



## E1.2. Informe del estado del arte de técnicas IA explicable y algoritmos para proteger la biodiversidad de parques eólicos



## Contenido

<b>E1.2. Informe del estado del arte de técnicas IA explicable y algoritmos para proteger la biodiversidad de parques eólicos</b> .....	1
1. Introducción .....	3
1.1 Objetivo .....	3
1.2 Alcance.....	3
2 Estado del arte de IA explicable y algoritmos para la Planificación Estratégica en el contexto general de la energía eólica .....	3
2.1 Estado del arte de los algoritmos de IA Explicable existentes alineados con la elaboración de directrices y criterios que optimicen la evaluación de espacios destinados a ser parques eólicos y propuesta de líneas de investigación .....	4
2.1.1 Planificación estratégica.....	4
2.1.2 Maximización de la producción.....	5
2.1.3 Protección de la biodiversidad .....	7
2.2 Investigación de casos y estudios que aplican modelos explicables de redes neuronales bayesianas (BNN) para explicar el proceso de toma de decisiones optimizando las predicciones aplicadas a proyectos de energía eólica. ....	9
2.2.1 Redes neuronales bayesianas.....	9
2.2.2 Estado del arte.....	9
2.3 Estado del arte del uso de Redes Neuronales Convolucionales (CNN) para el procesamiento inteligente de diversos tipos de mapas.....	12
2.3.1 Redes Neuronales Convolucionales.....	12
2.3.2 Procesamiento inteligente de mapas.....	12
2.4 Investigación de casos y estudios que utilizan Redes Neuronales Convolucionales (CNN) y Redes Neuronales Recurrentes Convolucionales (RNN) para la detección y monitorización de aves in-situ. ....	15
2.4.1 Redes Neuronales Convolucionales.....	15
2.4.2 Redes Neuronales Recurrentes .....	15
2.4.3 Estado de arte .....	16
3 Conclusión .....	20
4 Referencias bibliográficas .....	22

## 1. Introducción

El proyecto titulado Plataforma de IA Explicable para la predicción y protección de aves en espacios destinados a ser parques eólicos, o de forma abreviada, IA4BIRDS, pretende diseñar una plataforma inteligente para optimizar la evaluación y planificación de espacios destinados a ser parques eólicos, basándose, principalmente, en la recopilación de datos sobre aves en la zona para su posterior análisis aplicando algoritmos de inteligencia artificial.

El proyecto se subdivide en diferentes tareas, que, en conjunto, permiten acometer la funcionalidad global del sistema. Este documento corresponde al entregable:

### E1.2 - Informe del estado del arte de técnicas IA explicable y algoritmos para proteger la biodiversidad de parques eólicos

Refleja los trabajos realizados y los resultados alcanzados durante la ejecución de la actividad:

**A1.2 Estado del arte de IA explicable y algoritmos para la Planificación Estratégica en el contexto general de la energía eólica** cuyo objetivo es Investigar y estudiar el estado del arte de los algoritmos de IA Explicable como herramienta de Planificación Estratégica para incorporar modelos predictivos que permitan la evaluación y el diagnóstico de proyectos de energía eólica.

Esta tarea se encuadra dentro de LA ACTIVIDAD A1 y la línea de investigación:

**A1. Estado del arte de IA Explicable y requisitos para la gestión de la biodiversidad en parques eólicos del proyecto IA4BIRDS: Plataforma de IA Explicable para la predicción y protección de aves en espacios destinados a ser parques eólicos**, cuyo objetivo es diseñar una plataforma global, modular y escalable basada en IA Explicable que permita optimizar la evaluación y planificación de espacios destinados a ser parques eólicos aplicando algoritmos híbridos de inteligencia artificial para la detección y predicción de aves.

### 1.1 Objetivo

El objetivo de esta actividad es investigar y estudiar el estado del arte de los algoritmos de IA Explicable como herramienta de planificación estratégica para incorporar modelos predictivos que permitan la evaluación y el diagnóstico de proyectos de energía eólica tratando de explorar diferentes maneras de establecer los estudios, desde el punto de vista de la optimización de la posición de las turbinas para aumentar la energía producida hasta la revisión de los requisitos ambientales, imprescindibles para un completo estudio del impacto producido.

### 1.2 Alcance

Este documento se encuentra en la versión 1.0, y aunque está sujeta a nuevas evoluciones si en las siguientes fases del proyecto se hacen necesarios ajustes, la investigación aquí plasmada trata de presentar el trabajo realizado para la consecución de los objetivos de la tarea de diseñar una plataforma de IA explicable para optimizar la evaluación de espacios destinados a ser parques eólicos.

## 2 Estado del arte de IA explicable y algoritmos para la Planificación Estratégica en el contexto general de la energía eólica

El rápido progreso tecnológico y la creciente demanda de energía eléctrica han llevado a un aumento en el uso de fuentes de energía renovables. Sin embargo, no se puede ignorar el impacto de estos parques eólicos en las aves y los ecosistemas locales. Por lo tanto, es crucial

desarrollar sistemas de reconocimiento de aves para minimizar los efectos perjudiciales de los parques eólicos sobre las aves. La investigación futura debería centrarse en el desarrollo de técnicas de reconocimiento de aves rentables y eficientes que puedan implementarse fácilmente en futuros proyectos parques eólicos y en el seguimiento de los existentes.

## 2.1 Estado del arte de los algoritmos de IA Explicable existentes alineados con la elaboración de directrices y criterios que optimicen la evaluación de espacios destinados a ser parques eólicos y propuesta de líneas de investigación

### 2.1.1 Planificación estratégica

La planificación estratégica de la energía eólica es un proceso que implica la identificación de los recursos eólicos disponibles y la evaluación de su potencial para generar energía eléctrica. Los algoritmos se utilizan para analizar los datos de viento y predecir la producción de energía en diferentes condiciones climáticas. Estos algoritmos también pueden ayudar a optimizar la ubicación de los aerogeneradores y el diseño de los parques eólicos [1], también se han explorado el uso de algoritmos de optimización para el micrositing en parques eólicos offshore, evaluando diferentes algoritmos como la búsqueda de gradientes y algoritmos evolutivos para optimizar la colocación de las turbinas eólicas con el objetivo de minimizar los costos y maximizar la producción energética [2].

Un estudio describe un marco de optimización para el diseño de parques eólicos en terrenos complejos. Se utiliza una combinación de herramientas de evaluación de recursos eólicos, un modelo de estela de viento adaptado a terrenos complejos y un algoritmo de búsqueda aleatoria para maximizar la producción anual neta de energía (AEP), teniendo en cuenta restricciones como límites de terreno y distancias entre turbinas. Se introduce un nuevo algoritmo llamado "Heuristic Fill" para la generación inicial de diseños de parques eólicos. El estudio de caso muestra la mejora de la AEP de un parque eólico existente, respetando las restricciones de área y distancia entre turbinas [3].

El diseño de los parques eólicos está sujeto a varias restricciones, que pueden venir de consideraciones técnicas, logísticas, ambientales, económicas, legales y/o incluso sociales. En el marco actual, se consideran tres tipos de restricciones:

- (1) límites inclusivos y exclusivos;
  - (2) requisitos mínimos de distancia;
  - (3) límites en ciertas variables de condición del sitio.
- Los límites inclusivos y exclusivos denotan el área factible e inviable para colocar turbinas, que puede deberse de limitaciones y requisitos en terrenos arrendados, carreteras y propiedades existentes, condiciones del suelo, etc
  - El segundo tipo de restricción también es típico en la práctica de ingeniería, que requiere que la distancia entre dos turbinas cualquiera sea mayor que un valor mínimo. Esto se debe a que una distancia más corta entre las turbinas dará una mayor pérdida de estela

y una mayor intensidad de turbulencia, lo que resulta en un mayor nivel de cargas de fatiga y costos de mantenimiento, e incluso una vida útil más corta de las turbinas. Además, se requiere una distancia mínima para asegurarse de que las palas de dos turbinas nunca entren en contacto entre sí y que una turbina nunca caiga sobre la otra turbina.

