



Universidad Europea

UNIVERSIDAD EUROPEA DE MADRID

ESCUELA DE ARQUITECTURA, INGENIERÍA Y DISEÑO

GRADO EN FÍSICA

TRABAJO DE FIN DE GRADO

**DETECCIÓN DE GALAXIAS MEDIANTE EL EFECTO
LENTE GRAVITATORIA EN MAPAS DE LA MISIÓN
ESPACIAL EUCLID CON TÉCNICAS DE APRENDIZAJE
PROFUNDO**

DIEGO SANTAMARÍA VILLEGAS

Dirigido por

Dr. MARCOS LÓPEZ CANIEGO ALCARRIA

CURSO 2024-2025

TÍTULO: DETECCIÓN DE GALAXIAS MEDIANTE EL EFECTO LENTE GRAVITATORIA
EN MAPAS DE LA MISIÓN ESPACIAL EUCLID CON TÉCNICAS DE APRENDIZAJE PRO-
FUNDO

AUTOR: : DIEGO SANTAMARÍA VILLEGAS

TITULACIÓN: GRADO EN FÍSICA

DIRECTOR/ES DEL PROYECTO: : Dr. MARCOS LÓPEZ CANIEGO ALCARRIA

FECHA: Junio de 2025

RESUMEN

La misión *Euclid*, un proyecto de la Agencia Espacial Europea (ESA), tiene como objetivo principal investigar la naturaleza de la materia oscura y la energía oscura, así como cartografiar la estructura del universo a gran escala. Lanzada en 2023, se espera que genere aproximadamente 25 petabytes de datos astronómicos durante su operación. Este volumen masivo de datos presenta un desafío significativo para su análisis, requiriendo métodos automatizados avanzados para detectar lentes gravitatorias, clasificar galaxias morfológicamente o localizar objetos con alto desplazamiento al rojo. Estos fenómenos son clave para estudiar el universo, pero los enfoques tradicionales, basados en análisis espectroscópicos, fotometría y algoritmos semi-automatizados de procesamiento de imágenes, resultan ineficientes ante este desafío por su complejidad.

En este trabajo se han propuesto distintas soluciones basadas en aprendizaje profundo para abordar algunos de los problemas científicos de la misión *Euclid*. En concreto, se han desarrollado tres modelos: uno para detectar lentes gravitatorias fuertes, otro para clasificar galaxias en cuatro categorías morfológicas (elíptica, espiral, espiral barrada e irregular), y un tercero para identificar candidatos a objetos con alto desplazamiento al rojo. Estos modelos utilizan versiones preentrenadas de YOLO (You Only Look Once), un modelo de aprendizaje profundo conocido por detectar objetos en imágenes en tiempo real con alta precisión. El uso de YOLO simplifica el diseño de redes neuronales, haciendo el aprendizaje profundo accesible a usuarios sin experiencia avanzada. Parte del proyecto se realizó procesando imágenes de *Euclid* en un entorno Linux, empleando herramientas como SExtractor y Aladin para generar y validar datos.

Los resultados demuestran una alta precisión en la detección y clasificación de patrones característicos, superando las limitaciones de los métodos tradicionales. Este trabajo establece una base sólida para futuras investigaciones en el análisis automatizado de imágenes astronómicas.

Palabras clave: YOLO, lentes gravitatorias, clasificación morfológica, alto desplazamiento al rojo, *Euclid*

ABSTRACT

The *Euclid* mission, led by the European Space Agency (ESA), seeks to unravel the mysteries of dark matter and dark energy while mapping the universe's large-scale structure. Launched in 2023, it's projected to produce around 25 petabytes of astronomical data throughout its operation. Handling this enormous volume of data poses a major challenge, requiring cutting-edge automated techniques to identify gravitational lenses, classify galaxy shapes, and pinpoint high-redshift objects. These phenomena are vital for understanding the cosmos, yet traditional methods like spectroscopic analysis, photometry, and semi-automated image processing struggle to keep up due to their complexity.

To tackle some of the scientific challenges of the *Euclid* mission, this study proposes several deep learning solutions. Three models were developed: one to detect strong gravitational lenses, another to classify galaxies into four morphological types (elliptical, spiral, barred spiral, and irregular), and a third to spot potential high-redshift objects. These models rely on pre-trained versions of YOLO (You Only Look Once), a deep learning model known for its fast and accurate object detection in images. YOLO's straightforward approach to neural network design makes deep learning approachable, even for those without extensive expertise. Part of the project involved analyzing *Euclid* images in a Linux setup, using tools like SExtractor and Aladin to create and verify data.

The results show high accuracy in both detection and classification tasks, surpassing the limitations of traditional methods. This work lays a solid foundation for future research in the automated analysis of astronomical images.

Keywords: YOLO, gravitational lenses, morphological classification, high redshift, *Euclid*

Non est ad astra mollis e terris via

TABLA RESUMEN

	DATOS
Nombre y apellidos:	DIEGO SANTAMARÍA VILLEGAS
Título del proyecto:	DETECCIÓN DE GALAXIAS MEDIANTE EL EFECTO LENTE GRAVITATORIA EN MAPAS DE LA MISIÓN ESPACIAL EUCLID CON TÉCNICAS DE APRENDIZAJE PROFUNDO
Directores del proyecto:	Dr. MARCOS LOPEZ CANIEGO ALCARRIA
El proyecto se ha realizado en colaboración de una empresa o a petición de una empresa:	NO
El proyecto ha implementado un producto:	NO
El proyecto ha consistido en el desarrollo de una investigación o innovación:	SI
Objetivo general del proyecto:	DETECCIÓN DEL EFECTO LENTE GRAVITACIONAL

Índice de figuras

1.	Regiones de interés que <i>Euclid</i> cartografiará a lo largo de los años.	17
2.	Imagen del cúmulo de Perseo tomada por <i>Euclid</i>	18
3.	Diagrama del funcionamiento del efecto lente gravitacional.	19
4.	Ilustración de un sistema de lente gravitacional. La luz se propaga desde la fuente S hasta el observador O, y es desviada un ángulo $\hat{\alpha}$. La imagen que ve el observador es I.	20
5.	Diagrama de Hubble - De Vaucouleurs	23
6.	Tipos de galaxias elípticas	24
7.	Tipos de galaxias lenticulares	25
8.	Tipos de galaxias espirales según familia y etapa	26
9.	Galaxias espirales SA, SAB y SB con etapas intermedias	27
10.	Tipos de galaxias espirales según su variedad	27
11.	Tipos de galaxias irregulares	28
12.	Arquitectura típica de una CNN	31
13.	Zoom en una región de la imagen FITS del cúmulo de Perseo, visualizada con Aladin.	33
14.	Fragmento inicial del catálogo generado con SExtractor del cúmulo de Perseo.	34
15.	Proceso de creación de catálogos a partir de una imagen FITS, incluyendo la subdivisión, creación de catálogos, combinación de los catálogos y filtrado.	34
16.	Catálogo de galaxias superpuesto a imagen FITS en Aladin. Zoom en zona verde con galaxias detectadas.	37
17.	Misma galaxia: (1) con ajuste lineal; (2) ajuste logarítmico sin cota; (3) ajuste logarítmico acotado.	39
18.	Etiquetado de imagen con el software LabelImg.	41
19.	Esquematación de las carpetas para el entrenamiento de YOLO.	42
20.	Candidatos a lente gravitacional fuerte publicados por la ESA	46
21.	Etiquetado (4×4 izquierda) y predicción (4×4 derecha) del modelo lentev1.	47
22.	Zoom en la región de Abell 2390 donde hay arcos.	48
23.	A la izquierda detecciones incorrectas del modelo. A la derecha, detección correcta del arco.	48
24.	Predicción correcta del modelo sobre los arcos a distintas resoluciones.	49
25.	Anillo de Einstein alrededor del centro de la galaxia NGC 6505	50
26.	Detección correcta del modelo sobre el anillo de Einstein.	50
27.	Predicción del modelo lentev5 con etiquetas sobre recortes del cúmulo Abell 2390.	51
28.	Candidatos a lente fuerte identificados por lentev5, presentes en el artículo . Recortes generados a partir de la imagen FITS del cúmulo Abell 2390 y su correspondiente catálogo.	52

29.	Matriz de confusión del modelo train18. El eje x corresponde a la clase real y el eje y a clase predicha por el modelo.	53
30.	Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo train18.	53
31.	Distribución de clases en el dataset.	54
32.	Métricas generales de los modelos train18, train21 y train22.	55
33.	Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo train22.	55
34.	Etiquetado erróneo (2×2 izda) de la clase estrella. Predicción del modelo (2×2 dcha).	56
35.	Comparación de métricas generales de train18, train21, train22, train27.	56
36.	Comparación de métricas por clase de train18, train21, train22, train27.	56
37.	Etiquetado (6×2 izquierda) y predicción (6×2 derecha) del modelo train27.	57
38.	Comparación morfológica de galaxias espirales (izda) y espirales barradas (dcha). Recortes generados a partir del catálogo generado con SExtractor y la imagen FITS mediante un script en Python.	59
39.	Etiquetado (4×2 izquierda) y predicción (4×2 derecha) del modelo train27_espiral.	61
40.	Métricas generales del modelo train27, train27_espiral y train27_espiral5.	61
41.	Métricas por clase del modelo train27, train27_espiral y train27_espiral5.	62
42.	Etiquetado (4×2 izquierda) y predicción (4×2 derecha) del modelo train27_espiral5.	63
43.	Recortes sin cota de brillo (arriba) y con cota de brillo (abajo).	63
44.	Ejemplo de etiquetado en diferentes recortes.	64
45.	Métricas de desempeño generales del modelo train3v2 frente a train1v2 y train2v2.	66
46.	Métricas de desempeño por clase del modelo train3v2 frente a train1v2 y train2v2.	67
47.	Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo.	67
48.	Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo.	68
49.	Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo.	68
50.	Ejemplos de posibles candidatos en un recorte del cúmulo de Perseo.	69
51.	Predicción a diferentes umbrales de confianza: (1) $conf=0.3$; (2) $conf=0.25$	69
52.	Mosaico de candidatos detectados en diferentes recortes del cúmulo Abell 2390.	70
53.	Lentes fuertes presentes en Abell 2390 no detectadas por el modelo lentev5.	71

Índice de tablas

1.	Métricas de desempeño del modelo lentev1.	47
2.	Métricas de desempeño generales y por clase del modelo train18.	52
3.	Métricas de desempeño generales y por clase del modelo train21.	54
4.	Métricas de desempeño generales y por clase del modelo train27_espiral.	60
5.	Métricas de desempeño generales y por clase del modelo train1v2.	65
6.	Métricas de desempeño generales y por clase del Modelo train2v2.	66

Índice

Índice de figuras	6
Índice de tablas	8
1. INTRODUCCIÓN / ESTADO DEL ARTE	11
1.1. Estado del arte	11
1.2. Contexto y justificación	12
1.3. Planteamiento del problema	13
2. OBJETIVOS	15
2.1. Objetivos generales	15
2.2. Objetivos específicos	15
2.3. Beneficios del proyecto	15
3. MARCO TEÓRICO	17
3.1. Misión <i>Euclid</i>	17
3.1.1. Cúmulo de Perseo	17
3.2. Efecto lente gravitacional	19
3.2.1. Principio de funcionamiento	20
3.2.2. Clasificación del efecto lente	21
3.2.3. Dinámica de Fluidos en un Universo en Expansión	21
3.3. Cúmulos de galaxias	22
3.4. Tipos de galaxias	23
3.4.1. Galaxias elípticas	23
3.4.2. Lenticulares	24
3.4.3. Espirales	25
3.4.4. Irregulares	27
3.5. Objetos lejanos	28
3.6. Redes Neuronales Convolucionales (CNNs)	30
4. DESARROLLO	32
4.1. Planificación del trabajo fin de grado	32
4.2. SExtractor	33
4.3. YOLO (You Only Look Once)	37
4.3.1. Selección del modelo YOLO	37
4.3.2. Configuración de YOLO	40
4.3.3. Estructura del Conjunto de Datos para el Entrenamiento	42
4.3.4. Archivo de configuración	42
4.3.5. Entrenamiento	43
4.3.6. Métricas de entrenamiento	44

4.4. Resultados del TFG	45
5. RESULTADOS	46
5.1. Modelo de detección de lentes gravitacionales	46
5.2. Modelo de clasificación morfológica de galaxias	52
5.2.1. Modelo de 5 clases	52
5.2.2. Modelo de 6 clases	59
5.2.3. Modelo de 3 clases	64
5.2.4. Modelo de 4 clases	65
5.3. Modelo de detección de candidatos a objetos más antiguos del universo	68
6. DISCUSIÓN	71
6.1. Limitaciones del trabajo	71
6.2. Cambios respecto a los objetivos originales.	72
6.3. Impacto de los resultados	73
7. CONCLUSIONES	74
7.1. Conclusiones del trabajo	74
7.2. Conclusiones personales	74
8. FUTURAS LÍNEAS DE TRABAJO	76
Referencias	77
9. ANEXOS	81
9.1. Resultados adicionales	81
9.2. Códigos	81
9.3. Declaración de uso de IA	82

1. INTRODUCCIÓN / ESTADO DEL ARTE

1.1. Estado del arte

La detección y estudio de galaxias lejanas mediante el efecto lente gravitatoria es una de las áreas de estudio con más actividad en astrofísica. Este fenómeno, predicho por la teoría de la relatividad general de A. Einstein, permite estudiar la distribución de masa en el universo, incluida la materia oscura, a partir de la desviación de la luz emitida por objetos lejanos cuando atraviesa el campo gravitatorio de estructuras masivas en la línea de visión entre el observador y los objetos lejanos [1]. En particular, la lente gravitacional fuerte puede generar múltiples imágenes, arcos o anillos de Einstein, mientras que la lente débil induce distorsiones sutiles en la forma de las galaxias de fondo, cuyo estudio estadístico ayuda a conocer como se distribuye la materia y energía en el universo [2]. Estas técnicas se han consolidado como herramientas fundamentales para cartografiar el contenido y la geometría del universo, proporcionando evidencia directa de la materia oscura y de la evolución estructural a gran escala.

En las primeras etapas de la búsqueda de lentes gravitacionales en el universo, los astrónomos se basaron principalmente en la inspección visual de imágenes y en el análisis espectroscópico de galaxias que podrían estar actuando como lentes [3]. Aunque estos métodos permitieron hacer los primeros descubrimientos, tenían importantes limitaciones: eran procesos largos, susceptibles a errores humanos y, a menudo, ineficientes. Sin embargo, la espectroscopía tiene la ventaja de poder identificar tanto la galaxia que actúa como lente como la fuente lejana al mismo tiempo, gracias a la detección de líneas de emisión con diferentes desplazamientos al rojo [3]. Esto permitía encontrar lentes que no eran evidentes en las imágenes fotométricas habituales, ya sea porque eran poco luminosas o porque estaban muy cerca angularmente de la fuente .

El auge de grandes campañas de observación, como el *Square Kilometer Array* (SKA), el *Vera C. Rubin Observatory* (previamente llamado LSST), el *Roman Space Telescope* de la NASA o la misión *Euclid* de la ESA están impulsando el desarrollo de técnicas automatizadas para el análisis de datos astronómicos. Aunque algunos de estos proyectos aún están en fase de construcción o desarrollo, otros ya han comenzado a operar, y todos ellos generarán volúmenes de datos cada vez mayores. Esto hace evidente que los métodos tradicionales, incluso los semiautomáticos, resultan insuficientes para procesar la información de manera eficiente. En particular, la identificación de lentes gravitacionales, objetos escasos pero de gran relevancia científica, requiere detectar casos excepcionales entre decenas de millones de imágenes [4].

Para afrontar este desafío, se están implementando enfoques automáticos basados en el procesamiento de imágenes y algoritmos avanzados, como máquinas de vectores de soporte (SVM) o redes neuronales convolucionales (CNNs) [4]. Estos métodos permiten no solo acelerar el análisis de grandes conjuntos de datos, sino también reducir significativamente el número de falsos positivos en comparación con la inspección visual humana. No obstante, lograr una detección eficaz exige entrenar estos algoritmos con datos simulados lo más realistas posible, así como contar con observaciones multibanda, que han demostrado ser especialmente útiles para distinguir entre

lentes reales y galaxias anulares o irregulares que pueden producir señales similares [4].

En astronomía, el aprendizaje profundo se introdujo en años recientes como una posible solución para este reto. Las CNNs muestran un buen rendimiento en tareas como la detección de lentes gravitacionales fuertes o la clasificación morfológica de galaxias. En campañas de observación como el *Canada-France-Hawaii Telescope Legacy Survey* (CFHTLS) o el *Kilo-Degree Survey* (KiDS), por ejemplo, se aplicaron CNNs para detectar candidatos a lentes fuertes y obtuvieron una precisión superior a los métodos habituales [5]. Modelos más recientes como YOLO (You Only Look Once), basados también en CNNs, destacan por su rapidez y eficacia en la detección de objetos [6].

La detección manual de objetos de alto desplazamiento al rojo es otro proceso lento y propenso a errores, especialmente considerando el volumen de datos que generan los telescopios modernos. Aquí es donde entra la automatización mediante redes neuronales, como YOLO. Aunque no se encontraron estudios específicos sobre el uso de modelos preentrenados de YOLO para galaxias de alto desplazamiento al rojo, su aplicación en contextos relacionados, como la detección de cúmulos de galaxias, sugiere su potencial. Por ejemplo, el modelo YOLO-DG [7], basado en la arquitectura de YOLOv7, ha sido utilizado para detectar galaxias enanas en imágenes del *DESI Legacy Imaging Surveys*, enfocándose en objetos con desplazamientos al rojo bajos, generalmente menores a 0.1. Este éxito indica que YOLO podría ser entrenado para identificar objetos de alto desplazamiento al rojo basándose en características como su color rojo extremo.

Todos los datos astronómicos que se van a utilizar en este trabajo provienen de la misión *Euclid*. La misión *Euclid* es un proyecto espacial diseñado para investigar la causa de la expansión acelerada del Universo [8]. Su objetivo principal es estudiar la energía oscura, la materia oscura y la gravedad mediante observaciones del cosmos a gran escala. Para ello, utiliza dos técnicas clave: lente gravitacional débil (WL) y oscilaciones acústicas de bariones (BAO). El efecto lente débil permite cartografiar la materia oscura observando las distorsiones en la forma de las galaxias mientras que las BAO miden patrones en la distribución de galaxias para calcular la expansión del Universo. *Euclid* estudiará la estructura cósmica de los últimos 10 mil millones de años, abarcando más del 75 % de la edad del Universo [8].

Los datos de *Euclid* son ideales para estudiar el efecto de lente gravitatoria, pero su gran volumen plantea retos significativos en el procesamiento y análisis.

