarinas, se espera que los efectos sean sustancialmente más devastadores [49,51]. No obstante, existen algunos métodos de mitigación para prevenir efectos extremadamente perjudiciales, tales como la vaporización, mecanismos de haz rotatorio, y la utilización de ópticas adaptables de bucle cerrado, las cuales ayudan a corregir las distorsiones de fase acumuladas [52,53].

Divergencia e intensidad máxima. El perfil del haz recibido en el plano objetivo es el resultado de la combinación de múltiples factores. Para comenzar, la luz experimenta divergencia debido a la difracción, ampliando su tamaño con respecto a un haz ideal. La relevancia de la difracción está determinada por la longitud de onda de la fuente, la apertura y la calidad del haz. Además, los fenómenos mencionados anteriormente (turbulencia y dispersión térmica) también influyen significativamente en la forma final del spot. Adicionalmente, es necesario considerar el impacto de las vibraciones mecánicas (*jitter*) en el análisis. Estas vibraciones son causadas por sacudidas o movimiento general de la fuente de luz y la óptica asociada. Algunos ejemplos son las vibraciones provenientes de los mecanismos de refrigeración o rachas de viento [8,9,54]. Representar la interacción conjunta de estos fenómenos con el medio suele ser extremadamente complejo, ya que entre ellos pueden darse simultáneamente sinergias que potencien sus efectos o, por el contrario, situaciones en las que el impacto final disminuya debido a que se contrarresten entre sí. Para simplificar este problema, las expresiones presentadas en las referencias [55,56] ejemplifican

al caso de estudio simple de la atmósfera, aunque pueden ajustarse adecuadamente a otros escenarios particulares.

7.5. REFERENCIAS

1. Algora, C., García, I., Delgado, M., Peña, R., Vázquez, C., Hinojosa, M., and Rey-Stolle, I. (2022) Beaming power: Photovoltaic laser power converters for power-by-light. *Joule*, **6** (2), 340–368.
2. Zheng, Y., Zhang, G., Huan, Z., Zhang, Y., Yuan, G., Li, Q., Ding, G., Lv, Z., Ni, W., Shao, Y., Liu, X., and Zu, J. (2024) Wireless laser power transmission: Recent progress and future challenges. *Space Solar Power and Wireless Transmission*.
3. Jin, K., and Zhou, W. (2019) Wireless Laser Power Transmission: A Review of Recent Progress. *IEEE Trans Power Electron*, **34** (4), 3842–3859.
4. Zheng, Y., Zhang, G., Huan, Z., Zhang, Y., Yuan, G., Li, Q., Ding, G., Lv, Z., Ni, W., Shao, Y., Liu, X., and Zu, J. (2024) Wireless laser power transmission: Recent progress and future challenges. *Space Solar Power and Wireless Transmission*.
5. U.S. Naval Research Laboratory First In-Space Laser Power Beaming Experiment Surpasses 100 Days of Successful On-Orbit Operations.
6. Titterton, D.H. (2015) *Military laser technology and systems*, Artech House, Boston.
7. Anil K. Maini (2018) Laser Fundamentals, in *Handbook of Defence Electronics and Optronics*, Wiley, pp. 555–668.
8. Kare, J.T. (2004) Modular Laser Launch Architecture: Analysis and Beam Module Design.
9. Mason, R. (2011) Feasibility of Laser Power Transmission to a High-Altitude Unmanned Aerial Vehicle.
10. Franken, P.A., Hill, A.E., Peters, C.W., and Weinreich, G. (1961) Generation of Optical Harmonics. *Phys Rev Lett*, **7** (4), 118–119.
11. Xue, Q.H., Zheng, Q., Bu, Y.K., Jia, F.Q., and Qian, L.S. (2006) High-power efficient diode-pumped Nd:YVO₄/LiB_{3O₅} 5457 nm blue laser with 46 W of output power. *Opt Lett*, **31** (8), 1070.
12. Kablukov, S.I., Dontsova, E.I., Akulov, V.A., Vlasov, A.A., and Babin, S.A. (2010) Frequency doubling of Yb-doped fiber laser to 515 nm. *Laser Phys*, **20** (2), 360–364.
13. Stolzenburg, C., Schüle, W., Zawischa, I., Killi, A., and Sutter, D. (2010) 700W intracavity-frequency doubled Yb:YAG thin-disk laser at 100 kHz repetition rate. 75780A.
14. IPG Photonics.
15. TRUMPF.
16. Havrilla, D., and Brockmann, R. (2009) Disk laser: A new generation of industrial laser. *International Congress on Applications of Lasers & Electro-Optics*, 151–158.
17. Giesen, A., and Speiser, J. (2007) Fifteen Years of Work on Thin-Disk Lasers: Results and Scaling Laws. *IEEE Journal of Selected Topics in Quantum Electronics*, **13** (3), 598–609.
18. Krupke, W.F. (2004) DPAL: A new class of lasers for cw power beaming at ideal photovoltaic cell wavelengths. *AIP Conf Proc*, 367–377.