El modelo de estela de Jensen adaptado asume que la línea central de estela de una turbina eólica sigue el terreno a la misma altura sobre el suelo a lo largo de la dirección de entrada local del viento, mientras que su zona de estela se expande linealmente y su déficit de estela se desarrolla siguiendo la misma regla que el modelo original de Jensen.

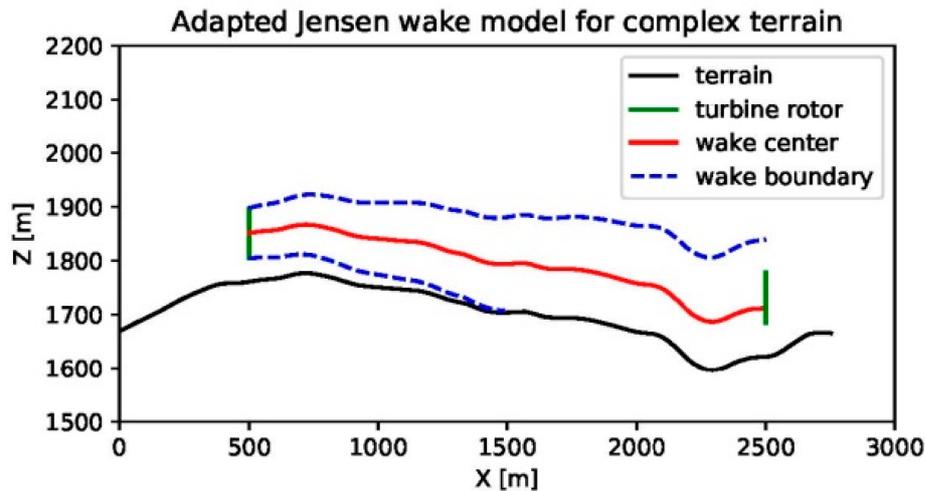


Figura 1. Esquema del modelo de estela de Jensen adaptado para una turbina eólica en terrenos complejos.

- El tercer tipo de restricciones expone los requisitos de ciertas variables de condición del sitio para descartar ciertos sitios desfavorables, como aquellos con una velocidad media del viento demasiado baja, una intensidad de turbulencia demasiado alta o un terreno demasiado accidentado. Cuando se aplica correctamente, este tipo de restricción puede ayudar al optimizador a centrarse en el espacio de diseño más favorable y acelerar el proceso de convergencia

### 2.1.2 Maximización de la producción

El algoritmo de Búsqueda Aleatoria (RS) se utiliza para optimizar el diseño de parques eólicos en terreno complejo, mejorando la producción energética. RS realiza ajustes menores en la posición de las turbinas de forma iterativa para encontrar la configuración óptima, respetando restricciones de distancia y área. Se incluye un nuevo método, Relleno Heurístico, para crear diseños iniciales viables basados en condiciones del viento y restricciones del sitio. La calidad del diseño inicial es clave para la efectividad y velocidad del algoritmo.

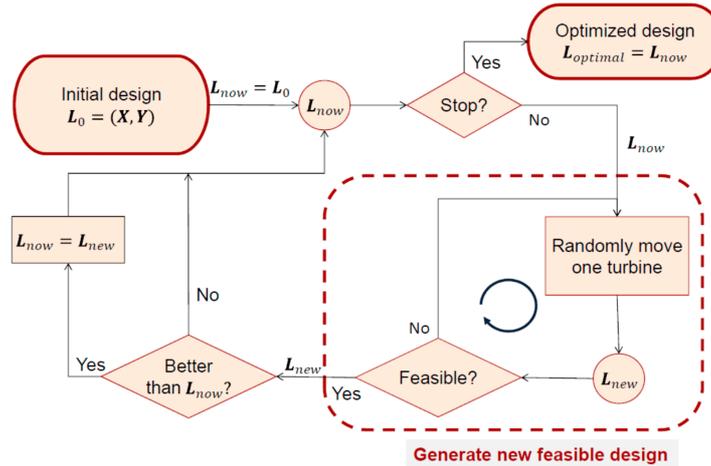


Figura 2. Diagrama de flujo del algoritmo de búsqueda aleatoria.

Este opera mediante dos parámetros principales: el tamaño máximo del paso (MMax), que determina cuán lejos puede moverse una turbina, y el número máximo de evaluaciones (EMax), que indica cuándo detener el algoritmo. La naturaleza estocástica del RS significa que puede ofrecer diferentes resultados en distintas ejecuciones, y la calidad de la solución inicial puede afectar significativamente el resultado y la rapidez de la optimización. Se propuso un algoritmo de Relleno Heurístico para establecer una buena disposición inicial de turbinas basándose en las condiciones del sitio y las restricciones de espacio.

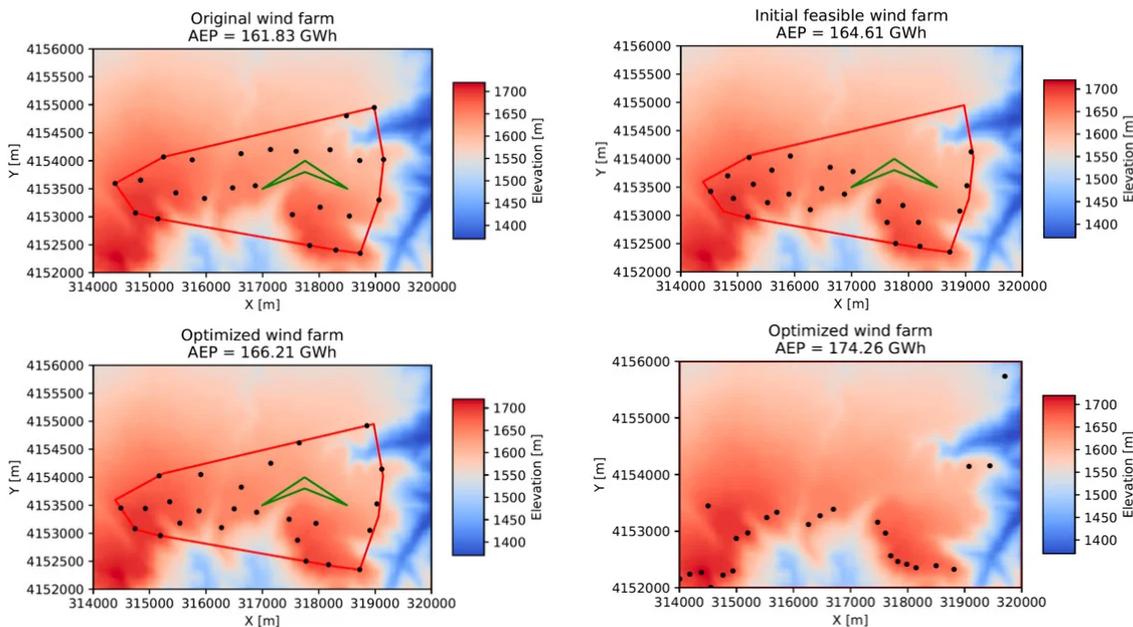


Figura 3.

- A Diseño original del parque eólico anónimo en un terreno complejo.
- B Diseño inicial obtenido por el algoritmo de relleno heurístico.
- C. El mejor diseño optimizado que se encuentra en el marco con EMax=10.000, MMax=5000 m.
- D El mejor diseño optimizado para el parque eólico sin ninguna restricción (encontrado por búsqueda aleatoria con EMax=10.000 y MMax=5000 m en el escenario aleatorio)

En el estudio se presentó un marco para optimizar el diseño de parques eólicos en terrenos complejos, combinando herramientas avanzadas de evaluación de recursos eólicos y modelos de estela con algoritmos de optimización, y se comparó con otros algoritmos utilizados

anteriormente en otros estudios, dando mejores resultados en cuanto a producción esperada se refiere.

El algoritmo RS se destaca por su desempeño superior en comparación con otros algoritmos populares como el Algoritmo Genético (GA), el NSGA-II (Non-dominated Sorting Genetic Algorithm II), y la optimización por enjambre de partículas (Particle Swarm Optimization, PSO) en su variante mixta-discreta. Estas comparaciones sugieren que RS es más efectivo para los casos de uso especificados, posiblemente debido a su capacidad para explorar de manera más efectiva el espacio de soluciones en problemas de optimización complejos y altamente dimensionales típicos de la ingeniería de parques eólicos.