1.2. Contexto y justificación

La creación de métodos automatizados para detectar galaxias mediante el efecto de lente gravitatoria en imágenes de la misión *Euclid* es necesario. *Euclid* será capaz de derivar la función de masa de cúmulos de galaxias y a partir de ello se podrán encontrar más de 300.000 sistemas de lente fuerte, además de analizar más de mil millones de galaxias para estudiar el efecto de lente débil [8]. La gran cantidad de información que *Euclid* dará sobrepasa las capacidades de análisis de los métodos convencionales. Por esta razón, se justifica la exploración de técnicas de aprendizaje

profundo para analizar estas imágenes de forma eficaz y con precisión.

Por otra parte, la clasificación morfológica de galaxias desempeña un papel crucial en la comprensión de su formación y evolución. Las imágenes de alta calidad de *Euclid* permiten catalogar con gran claridad a las galaxias en clases como elípticas, espirales, espirales barradas o irregulares. Sin embargo, debido al gran volumen de datos, hacer esta tarea de forma manual es imposible. Esto refuerza la importancia de desarrollar modelos automatizados.

La principal ventaja de los métodos propuestos en este trabajo se basan en su capacidad para identificar rápidamente candidatos a lentes gravitatorias, clasificar galaxias e identificar candidatos a objetos más antiguos del universo.

La contribución de este trabajo al campo de estudio es triple. Por un lado, se ha desarrollado un modelo de cajas orientadas basado en YOLOv11-obb para detectar el efecto de lente gravitatoria fuerte en imágenes de *Euclid*. En este caso, las "cajas orientadas" consisten en regiones de interés definidas no solo por su ancho y alto (como en las cajas rectangulares convencionales de YOLO), sino también por un ángulo de rotación que permite ajustarse exactamente a la forma y orientación curvada de los arcos gravitatorios.

También se han implementado modelos para clasificar galaxias morfológicamente, optimizando su rendimiento con técnicas de preprocesamiento. Finalmente, se ha entrenado un modelo capaz de detectar objetos que, por su color, podrían presentar un alto grado de desplazamiento al rojo. Se espera que aquellas fuentes cuyo color tienda hacia los tonos más rojizos sean identificadas como candidatas a ser los objetos más antiguos del universo, donde sus espectros podrían estar altamente desplazados hacia el infrarrojo. En el futuro, este sistema podría permitir filtrar y analizar automáticamente grandes volúmenes de datos y seleccionar con eficiencia los candidatos de mayor interés cosmológico.

1.3. Planteamiento del problema

El análisis del estado del arte muestra que, pese a los avances en aprendizaje profundo, siguen habiendo desafíos en la detección de objetos astronómicos específicos. Los efectos de lente gravitacional y los candidatos a objetos más antiguos del universo requieren una identificación precisa de características visuales sutiles y variaciones de color. A ello se suman las particularidades propias de las imágenes astronómicas, como el ruido del propio instrumento de medición, la variabilidad lumínica o la baja relación señal/ruido en objetos de pequeño tamaño.

Muchos estudios recientes han optado por diseñar modelos desde cero, adaptando específicamente las arquitecturas de redes neuronales a las características físicas del problema. En el caso de la detección de lentes gravitatorias, se han modificado CNNs para ajustarlas a parámetros que describen las lentes gravitacionales, con el objetivo de maximizar la precisión en la identificación de deformaciones características o patrones, como en el artículo [9]. En cuanto a la detección de lentes fuertes, las arquitecturas más populares que se han usado para encontrarlas son *EfficientNet*, *DenseNets* y *ResNet* [10]. De forma similar, en clasificación morfológica, en algunas investi-

gaciones se han desarrollado arquitecturas personalizadas capaces de inferir parámetros como el índice de Sérsic o la distribución de luminosidad superficial de las galaxias [11]. Aunque estos enfoques permiten una adaptación muy precisa al problema, también requieren un alto nivel de especialización y un esfuerzo considerable en el diseño y entrenamiento del modelo.

En este trabajo, en cambio, se ha evaluado la eficacia de modelos preentrenados de alto rendimiento como YOLOv11. Para ello, se ha optado por realizar un etiquetado manual de imágenes que permita adaptar la red a tareas específicas como la detección de lentes fuertes o la clasificación morfológica. De este modo, se evita el complejo proceso de diseño desde cero, aprovechando una arquitectura ya optimizada para la detección rápida y precisa de objetos en imágenes, lo que facilita la implementación y acelera los tiempos de desarrollo sin renunciar a un alto rendimiento.

Se plantea, por tanto, la falta de una solución automatizada y accesible que combine precisión, escalabilidad y facilidad de implementación. Este trabajo busca explorar esta carencia mediante la evaluación de modelos preentrenados de detección aplicados a datos astronómicos reales obtenidos de la misión espacial *Euclid*. Los modelos se han adaptado para identificar con precisión lentes gravitatorias fuertes, distintas morfologías en galaxias y detectar objetos con alto desplazamiento al rojo. De esta forma, se elimina la necesidad de diseñar arquitecturas desde cero y se proporciona una herramienta práctica, eficiente y reproducible para el análisis de grandes volúmenes de datos en astronomía.

2. OBJETIVOS

2.1. Objetivos generales

El objetivo general del presente trabajo es aplicar y evaluar modelos de aprendizaje profundo, partiendo de arquitecturas preentrenadas y adaptándolas mediante fine-tuning, para la detección de efectos de lente gravitatoria fuerte, la clasificación morfológica automatizada de galaxias y la identificación de candidatos a alto desplazamiento al rojo en imágenes astronómicas de la misión *Euclid*.

2.2. Objetivos específicos

Para cumplir con el objetivo general, se han establecido los siguientes objetivos específicos:

- Preparar un conjunto de imágenes astronómicas de la misión *Euclid* mediante técnicas de preprocesamiento que optimicen el contraste y la visibilidad de estructuras relevantes.
- Generar recortes centrados de galaxias a partir de imágenes FITS, utilizando catálogos creados con SExtractor y verificados mediante superposición en Aladin, asegurando así la calidad y precisión del conjunto de datos para la clasificación morfológica.
- Etiquetar manualmente los conjuntos de datos seleccionados, identificando lentes gravitatorias fuertes, las distintas morfologías de galaxias y posibles objetos con alto desplazamiento al rojo.
- Implementar un modelo de aprendizaje profundo de cajas orientadas para identificar efectos de lente gravitatoria fuerte en imágenes de la misión *Euclid*. Este modelo se centrará en reconocer patrones característicos utilizando datos etiquetados.
- Diseñar un sistema de clasificación morfológica que categorice galaxias en tipos como elípticas, espirales, espirales barradas e irregulares. Se emplearán técnicas de procesamiento de imágenes para optimizar la precisión de la clasificación.
- Explorar la detección de objetos con alto desplazamiento al rojo en los datos de *Euclid*. Este modelo identificará candidatos a estructuras más antiguas del universo.
- Evaluar el rendimiento de los modelos mediante métricas cuantitativas como precisión y recall y mAP50. Se utilizarán conjuntos de datos independientes al entrenamiento para validar su eficacia y robustez.

2.3. Beneficios del proyecto

El proyecto aporta beneficios concretos tanto para la comunidad astrofísica como para el ámbito del análisis automatizado de datos astronómicos. Se ha desarrollado un sistema que automatiza el análisis de grandes volúmenes de imágenes, reduciendo el tiempo y esfuerzo necesarios para identificar lentes gravitatorias, clasificar galaxias e identificar candidatos antiguos en los datos de

la misión *Euclid*. Esta automatización impulsa avances en el estudio del universo al permitir una detección más precisa de lentes gravitatorias y objetos antiguos. Además, esta estrategia reduce significativamente el tiempo y la complejidad necesarios para procesar grandes volúmenes de imágenes, evitando la necesidad de diseñar redes desde cero.

Los modelos y metodologías diseñados son parametrizables, lo que los hace útiles y versátiles para futuras investigaciones o aplicaciones en otras misiones astronómicas. El trabajo promueve una aplicación práctica y accesible de la inteligencia artificial en astrofísica, al ofrecer herramientas que aceleran el descubrimiento de fenómenos clave como lentes gravitatorias y objetos con alto desplazamiento al rojo. Todo ello contribuye al avance del conocimiento sobre la evolución y la distribución de materia oscura en el universo.

3. MARCO TEÓRICO

3.1. Misión *Euclid*

La Misión *Euclid*, desarrollada por la Agencia Espacial Europea (ESA), tiene como propósito principal explorar algunos de los misterios más profundos del Universo, como la naturaleza de la energía oscura, la materia oscura y la gravedad [8]. El objetivo central de *Euclid* es cartografiar la estructura a gran escala del Universo con un nivel de detalle sin precedentes. Para ello, observará miles de millones de galaxias, abarcando más de un tercio de la bóveda celeste. Este mapa del cielo permitirá a los científicos estudiar cómo se distribuyen la materia y la energía a lo largo del espacio y el tiempo, ofreciendo pistas clave sobre la evolución del Universo desde el Big Bang hasta la actualidad [8].




Figura 1: Regiones de interés que *Euclid* cartografiará a lo largo de los años [12].

Euclid utilizará dos técnicas avanzadas para cumplir su misión. Por una parte medirá el efecto **lente gravitacional débil**. Esta técnica analiza las pequeñas distorsiones en la luz de las galaxias lejanas causadas por la gravedad de la materia oscura que se encuentra en el camino. Al cartografiar estas distorsiones, *Euclid* podrá reconstruir la distribución de la materia oscura y analizar cómo la energía oscura afecta la formación de estructuras cósmicas [8]. La otra técnica son las **oscilaciones acústicas bariónicas**. Estas consisten en patrones específicos en la distribución de galaxias que se originaron en las ondas de sonido del Universo primitivo. Al estudiar estos patrones, *Euclid* medirá la tasa de expansión del Universo y cómo esta ha cambiado con el tiempo, proporcionando datos cruciales sobre la influencia de la energía oscura [8]. Los resultados de *Euclid* prometen responder preguntas fundamentales de la cosmología moderna. *Euclid* estudiará las regiones de interés mostradas en el **Fig. 1** a lo largo de sus años de operación.

3.1.1. Cúmulo de Perseo

El Cúmulo de Galaxias de Perseo, parte del Supercúmulo de Perseo-Piscis, constituye una de las estructuras más masivas y estudiadas del universo cercano [13]. Se localiza a 240 millones de años luz de la Tierra y alberga miles de galaxias, predominantemente sistemas tempranos con pocas ga-

laxias espirales, inmersas en una extensa nube de gas caliente. En su centro se encuentra la galaxia elíptica gigante NGC 1275, que exhibe un flujo de enfriamiento central y actividad en el núcleo galáctico activo (en inglés AGN) en forma de radiación intensa [13]. Además de su relevancia científica, el cúmulo de Perseo constituye un entorno denso y complejo que ofrece un escenario ideal para poner a prueba modelos de aprendizaje profundo, por ejemplo para clasificar galaxias por su morfología. Por ello, se ha seleccionado este cúmulo como caso de estudio representativo en este trabajo.



Figura 2: Imagen del cúmulo de Perseo tomada por *Euclid* [14].

La existencia de materia oscura ha sido confirmada mediante el estudio de cúmulos como este, ya que su formación solo es posible en presencia de dicha materia [14]. La gravedad induce la formación de estructuras filamentosas de materia oscura, denominadas comúnmente red cósmica. Los puntos de intersección entre estos filamentos facilitan la aglomeración de galaxias, dando origen a cúmulos como Perseo. Esta red cósmica se extiende a lo largo del universo, y estructuras similares son observables más allá de Perseo, a una distancia de 12 millones de años luz [14].

La imagen capturada por *Euclid* (**Fig. 2**) incluye aproximadamente 1000 galaxias pertenecientes al cúmulo, junto con más de 100.000 galaxias adicionales visibles en el fondo [14]. Cada una de estas galaxias alberga hasta cientos de miles de millones de estrellas. Esta imagen destaca por ser

la primera en mostrar un número tan elevado de galaxias de Perseo con un nivel de detalle sin precedentes .

Se puede observar en la **Fig. 2** una luz tenue entre las galaxias del núcleo del cúmulo. Esta luz, conocida como luz intracúmulo, es producida por estrellas que flotan libremente debido a interacciones galácticas. Su análisis permite reconstruir la historia del cúmulo y cartografiar la distribución de la materia oscura en su interior [14].

3.2. Efecto lente gravitacional

El efecto lente gravitacional ocurre cuando la luz de una fuente distante, como una galaxia, se desvía al pasar cerca de un objeto masivo, como otra galaxia o un cúmulo. Este fenómeno es una consecuencia directa de la Teoría de la Relatividad General de Einstein, que predice que la presencia de masa curva el espacio-tiempo, provocando que los rayos de luz sigan trayectorias curvas [15].




Figura 3: Diagrama del funcionamiento del efecto lente gravitacional [16].

Aunque esta desviación fue explicada correctamente por Einstein en 1915 al aplicar las ecuaciones completas del campo gravitacional, la posibilidad de que la gravedad pudiera afectar la trayectoria de la luz ya se había planteado anteriormente. En 1804, Johann Georg von Soldner quiso calcular la magnitud de esta desviación debida al Sol, asumiendo que la luz estaba compuesta por partículas y utilizando las leyes de la gravedad newtoniana. Más de un siglo después, en 1911, Einstein retomó el problema utilizando el principio de equivalencia, y obtuvo el mismo resultado que Soldner. Sin embargo, al formular la relatividad general en 1915, Einstein descubrió que la deflexión real era el doble de la predicha por la gravedad newtoniana: esta diferencia se debía a la curvatura del espacio, no solo del tiempo [15].

La confirmación esta predicción llegó en 1919, durante un eclipse solar total, cuando Dyson, Eddington y Davidson midieron el desplazamiento aparente de estrellas cercanas al borde del

Sol. La concordancia entre las observaciones y el valor predicho por la relatividad general fue interpretada de inmediato como una prueba contundente a favor de la teoría de Einstein [15].

Actualmente, el efecto lente gravitacional se ha convertido en una herramienta poderosa en astrofísica y cosmología. Sus aplicaciones abarcan varios frentes. En primer lugar, permite la **amplificación de objetos lejanos o débiles**, haciendo posible observar fuentes que, sin la lente, quedarían fuera del alcance de los telescopios: los lentes actúan como verdaderos telescopios cósmicos. En segundo lugar, ofrece un medio para el **estudio de la materia oscura**, ya que la deflexión de la luz depende únicamente de la distribución de masa (visible o invisible), lo que permite cartografiar la materia oscura en cúmulos y galaxias. Finalmente, contribuye a la **determinación de parámetros cosmológicos** (como la constante de Hubble, la densidad de materia o la constante cosmológica), dado que las propiedades de los sistemas con lente están ligadas a la geometría y evolución del universo [15].

3.2.1. Principio de funcionamiento

Un sistema de lente gravitacional se puede describir geoméricamente mediante la desviación que sufre un rayo de luz proveniente de una fuente lejana al pasar cerca de una masa intermedia, como se ilustra en la **Fig. 4** [15].




Figura 4: Ilustración de un sistema de lente gravitacional. La luz se propaga desde la fuente \$S\$ hasta el observador \$O\$, y es desviada un ángulo \$\hat{\alpha}\$. La imagen que ve el observador es \$I\$ [15].

El rayo se curva con un ángulo de deflexión \$\hat{\alpha}\$ en la lente, alcanzando finalmente al observador, y se define como:

$$\hat{\alpha} = \frac{4GM}{c^2\xi} \quad (3.1)$$

La posición angular real de la fuente con respecto al eje óptico se denota por \$\vec{\beta}\$ mientras que la posición angular aparente de la imagen observada es \$\vec{\theta}\$. Las distancias relevantes son las denominadas distancias angulares: \$D_d\$ (observador-lente), \$D_s\$ (observador-fuente), y \$D_{ds}\$ (lente-fuente).

Estas permiten aplicar relaciones euclidianas en un espacio-tiempo curvo, como $separación = ángulo \times distancia\ angular$ [15]. A partir de estas cantidades, se define la desviación de ángulo reducida como:

$$\vec{\alpha} = \frac{D_{ds}}{D_s} \vec{\hat{\alpha}} \quad (3.2)$$

y la relación entre la posición real y la imagen queda dada por la ecuación de lente:

$$\vec{\beta} = \vec{\theta} - \vec{\alpha}(\vec{\theta}) \quad (3.3)$$

Por lo general, esta ecuación no es lineal, permitiendo la formación de múltiples imágenes para una misma fuente, dependiendo de la estructura de la lente [15].

Aunque las lentes gravitacionales presentan muchas de las aberraciones ópticas clásicas (como la distorsión geométrica de las imágenes), no sufren aberración cromática, ya que la desviación de la luz es independiente de su longitud de onda. Esto las convierte en herramientas muy precisas para estudiar la estructura del universo, sin depender de la emisión espectral de los objetos involucrados [15].

3.2.2. Clasificación del efecto lente

El efecto de lente gravitacional se divide en tres tipos principales según la alineación y la masa de la lente. El efecto ***lente gravitacional fuerte*** ocurre cuando existe una alineación casi perfecta entre la fuente, la lente y el observador, y la masa de la lente es suficientemente grande [2]. Esto da lugar a múltiples imágenes de la fuente, arcos brillantes o incluso anillos de Einstein completos. El efecto ***lente gravitacional débil*** ocurre cuando la alineación es imperfecta o la masa de la lente es insuficiente para crear imágenes múltiples claras. En este caso, se observan distorsiones sutiles en las formas de las galaxias de fondo, que requieren análisis estadísticos sobre poblaciones de galaxias para ser detectadas [2]. Finalmente, el efecto de ***microlente gravitacional*** implica lentes de masa relativamente baja, como estrellas, que no resuelven múltiples imágenes, pero provocan aumentos temporales en el brillo de una fuente de fondo. Este fenómeno resulta especialmente útil para detectar objetos compactos y exoplanetas [2].

3.2.3. Dinámica de Fluidos en un Universo en Expansión

La evolución de un fluido en un universo en expansión se modela con tres ecuaciones fundamentales; la ecuación de continuidad (describe la conservación de la masa), las ecuaciones de Euler (ecuaciones de movimiento) y la ecuación de Poisson (describe el campo gravitacional) [17].

$$\frac{D\rho}{Dt} + \rho \nabla_r \cdot \mathbf{u} = 0 \quad (\text{Continuidad}) \quad (3.4)$$

$$\frac{D\mathbf{u}}{Dt} = -\frac{\nabla_r P}{\rho} - \nabla_r \phi \quad (\text{Euler}) \quad (3.5)$$

$$\nabla_r^2 \phi = 4\pi G \rho \quad (\text{Poisson}) \quad (3.6)$$

Aquí r es la coordenada propia, $\partial/\partial t$ es la derivada parcial para r fija y

$$\frac{D}{Dt} = \frac{\partial}{\partial t} + \mathbf{u} \cdot \nabla_r \quad (3.7)$$

describe la derivada temporal como una cantidad que se mueve con el fluido. Las **Ecs. 3.4-3.6** describen 5 relaciones para 6 incógnitas ($\rho, u_x, u_y, u_z, P, \phi$). Por tanto, para poder resolver el sistema se necesita la ecuación de estado, la cual especifica la presión P del fluido [17].