19. Beach, R.J., Krupke, W.F., Kanz, V.K., Payne, S.A., Dubinskii, M.A., and Merkle, L.D. (2004) End-pumped continuous-wave alkali vapor lasers: experiment, model, and power scaling. *Journal of the Optical Society of America B*, **21** (12), 2151.
20. Zhdanov, B. V., and Knize, R.J. (2011) Diode pumped alkali lasers. 818707.
21. Cai, H., Wang, Y., Han, J., An, G., Zhang, W., Xue, L., Wang, H., Zhou, J., Gao, M., and Jiang, Z. (2015) Reviews of a Diode-Pumped Alkali Laser (DPAL): a potential high powered light source. 95211U.
22. Krupke, W.F. (2008) Diode pumped alkali lasers (DPALs): an overview. 700521.
23. Liu, S., Tan, R., Xu, W., Ning, F., and Li, Z. (2024) Double-Cycle Alternating-Flow Diode Pumped Potassium Vapor Laser. *Photonics*, **11** (5), 391.
24. Ren Guoguang, 任国光, Yi Weiwei, 伊炜伟, Qi Yu, 齐予, Huang Jijin, 黄吉金, and Qu Changhong, 屈长虹 (2017) U.S. Theater and Strategic UVA-Borne Laser Weapon. *Laser & Optoelectronics Progress*, **54** (10), 100002.
25. Page, R.H., Boley, C.D., Rubenchik, A.M., and Beach, R.J. (2005) Diode Pumped Alkali Vapor Lasers - A New Pathway to High Beam Quality at High Average Power.
26. Fafard, S., and Masson, D.P. (2021) Perspective on photovoltaic optical power converters. *J Appl Phys*, **130** (16).
27. Helmers, H., Lopez, E., Höhn, O., Lackner, D., Schön, J., Schauerte, M., Schachtner, M., Dimroth, F., and Bett, A.W. (2021) 68.9% Efficient GaAs-Based Photonic Power Conversion Enabled by Photon Recycling and Optical Resonance. *Physica Status Solidi - Rapid Research Letters*, **15** (7).
28. Fernández, E.F., García-Loureiro, A., Seoane, N., and Almonacid, F. (2022) Band-gap material selection for remote high-power laser transmission. *Solar Energy Materials and Solar Cells*, **235**.
29. Sanmartín, P., Almonacid, F., Ceballos, M.A., García-Loureiro, A., and Fernández, E.F. (2024) Wide-bandgap III-V materials for high efficiency air and underwater optical photovoltaic power transmission. *Solar Energy Materials and Solar Cells*, **266**.
30. Steinsiek, F., Weber, K.H., Foth, W.P., Foth, H.J., and Schäfer, C. Wireless Power Transmission Experiment using an airship as relay system and a moveable rover as ground target for later planetary exploration missions.
31. Blackwell, T. (2005) Recent demonstrations of Laser power beaming at DFRC and MSFC. *AIP Conf Proc*, **766** (1), 73–85.
32. Ortabasi, U., and Friedman, H. (2006) Powersphere: A Photovoltaic Cavity Converter for Wireless Power Transmission using High Power Lasers. *2006 IEEE 4th World Conference on Photovoltaic Energy Conference*, 126–129.
33. Kawashima, N., and Take, K. (2008) Laser Energy Transmission for a Wireless Energy Supply to Robots, in *Robotics and Automation in Construction*, InTech.
34. Becker, D.E., Chiang, R., Keys, C.C., Lyjak, A.W., Nees, J.A., and Starch, M.D. (2010) Photovoltaic-Concentrator Based Power Beaming For Space Elevator Application. *AIP Conf Proc*, **1230** (1), 271.
35. Nugent, T., Kare, J., Bashford, D., Erickson, C., and Alexander, J. (2010) 12-HOUR HOVER: FLIGHT DEMONSTRATION OF A LASER-POWERED QUADROCOPTER.
36. Smith, M.D., Brandhorst, J., and Henry W. (2011) Support to a Wireless Power System Design.
37. Mukherjee, J., Jarvis, S., Perren, M., and Sweeney, S.J. (2013) Efficiency limits of laser power converters for optical power transfer applications. *J Phys D Appl Phys*, **46** (26), 264006.

38. He, T., Yang, S.-H., Zhang, H.-Y., Zhao, C.-M., Zhang, Y.-C., Xu, P., and Muñoz, M.Á. (2014) High-Power High-Efficiency Laser Power Transmission at 100 m Using Optimized Multi-Cell GaAs Converter. *Chinese Physics Letters*, **31** (10), 104203.
39. Katsuta, Y., and Miyamoto, T. (2019) Design, simulation and characterization of fly-eye lens system for optical wireless power transmission. *Jpn J Appl Phys*, **58** (SJ), SJJE02.
40. Gou, Y., Wang, H., Wang, J., Niu, R., Chen, X., Wang, B., Xiao, Y., Zhang, Z., Liu, W., Yang, H., and Deng, G. (2022) High-performance laser power converts for direct-energy applications. *Opt Express*, **30** (17), 31509.
41. Wong, Y.L., Shibui, S., Koga, M., Hayashi, S., and Uchida, S. (2022) Optical Wireless Power Transmission Using a GaInP Power Converter Cell under High-Power 635 nm Laser Irradiation of 53.5 W/cm². *Energies (Basel)*, **15** (10), 3690.
42. Fitzpatrick, E.L. (2004) Interstellar Extinction in the Milky Way Galaxy. *Astrophysics of Dust, ASP Conference Series*, 33.
43. Davies, P.C.W. (1977) *The physics of time asymmetry*, University of California Press.
44. Smith, D.C. (1977) High-power laser propagation: Thermal blooming. *Proceedings of the IEEE*, **65** (12), 1679–1714.
45. Sprangle, P., Hafizi, B., Ting, A., and Fischer, R. (2015) High-power lasers for directed-energy applications. *Appl Opt*, **54** (31), F201.
46. Baykal, Y., Ata, Y., and Gökçe, M.C. (2022) Underwater turbulence, its effects on optical wireless communication and imaging: A review. *Opt Laser Technol*, **156**, 108624.
47. Milonni, P.W., and Eberly, J.H. (2010) *Laser Physics*, Wiley.
48. Spencer, M.F. (2020) Wave-optics investigation of turbulence thermal blooming interaction: II. Using time-dependent simulations. *Optical Engineering*, **59** (08), 1.
49. Zhu, X., Yu, W., Liu, G., and Zhang, C. (2024) The influence of steady-state thermal blooming effect on the quality of underwater laser power transmission. *AIP Adv*, **14** (3).
50. Ahn, K., Lee, S.-H., Park, I.-K., and Yang, H.-S. (2021) Numerical simulation of high-energy laser propagation through the atmosphere and phase correction based on adaptive optics. *Journal of the Korean Physical Society*, **79** (10), 918–929.
51. Reich, S., Schäffer, S., Lueck, M., Wickert, M., and Osterholz, J. (2021) Continuous wave high-power laser propagation in water is affected by strong thermal lensing and thermal blooming already at short distances. *Sci Rep*, **11** (1), 22619.
52. Qiu, D., Tian, B., Ting, H., Zhong, Z., and Zhang, B. (2021) Mitigation of thermal blooming by rotating laser beams in the atmosphere. *Appl Opt*, **60** (27), 8458.
53. Spencer, M.F., Cusumano, S.J., Schmidt, J.D., and Fiorino, S.T. (2010) Impact of spatial resolution on thermal blooming phase compensation instability. 781609.
54. Gebhardt, F.G. (1976) High power laser propagation. *Appl Opt*, **15** (6), 1479.
55. Tyson, R.K., and Ulrich, P.B. (1993) Adaptive Optics, in *The Infrared & Electro-Optical Systems Handbook, Vol. 8: Emerging Systems and Technologies*, SPIE.
56. Breaux, H., Evers, W., Sepucha, R., and Whitney, C. (1979) Algebraic model for cw thermal-blooming effects. *Appl Opt*, **18** (15), 2638.