Escenario Inicial	Algoritmo	AEP [GWh]			E <sub>máx</sub> [W]
		Peor inicial	Mejor inicial	Optimizado	
Aleatorio	PSO	119,12	152,44	160,76	5000
	RCGA	119,12	152,44	156,68	5000
	RS	119,12	119,12	173,58	5000
	PSO	119,12	152,44	161,66	50.000
	RCGA	119,12	152,44	165,43	50.000
	RS	119,12	119,12	<b>174,26</b>	10.000
Relleno heurístico	PSO	170,27	171,18	171,74	10.000
	RCGA	170,27	171,18	171,96	10.000
	RS	170,27	170,27	174,10	10.000
	PSO	170,27	171,18	171,84	50.000
	RCGA	170,27	171,18	172,58	50.000
	RS	170,27	170,27	173,80	5000

**Tabla 1.** Comparación de rendimiento de tres algoritmos: PSO (optimización de enjambre de partículas), RCGA (algoritmo genético de código real) y RS (búsqueda aleatoria).

El marco permite maximizar la producción de energía, con una estructura modular adaptable para incluir distintas funciones y restricciones. Se introduce un índice para evaluar la rugosidad del terreno y un método heurístico para generar diseños iniciales eficientes. La eficacia se demuestra en un caso real, mostrando mejoras significativas en la producción de energía.

En este sentido existen en el mercado software especializado en el diseño de parques eólicos desde el punto de vista de la optimización del recurso eólico junto con las restricciones mencionadas, WAsP (Wind Atlas Analysis and Application Program) es un software para el diseño de parques eólicos que ayuda a estimar el recurso eólico en un área específica, teniendo en cuenta la topografía y las condiciones locales del viento. El programa genera un mapa de velocidad del viento que predice la producción de energía, facilitando la ubicación óptima de las turbinas para maximizar la eficiencia. WAsP es ampliamente utilizado por ingenieros y planificadores para evaluar el potencial eólico antes de la construcción del parque eólico [4].

Otro estudio ha utilizado un modelo de partículas virtuales para simular la estela del viento y maximizar la producción total de energía mediante la colocación estratégica de las turbinas. Este método ha demostrado generar una mayor producción de energía en comparación con las disposiciones optimizadas por algoritmos genéticos. Además, se destaca por su alta resolución y bajo coste temporal en la discretización del área [5].

### 2.1.3 Protección de la biodiversidad

Pero no sólo hay que tratar de maximizar la producción de energía en localizaciones concretas, se trata de incorporar datos de biodiversidad en estos análisis que permitan un mejor conocimiento de las zonas de estudio para el desarrollo de nuevos proyectos.

Para ello hay que tener en cuenta elementos claves en los requisitos necesarios para que una localización sea la adecuada, así como la legislación vigente que prohíba la implantación de este tipo de plantas, para ello hacen falta modelos aplicables a la protección de la biodiversidad que trabajen en conjunto con los anteriores, para realizar EIA. Los modelos de riesgo de colisión (CRM, por sus siglas en inglés) son una herramienta, a menudo utilizada en evaluaciones de impacto ambiental, que puede proporcionar estimaciones de riesgos relacionados con aerogeneradores específicos o un parque eólico completo. Sin embargo, todavía hay preguntas asociadas con la incertidumbre en las estimaciones de CRM [6]



Figura 4. Parámetros que se utilizan a menudo en los modelos de riesgo de colisión. Gráfico del Laboratorio Nacional de Energías Renovables;

Se analiza la susceptibilidad de las aves rapaces a colisiones con aerogeneradores, enfocándose en cómo sus características fisiológicas y comportamentales, como los puntos ciegos y la frecuencia de movimientos oculares durante el vuelo, influyen en los eventos de colisión. Se introducen los Modelos de Riesgo de Colisión (CRM) que calculan la probabilidad de colisiones basándose en características específicas del parque eólico y las especies involucradas, proponiendo medidas de mitigación para minimizar impactos en las aves rapaces durante diversas temporadas, incluyendo la migración y la reproducción...

La zonificación ambiental para grandes instalaciones de energía renovable en España excluye instalaciones pequeñas y se centra en la eólica y fotovoltaica. Aunque este modelo no reemplaza la evaluación ambiental requerida para cada instalación, ofrece una guía preliminar sobre los condicionantes ambientales de las zonas donde se pueden desarrollar proyectos. La herramienta incluye dos capas de información visualizables en la Infraestructura de Datos Espaciales del Ministerio para la Transición Ecológica, que indican el índice de sensibilidad ambiental y los indicadores asociados. [7]

El índice de sensibilidad eólica es una medida utilizada para evaluar el impacto ambiental potencial de los proyectos de energía eólica en una ubicación específica. Este índice considera varios factores ambientales como la biodiversidad, las características del terreno y las condiciones meteorológicas para determinar la sensibilidad de un área a la instalación de turbinas eólicas. Un valor alto en el índice indica una mayor sensibilidad, lo que sugiere la necesidad de evaluaciones detalladas y posiblemente medidas de mitigación para proteger el entorno.

Los Modelos de Riesgo de Colisión (CRM) enfrentan desafíos significativos debido a la sensibilidad a ciertos parámetros como la tasa de evasión, que puede alterar drásticamente las estimaciones de colisiones con pequeñas variaciones en los datos. La incertidumbre del modelo y la falta de datos específicos son limitaciones adicionales, complicando la predicción precisa de colisiones. Mejorar los CRM implica refinar parámetros de comportamiento clave y utilizar tecnologías avanzadas para recopilar datos más precisos sobre las tasas de evasión y la velocidad de vuelo, lo que podría mejorar sustancialmente las predicciones de los modelos, ésta es una tarea que se podrá abordar en investigaciones futuras.

## 2.2 Investigación de casos y estudios que aplican modelos explicables de redes neuronales bayesianas (BNN) para explicar el proceso de toma de decisiones optimizando las predicciones aplicadas a proyectos de energía eólica.

### 2.2.1 Redes neuronales bayesianas

En la investigación y desarrollo de tecnologías para la toma de decisiones aplicada a proyectos de energía eólica, las redes neuronales bayesianas (BNN) han emergido como una herramienta prometedora. Estos modelos computacionales no solo facilitan la interpretación y cuantificación de incertidumbres inherentes al proceso decisional, sino que también mejoran la interpretabilidad de los modelos predictivos en un sector que enfrenta desafíos únicos por la variabilidad del viento. Se explora la capacidad de las BNN no solo en la previsión meteorológica sino también en la gestión y protección del medio ambiente, ofreciendo así un marco robusto para una operación más eficiente y consciente de los parques eólicos.

En el ámbito de la toma de decisiones utilizando redes neuronales bayesianas (BNN), se han realizado estudios que ilustran la aplicación de estos modelos en contextos específicos, evidenciando su utilidad en la explicación del proceso decisional mediante la cuantificación de incertidumbres y la mejora de la interpretabilidad de los modelos predictivos. No existen muchos estudios que apliquen redes neuronales bayesianas para la toma de decisiones un parque eólico, y los que se han encontrado tratan de hacer una previsión del viento con buenos resultados obtenidos de una hora de antelación.

Si existen diferentes estudios que han empleado BNN para la ayuda a la toma de decisiones, junto con otras técnicas de aprendizaje automático, pero no directamente relacionado con la protección de las aves y optimización de decisiones en proyectos eólicos.

### 2.2.2 Estado del arte

Un ejemplo relevante es el empleo de las BNN en la predicción de vibraciones en el suelo inducidas por explosiones, donde se comparan las BNN con otras técnicas de regresión de aprendizaje automático, demostrando la superioridad de las BNN en términos de menor error en las predicciones. Este estudio también aplicó técnicas como SHAP (SHapley Additive exPlanations) para interpretar la importancia de las características de los modelos, abordando así el problema de la caja negra asociado con las redes neuronales [8].