En un universo en expansión de Friedmann-Robertson-Walker (FRW), las perturbaciones se analizan usando coordenadas comóviles \mathbf{x} , definidas como:

$$\mathbf{r} = a(t)\mathbf{x} \quad (3.8)$$

donde $a(t)$ es el factor de escala del Universo. Reemplazando las coordenadas temporales (r, t) por (\mathbf{x}, t) y sabiendo también que $\bar{\rho} \propto a^{-3}$, se puede escribir la **Ec. 3.6** en coordenadas comóviles como

$$\nabla^2 \Phi = 4\pi G \bar{\rho} a^2 \delta, \quad \Phi = \phi + a\ddot{x}^2/2 \quad (3.9)$$

donde $\nabla \equiv \nabla_x$ y ahora $\partial/\partial t$ está fijo para \mathbf{x} .

En el espacio de Fourier, la ecuación de Poisson (**Eq. 3.9**) para perturbaciones en el potencial gravitacional se puede escribir en términos de fluctuaciones de densidad de masa como [17]

$$\Phi_k = -\frac{3}{2} H^2 \Omega_m a^2 \frac{\delta_k}{k^2} \quad (3.10)$$

donde Ω_m es el parámetro de densidad de masa del Universo.

Estas fluctuaciones en el potencial tienen efectos que se pueden observar directamente, ya que afectan a las geodésicas, las trayectorias en el espacio por donde se propagan los fotones. Cuando estas trayectorias se alteran, las imágenes que se observan de objetos lejanos, como galaxias, se distorsionan. Este fenómeno se llama *lente gravitacional*, porque es similar a cómo una lente óptica desvía la luz en un telescopio o unas gafas [17].

3.3. Cúmulos de galaxias

En el universo actual, una fracción importante de las galaxias está agrupada en grupos y cúmulos, regiones donde la densidad de galaxias supera entre decenas y cientos de veces el promedio cósmico, entendido como la densidad media de galaxias por unidad de volumen en el cosmos a gran escala [17]. Estas estructuras desempeñan un papel fundamental en la comprensión de la estructura y evolución del universo. Los cúmulos de galaxias son agrupaciones más densas y pobladas. Típicamente, contienen más de 50 galaxias brillantes concentradas en un volumen de pocos megaparsecs. Su alta densidad las distingue como sistemas masivos y complejos. En contraste, los grupos de galaxias son agregaciones más pequeñas y menos pobladas, con una cantidad reducida de galaxias en comparación con los cúmulos [17]. Estos sistemas constituyen los objetos virializados más masivos del universo, lo que significa que han alcanzado un equilibrio gravitacional.

Esta propiedad los hace esenciales para analizar la evolución de las poblaciones galácticas, ya que ofrecen una ventana a los procesos de formación y dinámica de galaxias a lo largo del tiempo cósmico. Gracias a su alta densidad superficial y la presencia de galaxias muy luminosas, tanto los grupos como los cúmulos pueden ser detectados a grandes distancias. Esta característica los convierte en herramientas valiosas, permitiendo estudiar la distribución de materia y la evolución del universo a gran escala.

3.4. Tipos de galaxias

Las galaxias son sistemas enormes formados por una gran cantidad de estrellas, polvo, gas y materia oscura. Su variedad en formas y tamaños motivó al astrónomo Edwin Hubble a crear un sistema de clasificación conocido como la "horquilla de Hubble" [17]. Este sistema organiza las galaxias según su apariencia visual y establece conexiones entre los diferentes tipos. La clasificación de Hubble incluye varios tipos de galaxias, cada uno con características distintivas, como galaxias elípticas (E), lenticulares ($SA0$ y $SB0$) y espirales (SA), aunque más adelante también se añadieron las espirales barradas (SB), las irregulares y las enanas esferoidales ($dSph$) [18].




Figura 5: Diagrama de Hubble - De Vaucouleurs [19].

3.4.1. Galaxias elípticas

Las galaxias elípticas muestran una amplia gama de formas y tamaños, y no es fácil clasificarlas con precisión debido a sus bordes difusos y su apariencia nebulosa. La formación de estas galaxias es una incógnita, pero hay dos modelos que explican este fenómeno. El primero de ellos, llamado *Modelo de colapso monolítico*, propone que se originan a partir del colapso de nubes de gas sin rotación, formando estrellas rápidamente en una estructura elíptica [17]. El segundo modelo, llamado *Modelo de fusión galáctica* sugiere que surgen de colisiones y fusiones de galaxias espirales, produciendo sistemas con perfiles similares a las elípticas. Las evidencias actuales, apoyadas en simulaciones y el papel de la materia oscura, favorecen el modelo de fusión como el más probable [17].

Según el modelo de Hubble, la principal característica por la que se pueden clasificar y catalogar las galaxias elípticas (E) es su achatamiento [18]. Estas galaxias reciben un valor entre 0 y 7 que describe su grado de achatamiento. Una $E0$ sería una galaxia elíptica casi totalmente esférica, mientras que una $E7$ tendría una forma muy ovalada, como se puede ver en la **Fig. 6**. Sin embargo, esta escala tiene limitaciones, ya que las galaxias $E6$ y $E7$ pueden confundirse con galaxias lenticulares vistas de perfil. Por otra parte, las galaxias elípticas también se pueden clasificar según la fase de evolución en la que se encuentren; pueden ser compactas (cE), normales (E) o tardías (E^+). Estas últimas muestran características que indican que se encuentran en fase de transición hacia las galaxias lenticulares ($S0$) [18].




Figura 6: Tipos de galaxias elípticas [18].

3.4.2. Lenticulares

Las galaxias lenticulares tienen una apariencia intermedia entre las elípticas y las espirales [17]. Algunas de estas parecen antiguas galaxias espirales que han perdido sus brazos mientras que otras tienen una barra central. Al compartir similitudes con ambos tipos, se piensa que este tipo de galaxias son espirales viejas que han agotado su gas o que han perdido sus brazos debido a la interacción gravitatoria con otras galaxias cercanas [17].

La clasificación de las galaxias lenticulares, o $S0$, se basan en la presencia de un disco, un bulbo y, a menudo, una lente, sin brazos espirales [18]. Existen dos tipos principales, las de tipo $SA0$, sin barra central, y las de tipo $SB0$, con barra central pero menos comunes, como se puede ver en la **Fig. 7**. En algunos casos, la orientación de la galaxia o su estructura difusa dificulta determinar la presencia de barra, clasificándolas simplemente como $S0$. Hay otros símbolos que permiten clasificarlas con más precisión, con los superíndices S^- , S^0 , S^+ , que describen si la galaxia es temprana, intermedia o tardía, respectivamente [18].




Figura 7: Tipos de galaxias lenticulares [18].

Las galaxias en forma de disco tienen una morfología mucho más compleja que las elípticas [17]. Consisten en un disco delgado soportado por rotación que incluye brazos espirales y a menudo una barra, junto a un bulbo central. La estructura espiral, visible especialmente en galaxias vistas de cara, está definida por una distribución suave de luz sin brazos espirales ni regiones HII (nubes de hidrógeno ionizado), mientras que los sistemas de perfil permiten estudiar la estructura vertical, revelando un disco delgado y otro grueso, además de un halo estelar esferoidal [17].

3.4.3. Espirales

Las galaxias espirales se clasifican según tres dimensiones principales: familia, etapa y variedad [18]. Estas dimensiones reflejan características morfológicas clave que permiten diferenciarlas en el sistema de clasificación de Vaucouleurs.

La familia indica la presencia o ausencia de una barra central, una estructura alargada que atraviesa el núcleo de la galaxia. Este criterio divide a las espirales en tres categorías principales [18]:

- **SA (Sin barra):** No presentan barra central. La estructura espiral emerge directamente del bulbo o del disco sin una característica lineal prominente (Primera fila de la **Fig. 8**).
- **SAB (Intermedias):** Muestran una barra débil o ambigua. La barra no domina la morfología pero es detectable, a menudo más ovalada que recta. Es un estado intermedio entre S y SB (Segunda fila de la **Fig. 8**).
- **SB (Barradas):** Poseen una barra central bien definida que conecta el bulbo con los brazos espirales. Las barras suelen ser rectas y pueden tener isofotas más cuadradas que elípticas (Tercera fila de la **Fig. 8**).

Por otra parte, la etapa se refiere a la posición de una galaxia espiral a lo largo de la secuencia de Hubble, que va desde los tipos tempranos (Sa) hasta los tardíos (Sc o Sd). Este criterio está relacionado con el tamaño relativo del bulbo central, la resolución de los brazos espirales y la

cantidad de estructura visible [18]. Esto se puede observar en la **Fig. 8** de izquierda a derecha.

- **Sa (tempranas):** Bulbo central grande y prominente que domina la luz de la galaxia. Los brazos espirales son apretados, lisos y poco definidos, con escasa resolución en regiones de formación estelar.
- **Sb (intermedias):** Bulbo central de tamaño intermedio. Los brazos espirales son más abiertos y comienzan a mostrar algo de estructura, como regiones de formación estelar o nudos brillantes.
- **Sc (tardías):** Bulbo central pequeño o poco prominente. Los brazos espirales son muy abiertos, sueltos y bien resueltos, con abundantes regiones de formación estelar y evidencia de polvo.
- **Sd (muy tardías):** Bulbo central extremadamente pequeño o ausente. Los brazos espirales son fragmentados, débiles y poco definidos, a menudo con una estructura irregular.

También existen etapas intermedias, como Sab, Sbc, Scd, and Sdm, que se muestran en la **Fig. 9**.

Finalmente se tiene la variedad, que describe la forma en que los brazos espirales se conectan al bulbo o a la barra, destacando la presencia de anillos o patrones espirales puros (**Fig. 10**) [18]:

- **s (Espiral pura):** Los brazos espirales emergen directamente del bulbo o del borde del disco sin formar anillos. La estructura es continua y sin interrupciones.
- **rs (Intermedio):** Combinan rasgos de "s" y "r", con un anillo parcial o pseudoanillo que no está completamente cerrado, seguido de brazos espirales.
- **r (Con anillo interno):** Presentan un anillo interno prominente cerca del bulbo o la barra, desde el cual emergen los brazos espirales. Estos anillos suelen estar asociados a resonancias dinámicas.




Figura 8: Tipos de galaxias espirales según familia y etapa [18].




Figura 9: Galaxias espirales SA, SAB y SB con etapas intermedias [18].




Figura 10: Tipos de galaxias espirales según su variedad [18].

3.4.4. Irregulares

Las galaxias irregulares no presentan un bulbo central ni brazos espirales definidos y se caracterizan principalmente por su falta de simetría, por lo que su categorización en función de su morfología es complicada [20]. Estas galaxias se clasifican en tres grupos; Las de tipo I mantienen señales débiles de un disco y un bulbo central, las de tipo II no presentan ningún indicio de estructura definida y la tercera categoría se corresponde con galaxias irregulares enanas, las cuales son galaxias muy jóvenes con una metalicidad muy baja [20].

Las galaxias irregulares representan una cuarta parte de las galaxias del universo y no se encuentran en ninguna de las categorías del diagrama de Hubble ya que no existe una definición exacta para ellas [20]. Sin embargo, son muy útiles para estudiar los procesos de formación de estrellas, ya que al no tener brazos espirales, no perturban el medio interestelar y por tanto no fuerzan la producción de estrellas nuevas en regiones concretas. Esto permite estudiar con más precisión los factores que contribuyen al proceso de formación estelar [20].




Figura 11: Tipos de galaxias irregulares [18].

3.5. Objetos lejanos

El astrónomo Edwin Hubble revolucionó la astronomía en 1929 al demostrar que las galaxias distantes se alejan de la Vía Láctea a velocidades proporcionales a su distancia. Este descubrimiento reveló que las galaxias más lejanas se desplazan a mayor velocidad que las cercanas, un comportamiento que solo puede explicarse si el universo está en expansión [17]. Este hallazgo sentó las bases para la teoría del Big Bang, que postula que todas las galaxias compartieron un origen común en un pasado remoto, cuando el universo era mucho más denso y compacto. Años más tarde, observaciones adicionales indicaron que esta expansión no es constante, sino que se acelera con el tiempo. Este fenómeno llevó a los científicos a plantear la existencia de la energía oscura, una fuerza de naturaleza repulsiva que contrarresta la gravedad y acelera la separación de las galaxias [17].

Las galaxias emiten luz en todo el rango del espectro electromagnético. Sin embargo, debido a la expansión del universo, esta luz sufre un desplazamiento hacia longitudes de onda más largas, un efecto conocido como desplazamiento al rojo [21]. Este desplazamiento ocurre porque, al alejarse un objeto de un observador, la longitud de onda de los fotones que emite se estira, desplazando sus líneas espectrales hacia el extremo rojo del espectro. Cuanto mayor es el desplazamiento al rojo de un objeto, más distante se encuentra y más rápido se aleja. Este fenómeno no solo permite estimar la distancia de los objetos celestes, sino también su edad, convirtiéndose en una herramienta clave para identificar a los candidatos más antiguos del universo [21].

Es importante entender cómo se propagan los fotones en un universo homogéneo e isótropo. La métrica que describe este tipo de universo, llamada métrica de Robertson-Walker, se escribe de la siguiente forma [17]:

$$ds^2 = a^2(\tau)[d\tau^2 - d\chi^2 - f_K^2(\chi)(d\theta^2 + \sin^2\theta d\phi^2)] \quad (3.11)$$

donde

$$f_K(\chi) = r = \begin{cases} \sin \chi & (K = +1) \\ \chi & (K = 0) \\ \sinh \chi & (K = -1) \end{cases} \quad (3.12)$$

Las coordenadas (χ, θ, ϕ) se llaman coordenadas comóviles, y la función $a(t)$ es el factor de escala cosmológico. En este caso, χ representa la distancia comóvil entre dos observadores en reposo. Si se define el tiempo propio de un observador como el registrado por un reloj en reposo con respecto al observador, entonces el tiempo cósmico t es el tiempo propio de todos los observadores fundamentales [17].

Sin pérdida de generalidad, se puede considerar una señal de luz que se propaga hacia el origen en una dirección radial, es decir que $d\theta = d\phi = 0$ [17]. Como los fotones viajan sobre geodésicas nulas, donde $ds = 0$, su trayectoria se puede escribir a partir de la **Eq. 3.11** como:

$$d\tau = d\chi \quad (3.13)$$

Por tanto, si la onda es emitida en un tiempo t_e por un observador en reposo, entonces el tiempo t_0 en el que la onda llega al origen viene dado por [17]:

$$\tau(t_0) - \tau(t_e) = \chi(r_e) - \chi(0) = \chi(r_e) \quad (3.14)$$

Como la distancia comóvil $\chi(r_e)$ entre el observador y el origen no cambia con el tiempo, la siguiente onda que se emita en un tiempo $t_e + \delta t_e$ llegará al origen en el tiempo $t_0 + \delta t_0$:

$$\tau(t_0 + \delta t_0) - \tau(t_e + \delta t_e) = \chi(r_e) \quad (3.15)$$

Combinando ambas las **Eqs. 3.14 y 3.15** se obtiene

$$\tau(t_0 + \delta t_0) - \tau(t_0) = \tau(t_e + \delta t_e) - \tau(t_e) \quad (3.16)$$

En casos reales ocurre que $\delta t_e \ll t_e$ y $\delta t_0 \ll t_0$ [17], de modo que sabiendo que la definición de $\tau(t)$ es

$$\tau(t) = \int_0^t \frac{c}{a(t)} dt \quad (3.17)$$

se puede reescribir la **Eq.3.16** como

$$\frac{\delta t_0}{a(t_0)} = \frac{\delta t_e}{a(t_e)} \quad (3.18)$$

Por tanto, el periodo de la onda, y en consecuencia su longitud de onda, aumenta en proporción al factor de escala:

$$\frac{\lambda_0}{\lambda_e} = \frac{\delta t_0}{\delta t_e} = \frac{a(t_0)}{a(t_e)} \quad (3.19)$$

Definiendo el cambio relativo de longitud de onda por un parámetro de desplazamiento al rojo, $z \equiv (\lambda_0 - \lambda_e)/\lambda_e$, se tiene:

$$1 + z \equiv \frac{\lambda_0}{\lambda_e} = \frac{a(t_0)}{a(t_e)} \quad (3.20)$$

En un universo en expansión, $a(t_0) > a(t_e)$, de modo que $z > 0$ y por tanto las líneas espectrales muestran un desplazamiento al rojo, correspondiéndose a la teoría del universo en expansión y coincidiendo con el desplazamiento al rojo observado en galaxias lejanas [17].

El estudio de objetos de alto desplazamiento al rojo es crucial para entender la formación de las primeras galaxias y estrellas. Por ejemplo, [22] destaca que la emisión de la línea Lyman- α es una herramienta poderosa para identificar el redshift de galaxias distantes ($z \geq 5$), y que las galaxias que presentan altos anchos equivalentes de esta línea podrían requerir la existencia de estrellas masivas, baja metalicidad o actividad de núcleos galácticos activos (AGN). Estos anchos equivalentes de Lyman- α , detectados en proyectos como GLARE y LALA, son un indicio clave para estudiar las condiciones físicas de las primeras galaxias y el estado del medio intergaláctico en estas épocas tempranas [22].

Por otro lado, estudios como [23] muestran cómo grandes campañas de observación, como el *Dark Energy Survey*, permiten identificar poblaciones de galaxias masivas a $z \geq 4$. Estas observaciones ayudan a refinar los modelos de formación y evolución de galaxias en el universo temprano y abren la puerta a futuros estudios sobre la distribución de materia a gran escala en estos períodos.

3.6. Redes Neuronales Convolucionales (CNNs)

Las CNNs se encargan de aprender a identificar patrones complejos en imágenes, como bordes, texturas o formas. Las CNN se componen de una serie de capas que transforman progresivamente la entrada (la imagen) en una salida (por ejemplo una etiqueta de clase) [24]. En primer lugar se tiene una **capa de entrada**, que almacena el valor de los píxeles de la imagen de entrada (por ejemplo, un tensor de dimensiones altura \times anchura \times canales).

Tras este paso, la CNN usa las **capas convolucionales**. Cada capa aplica un conjunto de filtros (o kernels) sobre la entrada mediante productos escalares. Cada filtro se va desplazando píxel a píxel sobre la imagen de entrada y calcula el producto escalar entre sus pesos y la región correspondiente. El resultado de cada filtro es un mapa de características (o feature map) que resalta la presencia de cierta característica (por ejemplo, un borde o textura) [24].

Inmediatamente después del filtrado, se aplica una función de activación no lineal, normalmente ReLU (Rectified Linear Unit), que convierte los valores negativos en cero. Esto implica que si una región del filtro produce una activación negativa (es decir, no se parece a la característica que el

filtro busca), ReLU la suprime poniéndola a cero.

$$ReLU(x) = x^+ = \max(0, x) = \frac{x + |x|}{2} = \begin{cases} x & \text{if } x > 0 \\ 0 & \text{if } x \leq 0 \end{cases} \quad (3.21)$$

Suele haber varias capas convolucionales consecutivas, cada una aprendiendo características de nivel creciente (desde bordes simples en capas bajas hasta formas más complejas en capas profundas).