7.6. ACRÓNIMOS

UJA	Universidad de Jaén
WPT	Transmisión inalámbrica de potencia (<i>Wireless Power Transmission</i>)
HPOT	Transmisión de energía óptica de alta potencia (<i>High-Power Optical Transmission</i>)
UAV	Vehículo aéreo no tripulado (<i>Unmanned Autonomous Vehicle</i>)
OPC	Convertidor óptico fotovoltaico (<i>Optical Power Converter</i>)
LD	Diodo láser (<i>Laser Diode</i>)
DPSSL	Láseres de estado sólido bombeados por diodo (<i>Diode-Pumped Solid-State Lasers</i>)
DPAL	Láseres alcalinos bombeados por diodo (<i>Diode-Pumped Alkali Lasers</i>)
IoT	Internet de las cosas (<i>Internet of Things</i>)



Universidad de Jaén

Generación de rutas transitables por robots a partir de modelos 3D en escenarios No Estructurados

Informe de Prospectiva 2024



1. INTRODUCCIÓN	84
1.1. Objetivo del informe	84
1.2. Contexto	84
2. FACTORES DE INFLUENCIA	86
3. IDENTIFICACIÓN DE TENDENCIAS	87
3.1. Tendencias actuales	87
3.1.1. Digitalización y Ciberseguridad	87
3.1.2. Uso de Drones y Tecnología Autónoma	87
3.1.3. Guerra Híbrida y Asimétrica	87
3.1.4. Colaboración Internacional y Alianzas	88
3.1.5. Inversión en I+D	88
3.1.6. Enfoque en la Capacitación y el Bienestar del Personal	88
3.2. Tendencias emergentes	88
3.2.1. Sostenibilidad y Defensa Verde	88
3.2.2. Inteligencia Artificial y Automatización	88
3.2.3. Tecnologías de Combate Espacial	88
3.2.4. Innovación en Materiales y Equipamiento	88
3.2.5. Adaptación a Cambios Climáticos	89
4. ESCENARIOS FUTUROS	89
4.1. Escenario #1 - Cooperación Internacional (Optimista)	89
4.1.1. Análisis del escenario	89
4.1.2. Probabilidad y Potencial	89
4.1.3. Riesgos	89
4.1.4. Oportunidades	89
4.1.5. Medidas de Mitigación	90
4.2. Escenario #2 - Escala Militar (Pesimista)	90
4.2.1. Análisis del escenario	90
4.2.2. Probabilidad y Potencial	90
4.2.3. Riesgos	90
4.2.4. Oportunidades	90
4.2.5. Medidas de Mitigación	91
4.3. Escenario #3 - Adaptación Mínima (Conservador)	91
4.3.1. Análisis del escenario	91
4.3.2. Probabilidad y Potencial	91
4.3.3. Riesgos	91
4.3.4. Oportunidades	91
4.3.5. Medidas de Mitigación	92
4.4. Escenario #4 - IA y Robotización del Ejército (Disruptivo)	92

TABLA DE CONTENIDOS

4.4.1. Análisis del escenario #4	92
4.4.2. Probabilidad del escenario #4	92
4.4.3. Riesgos	92
4.4.4. Oportunidades	92
4.4.5. Medidas de Mitigación	93
5. PROPUESTA DE ACCIONES	93
5.1. Acciones recomendadas	93
5.2. Plan de seguimiento	94
5.2.1. Análisis de Tendencias en Tecnologías de Conducción Autónoma	94
5.2.2. Ajuste de las Estrategias de Investigación y Desarrollo de los Sistemas	94
5.2.3. Definición de los Indicadores Clave de Desempeño (KPIs) de los Sistemas	94
6. CONCLUSIONES	95
7. ANEXOS	96
7.1. Datos y estadísticas	96
7.2. Referencias	96
7.3. Acrónimos	96

1. INTRODUCCIÓN

1.1. OBJETIVO DEL INFORME

El objetivo del presente informe de prospectiva es anticipar y analizar tendencias y posibles futuros escenarios en el sector de defensa que permitan guiar estrategias y decisiones para aprovechar las oportunidades y mitigar los riesgos. Se establece un alcance temporal de medio plazo (entre 2 y 5 años).

El informe aborda ámbitos tecnológicos de gran interés tanto para defensa como para el sector civil, tales como el análisis espacial de entornos rurales y forestales, entrenamiento de modelos de Inteligencia Artificial para conducción autónoma, sistemas de teledetección y comunicaciones en entornos con poca o nula cobertura.

Este informe de prospectiva forma parte del trabajo realizado por el *Grupo de Investigación de Gráficos y Geomática de la Universidad de Jaén*, dentro del marco de proyectos de la cátedra entre **Isdefe**, el **CETEDEX** y la **Universidad de Jaén**.

1.2. CONTEXTO

El **sector defensa en España y Europa** se encuentra en un periodo de transformación impulsado por la inestabilidad geopolítica y la necesidad de modernización.

En **España**, la inversión en defensa ha crecido, alcanzando un 1,28% del PIB en 2024, con miras a cumplir el compromiso de la OTAN de elevarlo al 2% para este año, lo que lo sitúa como el país de la OTAN que menos proporción de su PIB gasta en defensa.