El estudio aborda la importancia crítica de la previsión de inundaciones y la necesidad de entender la incertidumbre asociada a estas previsiones para mejorar la gestión de los recursos hídricos. Tradicionalmente, los modelos deterministas no pueden proporcionar información sobre la incertidumbre de las previsiones. Por ello, se propone un modelo de red neuronal bayesiana variacional (VBNN) para la previsión de inundaciones en conjunto, que utiliza una distribución variacional para aproximar la distribución posterior, evitando los altos costos computacionales asociados a las redes neuronales bayesianas tradicionales.

El modelo VBNN convierte la incertidumbre de los parámetros del modelo en incertidumbre de salida del modelo mediante muestras de Monte Carlo para proporcionar resultados de previsión en conjunto. Este método se verifica mediante un caso de estudio de previsión de inundaciones en la parte superior del río Yangtze, comparándolo con un modelo de previsión puntual y dos modelos de previsión probabilísticos, incluyendo un Modelo de Markov Oculto y la regresión de procesos gaussianos [9]. Los resultados experimentales indican que el modelo VBNN supera a los modelos comparables en términos de precisión y fiabilidad. Además, los resultados de la

estimación de incertidumbre demuestran que el VBNN maneja eficazmente los datos heterocedásticos de flujo de inundaciones, ofreciendo un marco más robusto y confiable para la toma de decisiones en la gestión de desastres naturales y la planificación de recursos hídricos.

En lo que a energía eólica se refiere, ha habido estudios que examinan la predicción de la producción de energía eólica, destacando la incertidumbre debida a la variabilidad climática y la limitada disponibilidad de datos históricos. Se revisan diversas técnicas avanzadas para mejorar la precisión de las predicciones, incluyendo redes neuronales y modelos de regularización bayesiana, que ayudan a prevenir el sobreajuste en situaciones de datos limitados. Además, se discuten métodos como la Determinación Automática de Relevancia Bayesiana para optimizar el uso de características en los modelos predictivos.

Los modelos que se estudiaron son los siguientes:

- Perceptrón multicapa entrenado a través de Maximum Probabilidad (MLP)
- NN bayesiano con un solo parámetro de regularización (BNN)
- NN bayesiano con determinación automática de relevancia (BNN-ARD).

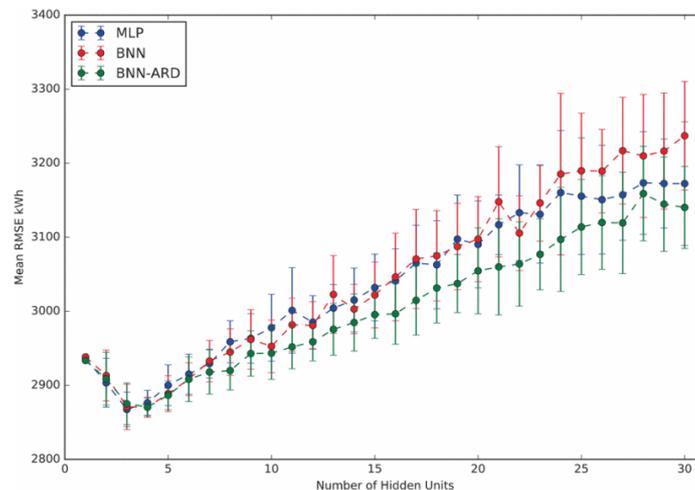
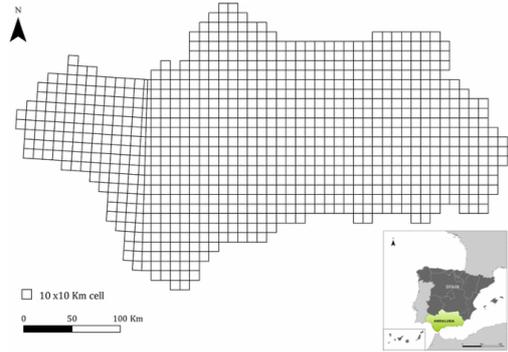


Figura 5. El RMSE medio para 30 pruebas de los modelos de pronóstico con una hora de anticipación con diferentes arquitecturas en las pruebas. Las barras de error indican la desviación estándar de la prueba RMSE de 30 ensayos.

Este estudio desarrolla modelos de Redes Neuronales Bayesianas (BNN) para pronosticar la producción de energía eólica con una hora de anticipación, utilizando técnicas avanzadas para mejorar la precisión de la predicción y manejar la incertidumbre inherente a los datos de entrada limitados. Los modelos BNN se comparan con un Perceptrón Multicapa (MLP) tradicional, mostrando un desempeño competitivo. Se utilizó el método de Determinación Automática de Relevancia (ARD) para identificar y eliminar características irrelevantes, lo que mejoró significativamente el rendimiento del modelo. El estudio sugiere explorar enfoques adicionales en redes neuronales bayesianas [10]

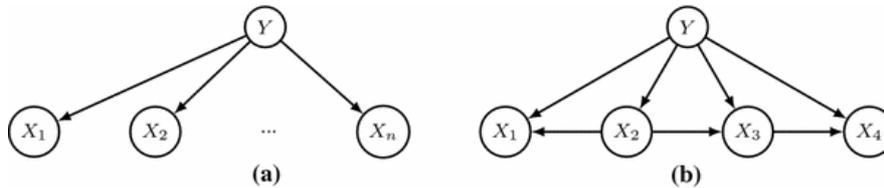
Los gráficos también sugieren que los modelos bayesianos tienden a ser más robustos en el conjunto de pruebas a medida que aumenta la complejidad. Lo que también es interesante es que el modelo de unidad oculta única, que es efectivamente un modelo de regresión logística, funciona relativamente bien con un RMSE medio de 2938.4 kWh en el modelo de BNN de peor rendimiento.

En otro estudio se busca un enfoque innovador utilizando redes neuronales bayesianas para estimar la riqueza de especies terrestres vertebradas en Andalucía, basándose en variables ambientales continuas [11].



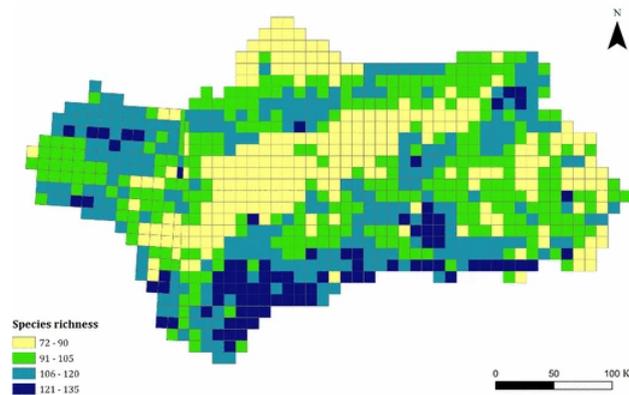
**Figura 6.** Localización de la zona de estudio y la cuadrícula de 10 x 10 km utilizada para calcular las variables explicativas

Se empleó específicamente una red bayesiana de estructura restringida conocida como Tree Augmented Naive Bayes (TAN) para analizar la relación entre la riqueza de especies y diversos predictores ambientales como la heterogeneidad del paisaje, variables climáticas, topográficas y sociales.



**Figura 7.** Estructura de un modelo Bayesiano (a) y de un modelo TAN (b)

Tras construir el modelo TAN con estos predictores, se utilizó para predecir y mapear la riqueza de especies en la región. El rendimiento del modelo TAN se comparó con otros tres métodos de regresión, mostrando que TAN no solo competía en términos de precisión, sino que también maneja adecuadamente las complejidades ecológicas de las relaciones entre la riqueza de especies y el ambiente. Esto destacó la utilidad de las redes bayesianas en la ciencia ambiental, particularmente para comprender y predecir patrones de biodiversidad en base a datos ambientales.