Tras ciertas capas convolucionales, se introduce una **capa de pooling** o submuestreo para reducir las dimensiones espaciales (altura \times anchura) de cada mapa de características. El objetivo principal de esta capa es reducir la cantidad de parámetros para disminuir el coste computacional y el riesgo de sobreajuste. El método más común es el *max pooling*, que conserva el valor más alto en cada región [24].

A continuación se realizan operaciones de aplanado, donde se convierten los tensores de 3 dimensiones a vectores unidimensionales, para poder conectar los volúmenes de activación con las **capas completamente conectadas**. Este tipo de capas funcionan igual que en una red neuronal clásica: cada neurona está conectada a todas las salidas anteriores. Se encargan de generar las puntuaciones de clase, es decir, la predicción de a qué categoría pertenece la imagen. También se suelen aplicar las funciones ReLU entre estas capas para mejorar el rendimiento [24]. A continuación se muestra un esquema de la arquitectura típica de una red CNN, con un intercalado de las capas vistas anteriormente:




Figura 12: Arquitectura típica de una CNN [24].

4. DESARROLLO

4.1. Planificación del trabajo fin de grado

- **Estudio del arte y análisis de informes previos:**

Duración: 1 semana (1-7 de febrero)

Descripción: Se llevó a cabo una revisión de trabajos previos y se recopiló información relevante utilizando herramientas bibliográficas como Web of Science. La tarea fue relativamente sencilla debido a la disponibilidad de recursos.

- **Uso de SExtractor y Aladin para la creación del catálogo de galaxias:**

Duración: 1 mes (8 de febrero - 8 de marzo)

Descripción: Se utilizaron en conjunto SExtractor y Aladin para generar un catálogo de galaxias. Esta fue la actividad más complicada del trabajo debido a la escasez de ejemplos prácticos de SExtractor en internet y tener que familiarizarse con el entorno Linux, lo que requirió un esfuerzo significativo para aprender a usarlo.

- **Generación de recortes a partir de la imagen FITS y el catálogo:**

Duración: 1 semana (9-15 de marzo)

Descripción: Se generaron recortes mediante un script en Python de la imagen FITS, usando un catálogo filtrado a partir del catálogo creado con SExtractor. La tarea tuvo una dificultad moderada.

- **Entrenamiento de los modelos de clasificación morfológica:**

Duración: 1 mes (16 de marzo - 15 de abril)

Descripción: Se entrenaron un total de 4 modelos basados en YOLO para clasificar galaxias según su morfología a partir de las imágenes generadas anteriormente. La dificultad fue moderada gracias a una gran cantidad de información en internet, aunque el etiquetado manual de imágenes fue lento por el gran volumen de datos.

- **Entrenamiento del modelo de detección de lentes gravitacionales:**

Duración: 3 semanas (16 abril-7 de mayo)

Descripción: Se entrenó un modelo (basado en YOLO11-obb) para detectar lentes gravitacionales. Gracias a la experiencia adquirida en la elaboración del modelo anterior, el proceso fue más rápido, con una dificultad moderada y resultados prometedores.

- **Entrenamiento del modelo de detección de objetos con alto desplazamiento al rojo:**

Duración: 1.5 semanas (27 de abril - 8 de mayo)

Descripción: Se desarrolló un modelo para identificar objetos antiguos con alto redshift. La dificultad fue moderada, beneficiándose de optimizaciones de los entrenamientos anteriores.

4.2. SExtractor

SExtractor (SourceExtractor) es un software ampliamente utilizado en astronomía para detectar, medir y clasificar fuentes en imágenes astronómicas almacenadas en archivos FITS (Flexible Image Transport System) [25]. Este formato estándar contiene los metadatos de la imagen en su cabecera (o header), que describen propiedades como el tamaño de la imagen, coordenadas astronómicas y parámetros instrumentales. SExtractor automatiza la extracción de catálogos de objetos celestes, como estrellas y galaxias, a partir de imágenes bidimensionales, proporcionando información sobre posiciones, flujos, magnitudes, tamaños y formas. Las imágenes FITS almacenan una gran cantidad de información, por lo que cada una suele ocupar varios gigabytes de memoria. Por ejemplo, en la siguiente imagen FITS del cúmulo de Perseo se puede apreciar la gran cantidad de objetos celestes que se encuentran en una pequeña región de la misma:




Figura 13: Zoom en una región de la imagen FITS del cúmulo de Perseo, visualizada con Aladin.

SExtractor procesa imágenes astronómicas mediante los siguientes pasos automatizados [25]:

- **Estimación del Fondo:** Calcula y sustrae el fondo de la imagen FITS para aislar las fuentes, ajustado por parámetros como `BACK_SIZE` y `BACK_FILTERSIZE`.
- **Detección de Fuentes:** Identifica píxeles que superan un umbral de ruido de fondo (`DETECT_THRESH`) y forman objetos con un área mínima (`DETECT_MINAREA`), agrupados mediante un algoritmo de conectividad.
- **Deblending:** Separa fuentes superpuestas mediante umbrales de contraste definidos por `DEBLEND_NTHRESH` y `DEBLEND_MINCONT`.
- **Medición:** Determina propiedades como posiciones (`X_IMAGE`, `Y_IMAGE`, `ALPHA_J2000`, `DELTA_J2000`), flujos (`FLUX_AUTO`, `FLUX_APER`), magnitud (`MAG_AUTO`), tamaños (`FWHM_IMAGE`, `FLUX_RADIUS`), formas (`ELLIPTICITY`, `ELONGATION`) y clasificación (`CLASS_STAR`, `SPREAD_MODEL`).

- **Salida:** Genera un catálogo en formato ASCII o FITS con las propiedades especificadas en el archivo default.param.

Un fragmento de un catálogo generado con SExtractor se ve de la siguiente forma

```
# 1 NUMBER          Running object number
# 2 X_IMAGE         Object position along x          [pixel]
# 3 Y_IMAGE         Object position along y          [pixel]
# 4 ALPHA_J2000    Right ascension of barycenter (J2000) [deg]
# 5 DELTA_J2000    Declination of barycenter (J2000)   [deg]
# 6 CLASS_STAR     S/G classifier output
# 7 ELLIPTICITY    1 - B_IMAGE/A_IMAGE
# 8 ELONGATION     A_IMAGE/B_IMAGE
# 9 FLUX_AUTO      Flux within a Kron-like elliptical aperture [count]
# 10 MAG_AUTO      Kron-like elliptical aperture magnitude [mag]
# 11 MAG_ISO       Isophotal magnitude [mag]
# 12 FLAGS         Extraction flags
# 13 SNR_WIN       Gaussian-weighted SNR
# 14 FLUX_RADIUS   Fraction-of-light radii [pixel]
# 15 FLUX_APER     Flux vector within fixed circular aperture(s) [count]
# 16 FWHM_IMAGE    FWHM assuming a gaussian core [pixel]
9  8830.0645  10496.7354  328.7516122 +17.4176894  0.029  0.226  1.292  989.413  22.6436  22.6641  24  152.1  2.913  405.1757  5.94
12  5538.6318  10445.9943  328.8474251 +17.4160854  0.029  0.774  4.418  3046.791  21.4224  21.5466  18  224.9  5.675  694.4662  5.32
19  4755.7549  10496.1592  328.8702185 +17.4174289  0.023  0.618  2.619  4135.018  21.0908  21.1117  27  299.9  5.872  630.639  21.31
25  6334.3301  10479.1367  328.8242642 +17.4170591  0.003  0.606  2.535  890.9939  22.7573  22.8233  16  100.1  3.926  262.0284  11.22
31  9218.5537  10462.6582  328.7403009 +17.4167625  0.014  0.848  1.050  1675.149  22.0719  22.1267  0  157.5  4.828  295.4479  10.20
37  5328.4385  10453.2695  328.8535444 +17.4162761  0.032  0.294  1.417  1992.14  21.8837  21.8918  2  296.4  2.645  946.1228  3.77
52  7339.7197  10427.9277  328.7949935 +17.4156969  0.001  0.047  1.049  1985.787  21.8872  22.0035  0  148.6  5.980  275.7348  9.49
57  9177.1074  10394.8408  328.7415939 +17.4148767  0.001  0.004  1.940  7842.309  20.4302  20.5284  0  203.3  11.756  416.5379  20.89
67  7151.2666  10404.0762  328.8004700 +17.4150234  0.034  0.939  1.040  1028.845  22.6096  22.6191  0  294.9  1.169  852.7789  1.62
68  4778.6436  10404.1807  328.8695455 +17.4148756  0.045  0.833  1.034  1012.873  22.6181  22.6229  0  290.4  1.184  848.9464  1.78
72  9621.3213  10393.3477  328.7285724 +17.4148570  0.024  0.674  3.068  1157.946  22.4728  22.5362  0  108.9  4.796  230.0965  18.59
74  8153.2500  10390.7451  328.7713089 +17.4147096  0.029  0.505  2.022  2635.656  21.5798  21.6153  0  248  4.551  576.6462  11.61
84  6832.1816  10355.3516  328.8097636 +17.4136511  0.001  0.232  1.303  2112.395  21.8201  21.8856  0  176  5.466  340.636  11.72
85  5872.1099  10354.1328  328.8377112 +17.4135579  0.030  0.077  1.083  2422.894  21.6712  21.6616  0  244.8  4.042  794.6936  3.31
86  5451.4990  10357.0029  328.8499554 +17.4136104  0.028  0.210  1.266  952.8223  22.6845  22.7893  3  111.1  3.872  294.2624  5.38
94  4023.0366  10332.2793  328.8692400 +17.4128015  0.029  0.267  1.364  976.0892  22.6503  22.7558  0  151.6  2.646  465.5237  2.00
96  8614.5596  10319.6816  328.7578759 +17.4127603  0.029  0.467  1.876  4025.27  21.1200  21.1590  0  315.3  5.419  782.439  8.41
98  5531.1285  10263.5332  328.8476309 +17.4110193  0.029  0.392  1.644  67226.61  18.0631  18.0611  3  2213  9.830  10733.16  5.40
124  5733.6899  10270.9941  328.8417349 +17.4112397  0.001  0.122  1.139  1595.438  22.1248  22.2626  3  131.8  5.381  324.3553  8.22
```

Figura 14: Fragmento inicial del catálogo generado con SExtractor del cúmulo de Perseo.

La imagen FITS utilizada proviene de las *Early Release Observations* (ERO) del telescopio *Euclid* [26] y tiene una resolución de $42,000 \times 42,000$ píxeles, lo que equivale a un total de 1.764×10^9 píxeles. Dado su gran tamaño, procesarla directamente con SExtractor mediante el hardware disponible para la elaboración de este proyecto sería computacionalmente costoso y podría perder detalles importantes. Por ello, se decidió dividir la imagen en 16 subimágenes más manejables, procesando cada una de forma independiente y combinando posteriormente los resultados en un catálogo único mediante un script en bash, el cual se encuentra en la **Sección 9.2-Script 1**. En el siguiente esquema se muestra el flujo de operación:




Figura 15: Proceso de creación de catálogos a partir de una imagen FITS, incluyendo la subdivisión, creación de catálogos, combinación de los catálogos y filtrado.

Antes de configurar SExtractor, es importante entender los parámetros de la cabecera del archivo FITS, los cuales contienen los metadatos de la imagen, ya que influyen directamente en la detección y medición de fuentes. Estos son [27]:

- **NAXIS1 y NAXIS2:** Dimensiones de la imagen, ambas de 42,000 píxeles.
- **CD1_1 y CD2_2:** Elementos de la matriz de proyección lineal, que relacionan píxeles con coordenadas celestes. Ambos tienen valores de $|2,777 \times 10^5|$ grado/píxel, equivalente a 0.1 arcsec/píxel (usando la conversión 1 grado = 3600 arcsec). CD1_1 indica el cambio en ascensión recta (RA) por píxel a lo largo del eje X, y CD2_2 el cambio en declinación (DEC) por píxel a lo largo del eje Y.
- **GAIN:** Factor de conversión de ADU (unidades de datos analógicas) a electrones (e^- /ADU), con un valor de $282.9178372872 e^-$ /ADU. Representa la sensibilidad del detector
- **SATURATE:** Indica el umbral en ADU por encima del cual los píxeles se consideran saturados. Su valor es de 19312.59156 ADU

Estos valores son fundamentales para ajustar correctamente los parámetros de SExtractor y garantizar que las medidas sean consistentes con las propiedades físicas de la imagen.

A continuación, se describen los valores finales utilizados en los parámetros clave de SExtractor, junto con la justificación de su elección basada en las características de la imagen y los objetivos del análisis. Se realizaron numerosas pruebas hasta poder dar por válidos estos valores, con el objetivo de poder detectar el mayor número de galaxias posibles en la imagen. Estos parámetros se modifican siempre en el archivo *default.sex*, el archivo de configuración de SExtractor.

- **DETECT_THRESH:** Se estableció el umbral de detección en 1.5σ (desviaciones estándar por encima del fondo). Este valor permite detectar fuentes débiles en una imagen profunda como la de *Euclid*, logrando un equilibrio entre sensibilidad y reducción de falsos positivos. Se observó que un umbral mayor (por ejemplo 3σ) omitía fuentes débiles, mientras que uno menor (por ejemplo 1.0σ) incrementaba el ruido.
- **DETECT_MINAREA:** Se fijó el área mínima de detección en 260 píxeles², equivalente a 2.6 arcsec^2 , ya que con áreas inferiores a esta SExtractor comenzó a confundir ruido de fondo con objetos. Esto se calculó considerando la escala de 0.1 arcsec/píxel, calculada con los datos de la cabecera de la imagen (CD1_1). Si $1 \text{ arcsec}^2 = (1 \text{ arcsec} / 0.1 \text{ arcsec/píxel})^2 = 100 \text{ píxeles}^2$, por lo que $2.6 \text{ arcsec}^2 \times 100 \text{ píxeles}^2/\text{arcsec}^2 = 260 \text{ píxeles}^2$.
- **BACK_SIZE:** Tamaño de la malla para estimar el fondo, configurado en 128 píxeles (equivalente a 12.8 arcsec con la escala de 0.1 arcsec/píxel). Este tamaño es significativamente mayor que las fuentes objetivo, evitando que la señal de estas contamine la estimación del fondo. Como *Euclid* tiene un fondo de imagen muy limpio, este valor permite estimar el fondo de una manera muy efectiva.
- **PIXEL_SCALE:** Escala de píxeles establecida en 0.1 arcsec/píxel, derivada de CD1_1 y

CD2_2, lo que permite a SExtractor interpretar correctamente tamaños y posiciones en coordenadas astronómicas.

- **DEBLEND_NTHRESH:** Controla la separación de fuentes superpuestas, configurado en 32. Este valor es adecuado para imágenes como las de *Euclid*, evitando que SExtractor realice tanto una fragmentación excesiva de fuentes difusas como la fusión de galaxias cercanas.
- **DEBLEND_MINCONT:** Umbral de contraste mínimo para separar fuentes, establecido en 0.005. Este umbral bajo permite separar objetos débiles en imágenes profundas sin dividir incorrectamente estructuras extensas.

Para optimizar la generación de catálogos a partir de las 16 subimágenes, se desarrolló un procedimiento automatizado. Se diseñó un script para ejecutar secuencialmente SExtractor en cada subimagen, otro para combinar los catálogos resultantes y otro para aplicar el filtrado que se explicará a continuación. Estos scripts, guardados en formato *shell* (archivo *.sh*), están optimizados para su ejecución en un entorno Linux desde la terminal. De esta forma se eliminó la necesidad de procesar cada subimagen individualmente, reduciendo el tiempo y el esfuerzo requeridos. Todos ellos se encuentran en la **Sección 9.2-Scripts 2,3,4**.

Para obtener únicamente galaxias, se aplicó un primer filtrado al catálogo basado en el parámetro `CLASS_STAR` del catálogo, que clasifica las fuentes entre estrellas (valores cercanos a 1) y galaxias (valores cercanos a 0) [25]. Se seleccionaron las fuentes con `CLASS_STAR < 0.1` mediante los comandos *grep* y *awk*. Este paso asegura que el catálogo final contenga exclusivamente galaxias, alineándose con los objetivos del análisis. Para poder comprobar si el catálogo creado contenía suficientes galaxias y no filtraba por equivocación alguna estrella debido a un mal ajuste de parámetros, se superpuso en varias ocasiones la imagen FITS con el catálogo mediante el software *Aladin*. La versión final del catálogo, ya con los valores de los parámetros correctamente ajustados, contuvo más de 25.000 galaxias (disponible desde el link de la **Sección 9**). Por ejemplo, en la **Fig. 16**, cada punto rojo corresponde únicamente a las galaxias del catálogo, y se pueden ver algunas de estas detecciones superpuestas (en verde) sobre la imagen FITS:

Para la generación de imágenes de entrenamiento para la red neuronal, descrito en la **Sección 4.3.1**, se necesitaron imágenes de galaxias con características morfológicas bien definidas. Dado que las más de 25.000 galaxias del catálogo presentaban mucha variedad de tamaños y niveles de brillo, muchas de ellas no servían para realizar un entrenamiento efectivo debido a la falta de rasgos claros. Por tanto, se realizó un segundo filtrado en el catálogo, seleccionando aquellas galaxias con una magnitud aparente menor a 19 y una SNR (relación señal/ruido) superior a 100. Se obtuvo un nuevo catálogo reducido de aproximadamente 620 galaxias (disponible desde el link de la **Sección 9**). De esta forma se aseguró tener galaxias con características morfológicas claras y se evitó tener fuentes de peor calidad para el entrenamiento.




Figura 16: Catálogo de galaxias superpuesto a imagen FITS en Aladin. Zoom en zona verde con galaxias detectadas.

4.3. YOLO (You Only Look Once)

YOLO (You Only Look Once) es una familia de algoritmos de aprendizaje profundo que se encarga de detectar objetos en tiempo real. Su objetivo principal es usar redes neuronales para localizar y clasificar a estos objetos en las imágenes [6]. Existen muchos tipos de redes neuronales, pero la que usan todos los modelos YOLO son las CNNs, descritas en la **Sección 3.6**.

4.3.1. Selección del modelo YOLO

La elección del modelo de aprendizaje profundo adecuado es fundamental para garantizar la precisión y eficiencia de las tareas propuestas en este trabajo.

Modelo para la Detección de Lentes Gravitacionales Para la detección del efecto de lente gravitacional fuerte, se seleccionó el modelo YOLO11-obb (Oriented Bounding Box), que incorpora cajas delimitadoras orientadas. Estas cajas ajustan su ángulo y forma para adaptarse a la inclinación de los objetos, a diferencia de las cajas rectangulares tradicionales, y resultan especialmente útiles para identificar los arcos y distorsiones característicos de las lentes gravitacionales [28]. Esta característica mejora significativamente la localización de lentes gravitacionales en imágenes astronómicas.