Este aumento refleja un compromiso político sólido y una voluntad de fortalecer las Fuerzas Armadas a través de la adquisición de tecnología avanzada y la modernización de equipos.

A **nivel europeo**, la situación es similar, con varios países incrementando su gasto en defensa como respuesta a las amenazas crecientes. La Unión Europea ha fomentado la cooperación en defensa mediante iniciativas como el Fondo Europeo de Defensa, que busca promover la investigación y el desarrollo en este ámbito.

Como parte de la inversión en I+D+i en el sector defensa, este proyecto resulta del convenio de la cátedra entre **Isdefe**, **CETEDEX** y la **Universidad de Jaén**, donde se propone como objetivos:

- **Prospectiva y vigilancia tecnológica.**
En los ámbitos tecnológicos de interés para las Partes y CETEDEX, con difusión abierta de los resultados obtenidos.
- **Difusión y explotación de resultados y conocimiento.**
Organización y participación tanto en conferencias, workshops y seminarios técnicos como en mercados tecnológicos, facilitando la difusión y el contacto entre quienes ofrecen resultados y capacidades de I+D+i y quienes necesitan éstas para resolver problemáticas de su negocio o del mercado
- **Captación de talento.**
A través de actividades de cooperación educativa, concesión de becas, apoyo a la realización de trabajos fin de grado y máster, premios, etc.

- **Fomento del emprendimiento basado en la innovación en Jaén.**
Mediante el apoyo al ecosistema de empresas emergentes (startups) con el fin de impulsar el crecimiento de estas empresas.



Figura 1: Cátedra entre Isdefe, CETEDEX y UJA

El proyecto GENES entra en este marco de investigación para aportar un avance en el campo de la **conducción autónoma** y el **análisis de la transitabilidad** de un escenario no estructurado, pudiendo ser adaptado a aplicaciones como el **acceso de vehículos** a zonas de bosque y montaña que no han sido adaptadas previamente para la conducción en ellas, o en zonas afectadas por cambios radicales de la orografía, a raíz de una emergencia de desastre natural o un conflicto armado.

A fecha de redacción de este documento se ha desarrollado durante 6 meses un **prototipo inicial** orientado a la **creación de trayectorias sobre escenarios virtuales no estructurados**, junto con **sistemas de generación de dichos escenarios sintéticos** aptos para la evaluación y entrenamiento del modelo desarrollado. Se plantea como punto de partida para una futura continuación del proyecto.

Un caso de **aplicación real** pudiera ser la emergencia nacional ocurrida por **inundaciones** a causa de una DANA en la Comunidad Valenciana (noviembre 2024). En este escenario surge la necesidad del acceso de vehículos militares y maquinaria pesada en **zonas de riesgo o de poca o nula accesibilidad** con métodos convencionales.

2. FACTORES DE INFLUENCIA

FACTORES DE INFLUENCIA	
Factores normativos	<p>Regulaciones Internacionales: Tratados y acuerdos internacionales, como el Tratado sobre el Comercio de Armas, establecen normas sobre la producción y el comercio de armamento.</p> <p>Derecho Humanitario: Las leyes que rigen la conducta en conflictos armados y la protección de civiles influirán en las estrategias y tácticas de defensa.</p> <p>Normativas de Seguridad Cibernética: Con el aumento de las amenazas cibernéticas, se están estableciendo nuevas normativas para proteger infraestructuras críticas.</p>
Factores geoestratégicos	<p>Tensiones Regionales: Conflictos y rivalidades en regiones específicas, como el Mar del Sur de China o Europa del Este, afectan la planificación militar y las alianzas.</p> <p>Cambios en el Balance de Poder: La ascensión de potencias como China y Rusia está redefiniendo la dinámica de seguridad global.</p> <p>Alianzas Estratégicas: La formación y fortalecimiento de alianzas, como la OTAN, influirán en la cooperación y la interoperabilidad entre fuerzas armadas.</p>
Factores económicos	<p>Inversión en Defensa: Las decisiones sobre presupuestos de defensa impactan la capacidad de modernización y adquisición de nuevas tecnologías.</p> <p>Impacto de Crisis Económicas: Las recesiones pueden llevar a recortes en el gasto militar, afectando la investigación y el desarrollo.</p> <p>Colaboración Público-Privada: La creciente participación de empresas privadas en la defensa está transformando la innovación y el desarrollo de tecnologías militares.</p>
Factores tecnológicos	<p>Innovaciones en Armamento: Avances en inteligencia artificial, drones, y sistemas de armas hipersónicas están cambiando la naturaleza de la guerra.</p> <p>Ciberseguridad: La defensa cibernética se convierte en una prioridad, con un enfoque en proteger sistemas críticos de ataques.</p> <p>Tecnologías Espaciales: El desarrollo de capacidades militares en el espacio influirá en la vigilancia, la comunicación y la defensa estratégica.</p>
Factores políticos	<p>Cambios en el Liderazgo: Las decisiones políticas y el enfoque de los líderes pueden alterar las prioridades de defensa y las relaciones internacionales.</p> <p>Políticas de Seguridad Nacional: Las reformas en las políticas de seguridad pueden dar forma a las estrategias de defensa y las capacidades de respuesta ante amenazas.</p>

Tabla 1: Factores de influencia en el sector defensa.

El futuro del sector defensa está influenciado por varios factores clave que tienen un impacto significativo en su evolución. En primer lugar, los aspectos **normativos** son esenciales, ya que las regulaciones internacionales, como el **Tratado sobre el Comercio de Armas (ATT)**, establecen normas para la transferencia de armas convencionales, mientras que las **Convenciones de Ginebra** proporcionan un

marco legal para la protección de personas en conflictos armados. Además, las normativas de seguridad cibernética, como la **Directiva NIS de la Unión Europea**, promueven la ciberseguridad en infraestructuras críticas.