**Figura 8.** Valores estimados de riqueza de especies de vertebrados terrestres

Las redes neuronales bayesianas (BNN) poseen un potencial considerable para el pronóstico y la toma de decisiones en el contexto de la energía eólica. Los modelos desarrollados no solo proporcionan predicciones con una hora de anticipación, sino que también abordan con eficacia la incertidumbre y la heterocedasticidad de los datos eólicos. La integración del método de Determinación Automática de Relevancia Bayesiana (ARD) ha optimizado el rendimiento de los modelos al identificar y excluir características no esenciales. Estos hallazgos sugieren que la adopción de enfoques basados en BNN podría mejorar significativamente la planificación y la operación de parques eólicos.

## 2.3 Estado del arte del uso de Redes Neuronales Convolucionales (CNN) para el procesamiento inteligente de diversos tipos de mapas

### 2.3.1 Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales (CNN) han revolucionado numerosos campos del análisis de datos y la visión por computadora, incluida la cartografía y el análisis espacial, especialmente en el manejo de mapas de distribución de especies. Este tipo de redes se especializa en la interpretación automática de imágenes, lo que las hace ideales para tareas como la clasificación de imágenes de satélite, la detección de características geográficas y la modelización de hábitat. La efectividad de las CNN depende en gran medida de la cantidad y calidad de los datos de entrenamiento. En el contexto de los mapas de aves, esto puede ser un desafío debido a la variabilidad y la calidad de los datos recopilados en diferentes estudios o mediante diferentes metodologías. La capacidad para interpretar correctamente datos espaciales y temporales en mapas complejos es crítica. Las CNN y Deep Redes Neuronales Convolucionales profundas (DCNN) deben ser adaptadas o extendidas con otras técnicas de procesamiento de señales o patrones espaciales para manejar efectivamente estos datos.

### 2.3.2 Procesamiento inteligente de mapas

En un estudio se aborda el desafío de acceder de manera eficaz y precisa a diferentes tipos de mapas en la era digital, un problema persistente a pesar de la abundancia de mapas disponibles. Los esfuerzos previos se han centrado en la comparación y coincidencia a nivel local, pero tales métodos pueden ser limitados ya que las características extraídas de áreas locales del mapa podrían no ser suficientes para caracterizar adecuadamente el contenido completo del mapa.

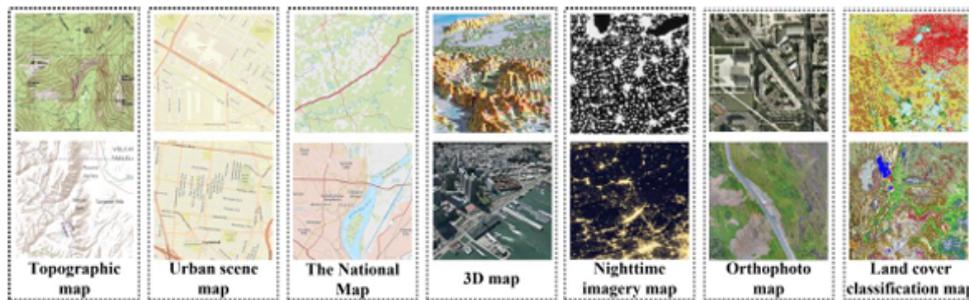


Figura 9. Ilustración de 7 tipos de mapas

Los mapas son fundamentales para entender la configuración de actividades culturales y elementos naturales a través del tiempo y el espacio. Sin embargo, la diversidad y la falta de elementos estándar en los mapas disponibles en línea complican su clasificación y acceso adecuado. La carencia de elementos como títulos o indicadores de dirección en muchos mapas online incrementa la dificultad para interpretar su contenido correctamente [12].

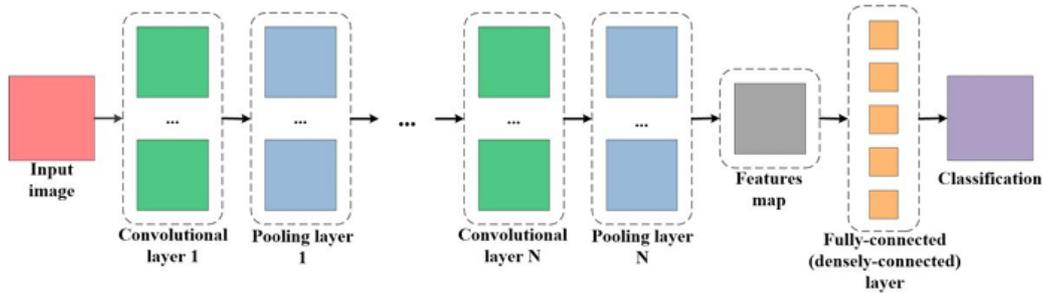


Figura 10. Arquitectura típica para clasificación de tipo de mapa

En este contexto, se expone una investigación sobre el uso de técnicas de aprendizaje profundo, específicamente redes neuronales convolucionales (CNN), para la clasificación automática de siete tipos distintos de mapas, incluyendo mapas topográficos, de terreno, físicos, de escenas urbanas, nacionales, 3D, nocturnos, de ortofotos y de clasificación de cobertura terrestre. Se emplearon diversas arquitecturas de DCNNs, incluyendo AlexNet [13], VGG Net [14], GoogleNet [15], ResNet [16] y Inception-ResNet [17].

CNNs & DCNNs	Experimental results	
	Group 1: 60% data used for training & 40% data used for testing	Group 2: 80% data used for training & 20% data used for testing
AlexNet	71% ~ 78%	77% ~ 83%
VGG Net-19	73% ~ 80%	78% ~ 84%
Inception V4	82% ~ 87%	88% ~ 94%
ResNet V2-152	82% ~ 86%	89% ~ 93%
ResNet-Inception V2	88% ~ 92%	95% ~ 99%

Tabla 2. Diseño experimental y resultados de la comparación de varios métodos de (D)CNN.

Los resultados experimentales revelaron que las CNN y DCNNs de última generación son capaces de clasificar automáticamente estos tipos de mapas con una precisión que varía según el tipo de mapa en cuestión. Esta capacidad para clasificar mapas de manera efectiva podría ser de gran utilidad para la comunidad cartográfica y representa un avance significativo en la aplicación de la inteligencia artificial en el ámbito geográfico (GeoAI), contribuyendo así al desarrollo de nuevas herramientas y metodologías en la disciplina.

Por último, las redes neuronales convolucionales (CNN) se utilizan en el ámbito de los Sistemas de Información Geográfica (SIG) ofrecidos por plataformas como Esri para una variedad de aplicaciones que involucran el procesamiento y análisis de imágenes satelitales y aéreas. A continuación, se detallan algunos ejemplos de cómo las CNN pueden ser aplicadas en los mapas [18].

Las CNN se utilizan para analizar imágenes satelitales y clasificar diferentes tipos de cobertura del suelo, como áreas urbanas, cuerpos de agua, bosques y tierras agrícolas. Esta clasificación ayuda en la planificación urbana, la gestión de recursos naturales y el monitoreo ambiental.

Utilizando imágenes satelitales tomadas en diferentes momentos, las CNN pueden identificar cambios en el paisaje, como la deforestación, la expansión urbana o los cambios en los cuerpos de agua. También son eficaces para detectar y ubicar objetos específicos dentro de imágenes aéreas o satelitales, como vehículos, edificaciones, y otros elementos relevantes para estudios de infraestructura o seguridad.



Figura 11. Ejemplo modelo preentrenado delimitación límites agrícolas

La delimitación de los límites de campos agrícolas tiene múltiples aplicaciones, como la gestión de cultivos, la agricultura de precisión, la planificación del uso del suelo y el seguro agrícola, entre otros. La digitalización manual de campos agrícolas a partir de imágenes es un proceso laborioso y que consume mucho tiempo. Este modelo de aprendizaje profundo automatiza el proceso de extracción de los límites de los campos agrícolas desde imágenes satelitales, reduciendo significativamente el tiempo y el esfuerzo requeridos. Su capacidad para adaptarse a diferentes tipos de cultivos, regiones geográficas y condiciones de imagen lo hace adecuado para operaciones a gran escala.