El modelo YOLO11-obb se entrenó con recortes provenientes de la **Fig. 20** que contienen ejemplos de lentes gravitacionales, asegurando que las cajas orientadas capturen correctamente las características distintivas de estos fenómenos. La elección de esta variante se justificó por su capacidad para proporcionar detecciones más precisas en comparación con otros modelos YOLO [28], especialmente en contextos donde la orientación de los objetos es crítica.

Modelo para la Clasificación Morfológica Para la clasificación morfológica de galaxias, se evaluaron diferentes versiones de YOLO, considerando sus características técnicas y su idoneidad para imágenes astronómicas. A continuación, se detalla el análisis realizado:

- **YOLOv1:** Introducido en 2016, YOLOv1 fue un modelo pionero en detección de objetos al procesar imágenes en una sola etapa, estableciendo un nuevo estándar para aplicaciones en tiempo real gracias a su buena precisión y velocidad computacional [29]. Sin embargo, su arquitectura limitada dificultaba la detección de objetos pequeños, como las galaxias, lo que lo hace inadecuado para este proyecto.
- **YOLOv5:** Publicado en 2020 por Ultralytics y desarrollado en PyTorch, YOLOv5 destacó por su facilidad de uso, modularidad y rendimiento optimizado en GPU. Introdujo cinco variantes (YOLOv5n, s, m, l, x), permitiendo adaptar el modelo a distintas capacidades computacionales. Aunque fue ampliamente utilizado por la comunidad, fue posteriormente superado por versiones más recientes con mejor desempeño en precisión y eficiencia [29].
- **YOLOv8:** Lanzado en 2023 también por Ultralytics, YOLOv8 supuso una mejora significativa al eliminar las anchor boxes, lo que permitió una detección más flexible de objetos con formas y tamaños variables, lo que sería compatible con la detección galaxias con bordes difusos. Introdujo variantes como YOLOv8-S, M, L y Tiny, además de mejoras en la arquitectura y funciones de pérdida avanzadas como CIOU (Complete Intersection over Union), lo que favoreció una localización más precisa de patrones en imágenes [29]. Por estas razones, YOLOv8 fue empleado para entrenar los tres primeros modelos de clasificación morfológica del TFG: *train27* (5 clases), *train27_spiral6* (6 clases) y *Entreno1* (3 clases).
- **YOLOv11:** Introducido a finales de 2024, YOLOv11 representa la evolución más reciente de la serie. Incorpora una arquitectura de backbone y neck altamente optimizada, diseñada para extraer características con mayor precisión. También mejora la eficiencia y velocidad de inferencia, incluyendo cinco variantes adaptadas a diferentes niveles de recursos [29]. Durante el desarrollo del TFG, la publicación de documentación detallada y ejemplos prácticos impulsó el uso de YOLOv11 en el entrenamiento del cuarto modelo de clasificación morfológica (4 clases: elíptica, espiral, espiral barrada e irregular), logrando un mejor rendimiento en tareas complejas.

La transición de YOLOv8 a YOLOv11 para el modelo final se debió a la evolución del conocimiento disponible durante el TFG. Inicialmente, YOLOv8 fue seleccionado por su estabilidad y documentación, pero las mejoras de YOLOv11 justificaron su adopción en la última etapa, asegurando un mejor desempeño en la clasificación de galaxias.

Una vez seleccionado el modelo, se procedió a generar el conjunto de datos (dataset) a partir del catálogo de galaxias creado previamente. Dado que el catálogo filtrado original incluía galaxias tenues cuya morfología no era distinguible, se generó el subcatálogo filtrado descrito al final de la **Sección 4.2**.

El catálogo proporciona parámetros esenciales, como las coordenadas celestes de las galaxias: ascensión recta (RA) y declinación (DEC). Utilizando la librería `astropy` en Python, se extrajo la cabecera del archivo FITS, que contiene metadatos como la matriz de proyección lineal para convertir coordenadas celestes a píxeles. Este proceso se implementó en el **Script 6**, el cual se encuentra en el link de la **Sección 9.2**:

Posteriormente, se realizaron recortes centrados en cada galaxia utilizando la función `Cutout2D` de `astropy`, con un tamaño de 640×640 píxeles, compatible con los requisitos de entrada de los modelos YOLO (la dimensión debe ser múltiplo de 32).

Inicialmente, los recortes generados presentaban problemas de visualización, ya que los objetos no eran perceptibles debido a la falta de normalización, como se muestra en la **Fig. 17.1**. Para corregirlo, se empleó el módulo `simple_norm` de `astropy.visualization`, evaluando modos como lineal, logarítmico, `asinh` y `pow2`. La normalización logarítmica resultó ser la más efectiva en los primeros ensayos, permitiendo visualizar mejor las estructuras galácticas (**Fig. 17.2**). Los dos primeros modelos (`train27` y `train27_espiral6`) se entrenaron con imágenes normalizadas logarítmicamente sin ajustes adicionales. Sin embargo, un análisis posterior reveló que el modelo a menudo confundía el ruido del fondo con algunas clases de galaxias, llegando a etiquetar regiones de la imagen que solo contenían fondo (sin ningún objeto) como si fueran galaxias irregulares u otras morfologías. Para resolver este problema, se establecieron valores mínimos y máximos de brillo en la normalización logarítmica, generando imágenes con mayor contraste y un fondo más oscuro. Esta configuración mejorada se aplicó al tercer y cuarto modelo, optimizando la capacidad del modelo para distinguir clases morfológicas como se muestra en la **Fig. 17.3**:



Figura 17: Misma galaxia: (1) con ajuste lineal; (2) ajuste logarítmico sin cota; (3) ajuste logarítmico acotado.

Modelo de detección de candidatos a objetos más antiguos del universo Dado que el modelo solo iba a tener una única clase (“candidato”) y un conjunto de datos de 400 recortes con más de 1000 etiquetas, se seleccionó la versión más ligera de YOLOv11, el modelo YOLOv11n (nano). Esta elección permitió usar valores de hiperparámetros más altos como el tamaño del *batch* (que no habrían sido posible usar con modelos más grandes), manteniendo capacidad suficiente para aprender los patrones característicos de objetos con colores rojizos, indicativos de un alto desplazamiento al rojo.

4.3.2. Configuración de YOLO

Mientras que los modelos de detección de lentes y de candidatos únicamente tuvieron una clase cada uno, el proceso de clasificación morfológica de galaxias requirió la definición de clases específicas y la preparación de un conjunto de datos etiquetado. En este apartado, se describen las clases empleadas en los modelos, el procedimiento de etiquetado y la estructura organizativa para el entrenamiento de los modelos YOLO.

Etiquetado para la Detección de Lentes Gravitacionales Para el modelo de detección de lentes gravitacionales basado en YOLO11-obb, se empleó la plataforma CVAT (Computer Vision Annotation Tool) para el etiquetado de las imágenes. Esta elección se justificó porque CVAT es una de las pocas herramientas que soportan el formato de cajas delimitadoras orientadas, las cuales son necesarias para etiquetar con precisión la geometría oblicua de los arcos de las lentes gravitacionales.

El modelo se diseñó para identificar una única clase, denominada "lente", que engloba las manifestaciones del efecto de lente gravitacional fuerte, como arcos, anillos de Einstein y múltiples imágenes. Cada imagen fue etiquetada manualmente en CVAT, especificando la clase "lente". Una vez etiquetada una imagen, la herramienta genera un archivo de texto (.txt) con el mismo nombre que la imagen, el cual incluye el identificador de la clase (en este caso un 0 al ser sólo una clase) y las coordenadas (x, y) de cada esquina de la caja delimitadora que enmarca el objeto.

Se emplearon los únicos 112 recortes disponibles de la misión *Euclid* en formato TIFF (se profundizará más sobre este tema en la **Sección 5.1**).

Etiquetado para la Clasificación Morfológica de Galaxias Se desarrollaron cuatro modelos de clasificación morfológica, cada uno con un conjunto específico de clases:

- **Primer modelo:** Incluyó cinco clases: elíptica, espiral, irregular, estrella y espuria.
- **Segundo modelo:** Evolucionó a partir del primero, incorporando una sexta clase, espiral barrada, con el propósito de permitir que la red neuronal diferenciara esta subcategoría dentro de las galaxias espirales.
- **Tercer modelo:** Simplificó la tarea al limitarse a tres clases morfológicas de galaxias: elíptica, espiral e irregular. Esta reducción se implementó tras optimizar la normalización de los recortes, buscando mejorar la precisión en la identificación de galaxias.
- **Cuarto modelo:** Combinó los avances previos, utilizando cuatro clases: elíptica, espiral, espiral barrada e irregular.

El etiquetado de las imágenes se llevó a cabo utilizando el software *LabelImg*, que permite asignar manualmente categorías a los objetos en cada imagen. Este procedimiento requiere identificar con precisión la morfología de cada galaxia, ya que un etiquetado incorrecto podría introducir confusión en el modelo y degradar las métricas de desempeño. En algunos casos, una imagen

puede contener múltiples etiquetas, pero se decidió no etiquetar objetos cuya clase fuera incierta, priorizando la calidad sobre la cantidad.

El conjunto de datos (llamado dataset) consta de más de 600 recortes extraídos de la imagen FITS. La principal limitación de este proceso es la laboriosa tarea de revisar y etiquetar cada imagen de forma individual. En este caso, es el software el que genera un archivo de texto (.txt) con el mismo nombre que la imagen, el cual incluye el identificador de la clase (un número entre 0 y el número de clases menos uno, según el modelo) seguido de las coordenadas del centro de la caja delimitadora y sus dimensiones (ancho y alto), todas normalizadas entre 0 y 1. A continuación se muestra un ejemplo de etiquetado con el software mencionado:




Figura 18: Etiquetado de imagen con el software LabellImg.

Etiquetado para la Detección de Candidatos El proceso de etiquetado para el modelo de detección de candidatos a objetos con alto desplazamiento al rojo se llevó a cabo utilizando el software LabellImg. Se definió una única clase, "candidato", que engloba objetos con colores que varían desde un rojo anaranjado hasta un rojo profundo, característicos de objetos como estrellas y galaxias lejanas afectadas por el desplazamiento al rojo cosmológico.

Se empleó una imagen de alta resolución a color en formato TIFF (ya que la imagen FITS está en escala de grises), de 8800×8800 píxeles, obtenida de la misión *Euclid* y correspondiente al cúmulo de Perseo (**Fig. 2**). De esta imagen se generaron 400 recortes de 448×448 píxeles. Una inspección visual confirmó que la mayoría de estos recortes contenían al menos dos candidatos por imagen, resultando en un conjunto de datos con más de 1000 etiquetas. Este volumen aseguró una base sólida para el entrenamiento, aunque la tarea de etiquetado manual fue laboriosa y susceptible a omisiones en objetos tenues.

4.3.3. Estructura del Conjunto de Datos para el Entrenamiento

La organización del conjunto de datos se diseñó para cumplir con los requisitos de los modelos YOLO. Se creó una carpeta principal, denominada `YOLO_dataset`, que contiene dos subcarpetas; **images**, que almacena las imágenes en formato PNG, y **labels**, que contiene los archivos de texto con las etiquetas correspondientes. Cada una de estas subcarpetas se divide a su vez en **train**, que incluye las imágenes y etiquetas utilizadas para entrenar el modelo y **val**, que contiene las imágenes y etiquetas empleadas para validar el desempeño del modelo [30]. A continuación se muestra un esquema de la estructura del dataset:

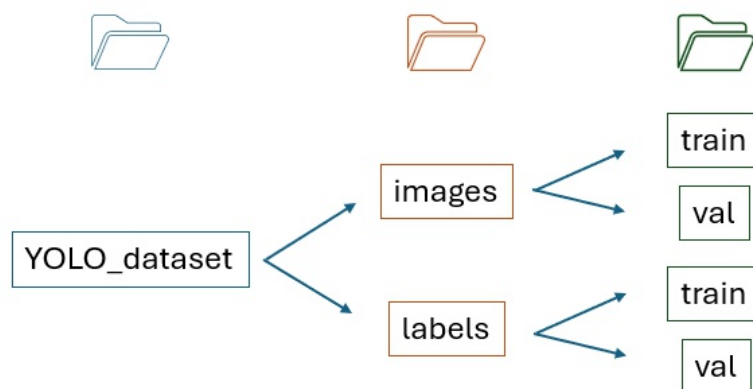


Figura 19: Esquemización de las carpetas para el entrenamiento de YOLO.

De las más de 600 imágenes disponibles, se asignó aproximadamente el 80 % a la carpeta *train* y el 20 % a la carpeta *val*. Esta distribución asegura que el modelo disponga de suficientes datos para aprender patrones, mientras reserva un conjunto representativo para evaluar su precisión. Las imágenes en *val* permiten al modelo realizar predicciones y compararlas con las etiquetas reales, generando métricas como precisión y recall. En la carpeta *labels* va el etiquetado de las imágenes (los archivos de texto) y deben coincidir con su imagen correspondiente, tanto en nombre como en ubicación. Por ejemplo si la imagen `galaxia_5.png` se encuentra en `images/train`, el archivo `galaxia_5.txt` debe estar en `labels/train` y no en `labels/val`.

La división de imágenes y etiquetas entre *train* y *val* se automatizó mediante un script en Python, evitando la tediosa tarea de realizar esta asignación manualmente y minimizando errores. Dicho script se encuentra recogido en el link de la **Sección 9.2- Script 7**.

4.3.4. Archivo de configuración

El entrenamiento de los modelos requiere un archivo en formato YAML (Yet Another Markup Language), que define los parámetros necesarios para el proceso. Dado que se emplearon modelos preentrenados (YOLOv8 para los tres primeros modelos y YOLOv11 para el cuarto), la configuración se simplificó, incluyendo solo los elementos esenciales [30]:

- **path:** Ruta absoluta a la carpeta principal del conjunto de datos (`YOLO_dataset`).

- **train:** Ruta a la carpeta que contiene las imágenes de entrenamiento (images/train).
- **val:** Ruta a la carpeta con las imágenes de validación (images/val).
- **nc:** Número de clases, especificado según el modelo (5, 6, 3 o 4).
- **names:** Lista de nombres de las clases (por ejemplo [”elíptica”, ”espiral”, ”irregular”, ”estrella”, ”espuria”] para el primer modelo).

Adicionalmente, se pueden incorporar parámetros opcionales, como *weights*, para ajustar la importancia relativa de las clases durante el entrenamiento, o *augmentation*, para aplicar técnicas de aumentación de datos que mejoren las métricas en clases poco representadas. Estas técnicas se abordarán al final de la **Sección 5.2.1** donde sí se implementaron.

4.3.5. Entrenamiento

Tras configurar un entorno virtual y realizar pruebas preliminares, como la inclusión de la herramienta CUDA, para ejecutar los modelos con GPU en vez de CPU, se llevó a cabo el primer entrenamiento. Este se ejecutó mediante el siguiente comando en la terminal *conda*:

```
yolo train model=yolov8n.pt data=yolo_dataset.yaml epochs=50  
imgsz=640 batch=8 workers=0
```

A continuación se van a desglosar cada uno de estos términos, llamados hiperparámetros. El primero de ellos tras `yolo` es `train`, el cual indica que el modelo está en modo de entrenamiento. Otros modos disponibles incluyen `predict`, para realizar predicciones con un modelo entrenado, y `val`, para evaluar métricas de validación [31]. Luego se especifica el tipo de modelo que se va a usar. Por ejemplo, en el primer entrenamiento de clasificación morfológica, se utilizó `yolov8n.pt` (versión nano de YOLOv8), que cuenta con aproximadamente 3 millones de parámetros, siendo el más ligero y rápido. En algunos entrenamientos posteriores, se emplearon los pesos del modelo previamente entrenado para optimizar los resultados, en lugar de iniciar desde cero. Para el cuarto modelo, se usó `yolov11s.pt`, acorde con la transición a YOLOv11. Con `data` se especifica el archivo YAML que contiene la configuración del conjunto de datos. El término `epochs` hace referencia a las épocas de entrenamiento del modelo, es decir el número de ciclos completos en los que la red neuronal ve los datos de entrenamiento de una vez [31]. Inicialmente se establecieron 50 iteraciones, suficiente para permitir al modelo aprender patrones sin sobreajuste inicial. El hiperparámetro `imgsz` indica tamaño objetivo de las imágenes de entrenamiento en píxeles [31]. Inicialmente, los recortes tenían una resolución de 300×300 píxeles, pero se redimensionaron a 640×640 píxeles para cumplir con los requisitos de YOLO. Este cambio mejoró la precisión, aunque incrementó el consumo de memoria y el tiempo de computación, siendo viable tras optimizar los recursos gráficos para los modelos posteriores. Por otra parte, `batch` indica el tamaño del lote, es decir, cuántas imágenes se procesan simultáneamente en cada paso del entrenamiento [31]. En este caso, el modelo procesa 8 imágenes por iteración antes de actualizar los pesos. Un valor mayor, como 16, se evaluó pero resultó inviable debido a limitaciones de hardware. Sin

embargo, en el modelo de detección de lentes gravitacionales, al tener un dataset menor y tan solo una clase, sí que se pudo usar este tamaño de batch. Finalmente, `workers` fue establecido en 0 para evitar problemas de paralelización en Windows, asegurando que la carga de datos se realice en el proceso principal [31].

4.3.6. Métricas de entrenamiento

Antes de analizar los resultados del entrenamiento, se describirán las métricas empleadas para evaluar el desempeño del modelo, fundamentales para interpretar su precisión y robustez [32]:

En primer lugar tenemos Precisión, que mide la proporción de detecciones correctas realizadas por el modelo [32]. Se calcula como:

$$Precision = \frac{TP}{TP + FP} \quad (4.1)$$

donde TP (del inglés True Positives) indica que el modelo ha realizado una detección correcta y FP (False Positives) indica que la detección es incorrecta, como predecir un objeto donde no hay o clasificarlo incorrectamente [32]. Por ejemplo si el modelo detecta 100 objetos y 80 son correctos, la precisión es 0.80.

El Recall evalúa la proporción de objetos reales que el modelo detectó. Se define como:

$$Recall = \frac{TP}{TP + FN} \quad (4.2)$$

donde FN (False Negative) son los falsos negativos, es decir objetos que existen pero que el modelo no identificó.

A partir de estas 2 primeras métricas existen las llamadas curvas Precisión-Recall, que indican la relación entre ambas [32]. Aumentar la precisión puede reducir el recall, ya que el modelo se vuelve más estricto, mientras que un recall elevado puede disminuir la precisión al detectar más objetos con mayor riesgo de error. El objetivo es lograr un equilibrio óptimo entre ambas métricas, y esto se visualiza con las curvas F1-score.