En el ámbito **geoestratégico**, las tensiones regionales, como el **conflicto en el Mar del Sur de China**, generan fricciones entre China y sus vecinos, lo que afecta la estrategia militar de EE.UU. en la región. Asimismo, el **ascenso de China** como potencia militar desafía la hegemonía de EE.UU. en Asia, y las alianzas estratégicas, como la **OTAN**, se ven influenciadas por la respuesta a la **agresión rusa en Ucrania**.

Los factores **económicos** también juegan un papel crucial. Por ejemplo, el **presupuesto de defensa** de EE.UU. alcanzó aproximadamente \$778 mil millones en 2022, reflejando un aumento en la inversión militar. Sin embargo, las **crisis económicas** pueden llevar a recortes en el presupuesto de defensa, como se observó en varios países europeos durante la crisis financiera de 2008. La **colaboración entre el sector público y privado** es evidente en proyectos como el desarrollo del caza F-35, que involucra tanto a gobiernos como a empresas privadas.

En cuanto a los avances **tecnológicos**, la innovación en armamento ha transformado la guerra moderna, como se evidencia en el uso de **drones militares** como el MQ-9 Reaper. La **ciberseguridad** también ha cobrado importancia, con la implementación de **firewalls y sistemas de detección de intrusos** para proteger las redes militares. Además, **tecnologías espaciales**, como el Sistema de Defensa de Misiles Aéreos (**Aegis**), son fundamentales para la vigilancia y defensa.

Finalmente, los factores **políticos** tienen un impacto significativo en la defensa. Las políticas de defensa de las administraciones de los países europeos y de EE.UU. han variado drásticamente en la última década.

En conjunto, estos factores interrelacionados moldean el panorama del sector defensa, afectando cómo las naciones se preparan para enfrentar las amenazas emergentes en un entorno global en constante cambio.

3. IDENTIFICACIÓN DE TENDENCIAS

3.1. TENDENCIAS ACTUALES

3.1.1. DIGITALIZACIÓN Y CIBERSEGURIDAD

La **digitalización de los sistemas de defensa** está transformando las operaciones militares, con un **enfoque creciente en la ciberseguridad**. Ejemplos incluyen los **sistemas de gestión de batalla** y el **trabajo del Comando Cibernético** de EE.UU. en la defensa de infraestructuras críticas.

3.1.2. USO DE DRONES Y TECNOLOGÍA AUTÓNOMA

El uso de **drones** como el **MQ-9 Reaper** para misiones de vigilancia y ataque está en aumento. La integración de **vehículos autónomos** en operaciones militares continuará siendo una tendencia clave.

3.1.3. GUERRA HÍBRIDA Y ASIMÉTRICA

La guerra híbrida, evidenciada en conflictos como el de Ucrania, donde se emplean tácticas no convencionales, obligará a las fuerzas armadas a adaptarse a un entorno de seguridad más complejo.

3.1.4. COLABORACIÓN INTERNACIONAL Y ALIANZAS

Las alianzas, como la **OTAN** y la **Iniciativa de Defensa del Pacífico**, seguirán siendo esenciales para enfrentar amenazas comunes y promover la cooperación en seguridad regional.

3.1.5. INVERSIÓN EN I+D

El aumento de los presupuestos de defensa para la investigación y desarrollo de nuevas tecnologías, como el **programa de Armas Dirigidas**, asegura que las fuerzas armadas mantendrán una ventaja competitiva.

3.1.6. ENFOQUE EN LA CAPACITACIÓN Y EL BIENESTAR DEL PERSONAL

El bienestar del personal militar, a través de programas como "**Resiliencia Militar**", se está priorizando para mejorar la preparación y la salud mental de los soldados.

3.2. TENDENCIAS EMERGENTES

3.2.1 SOSTENIBILIDAD Y DEFENSA VERDE

La sostenibilidad en el sector defensa está en ascenso, con programas como el "**Energía Verde para el Ejército**" que buscan reducir el impacto ambiental. La creación de **vehículos militares eléctricos** también es un ejemplo de esta tendencia.

3.2.2. INTELIGENCIA ARTIFICIAL Y AUTOMATIZACIÓN

La inteligencia artificial y la automatización están comenzando a tener un impacto significativo en la **toma de decisiones** y en las **operaciones militares**. Se espera que el desarrollo de sistemas de IA para análisis de datos y predicción de amenazas se expanda en el futuro.

3.2.3. TECNOLOGÍAS DE COMBATE ESPACIAL

La creciente **militarización del espacio** está dando lugar a nuevas capacidades y estrategias en combate espacial. La creación de la **Fuerza Espacial** de EE.UU. es un claro indicativo de esta tendencia emergente que podría transformar el ámbito de la defensa.

3.2.4. INNOVACIÓN EN MATERIALES Y EQUIPAMIENTO

El avance en materiales de defensa y equipamiento, como **armaduras ligeras**, **exoesqueletos** y **tecnologías de camuflaje**, tiene el potencial de mejorar la eficacia y la seguridad de las fuerzas armadas en el futuro.

3.2.5. ADAPTACIÓN A CAMBIOS CLIMÁTICOS

La necesidad de adaptarse a los cambios climáticos también se está convirtiendo en una preocupación emergente. Las fuerzas armadas están comenzando a planificar cómo **responder a desastres naturales** y conflictos relacionados con el clima.

4. ESCENARIOS FUTUROS

4.1. ESCENARIO #1 - COOPERACIÓN INTERNACIONAL (OPTIMISTA)

En este futuro **optimista**, las naciones logran establecer una **cooperación internacional sólida** en materia de defensa, creando un entorno internacional de **estabilidad** y paz.

4.1.1. ANÁLISIS DEL ESCENARIO

El avance en cooperación internacional fomenta un ambiente de confianza entre naciones. Esto puede llevar a la **reducción de tensiones** y al establecimiento de **acuerdos de desarme nuclear**, creando un entorno de paz más estable que disminuye la amenaza de conflictos armados. La inversión en **tecnologías sostenibles, inteligencia artificial y ciberseguridad** se convierte en una prioridad, impulsando innovaciones que reducen la huella de carbono de las operaciones militares. Como consecuencia, se observa una **disminución de los conflictos armados**, lo que **ahorra recursos y vidas** humanas. Además, esta mayor estabilidad global permite un **desarrollo social y económico** más robusto, y las fuerzas armadas se transforman en un recurso valioso para la **asistencia humanitaria y la respuesta a desastres naturales**.