A continuación, se listan otros ejemplos de modelos comerciales y sus respectivas funciones:

- **Text SAM:** Para detectar objetos en imágenes mediante texto.
- **Detección de coches:** Específico para EE. UU., detecta vehículos en imágenes.
- **Clasificación de cobertura de suelo:** Varias versiones incluyendo alta resolución y datos de Landsat 8 y Sentinel-2.
- **Detección de piscinas:** Orientado a la identificación de piscinas en EE. UU.
- **Segmentación de huellas de incendios:** Clasifica áreas afectadas por incendios.
- **Extracción de carreteras:** Focalizado en Norteamérica.
- **Extracción de masas de agua (SAR):** Específico para EE. UU., detecta cuerpos de agua.
- **Análisis de Daños:** Después de desastres naturales, las CNN pueden analizar rápidamente imágenes aéreas para evaluar los daños a estructuras y infraestructura, proporcionando datos valiosos para las operaciones de respuesta y recuperación.
- **Mejora de Imágenes:** Las CNN también se pueden utilizar para mejorar la resolución de imágenes satelitales, un proceso conocido como super-resolución. Esto es útil para obtener detalles más finos y precisos de áreas específicas sin necesidad de adquirir nuevas imágenes de mayor resolución.

Los modelos preentrenados de ArcGIS facilitan la extracción automática de entidades geográficas de imágenes y datos de nube de puntos. Estos modelos, que han sido entrenados con datos de diversas geografías, están disponibles en ArcGIS [19].

## 2.4 Investigación de casos y estudios que utilizan Redes Neuronales Convolucionales (CNN) y Redes Neuronales Recurrentes Convolucionales (RNN) para la detección y monitorización de aves in-situ.

### 2.4.1 Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales (CNN) surgen como un modelo multicapa inspirado en la neurobiología del córtex visual, que se compone de una o más capas convolucionales seguidas de capas completamente conectadas. Entre estas capas, es posible que existan pasos de submuestreo. Su principal ventaja sobre las DNN tradicionales es su habilidad para escalar efectivamente con datos de entrada multidimensionales y localmente correlacionados, razón por la cual su aplicación más destacada ha sido en el análisis de imágenes.

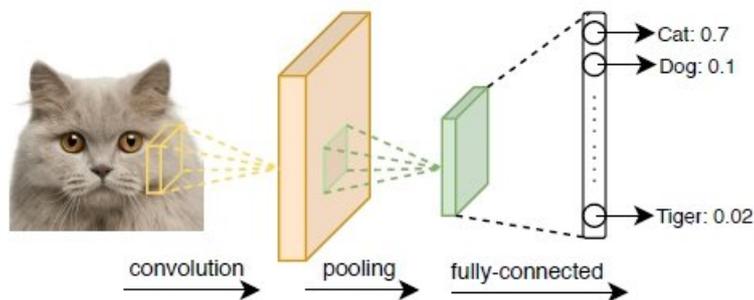


Figura 12. Concepto de red neuronal convolucional (CNN) [20]

Las CNN utilizan filtros de convolución para aprender núcleos dirigidos por datos, lo que, en combinación con funciones de agrupación apropiadas, reduce las características que se suministran a la red completamente conectada para su clasificación. No obstante, el manejo de conjuntos de datos extensos puede presentar desafíos significativos, solucionados a veces mediante el uso de redes escasamente conectadas. Configuraciones populares de CNN incluyen AlexNet, VGGNet y GoogLeNet, las cuales han marcado hitos importantes en el campo de la visión por computadora.

Las CNN son excelentes para reconocer objetos, animales y personas, pero no así la acción que posiblemente se esté dando dentro de la imagen. Esta limitación se debe principalmente a que las CNN están diseñadas para procesar información espacial estática, identificando patrones y características visuales en una instantánea, sin capturar la secuencia temporal o el movimiento que es fundamental para entender acciones o eventos dinámicos. Para abordar tareas que involucran la comprensión de acciones o la secuencia de eventos, como el análisis de videos, se suelen utilizar arquitecturas que integran tanto las CNN para el procesamiento espacial como redes recurrentes (como LSTM o GRU) para capturar la dependencia temporal [21].

### 2.4.2 Redes Neuronales Recurrentes

Por otro lado, las Redes Neuronales Recurrentes (RNN, por sus siglas en inglés) representan una avanzada arquitectura de modelo neuronal, específicamente diseñada para identificar patrones en flujos continuos de información. A diferencia de las redes neuronales de avance (feedforward NN), que procesan la información de manera unidireccional, de la entrada a la salida, las RNN tienen la capacidad de determinar la salida del estado actual basándose en las salidas de estados

anteriores, lo que les otorga una propiedad similar a la ‘memoria’. Esta particularidad es la que les ha conferido una creciente popularidad en diversas disciplinas que manejan datos en streaming, tales como la minería de textos, series temporales y genómica, entre otras [20].

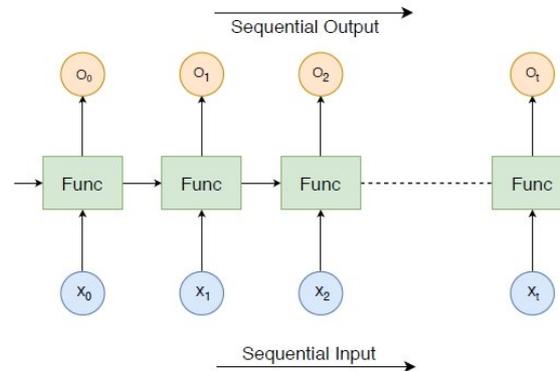


Figura 13. Concepto de red neuronal recurrente (RNN) [20]

Con el transcurso de los años, han surgido variantes importantes de las RNN, como las Redes Neuronales Recurrentes Bidireccionales (BRNN) y las Redes Neuronales de Memoria a Corto y Largo Plazo (LSTM), las cuales han encontrado aplicación en una serie de campos adicionales. Estas innovaciones han contribuido a superar algunos de los problemas de aprendizaje asociados a las RNN, como son los gradientes que tienden a desvanecerse o a explotar, expandiendo así su utilidad más allá de sus aplicaciones originales.

### 2.4.3 Estado de arte

Existen diferentes estudios que abordan el desarrollo e implementación de un sistema tecnológico avanzado para la prevención de colisiones de aves en parques eólicos. Dichos sistemas utilizan un enfoque de visión estereoscópica integrada con computación distribuida y sistemas de Internet de las cosas (IoT) para detectar aves en tiempo real y activar rutinas de evasión que incluyen el uso de disuasivos visuales y sonoros, así como la detención de las turbinas cuando es necesario [26].

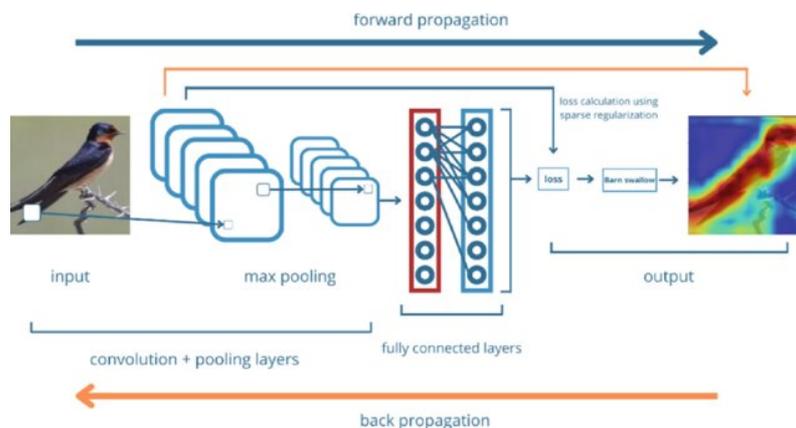


Figura 14. Arquitectura CNN detección de pájaros

Estos sistemas comerciales utilizan CNN para la detección visual, pero con soluciones al problema desde diferentes puntos de vista,

- DT Bird: Especializado en la detección de aves para la protección de parques eólicos, utilizando tecnologías de visión para evitar colisiones [21], se conecta al aerogenerador para reducir su velocidad o pararlo si el ave está en peligro de colisión.