También está la métrica mAP50 (Mean Average Precision IoU=0.50). Esta promedia la precisión de todas las clases utilizando un umbral de IoU (Intersection over Union) de 0.50 [32]. El IoU mide la superposición entre la caja delimitadora predicha y la real, calculado como:

$$IoU = \frac{Area\ de\ interseccion}{Area\ de\ union} \quad (4.3)$$

Por defecto, si $IoU \geq 0.5$, se considera una detección correcta, siendo esta métrica un estándar para evaluar la precisión general del modelo.

Finalmente tenemos mAP50-95, la cual es similar a mAP50, pero en lugar de usar un solo umbral IoU=0.50, promedia valores de IoU desde 0.50 hasta 0.95 en pasos de 0.05 [32], y se calcula como:

$$mAP50 - 95 = \frac{1}{10} \sum_{t=0,50}^{0,95} mAP@t \quad (4.4)$$

Esta métrica es más estricta por lo que ofrece una visión más global del rendimiento a distintos umbrales de detección [32].

4.4. Resultados del TFG

Se desarrolló un modelo basado en YOLO11-obb (llamado *lentev5*) que identifica el efecto de lente gravitacional fuerte. Utilizando un conjunto inicial de 112 recortes de imágenes de la misión *Euclid*, el modelo alcanzó un mAP50 de 0.93 y un recall de 0.90, demostrando una alta precisión en la detección de estas estructuras. El modelo fue capaz de localizar correctamente arcos en recortes del cúmulo Abell 2390 y un anillo de Einstein en la galaxia NGC 6505, aunque en este último caso requirió un zoom centrado para lograrlo. El entrenamiento comenzó con los pesos preentrenados de YOLO11-obb. El modelo tuvo limitaciones iniciales debido al reducido tamaño del conjunto de datos, lo que llevó a incorporar imágenes negativas (sin lentes) para reducir falsos positivos causados por galaxias o estrellas. Además, se realizaron reentrenamientos con ajustes en la tasa de aprendizaje (`lr0` reducido a 0.0025 y uso de `cos_lr=True`) para optimizar la convergencia. Estas iteraciones mejoraron la capacidad del modelo para discriminar lentes en imágenes complejas, consolidando su utilidad para aplicaciones en imágenes astronómicas de alta resolución.

Se implementó un modelo final de clasificación morfológica de galaxias (*train3v2*) con cuatro clases (elíptica, espiral, espiral barrada e irregular), alcanzando un mAP50 general superior a 0.80, con valores entre 0.70 (irregular) y 0.90 (elíptica). El desarrollo de este modelo comenzó con un conjunto de más de 600 imágenes del cúmulo de Perseo, ampliado posteriormente con recortes del cúmulo Abell 2390 para mejorar el recall de clases como espiral barrada. Se implementaron técnicas de aumentación de datos y ajustes de pesos de clases para compensar el desequilibrio entre clases. Un cambio clave durante el proyecto fue la optimización del preprocesamiento de imágenes, ajustando el brillo para maximizar el contraste y reducir la confusión con el fondo, lo que mejoró significativamente las métricas en comparación con los modelos iniciales.

Finalmente se entrenó un modelo para detectar candidatos a objetos con alto desplazamiento al rojo, esenciales para estudiar el universo temprano. Utilizando 400 recortes de 448×448 píxeles del cúmulo de Perseo, el modelo alcanzó un mAP50 de 0.85, demostrando potencial para identificar objetos lejanos con colores rojizos característicos. El entrenamiento requirió desactivar las técnicas de aumentación de color para evitar distorsiones en las tonalidades del rojo, un ajuste crítico que mejoró las predicciones.

5. RESULTADOS

5.1. Modelo de detección de lentes gravitacionales

El desarrollo de un modelo para detectar lentes gravitacionales fuertes, como arcos y anillos de Einstein, presentó desafíos significativos debido a la escasez de imágenes reales de alta calidad. La redacción de este trabajo comenzó en febrero de 2025, pero no fue hasta finales de marzo que se logró acceder a un número suficiente de recortes de calidad. En ese momento, la Agencia Espacial Europea (ESA) publicó un catálogo preliminar de 500 galaxias candidatas a estar afectadas por el efecto de lente gravitacional fuerte, de las cuales solo 112 estaban disponibles públicamente. Se proyecta que la misión *Euclid* identificará más de 7,000 candidatos para finales de 2026 y hasta 100,000 al concluir la misión, un aumento de cien veces respecto al conocimiento actual [33].



Figura 20: Candidatos a lente gravitacional publicados por la ESA [33].

Los recortes obtenidos mostraban una variedad de configuraciones, con arcos dispuestos diagonalmente y anillos completos o parciales. Sin embargo, esto complicó su representación mediante cajas delimitadoras tradicionales.

La detección de lentes gravitacionales requiere una representación precisa, por lo que se seleccionó el modelo YOLO11n-obb, una variante de YOLOv11 cuyas ventajas fueron expuestas en la **Sección 4.3.1**.

El modelo se configuró para identificar una única clase, "lente", que engloba todas las manifestaciones del efecto de lente gravitacional fuerte. Esta elección simplificó la tarea, enfocándola en la localización de patrones distintivos sin necesidad de subcategorías.

El conjunto de datos de entrenamiento incluyó los 112 recortes disponibles, distribuidos en 90 para entrenamiento (train) y 22 para validación (val). La limitada cantidad de datos representó un desafío.

Dado que se utilizó la versión nano de YOLO11-obb y una sola clase ("lente"), fue posible aumentar el tamaño del batch a 16 imágenes sin comprometer los recursos computacionales, mejorando la calidad del entrenamiento. El entrenamiento inicial se configuró con 100 épocas, sin aumento de datos ni pesos diferenciados, para evaluar el comportamiento base.

Las métricas fueron verdaderamente prometedoras en este primer entrenamiento (denominado "lentev1"), con la precisión y el mAP50 superando el 90 % y un recall del 87 %.

Tabla 1: Métricas de desempeño del modelo lentev1.

Clase	Métricas			
	Precisión	Recall	mAP@50	mAP@50:95
Lente	0,920	0,871	0,939	0,564

Las predicciones en el conjunto de validación confirmaron la capacidad del modelo para localizar e identificar correctamente arcos y anillos en imágenes gracias al uso de cajas orientadas.




Figura 21: Etiquetado (4×4 izquierda) y predicción (4×4 derecha) del modelo lentev1.

Una vez entrenado el modelo, el objetivo fue aplicarlo a imágenes de *Euclid* en las cuales se conociese de antemano la existencia de lentes gravitacionales, como las del cúmulo Abell 2390 (Fig. 22), para evaluar su capacidad de detección y realizar los ajustes necesarios.




Figura 22: Zoom en la región de Abell 2390 donde hay arcos.

Sin embargo, al aplicar `lentev1` a todos los recortes de Abell 2390, el modelo falló en detectar uno de los arcos principales en la región destacada del cúmulo, mostrado en la **Fig. 22**. Su principal problema fue la confusión entre galaxias con arcos, generando falsos positivos. Al realizar un zoom intensivo sobre el arco y volver a ejecutar el modelo, este lo identificó correctamente, pero siguió detectando galaxias como arcos en otros recortes.

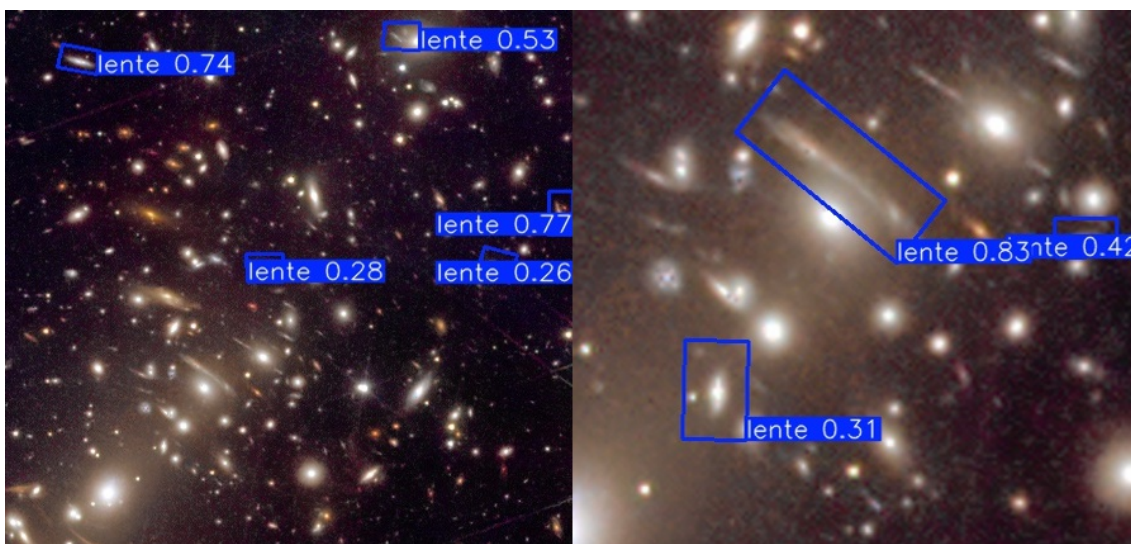


Figura 23: A la izquierda detecciones incorrectas del modelo. A la derecha, detección correcta del arco.

Para abordar este problema, se realizó un reentrenamiento con 50 épocas, implementando una tasa de aprendizaje baja para un ajuste fino (fine-tuning). Se redujo la tasa de aprendizaje predeterminada ($lr0=0.01$) para permitir actualizaciones más precisas de los pesos. En el comando de ejecución del entrenamiento se incluyó el hiperparámetro:

$$lr0=0.0025$$

Las métricas del modelo mejoraron, llegando el mAP50 a un 94 % y el mAP50-95 superó el 65 %. Sin embargo, el problema persistió, ya que no era capaz de identificar en los recortes el efecto lente sin ayuda de zoom intensivo. Este comportamiento se atribuyó a una diferencia clave en el conjunto de datos de entrenamiento: las imágenes de entrenamiento (**Fig. 20**) contenían lentes gravitacionales aisladas, mientras que los recortes de Abell 2390 incluían múltiples galaxias y estrellas, lo que complicaba la discriminación.

Para solucionar este problema, se implementó una estrategia efectiva: se añadieron imágenes sin lentes gravitacionales a la carpeta `images/train`, sin etiquetas asociadas. Esto permitió al modelo interpretar estas imágenes como fondo, entrenándolo para ignorar galaxias y estrellas irrelevantes y centrarse en patrones característicos de lentes gravitacionales.

El impacto fue inmediato. El modelo reentrenado (`lentev3`) dejó de etiquetar la mayoría de los recortes de Abell 2390, lo cual era correcto, ya que no contenían arcos ni anillos. Finalmente, logró detectar con precisión el arco principal en la región destacada del cúmulo (**Fig. 22**), validando la eficacia de la solución:



Figura 24: Predicción correcta del modelo sobre los arcos a distintas resoluciones.

Para probar la generalización del modelo, se aplicó *lentev3* a una imagen publicada por *Euclid* en febrero de 2025, que mostraba un anillo de Einstein alrededor del centro de la galaxia NGC 6505 [34].




Figura 25: Anillo de Einstein alrededor del centro de la galaxia NGC 6505 [34].

Inicialmente, el modelo no detectó el anillo, ni en la imagen completa ni con zoom sobre el centro de la galaxia. Para abordar este problema, se reentrenó el modelo 2 veces más, variando la tasa de aprendizaje y incluyendo este otro hiperparámetro:

```
cos_lr=True
```

Este hiperparámetro ajusta la tasa de aprendizaje siguiendo una curva coseno a lo largo de las épocas, ayudando a gestionar la tasa de aprendizaje para mejorar la convergencia [31].

Tras estos ajustes, el modelo *lentev5* logró detectar correctamente el anillo de Einstein en la imagen de NGC 6505 con un zoom centrado en el centro de la galaxia, aunque no en la imagen completa. Las métricas finales tuvieron un mAP50 de 0.93, un recall de 0.90 y un mAP50-95 de 0.63.




Figura 26: Detección correcta del modelo sobre el anillo de Einstein.

Un estudio publicado en abril de 2025 [35] reportó la detección de múltiples candidatos a lentes gravitacionales fuertes mediante CNNs, incluyendo 19 lentes en el cúmulo de Abell 2390. Sin embargo, al realizar una inspección visual de los recortes generados a partir de la imagen TIFF a color de este cúmulo (**Fig. 22**), se comprobó que era imposible identificar las morfologías de estas lentes debido a su pequeño tamaño y la insuficiente calidad de la imagen. Para confirmar esta observación, se examinó la imagen FITS original del cúmulo, de $42,000 \times 42,000$ píxeles, utilizando el software Aladin. Esta inspección reveló que, efectivamente, las lentes gravitacionales mostradas en el artículo eran estructuras extremadamente pequeñas, visibles solo en la imagen de mayor resolución. Aprovechando el catálogo de galaxias creado previamente para el modelo de clasificación morfológica, se generaron 19.361 recortes de 175×175 píxeles a partir de la imagen FITS del cúmulo Abell 2390. Al ejecutar el modelo sobre este conjunto de datos, con una confianza de $\text{conf}=0.6$, se lograron identificar 6 de los candidatos mencionados en el artículo [35], indicando así margen de mejora en el modelo. En la **Fig. 27** se muestra la confianza de las predicciones del modelo sobre los candidatos, y en la **Fig. 28** se muestran los mismos candidatos sin etiquetas para una mejor visualización. Las principales detecciones falsas del modelo confundieron algunos brazos de galaxias espirales con los arcos del efecto lente fuerte.

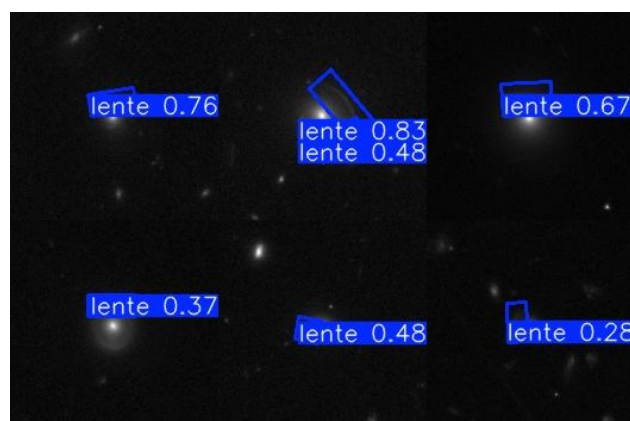


Figura 27: Predicción del modelo lentev5 con etiquetas sobre recortes del cúmulo Abell 2390.

El modelo lentev5 demostró un buen desempeño en la detección de lentes gravitacionales, superando las limitaciones iniciales mediante la incorporación de imágenes de fondo y ajustes finos en la tasa de aprendizaje. La capacidad de detectar arcos en Abell 2390 o el anillo en la galaxia NGC 6505 (con zoom) valida la robustez del modelo y el uso de cajas orientadas para estructuras complejas. La escasez de datos, con tan solo 112 recortes, hizo que su generalización no fuese tan buena. Sin embargo, el éxito con un conjunto tan limitado hace pensar que la futura disponibilidad de miles de candidatos de *Euclid* permitirá desarrollar modelos aún más precisos.

En la **Sección 9.1** hay un link para visualizar todos los candidatos detectados por el modelo lentev5 en el cúmulo Abell 2390 (incluyendo los no presentes en el artículo [35]), con sus coordenadas de ascensión recta (RA) y declinación (DEC). También se encuentra disponible en la **Sección 9.2** el catálogo del cúmulo Abell 2390 a partir del cual se generaron los 19361 recortes.




Figura 28: Candidatos a lente fuerte identificados por lentev5, presentes en el artículo [35]. Recortes generados a partir de la imagen FITS del cúmulo Abell 2390 y su correspondiente catálogo.

5.2. Modelo de clasificación morfológica de galaxias

5.2.1. Modelo de 5 clases

El modelo train18, basado en YOLOv8n, se entrenó con un conjunto de datos de 600 imágenes, distribuidas en 480 para entrenamiento (train) y 120 para validación (val). Las clases consideradas fueron elíptica, espiral, irregular, estrella y espuria. Las métricas obtenidas fueron las siguientes:

Tabla 2: Métricas de desempeño generales y por clase del modelo train18.

Clase	Métricas			
	Precisión	Recall	mAP@50	mAP@50:95
Generales	0,630	0,338	0,430	0,236
Elíptica	0,800	0,668	0,837	0,397
Espiral	0,679	0,562	0,606	0,377
Irregular	0,649	0,077	0,136	0,099
Estrella	0,484	0,051	0,187	0,091
Espuria	0,537	0,334	0,385	0,216

Analizando las métricas generales en primer lugar, se puede observar que la precisión fue moderada con un 63 % de predicciones son correctas. Sin embargo el recall fue bajo, ya que solo detectó el 33.8 % de los objetos reales. El mAP50 tuvo un valor por debajo del 50 % y el valor de mAP50-95 indicó una baja precisión en la localización exacta de las cajas delimitadoras a umbrales más estrictos. Se pueden entender más en profundidad estos resultados mirando las métricas por clase.

Las tres métricas principales para la clase elíptica son fuertes, y moderadas para la clase espiral. Sin embargo, aunque para la clase irregular la precisión fue moderada, tanto el recall como el mAP50 fueron malos, sugiriendo que el modelo apenas detectaba objetos de esta clase. Esto se puede deber a varios factores, desde una confusión del modelo con otra clase hasta falta de etiquetas de esa clase o necesidad de más épocas de entrenamiento.

La matriz de confusión confirmó que las clases irregular, estrella y espuria eran frecuentemente confundidas con el fondo de imagen (background), un problema que persistió en iteraciones posteriores y que no se solucionó hasta el cambio de dataset con el brillo normalizado.




Figura 29: Matriz de confusión del modelo train18. El eje x corresponde a la clase real y el eje y a clase predicha por el modelo.

Algunas de las predicciones de este modelo fueron las siguientes (a la izquierda la imagen etiquetada y a la derecha la predicción de la misma imagen)




Figura 30: Etiquetado (2x2 izquierda) y predicción (2x2 derecha) del modelo train18.

La distribución de clases en este punto en la carpeta de entrenamiento era la siguiente:

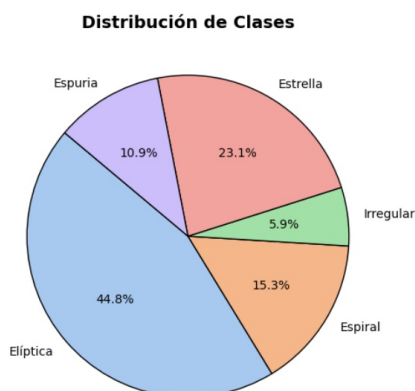


Figura 31: Distribución de clases en el dataset.

Dado el desempeño limitado de train18 y train19 (un ajuste ligero de train18) y considerando que YOLOv8n es el modelo más ligero (con 3 millones de parámetros), se decidió emplear YOLOv8s, con 11.1 millones de parámetros para entrenar el modelo train20. Este cambio buscaba mejorar las métricas al aumentar la capacidad del modelo. Sin embargo, los resultados mostraron solo una leve mejora.