4.1.2. PROBABILIDAD Y POTENCIAL

La **probabilidad** es **moderada**. Aunque existen movimientos hacia la cooperación internacional y el desarme, las tensiones geopolíticas actuales y los intereses nacionales a menudo obstaculizan estos esfuerzos.

El **potencial** de impacto sería **alto**. La reducción de conflictos y la colaboración en la defensa permitirían una **reasignación de recursos** hacia iniciativas de desarrollo social, así como un enfoque en la sostenibilidad. Esto podría transformar la manera en que se concibe la seguridad.

4.1.3. RIESGOS

Desigualdad en la distribución de recursos: La cooperación internacional puede no ser equitativa, dejando a algunos países en desventaja.

Dependencia excesiva: La confianza en alianzas podría llevar a una falta de preparación ante amenazas imprevistas.

4.1.4. OPORTUNIDADES

Innovación tecnológica: La colaboración puede fomentar el desarrollo de tecnologías sostenibles y defensivas.

Reducción de conflictos: Un entorno de paz puede permitir que los recursos se destinen a la educación y el desarrollo social.

4.1.5. MEDIDAS DE MITIGACIÓN

Establecer marcos de cooperación equitativa: Asegurar que todos los países tengan acceso a los beneficios de la cooperación.

Diversificación de capacidades: Mantener un enfoque proactivo en la defensa para no depender únicamente de alianzas.

4.2. ESCENARIO #2 - ESCALA MILITAR (PESIMISTA)

En un futuro **pesimista**, el aumento de las tensiones geopolíticas lleva a un **escalamiento militar**. Las potencias globales se involucran en una **carrera armamentista**. La **desinformación** y la **guerra cibernética** se convierten en herramientas comunes, debilitando la confianza. La falta de atención a la sostenibilidad resulta en un **impacto ambiental negativo**.

4.2.1. ANÁLISIS DEL ESCENARIO

Las naciones invierten fuertemente en tecnología militar avanzada, lo que puede desencadenar una **carrera armamentista**. La **desinformación** y la **guerra cibernética** se convierten en herramientas comunes, erosionando la confianza entre los países. Esta situación, combinada con una **falta de atención a la sostenibilidad**, puede tener un impacto ambiental negativo que afecte tanto a las operaciones militares como a la vida civil. Como resultado, la probabilidad de **guerras y conflictos armados aumenta**, generando un costo significativo en **vidas y recursos**. Además, las tensiones geopolíticas pueden desestabilizar regiones enteras, dando lugar a **crisis humanitarias y desplazamientos masivos** de población, mientras que los recursos se desvían de áreas críticas como educación y salud.

4.2.2. PROBABILIDAD Y POTENCIAL

La **probabilidad** es **alta**. Las tensiones geopolíticas han estado aumentando en diversas regiones del mundo, y la inversión en capacidades militares avanzadas sugiere que muchos países están adoptando un enfoque más agresivo en sus políticas de defensa.

El **potencial** de impacto es **muy alto**. No solo afectarían la seguridad internacional, sino que también **desviarían recursos críticos** de otras áreas, exacerbando problemas sociales y económicos en todo el mundo.

4.2.3. RIESGOS

Escalamiento de conflictos: Las tensiones pueden derivar en guerras abiertas.

Guerra cibernética: Aumento de ataques cibernéticos que desestabilizan infraestructuras críticas.

4.2.4. OPORTUNIDADES

Desarrollo de nuevas tecnologías defensivas: La creciente amenaza puede impulsar innovaciones en defensa cibernética y militar.

Fomento de la industria militar: Aumento de inversiones y empleo en el sector defensa.

4.2.5. MEDIDAS DE MITIGACIÓN

Fortalecimiento de la diplomacia: Promover el diálogo y la negociación para reducir tensiones.

Inversión en ciberseguridad: Proteger infraestructuras críticas contra amenazas cibernéticas.

4.3. ESCENARIO #3 - ADAPTACIÓN MÍNIMA (CONSERVADOR)

En un escenario conservador, las fuerzas armadas se centran en **mantener capacidades tradicionales** y adaptarse a las nuevas amenazas sin realizar cambios radicales. Se adoptan **medidas reactivas y limitadas** ante emergencias.

4.3.1. ANÁLISIS DEL ESCENARIO

Las fuerzas armadas se centran en mantener capacidades tradicionales y modernizar equipos existentes. Esto puede resultar en una capacidad militar que **no se adapta adecuadamente a las nuevas amenazas emergentes**. Aunque se reconoce la necesidad de acciones relacionadas con la sostenibilidad, estas suelen ser limitadas y reactivas. La cooperación internacional se basa en tratados existentes, sin que se desarrollen nuevas estrategias de defensa o desarme. Las consecuencias de este enfoque incluyen un **estancamiento en la innovación** y una **menor competitividad militar**, lo que podría dejar a las naciones vulnerables ante cambios en el entorno de seguridad. Además, la concentración de recursos en ciertas áreas puede llevar a **desigualdades en la defensa** y a un **riesgo creciente de conflictos**.

4.3.2. PROBABILIDAD Y POTENCIAL

La **probabilidad** es **moderada**. Muchos países tienden a mantener sus capacidades militares existentes en lugar de innovar, lo que puede llevar a un enfoque más reactivo frente a las amenazas emergentes.

El **potencial** es **medio**. Aunque la inacción puede resultar en estancamiento y vulnerabilidades, la falta de conflictos abiertos podría mantener una cierta **estabilidad**. Sin embargo, la incapacidad para adaptarse a cambios en el entorno de seguridad podría llevar a **problemas a largo plazo**.

4.3.3. RIESGOS

Estancamiento tecnológico: La falta de innovación puede resultar en vulnerabilidades frente a nuevas amenazas.

Incapacidad para adaptarse: No reconocer cambios en el entorno de seguridad puede llevar a sorpresas estratégicas.