Figura 15. Dispositivo DT-Bird

- SafeWind: de la empresa Biodiv-Wind aplica algoritmos de Inteligencia Artificial a la videodetección de fauna salvaje en el difícil entorno que suponen las inmediaciones de los aerogeneradores en funcionamiento. La detección y el seguimiento de objetivos en movimiento es uno de los principales objetivos del sistema ya que tiene un sistema para detener los aerogeneradores, [22].

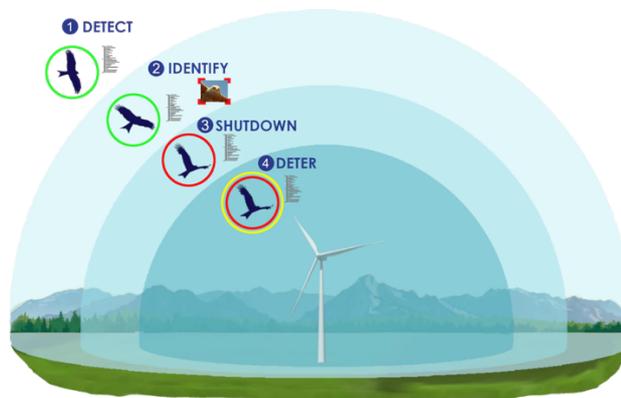


Figura 16. Esquema SafeWing

- IdentiFlight: Combina visión artificial con algoritmos de IA para identificar aves rápidamente y tomar medidas preventivas en tiempo real en un dispositivo alejado de los aerogeneradores permitiendo abarcar más superficie [23].



Figura 17. Dispositivo Identiflight

- BirdVision: Estas compañías también han desarrollado sistemas propios que - emplean tecnologías avanzadas de detección para la protección de aves en instalaciones eólicas [24]
- Airelectronics: Esta empresa ha desarrollado una Red neuronal para la detección de buitres. Esta red permite detectar buitres a la lejanía desde una fuente de video, uso potencial de esta red en la protección de un espacio aéreo. [25].

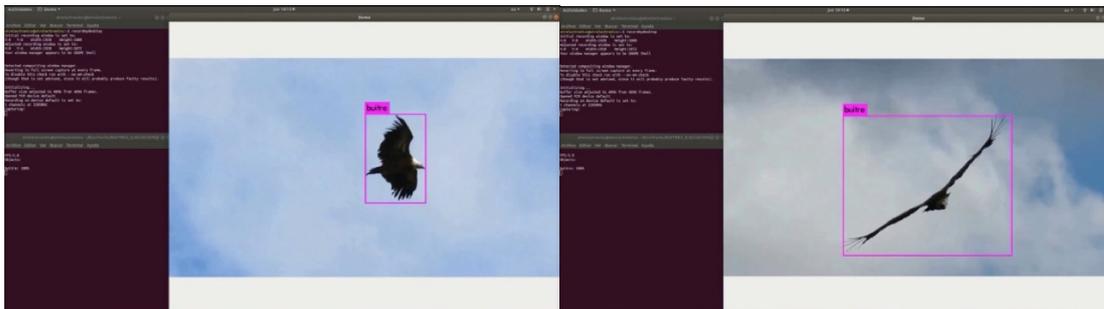


Figura 18. Detección automática buitre negro

Esta tabla resalta las diferencias en la funcionalidad y capacidad de los distintos sistemas.

Method	DT Bird	SafeWind	Identiflight	BirdVision	Airelectronics
Detection method	Monoscopic	Monoscopic	Stereoscopic	Monoscopic	Monoscopic
Distance estimation	No	No	Yes	No	Yes
Localization	No	No	Stereo-vision-based	No	No
Maximum detection range	650 m	-	1500 m	300 m	600 m
Target classification	No	No	Golden & Bald Eagles, Red Kite	No	No
Installation	Wind turbine	Wind turbine	Separate tower	Wind turbine	Wind turbine
Collision prevention	Audio, Turbine stop	Audio, Turbine Stop	Turbine stop	Turbine stop	Audio, Turbine stop

Tabla 2. Comparación soluciones comerciales detección aves en parques eólicos

Por ejemplo, *IdentiFlight* se destaca por su capacidad de estimación de distancia y localización basada en visión estereoscópica, con un rango de detección significativamente mayor y la habilidad de clasificar especies específicas de aves. Además, su instalación en una torre separada puede sugerir una cobertura más amplia y posiblemente un enfoque más enfocado en la detección, comparado con otros sistemas que se montan directamente en las turbinas eólicas, por lo que en el planteamiento de la herramienta para la detección de aves que se está desarrollando se han tenido en cuenta estos aspectos, y se va a optar por la detección con una cámara 360 puesto que está más pensada para llevar un control de la biodiversidad que la protección directa sobre impactos en parques, aunque si los resultados de la investigación son satisfactorios [26] se pretende que sea una herramienta versátil.

Las técnicas basadas en aprendizaje profundo son las más adecuadas para la identificación automática de especies de aves a partir de imágenes capturadas. En este documento, se revisa un estudio con una metodología de identificación de imágenes de aves basada en Redes Neuronales Convolucionales (CNN). Se han utilizado cuatro arquitecturas diferentes basadas en el aprendizaje por transferencia, a saber, *Resnet152V2*, *Inception V3*, *Densenet201* y *MobileNetV2* para la clasificación e identificación de imágenes de aves. Los modelos se entrenaron utilizando 58,388 imágenes pertenecientes a 400 especies de aves, y se probaron con 2,000 imágenes pertenecientes a 400 especies de aves [27].

El estudio aborda la identificación automática de especies de aves utilizando cuatro modelos de aprendizaje por transferencia: *ResNet152V2*, *InceptionV3*, *DenseNet201* y *MobileNetV2*. Estos modelos se seleccionaron por su rendimiento destacado en tareas previas y su amplio uso en la comunidad de aprendizaje profundo.

*DenseNet201*: Este modelo de extracción de características es una red neuronal convolucional de 201 capas que se destaca por su eficiente flujo de gradientes y su habilidad para extraer múltiples características. Aunque su entrenamiento es más lento debido a su densa conectividad, tiende a ofrecer una mayor precisión.

*ResNet152V2*: Utiliza el concepto de bloques residuales para evitar el problema de los gradientes desvanecientes y emplea conexiones de salto que omiten algunas capas para mejorar el rendimiento. Este modelo preentrenado proporciona una alta precisión en un tiempo menor en comparación con CNN tradicionales.

*InceptionV3*: Es un modelo de aprendizaje profundo para la clasificación de imágenes basado en CNN que alcanza una precisión mayor al 78.1% en conjuntos de datos de imágenes. Compuesto por bloques simétricos y asimétricos, utiliza el enfoque de aprendizaje por transferencia y presenta una estructura que incluye capas de convolución, agrupamiento y conexión completa.

*MobileNetV2*: Este modelo ligero es adecuado para dispositivos móviles y se basa en una estructura residual. Cuenta con capas convolucionales iniciales seguidas de capas residuales tipo bottleneck y puede clasificar imágenes en aproximadamente 1000 categorías de objetos.

## Entrenamiento

Cada modelo fue entrenado en Google Colab añadiendo capas de entrada y salida al modelo junto con una capa de agrupamiento global promedio antes de la capa de salida, que reduce las dimensiones para facilitar el entrenamiento. Se aceptan imágenes de dimensiones (300x300x3) y la capa de salida tiene 400 nodos para 400 especies. Los modelos tienen una conectividad densa y todas las capas están congeladas para reducir el tiempo de entrenamiento, utilizando

una función de activación SoftMax y una tasa de aprendizaje de 0.01. Se decidió entrenar los modelos por 15 épocas para asegurar una evaluación justa y resultados imparciales.

De estos cuatro modelos, Resnet152V2 y DenseNet201 tuvieron un rendimiento comparativamente bueno. La precisión de Resnet152V2 fue la más alta con un 95.45%, pero enfrentó una gran pérdida de 0.8835. Sin embargo, basándose en los resultados, aunque DenseNet201 tuvo una precisión del 95.05%, enfrentó menos pérdida, es decir, 0.6854. Los resultados muestran que DenseNet201.