En el modelo train21, se utilizaron los pesos de train20 como punto de partida, ejecutando el entrenamiento con el comando:

```
yolo train model=train20/weights/best.pt ...
```

Se entrenó con 200 épocas, esperando una mejora significativa. Sin embargo, aunque recall, mAP50 y mAP50-95 aumentaron ligeramente, la precisión disminuyó considerablemente respecto a modelos anteriores.

Tabla 3: Métricas de desempeño generales y por clase del modelo train21.

Clase	Métricas			
	Precisión	Recall	mAP@50	mAP@50:95
Generales	0,433	0,494	0,465	0,257
Elíptica	0,740	0,789	0,801	0,362
Espiral	0,567	0,750	0,653	0,418
Irregular	0,360	0,231	0,281	0,185
Estrella	0,260	0,271	0,203	0,079
Espuria	0,240	0,429	0,386	0,243

La matriz de confusión mostró aún una mayor confusión entre clases, sugiriendo dificultades para diferenciar las morfologías distintivas.

Para train22, se reentrenaron los pesos de train21 con 100 épocas y se añadieron los hiperparámetros $\text{conf}=0.1$ (umbral de confianza bajo para retener más predicciones) y $\text{iou}=0.6$ (umbral de solapamiento para supresión de no máximos). Esto permitió evaluar si el modelo descartaba predicciones correctas por baja confianza.




Figura 32: Métricas generales de los modelos train18, train21 y train22.

Aunque las predicciones mejoraron en casos específicos (p. ej en la galaxia_119, donde se identificaron correctamente múltiples clases en comparación a la Fig. 30), las métricas generales no mostraron avances significativos.




Figura 33: Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo train22.

Un análisis posterior reveló un error crítico en el etiquetado: algunas estrellas estaban etiquetadas como espurias, lo que inducía confusión en el modelo. Curiosamente, a la hora de realizar predicciones el modelo corregía ciertos errores de etiquetado, identificando patrones reales, pero las métricas se veían penalizadas al compararse con etiquetas incorrectas.




Figura 34: Etiquetado erróneo (2×2 izda) de la clase estrella. Predicción del modelo (2×2 dcha).

Tras corregir los errores de etiquetado y realizar entrenamientos progresivos desde cero (a 50, 100, 150 épocas), se obtuvo el modelo train27, el más efectivo para las cinco clases iniciales. Las métricas mejoraron en comparación a modelos anteriores, como se muestra en las **Figs. 35 y 36**:

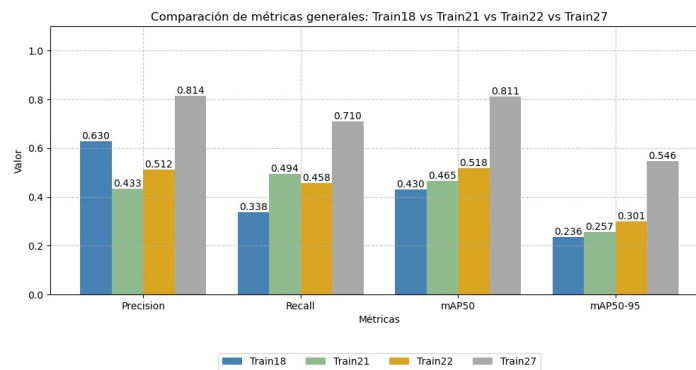


Figura 35: Comparación de métricas generales de train18, train21, train22, train27.

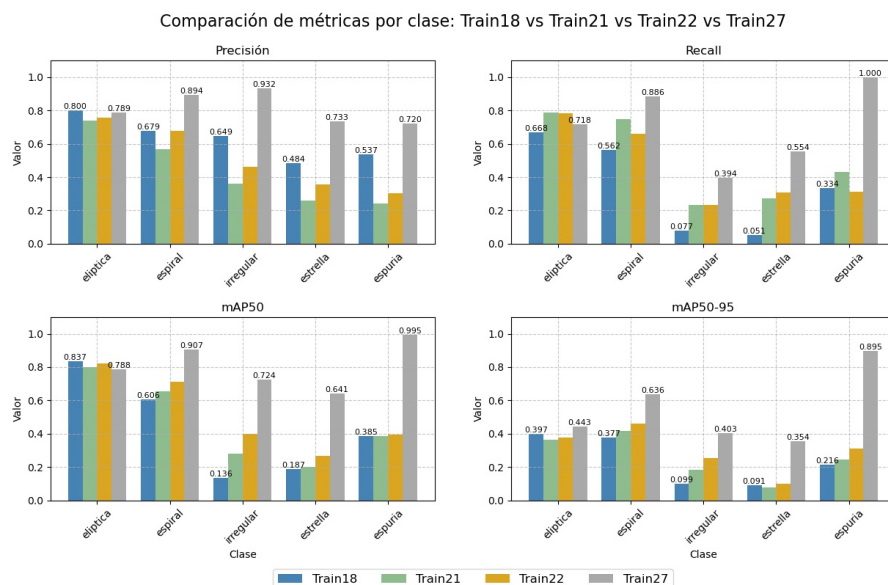


Figura 36: Comparación de métricas por clase de train18, train21, train22, train27.

Mientras que la mAP50 de la clase elíptica se mantuvo aproximadamente en el mismo valor que en los modelos anteriores, en el resto de clases subió considerablemente, siendo espuria la mejor de ellas. Esto se debe a que el patrón de esta clase es estable y no varía en morfología de imagen a imagen. La métrica precisión se comportó de manera similar, pero en este caso fue la clase irregular la que mejor resultado obtuvo. Finalmente, la métrica recall fue más sólida en las clases espiral y espuria. Sin embargo, la clase irregular, a pesar de haber obtenido buen mAP50 (0.724) y precisión (0.932), su recall fue mediocre (0.394).

Esto indica que el modelo es muy selectivo al clasificar esta clase, ya que cuando predice que un objeto pertenece a ella, suele estar en lo correcto pero a su vez pierde muchas instancias reales de la clase (es decir bajo recall). Sin embargo hay una explicación para este fenómeno. Existe un desequilibrio de clases en los datos del entrenamiento. En la imagen del cúmulo de Perseo hay muchas más galaxias de tipo elíptica y espiral que irregulares. Además, de las pocas imágenes que irregulares, hay muchas de ellas que son difusas y no se aprecia un patrón determinado. Por tanto, hay pocas muestras de esta clase en comparación a las demás. A continuación se muestran algunas imágenes etiquetadas y la predicción sobre las mismas del modelo.

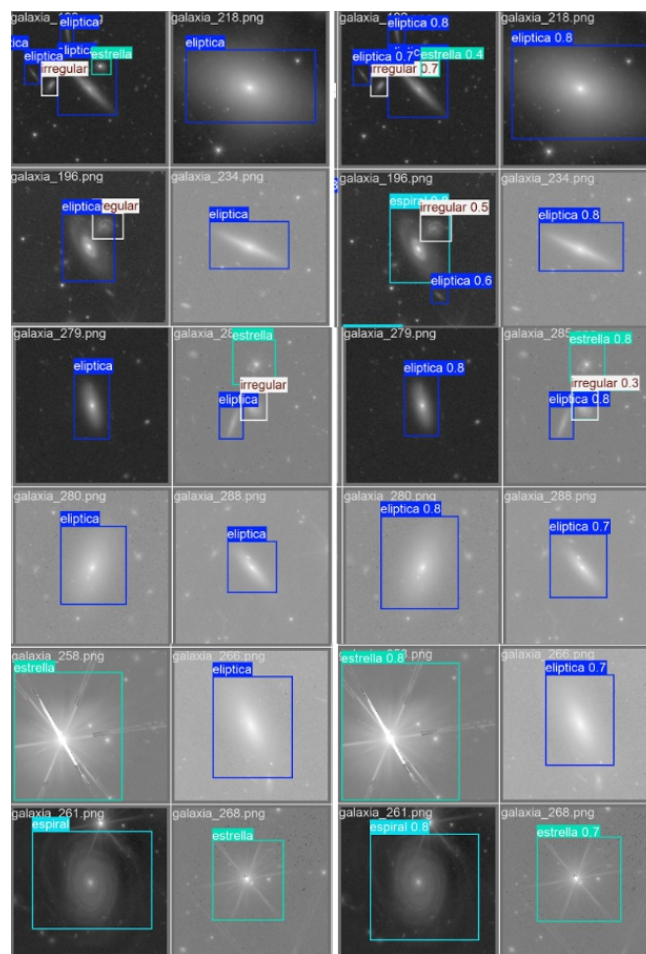


Figura 37: Etiquetado (6×2 izquierda) y precisión (6×2 derecha) del modelo train27.

Para abordar el desequilibrio de clases y mejorar el recall de la clase irregular, se implementó la técnica de aumentación de datos. Esta consiste en aplicar transformaciones a las imágenes originales para incrementar la diversidad del conjunto de datos y evitar el sobreajuste [36]. Los parámetros de aumentación se definieron en el archivo YAML como sigue:

```
augmentation:
  flipud: 0.5
  fliplr: 0.5
  hsv_h: 0
  hsv_s: 0.5
  hsv_v: 0.5
  scale: 0.5
  translate=0.25
  mosaic: 1.0
```

Las dos primeras, `flipud` y `fliplr`, se encargan de voltear las imágenes de forma vertical y horizontal respectivamente, y se les asigna un 50 % de probabilidad de que lo hagan, aumentando la variabilidad en la orientación. El siguiente parámetro, que normalmente aplicaría un cambio aleatorio en el matiz de la imagen en el espacio de color HSV, se ha establecido en 0, ya que las imágenes FITS están en escala de grises y no contienen información de matiz. Las dos siguientes se encargan de la variación de la saturación y del brillo. El parámetro `scale` indica que las imágenes pueden ser escaladas aleatoriamente en un factor de $\pm 50\%$, permitiendo que el modelo aprenda a detectar imágenes de distintos tamaños. A continuación, `translate` permite que las imágenes puedan moverse un 25 % en cualquier dirección, simulando así escenarios en los que los objetos aparecen en distintas partes del campo visual. Finalmente tenemos la aumentación con mosaico, cuyo valor de 1 indica que esta técnica está activada al 100 %. Consiste en combinar hasta 4 imágenes en una sola, cambiando la distribución de los objetos en la imagen. Es una de las técnicas más potentes en YOLO, ya que ayuda a mejorar la detección de objetos en múltiples escalas y posiciones [36].

Además de esto, en el archivo de configuración yaml se ajustaron los pesos de las clases para compensar el desequilibrio::

```
weights =[1, 1, 4, 0.5, 0.5]
```

Estos valores asignaron mayor importancia a la clase irregular (peso=4) frente a elíptica, espiral, estrella y espuria, promoviendo un aprendizaje más equilibrado.

A pesar de la aumentación y los ajustes de pesos, el recall de la clase irregular no mejoró significativamente. Esto sugiere que el modelo alcanzó un límite en su capacidad para generalizar esta clase con los datos disponibles.

5.2.2. Modelo de 6 clases

El segundo modelo (`train27_espisal`) buscó mejorar el desempeño del modelo `train27` al incorporar la capacidad de distinguir entre galaxias espirales y espirales barradas. Estas últimas presentan una estructura en forma de barra en el bulbo central desde la cual emergen los brazos espirales. En la siguiente imagen se muestran las diferencias morfológicas entre ambos tipos de galaxias:




Figura 38: Comparación morfológica de galaxias espirales (izda) y espirales barradas (dcha). Recortes generados a partir del catálogo generado con SExtractor y la imagen FITS mediante un script en Python.

La introducción de la clase "espiral barrada" requirió un reetiquetado manual de todo el conjunto de datos, una tarea laboriosa pero esencial para garantizar la precisión de las etiquetas. Cada imagen se revisó para asignar correctamente las seis clases: elíptica, espiral, espiral barrada, irregular, estrella y espuria.

Antes de iniciar el entrenamiento, se actualizó el archivo YAML para reflejar la nueva clase. El parámetro `nc` se modificó a 6, correspondiente al número total de clases. También se cambió el parámetro `names` al añadir "espiral barrada" a la lista de clases, manteniendo las demás sin cambios.

El entrenamiento reutilizó los pesos del modelo `train27` (`model=train27/weights/best.pt`), evitando comenzar desde cero para preservar las métricas previas. Sin embargo, la incorporación de una nueva clase aumentó la complejidad de la tarea, por lo que se esperó que inicialmente se redujeran las métricas debido al reajuste de los pesos del modelo.

El primer entrenamiento se ejecutó a 50 épocas para evaluar el comportamiento del modelo. Las métricas fueron las siguientes:

Tabla 4: Métricas de desempeño generales y por clase del modelo train27_espíral.

Clase	Métricas			
	Precisión	Recall	mAP@50	mAP@50:95
Generales	0,500	0,713	0,572	0,385
Elíptica	0,627	0,824	0,751	0,417
Espiral	0,354	0,821	0,445	0,282
Irregular	0,584	0,297	0,444	0,296
Estrella	0,568	0,510	0,428	0,213
Espuria	0,601	1,000	0,990	0,873
Espiral barr	0,393	0,834	0,389	0,256

Excepto el recall, todas las métricas disminuyeron tal y como se esperaba. La bajada en precisión indicó más falsos positivos, mientras que la bajada de mAP50 indicó una menor precisión en las detecciones.

Comparando la mAP50 con la de su predecesor (train27) en la **Fig. 36**, se puede observar que, mientras que su valor en la clase elíptica no varió demasiado, la clase más afectada fue la espiral como era de esperar, seguido de irregular y estrella.

Por otra parte, el recall se mantuvo muy similar, con una leve mejora en la clase elíptica. El hecho de que el recall se mantenga casi igual sugiere que el modelo sigue detectando los objetos de interés, es decir que su localización en la imagen no se ve demasiado afectada.

Finalmente, en la comparación de precisión por clases, la disminución de esta métrica en la clase “espiral” fue drástica. Esto se debe a la confusión del modelo con la nueva clase espiral barrada. Esto indicó que las 50 épocas fueron insuficientes para que el modelo aprendiera a diferenciar estas clases.

La matriz de confusión respaldó la confusión del modelo. Este clasificó erróneamente galaxias espirales como espirales barradas en un 45 % de los casos, y viceversa en un 50 %.

En la siguiente predicción de imágenes se puede apreciar la confusión del modelo:




Figura 39: Etiquetado (4×2 izquierda) y predicción (4×2 derecha) del modelo train27_espiral.

El comportamiento de este modelo implica que detectó los objetos de manera similar al modelo anterior debido a su alto recall, pero la capacidad para distinguir correctamente entre "espiral" y "espiral barrada" no fue suficiente, afectando la precisión y las métricas mAP. Para abordar este problema, se refinaron los hiperparámetros para mejorar la discriminación entre las clases. En los tres reentrenamientos posteriores, el número de épocas se incrementó a 200, permitiendo una convergencia más robusta. Un ensayo con 400 épocas no mostró mejoras significativas, por lo que se mantuvo en 200. Por otra parte, se ajustaron los pesos de las clases en el archivo yaml. Se dio menos prioridad a la clase elíptica (un valor de 0.5) siendo esta la más representada, y un valor más alto a la clase espiral barrada (un valor de 5), promoviendo un aprendizaje enfocado en esta nueva categoría.

Finalmente se obtuvieron las siguientes métricas.




Figura 40: Métricas generales del modelo train27, train27_espiral y train27_espiral5.

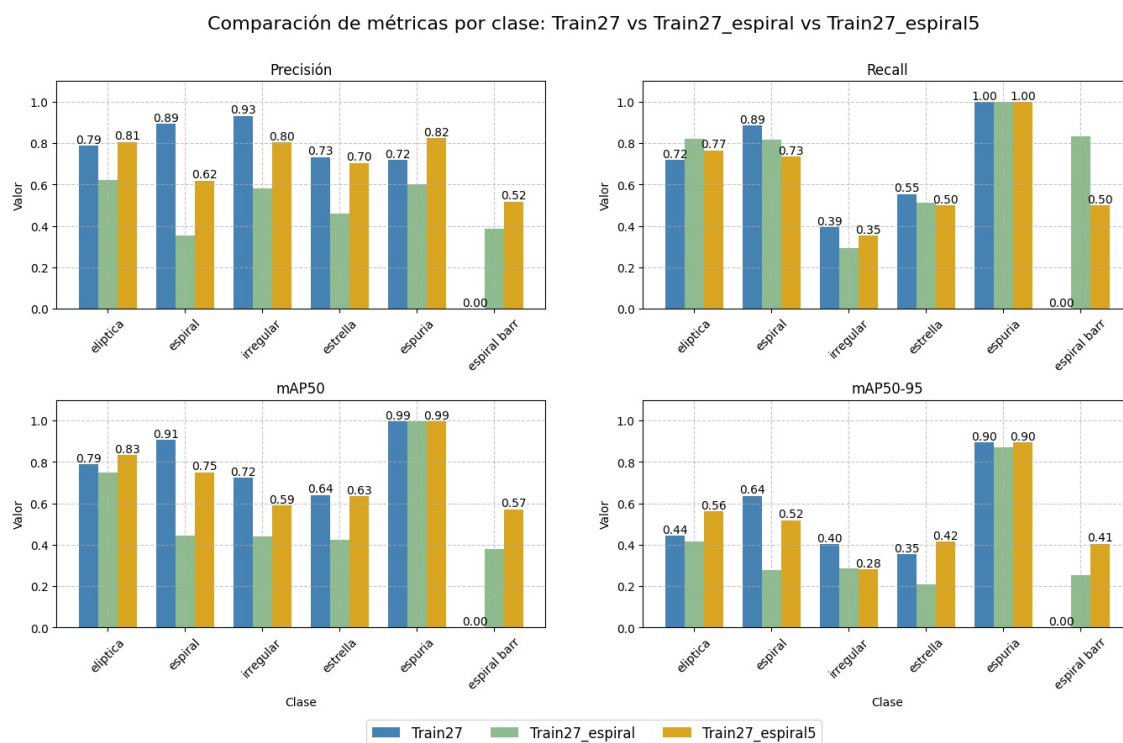


Figura 41: Métricas por clase del modelo train27, train27_espiral y train27_espiral5.

En las **Figs. 40-41** se muestra el mejor modelo con 5 clases (train27), el segundo modelo de 6 clases (train27_espiral) y el mejor segundo modelo de 6 clases (train27_espiral5). Entre el primer y último modelo de 6 clases, la única clase que disminuyó ligeramente fue el recall, mientras que en el resto mejoraron, siendo las más notorias la precisión y el mAP50. Esto significa que el modelo mejoró en la clasificación de los objetos detectados, implicando una menor cantidad de falsos positivos. La disminución de recall se pudo deber a que el modelo dejó de detectar algunos objetos reales (es decir falsos negativos), posiblemente debido al aumento del umbral de confianza del modelo, eliminando así predicciones menos seguras.