4.3.4. OPORTUNIDADES

Estabilidad relativa: La falta de conflictos abiertos puede permitir una paz temporal.

Recursos para otras áreas: La defensa conservadora puede liberar recursos para educación y salud.

4.3.5. MEDIDAS DE MITIGACIÓN

Evaluación continua de amenazas: Monitorear el entorno de seguridad para adaptar estrategias.

Inversión moderada en I+D: Mantener un enfoque en la innovación, aunque sea limitado.

4.4. ESCENARIO #4 - IA Y ROBOTIZACIÓN DEL EJÉRCITO (DISRUPTIVO)

En un futuro **disruptivo**, las nuevas tecnologías cambian radicalmente el panorama de la defensa. Se generan **desafíos éticos y legales** sobre el uso de la **inteligencia artificial** y la **automatización** de decisiones militares. Daría como consecuencia un entorno internacional de **inestabilidad**.

4.4.1. ANÁLISIS DEL ESCENARIO

Las nuevas tecnologías transforman radicalmente el panorama de la defensa. La **inteligencia artificial** y la **robótica** cambian la naturaleza del combate, planteando **desafíos éticos y legales** que deben ser abordados. La **militarización del espacio** y los **conflictos cibernéticos** se convierten en la norma, lo que genera **tensiones adicionales** entre potencias. Este entorno complejo exige la creación de nuevos marcos normativos para regular el uso de tecnologías emergentes. Las consecuencias incluyen cambios en la toma de **decisiones militares**, que podrían ser **delegadas a algoritmos**, generando **preocupaciones sobre la responsabilidad y la ética** en el uso de la fuerza. Además, la proliferación de tecnologías de guerra cibernética podría resultar en una mayor **inestabilidad**, creando nuevas fronteras de conflicto y desafiando la seguridad global.

4.4.2. PROBABILIDAD Y POTENCIAL

La **probabilidad** es **baja**. Aunque las tecnologías emergentes están avanzando rápidamente, la implementación de estas tecnologías en contextos militares a menudo está sujeta a regulaciones y consideraciones **éticas** que pueden limitar su uso.

Además, el auge de la inteligencia artificial aparenta un cambio de paradigma radical, pero actualmente empieza a desinflarse su burbuja conforme vamos descubriendo límites y problemáticas no esperadas.

El **potencial** es **muy alto**. La transformación radical del panorama de defensa a través de la inteligencia artificial y la militarización del espacio podría cambiar las dinámicas de conflicto y la naturaleza de la guerra. Esto requeriría un **replanteamiento de las estrategias de defensa y la gobernanza global**.

4.4.3. RIESGOS

Desigualdad en el acceso a tecnologías: Algunos países pueden quedar rezagados en capacidades defensivas.

Ética en el uso de IA: Las decisiones automatizadas en combate pueden plantear dilemas éticos importantes.

4.4.4. OPORTUNIDADES

Revolución en la defensa: Nuevas tecnologías pueden cambiar la naturaleza de la guerra y la defensa.

Colaboraciones internacionales: Desarrollo de normas y estándares para el uso de tecnología en conflictos.

4.4.5. MEDIDAS DE MITIGACIÓN

Establecimiento de regulaciones éticas: Crear marcos para el uso responsable de tecnologías emergentes.

Fomentar la cooperación internacional: Trabajar en conjunto para garantizar que las innovaciones sean accesibles y equitativas.

5. PROPUESTA DE ACCIONES

5.1. ACCIONES RECOMENDADAS

Investigación Colaborativa: Fomentar la colaboración entre la universidad y empresas tecnológicas para el desarrollo de sistemas y herramientas de apoyo en la investigación de proyectos como GENES, por medio de convenios como la cátedra Isdefe - UJA - CETEDEX.

Simulaciones y Prototipos: Crear modelos y simulaciones de escenarios en los que se planee actuar (campo, montaña, zonas de desastre) para entrenar y evaluar los sistemas antes de su implementación real.

Capacitación en Tecnologías Emergentes: Ofrecer programas de capacitación para estudiantes y personal sobre tecnologías como inteligencia artificial y análisis de datos geoespaciales, que son fundamentales para el proyecto.

Estudios de Viabilidad: Realizar estudios de viabilidad sobre la integración de los sistemas con los vehículos existentes en el sector defensa y en operaciones de emergencia. Y un estudio de las distintas alternativas de vehículos y sugerencias de cambios en estos para la adaptación de estos sistemas.

Pruebas de Campo: Adaptar espacios reservados para ejecutar pruebas en condiciones reales para evaluar la efectividad de los sistemas de conducción autónoma planteados en el proyecto con distintas condiciones climáticas y vehículos.

Integración de Sistemas: Asegurar que el nuevo sistema se integre con las plataformas y sistemas de comunicación existentes del sector defensa para mejorar la operatividad y evaluar la operatividad en zonas de pobre cobertura.

Desarrollo de Protocolos de Seguridad: Establecer protocolos de seguridad para proteger la información generada y el uso de tecnología en situaciones críticas.

Establecimiento de Unidades de Respuesta Rápida: Crear unidades especializadas dentro del sector defensa que puedan utilizar el sistema para responder rápidamente a situaciones de emergencia.

De cara a los organismos y administraciones públicas, como el Ministerio de Defensa, se plantea lo siguiente:

Financiación y Apoyo a la Innovación: Proporcionar financiamiento y apoyo a proyectos de investigación e innovación que busquen desarrollar tecnologías aplicables a la defensa y emergencias.

Colaboración Interinstitucional: Fomentar la colaboración entre diferentes agencias gubernamentales y el sector privado para maximizar los recursos y conocimientos en el desarrollo de los sistemas.

Adopción de Políticas de Innovación: Implementar políticas que promuevan la adopción de nuevas tecnologías en el sector defensa, asegurando que las capacidades de innovación se mantengan actualizadas.

Evaluación de Riesgos y Oportunidades: Realizar evaluaciones periódicas de riesgos y oportunidades relacionados con el uso de tecnologías emergentes en el sector defensa, ajustando las estrategias según sea necesario.