En cuanto a la detención de las aspas todas las soluciones incluyen la parada del aerogenerador u otras, también le suman un sistema de audio para ahuyentar, lo que les convierte en soluciones interesantes que explorar y sobre las que comenzar a trabajar en nuestro sistema.

Por último, hay que destacar que las CNN se utilizan para la identificación automática de especies de aves mediante señales de audio. Este proceso comienza con la grabación de sonidos de aves en exteriores, seguida de técnicas de preprocesamiento de audio para mejorar la calidad de la señal y eliminar el ruido. Se extraen características del audio procesado que luego se alimentan a una CNN para la clasificación. Este método facilita el monitoreo de aves y apoya la conservación, al reducir significativamente el esfuerzo y tiempo necesarios para la identificación manual de especies. Este enfoque también mejora la exactitud en comparación con métodos tradicionales, permitiendo una detección más fiable y eficiente para estudios de biodiversidad y conservación ambiental [28], en este sentido, durante la siguiente anualidad se estudiarán diferentes métodos para la detección automática e identificación de aves a través de audio.

### 3 Conclusión

La investigación presentada subraya la importancia crítica del uso de herramientas de inteligencia artificial (IA), particularmente de redes neuronales convolucionales (CNN), en la planificación estratégica y la gestión de parques eólicos, así como en estudios de biodiversidad y conservación.

La integración de modelos de IA y la cartografía avanzada se identifica como fundamental para la optimización de la energía eólica. Los mapas detallados y los modelos predictivos ayudan en la identificación de sitios potenciales para la ubicación de turbinas, maximizando la producción energética y minimizando el impacto ambiental y los costos. Además, las evaluaciones de los recursos eólicos basadas en IA permiten considerar la variabilidad del clima y otros factores ambientales que influyen en la producción de energía, mejorando la precisión de las predicciones y facilitando un diseño de parque eólico más eficiente.

El uso de CNN en la detección visual de aves en parques eólicos demuestra ser una aplicación comercial valiosa que equilibra la necesidad de energía renovable con la protección ambiental. Las CNN permiten una identificación y seguimiento precisos de las aves en tiempo real, activando medidas de mitigación, como la parada de turbinas o la emisión de señales de audio para evitar colisiones. Este enfoque proactivo no solo preserva la fauna local sino que también cumple con regulaciones ambientales y satisface las preocupaciones de los stakeholders en términos de conservación de especies.

En cuanto a la biodiversidad, los modelos de IA ofrecen un análisis profundo y comprensión de la distribución y la riqueza de las especies. Permiten integrar y analizar grandes volúmenes de datos de biodiversidad, que, junto con mapas de alta resolución, facilitan la identificación de áreas críticas para la conservación y ayudan a planificar proyectos eólicos que respeten la vida silvestre y los hábitats naturales.

En conclusión, el uso estratégico y sinérgico de modelos de IA y mapas avanzados está revolucionando el campo de la energía eólica y la conservación de la biodiversidad. Al integrar estas herramientas, no solo se optimizan los recursos eólicos y se minimiza el impacto ambiental, sino que también se fomenta una coexistencia sostenible y responsable entre la generación de energía renovable y la preservación de la biodiversidad. El progreso en la detección visual y automática de aves mediante CNN y otros modelos de IA, evidencia el potencial transformador de estas tecnologías para la protección ambiental y la gestión de recursos naturales, apuntando hacia un futuro más sostenible y respetuoso con el ecosistema.

## 4 Referencias bibliográficas

- [1]. CORTES-PEREZ, Danitza María; SIERRA-VARGAS, Fabio Emiro y ARANGO-GOMEZ, Jorge Eduardo. Evaluación, predicción y modelación del potencial eólico. Ingeniería Mecánica [online]. 2016, vol.19, n.3, pp.167-175. ISSN 1815-5944.
- [2]. Elkinton CN, Manwell JF, McGowan JG. Algorithms for Offshore Wind Farm Layout Optimization. *Wind Engineering*. 2008;32(1):67-84.
- [3]. Feng, J.; Shen, W.Z.; Li, Y. An Optimization Framework for Wind Farm Design in Complex Terrain. *Appl. Sci*. 2018, 8, 2053
- [4]. Mortensen, N. G. (2020). Wind resource assessment using WAsP software.
- [5]. Song, M. X., Chen, K., He, Z. Y., & Zhang, X. (2013). Bionic optimization for micro-siting of wind farm on complex terrain. *Renewable Energy*, 50, 551-557.
- [6]. Laura Dempsey y Cris Hein. Modelos de riesgo de colisión: una herramienta para evaluar los riesgos para las aves rapaces en instalaciones de energía eólica. 2022. FORO DE EXPERTOS WREN
- [7]. [https://www.miteco.gob.es/es/calidad-y-evaluacion-ambiental/temas/evaluacion-ambiental/zonificacion\\_ambiental\\_energias\\_renovables.html](https://www.miteco.gob.es/es/calidad-y-evaluacion-ambiental/temas/evaluacion-ambiental/zonificacion_ambiental_energias_renovables.html)
- [8]. Fissaha Y, Ikeda H, Toriya H, Adachi T, Kawamura Y. Application of Bayesian Neural Network (BNN) for the Prediction of Blast-Induced Ground Vibration. *Applied Sciences*. 2023; 13(5):3128.
- [9]. Zhan, X.; Qin, H.; Liu, Y.; Yao, L.; Xie, W.; Liu, G.; Zhou, J. Variational Bayesian Neural Network for Ensemble Flood Forecasting. *Water* 2020,
- [10]. R. Mbuva, M. Jonsson, N. Ehn y P. Herman, "Redes neuronales bayesianas para la previsión de energía eólica de una hora", 2017 IEEE 6a Conferencia Internacional sobre Investigación y Aplicaciones de Energías Renovables (ICRERA), San Diego, CA, EE. UU., 2017, pp. 591-596,
- [11]. Maldonado, A.D., Roper, R.F., Aguilera, P.A. et al. Continuous Bayesian networks for the estimation of species richness. *Prog Artif Intell* 4, 49–57 (2015). <https://doi.org/10.1007/s13748-015-0067-8>
- [12]. Zhou, X., Li, W., Arundel, S. T., & Liu, J. (2018). Deep convolutional neural networks for map-type classification. *arXiv preprint arXiv:1805.10402*.
- [13]. Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105)
- [14]. Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for largescale image recognition. *arXiv preprint arXiv:1409.1556*.
- [15]. Szegedy, C., et al (2015, June). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-5).
- [16]. He, K., et al. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer vision and Pattern Recognition*
- [17]. Szegedy, C., et al (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In *AAAI* (Vol. 4, p. 12).
- [18]. <https://www.esri.es/es-es/home>
- [19]. <https://doc.arcgis.com/es/pretrained-models/latest/get-started/intro.htm>
- [20]. <https://viso.ai/deep-learning/deep-neural-network-three-popular-types/>
- [21]. <https://www.dtbird.com/index.php/es/>
- [22]. <https://www.biodiv-wind.com/safewind/>
- [23]. <https://www.identiflight.com>
- [24]. <https://birdvision.org>

- [25]. [http://www.airelectronics.es/products/neural\\_network/net\\_vulture/](http://www.airelectronics.es/products/neural_network/net_vulture/)
- [26]. Gradolewski, D.; Dziak, D.; Martynow, M.; Kaniecki, D.; Szurlej-Kielanska, A.; Jaworski, A.; Kulesza, W.J. Comprehensive Bird Preservation at Wind Farms. *Sensors* 2021, 21, 267.
- [27]. R, Dharaniya & M, Preetha & S, Yashmi. (2022). Bird Species Identification Using Convolutional Neural Network. 10.3233/APC220053.
- [28]. S. Bhor, R. Ganage, O. Domb, H. Pathade y S. Khedkar, "Identificación automatizada de especies de aves mediante procesamiento de señales de audio y red neuronal", *Conferencia Internacional sobre Electrónica y Sistemas Renovables de 2022 (ICEARS)*, Tuticorin, India, 2022, pp. 335-339