5.2. PLAN DE SEGUIMIENTO

5.2.1. ANÁLISIS DE TENDENCIAS EN TECNOLOGÍAS DE CONDUCCIÓN AUTÓNOMA

En un entorno cambiante como el sector tecnológico debemos seguir un enfoque flexible y adaptarnos a la tecnología punta.

Investigación de tendencias tecnológicas: Monitorear avances en tecnologías de conducción autónoma, como la inteligencia artificial, aprendizaje automático, sensores a bordo de vehículos, sensores térmicos, hiperspectrales, etc.

Colaboración con centros de investigación: Establecer asociaciones con instituciones académicas y centros de investigación para compartir información y resultados sobre innovaciones.

5.2.2. AJUSTE DE LAS ESTRATEGIAS DE INVESTIGACIÓN Y DESARROLLO DE LOS SISTEMAS

Algunas medidas de seguimiento, respecto a la periodicidad y los recursos monetarios pueden ser:

Reuniones de ajuste periódicas: Organizar reuniones cada trimestre o semestre con el equipo de investigación para revisar hallazgos y proponer adaptaciones en las estrategias de desarrollo según los resultados obtenidos.

Asignación de recursos flexibles: Destinar parte del presupuesto de investigación a explorar nuevas líneas de tecnología que surjan en el sector, permitiendo una respuesta rápida a los cambios en tendencias.

5.2.3. DEFINICIÓN DE LOS INDICADORES CLAVE DE DESEMPEÑO (KPIs) DE LOS SISTEMAS

Dentro del proyecto, se puede evaluar según algunos indicadores clave para el seguimiento de los avances de éste:

Tasa de éxito de navegación autónoma: Porcentaje de misiones completadas con éxito en escenarios no estructurados utilizando tecnologías autónomas.

Precisión de la detección de obstáculos: Medir la efectividad de los sistemas de sensores en la identificación de obstáculos en tiempo real.

Fiabilidad del sistema: Evaluar la cantidad de fallos o errores en la navegación autónoma durante las pruebas en escenarios reales.

6. CONCLUSIONES

El **proyecto GENES** de **CETEDEX** viene a resolver carencias en el sector defensa en ciertos escenarios de mucha incertidumbre y difícil acceso.

El sistema propuesto podría ayudar a vehículos militares y maquinaria pesada a acceder a **zonas inaccesibles** por métodos convencionales.

Ayudará en la **mitigación de riesgos** gracias a la conducción autónoma, eliminando la necesidad de un piloto presente dentro. **Optimizará trayectos** gracias a algoritmos avanzados ejecutados sobre datos geoespaciales, los cuales serán tomados por sistemas de geolocalización actuales, como drones y satélites.

Será especialmente útil en **escenarios de poca accesibilidad y cobertura**, como zonas rurales, forestales y montañosas, y escenarios cambiantes, como puede ser una zona en emergencia a causa de un desastre natural o un conflicto armado.

Algunos de los objetivos finales del proyecto son:

- **Construcción de trayectorias y áreas transitables** en tiempo real a partir de datos geoespaciales tomados por sensores a bordo de un vehículo y un dron.
- Dotar de capacidad de **toma de decisión a un vehículo autónomo** sobre los datos geoespaciales obtenidos.
- **Teledetección y clasificación de obstáculos y vegetación** para afinar la toma de decisiones del vehículo autónomo.

7. ANEXOS

7.1. AVANCE ACTUAL DEL PROYECTO

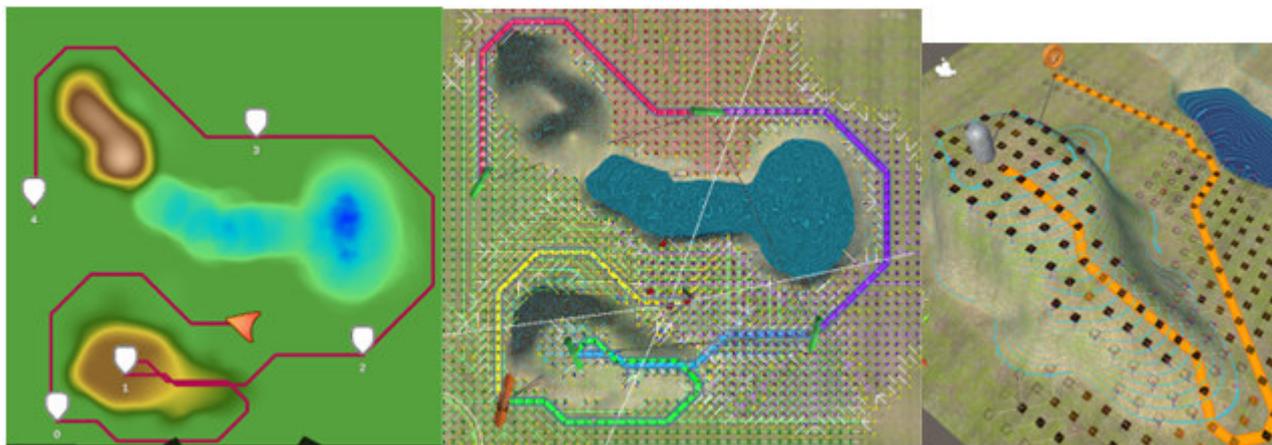


Figura 2. Prototipo Inicial Proyecto GENES

7.2. REFERENCIAS

Cátedra Isdefe/CETEDEx-UJA. <https://cetedex.ujaen.es>

Isdefe - Ingeniería de Sistemas para la Defensa de España. <https://www.isdefe.es>

Autonomous Vehicle Simulation for Off-Road Environments. Proyecto del Southwest Research Institute similar a GENES. <https://www.youtube.com/watch?v=jU4iMs51eo>

7.3. ACRÓNIMOS

ISDEFE	Ingeniería de Sistemas para la Defensa de España
CETEDEx	Centro Tecnológico de Desarrollo y Experimentación
UJA	Universidad de Jaén
OTAN	Organización del Tratado del Atlántico Norte
ATT	Arms Trade Treaty
NIS	Network and Information Security
KPI	Key Performance Indicator