La **Fig. 42** tiene las mismas imágenes que en la **Fig. 39** y se puede ver que este último modelo diferencia mejor las clases que train27_espiral, pero sigue teniendo errores:

La matriz de confusión de train27_espiral5 indicó que la confusión de espirales con espirales barradas se redujo al 16 %, aunque las espirales barradas aún se confundían con espirales en un 45 %.

A pesar de las mejoras, un problema recurrente en todos los modelos fue el ruido de fondo en las imágenes. Las matrices de confusión mostraron que las clases, especialmente la irregular, seguían confundándose con el fondo. Este ruido dificultaba la identificación de detalles morfológicos clave, como los brazos espirales o el halo de luminosidad, esenciales para una clasificación precisa. Para solucionar este problema, se optimizó la normalización de los recortes de imágenes en el script de Python. Mediante un proceso de prueba y error, se establecieron valores mínimos y




Figura 42: Etiquetado (4×2 izquierda) y predicción (4×2 derecha) del modelo *train27_espiral5*.

máximos de brillo que aseguraban un fondo oscuro, maximizando el contraste con las galaxias. Esta configuración permitió visualizar mejor las estructuras galácticas, facilitando la distinción de detalles finos. Los recortes con fondo oscuro se implementaron en los modelos posteriores, en contraste con las imágenes ruidosas utilizadas hasta *train27_espiral5*. A continuación se muestran imágenes del antes y el después.




Figura 43: Recortes sin cota de brillo (arriba) y con cota de brillo (abajo).

5.2.3. Modelo de 3 clases

El tercer modelo (Entreno1) se diseñó simplemente para validar la efectividad de los recortes de imágenes con un fondo optimizado, caracterizado por un mayor contraste gracias a los ajustes de brillo descritos previamente. Aunque se utilizaron las mismas imágenes base que en los modelos anteriores, la nueva normalización de brillo requirió un reetiquetado completo del conjunto de datos. Para simplificar la tarea y centrarse en los objetivos principales, se seleccionaron tres clases morfológicas de galaxias: elíptica, espiral e irregular. Esta reducción tuvo una justificación principal; el objetivo principal del modelo es clasificar las morfologías de galaxias. Por tanto, se tomó la decisión de excluir las clases estrella y espuria, ya que no contribuyen directamente a este propósito y añaden complejidad innecesaria al entrenamiento.

El mayor contraste con el fondo permitió identificar objetos tenues, por lo que se etiquetaron tanto galaxias grandes como pequeñas, buscando capturar una mayor diversidad de tamaños y brillos.




Figura 44: Ejemplo de etiquetado en diferentes recortes.

El modelo Entreno1, entrenado con YOLOv8s y los hiperparámetros establecidos previamente (epochs=100, imgsiz=640, batch=8, workers=0), mostró un desempeño superior al del modelo train18 (primer entrenamiento del modelo de 5 clases).

La matriz de confusión mostró que la confusión de clases con el fondo se redujo drásticamente, validando la decisión de optimizar el brillo de los recortes. Por tanto, se prosiguió a diseñar el último modelo de clasificación morfológica.

5.2.4. Modelo de 4 clases

El cuarto modelo incorporó cuatro clases morfológicas de galaxias: elíptica, espiral, espiral barrada e irregular, utilizando los recortes optimizados con fondo oscuro descritos previamente.

El conjunto de datos, ya organizado en las carpetas train (80 %) y val (20 %), se utilizó para entrenar el modelo con YOLOv11s, aprovechando las mejoras de esta versión frente a YOLOv8. El entrenamiento inicial se configuró con 150 épocas, aplicando técnicas de aumentación de datos pero sin asignar pesos diferenciados a las clases para evaluar el comportamiento general del modelo. Las métricas del modelo fueron las siguientes.

Tabla 5: Métricas de desempeño generales y por clase del modelo train1v2.

Clase	Métricas			
	Precisión	Recall	mAP@50	mAP@50:95
Generales	0,783	0,588	0,771	0,464
Elíptica	0,928	0,785	0,907	0,544
Espiral	0,824	0,573	0,807	0,472
Irregular	0,396	0,600	0,610	0,429
Espiral barr	1,000	0,403	0,781	0,430

Este modelo tuvo un mAP50 sólido para ser un modelo inicial, reflejando buena precisión en las detecciones. La precisión (0.783) fue notable, indicando que las detecciones que hizo tendieron a ser correctas. Sin embargo, el bajo recall (0.588), indica que no detectó tantas instancias reales.

Analizando la precisión por clase, para ser un primer modelo los valores fueron bastante buenos a excepción de irregular, probablemente por falta de representación en el dataset y su distribución de pesos. El mAP50 fue sólido en todas las clases, siendo algo menor para irregular. El recall fue la métrica que más fluctuó por clase. Mientras que no fue mala para elíptica, disminuyó bastante para espiral y espiral barrada, probablemente debido a la reasignación de algunas espirales a la clase espiral barrada.

La matriz de confusión mostró una mejora general en la distinción entre clases, con una confusión mínima con el fondo gracias al contraste optimizado. Sin embargo, el bajo recall de las clases espiral barrada e irregular señaló la necesidad de ajustes para equilibrar el aprendizaje.

Para abordar las limitaciones, se implementaron las siguientes modificaciones. En primer lugar, en el archivo YAML se ajustaron los pesos para compensar el desequilibrio:

- **Elíptica:** 0.5 por ser la clase más representada.
- **Espiral y espiral barrada:** 3.0 para mejorar su aprendizaje.
- **Irregular:** 5.0 al ser la clase menos representada.

La siguiente modificación fue la incorporación de nuevas imágenes en el dataset. Se añadieron 30 imágenes de galaxias espirales barradas para mejorar su recall. Dado que los recortes del cúmulo de Perseo agotaron las galaxias de esta clase, se utilizó una imagen del cúmulo Abell 2390 obtenida por *Euclid*. El proceso fue el mismo que para la obtención de recortes de Perseo; se generó de un catálogo con SExtractor, se filtró para galaxias con magnitud aparente inferior a 19, se crearon los recortes con el script correspondiente y se etiquetaron. Las 30 imágenes y sus etiquetas fueron añadidas a las carpetas de entrenamiento.

El reentrenamiento se realizó con 50 épocas, enfocándose en un fine-tuning para integrar las nuevas imágenes y los pesos ajustados. Las métricas resultantes (train2v2) fueron:

Tabla 6: Métricas de desempeño generales y por clase del Modelo train2v2.

Clase	Métricas			
	Precisión	Recall	mAP@50	mAP@50:95
Generales	0,867	0,657	0,788	0,505
Elíptica	0,918	0,791	0,910	0,553
Espiral	0,883	0,536	0,824	0,495
Irregular	0,789	0,600	0,635	0,429
Espiral barr	0,900	0,717	0,800	0,558

El objetivo principal de subir el recall de la espiral barrada se logró, ya que permitió que el modelo aprendiese mejor la morfología de esta clase, pero el recall de espiral bajó. La caída del recall en esta clase llevó a incorporar 20 imágenes adicionales de espirales, nuevamente extraídas del cúmulo de Abell 2390 y procesadas con el mismo flujo de trabajo (SExtractor, filtrado por magnitud < 19 , etc). Este reentrenamiento se realizó con 30 épocas, suficientes para refinar una clase ya existente sin riesgo de sobreajuste. En las **Figs.45-46** se muestran las métricas de desempeño generales y por clase de train3v2 frente a train1v2 y train2v2.




Figura 45: Métricas de desempeño generales del modelo train3v2 frente a train1v2 y train2v2.

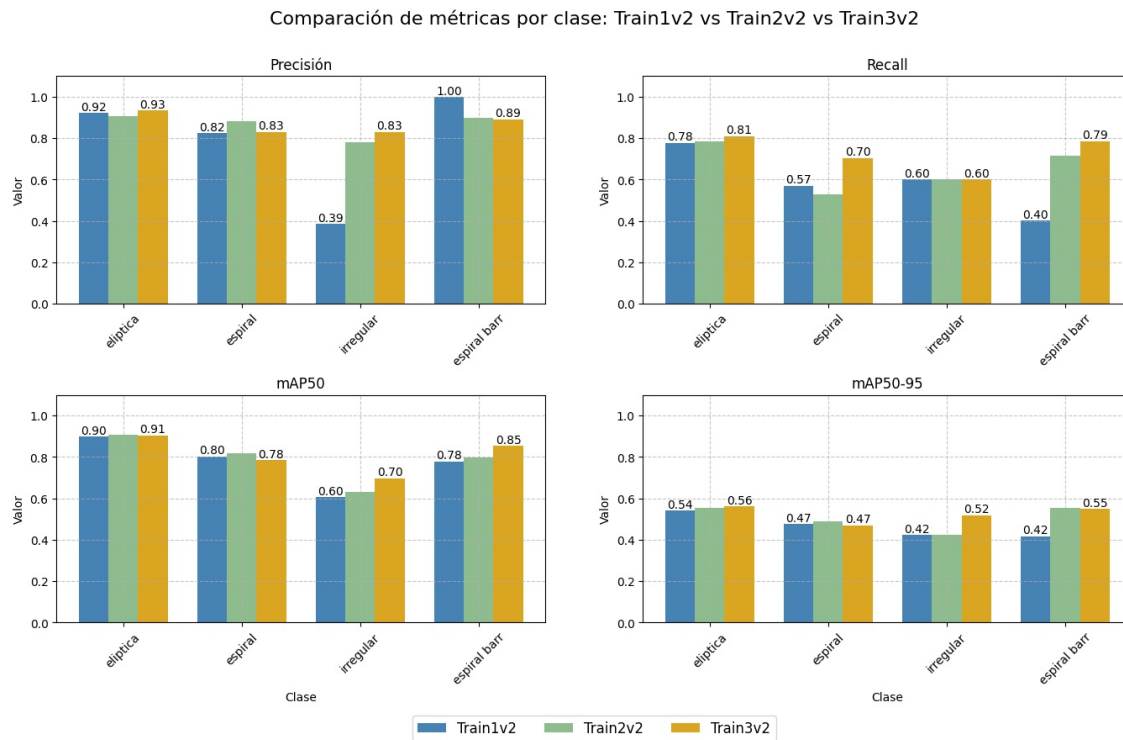


Figura 46: Métricas de desempeño por clase del modelo train3v2 frente a train1v2 y train2v2.

Tras los reentrenamientos y ajustes descritos, el modelo final (train3v2) se consolidó como el más efectivo para la clasificación morfológica de galaxias con cuatro clases. El mAP50 general fue superior al 80%. La clase elíptica obtuvo un valor superior al 90% mientras que la clase irregular registró un mAP50 de 0.70, el valor más bajo, pero aún robusto considerando su menor representación y morfología difusa. Además, la matriz de confusión mostró una confusión mínima entre clases, con una tasa inferior al 10% para espiral y espiral barrada, y una distinción clara frente al fondo gracias a los recortes optimizados.

A continuación se muestran algunas predicciones del modelo:




Figura 47: Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo.




Figura 48: Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo.




Figura 49: Etiquetado (2×2 izquierda) y predicción (2×2 derecha) del modelo.

En la **Sección 9.1** hay un link que contiene muchas más detecciones realizadas por el modelo (sin etiquetas para una mejor visualización) sobre recortes del cúmulo Abell 2390, distribuidas por clases.

5.3. Modelo de detección de candidatos a objetos más antiguos del universo

Se utilizaron para entrenar al modelo los 400 recortes de 448×448 píxeles del cúmulo de Perseo, seleccionados por su alta densidad de candidatos visibles por imagen, como se puede ver en el **Fig. 50**. El objetivo fue entrenar un modelo capaz de detectar estos objetos y validarlo en recortes de otras estructuras, como el cúmulo de Abell 2390.

El primer entrenamiento, ejecutado durante 150 épocas, empleó de manera automática los parámetros predeterminados de aumento de datos, una técnica que aplica transformaciones sobre las imágenes, como ajustes en la gama de color HSV (matiz, saturación y valor) para diversificar el conjunto de entrenamiento. Sin embargo, las métricas iniciales mostraron limitaciones: aunque el modelo detectaba correctamente muchos candidatos, omitía algunos y generaba falsos positivos. Un análisis visual en el conjunto de datos de entrenamiento generado por YOLO reveló que la aumentación de datos automática introducía variaciones no deseadas, como recortes saturados o en




Figura 50: Ejemplos de posibles candidatos en un recorte del cúmulo de Perseo.

blanco y negro, que confundían al modelo. Para corregir este problema, se desactivaron las transformaciones de color en el archivo YAML, estableciendo los parámetros HSV (hsv_h , hsv_s , hsv_v) a 0. Un segundo entrenamiento adoptó esta configuración y tanto las métricas como las predicciones mejoraron significativamente.

Tras esta mejoría se optó por reentrenar todo el dataset a 300 épocas desde 0 adoptando esta estrategia de desactivar la aumentación por color. Al probar el modelo en recortes de Abell 2390, se observó que algunos candidatos no eran detectados. La inspección del conjunto de datos sugirió que omisiones en el etiquetado manual, especialmente de objetos pequeños y tenues o de color ambiguo, podrían haber penalizado el recall. Además, la alta densidad de objetos por recorte complicaba la discriminación.

Se pudo observar la importancia de los hiperparámetros de confianza e intersección sobre unión ($conf$ y IoU) a la hora de hacer las predicciones, y se ajustaron para mejorarlas. Inicialmente, con $conf=0.3$ y $IoU=0.5$, el modelo detectaba candidatos, pero omitía algunos en recortes complejos. Un ajuste a $conf=0.25$ y $IoU=0.6$ mejoró los resultados, pero aún persistían omisiones. En la **Fig. 51** se puede observar la predicción del modelo a distintos umbrales de confianza y IoU , a la izquierda $conf=0.3$ sin detecciones y a la derecha $conf=0.25$ con una detección.



Figura 51: Predicción a diferentes umbrales de confianza: (1) $conf=0.3$; (2) $conf=0.25$.

Finalmente, se adoptó una configuración agresiva. Se optó por bajar de manera radical la confianza del modelo a $\text{conf}=0.01$ y aumentar la intersección sobre unión a $\text{iou}=0.7$. De esta forma, aunque una confianza baja pueda generar muchas detecciones iniciales, un IoU alto podrá eliminar muchas de ellas si son redundantes.

Esta configuración resultó altamente efectiva, permitiendo al modelo detectar la mayoría de los candidatos en Abell 2390 sin falsos positivos. Las predicciones fueron más robustas para objetos de color rojo intenso y tamaño significativo, con una confianza superior en comparación con candidatos pequeños o de tonalidad menos viva, que podrían confundirse con el fondo.



Figura 52: Mosaico de candidatos detectados en diferentes recortes del cúmulo Abell 2390.

A pesar del éxito, el modelo mostró limitaciones relacionadas con la cantidad de datos. Con solo 400 recortes y más de 1000 etiquetas, la diversidad de candidatos pequeños y tenues fue insuficiente para maximizar la confianza en estas detecciones. La incorporación de imágenes adicionales de otros cúmulos de *Euclid* podría robustecer el modelo, permitiendo un aprendizaje más completo de patrones sutiles.

El modelo desarrollado demostró un alto potencial para la detección automatizada de candidatos a objetos con alto desplazamiento al rojo, con métricas sólidas y una capacidad notable para generalizar a nuevos cúmulos.

6. DISCUSIÓN

6.1. Limitaciones del trabajo

Las principales limitaciones del trabajo estuvieron relacionadas con los datos utilizados y su procesamiento.

La primera dificultad encontrada fue la escasez de datos de calidad para entrenar el modelo de lentes gravitacionales. El conjunto de datos estuvo compuesto de 112 recortes de imágenes, lo que limitó la capacidad del modelo para generalizar casos complejos con muchos objetos astronómicos. Aunque se añadieron imágenes sin lentes gravitacionales para mejorar la discriminación, la falta de un conjunto más grande de datos impactó negativamente en la detección de imágenes completas como en la galaxia NGC 6505. Por otra parte, al usar el modelo sobre los 19.361 recortes, hubieron algunos candidatos a lente fuerte presentes en el cúmulo Abell 2390 según el artículo [35] que no fueron detectadas por `lentev5` (**Fig. 53**). También hubieron falsas detecciones realizadas por el modelo, confundiendo las lentes por brazos de galaxias espirales. Esto refuerza la necesidad de tener más datos de entrenamiento para robustecer el modelo.




Figura 53: Lentes fuertes presentes en Abell 2390 no detectadas por el modelo `lentev5`.

En el modelo de clasificación morfológica de galaxias, el principal problema fue el desequilibrio de clases. La clase "irregular" estuvo especialmente poco representada en el conjunto de datos. Esto hizo que las métricas de este modelo disminuyesen, a pesar de implementar ajustes de peso y técnicas de aumentación de datos. Además, el hecho de no tener una morfología bien definida y tener apariencias difusas hizo que el modelo tuviese aún más difícil identificarlas y clasificarlas. Otro problema que surgió fue el ruido de fondo en los recortes, ya que causó confusión entre clases con el fondo. Afortunadamente se pudo solucionar este problema optimizando la normalización del brillo, indicando así la importancia de un correcto preprocesado de imágenes astronómicas antes de ser entrenadas por un modelo de inteligencia artificial.

El etiquetado de los más de 600 recortes para la clasificación morfológica y los 400 recortes de candidatos fue un proceso muy lento y laborioso, siendo propenso a errores, especialmente en este último debido al pequeño tamaño de los objetos. Un etiquetado incorrecto o la falta de etiquetas pudo haber afectado marginalmente a las métricas de los modelos.

También hubo limitaciones relacionadas con la tecnología. En las pruebas iniciales al comienzo del trabajo, los modelos de YOLO funcionaban por defecto por CPU, por lo que los tiempos de entrenamiento, incluso para un dataset pequeño, podían ser de horas. Se recurrió a la instalación y configuración de CUDA, para poder emplear la aceleración por GPU y reducir notablemente los tiempos de entrenamiento. A pesar de todo, la capacidad de entrenamiento se vio limitada por la memoria virtual de tarjeta gráfica, la VRAM. Se hubiera preferido entrenar con modelos más grandes de YOLO, especialmente para el modelo de clasificación morfológica, ya que estos tienen más parámetros y son capaces de detectar detalles más finos, lo que permitiría una mayor precisión en la clasificación. Sin embargo, estos requieren de mucha memoria virtual, por lo que sólo se pudo usar máximo el modelo "small", el segundo modelo más pequeño.

6.2. Cambios respecto a los objetivos originales.

El trabajo tenía 2 objetivos principales. En primer lugar, entrenar un modelo de aprendizaje profundo que fuese capaz de detectar galaxias afectadas por el efecto lente gravitacional, y por otra parte, entrenar otro modelo que fuese capaz de detectar y clasificar galaxias por su morfología. Dado el éxito de ambos modelos, se probó a realizar un tercer modelo que fuese capaz de detectar candidatos a objetos más antiguos del universo, dada su importancia en el contexto de la astrofísica. El resultado fue bastante satisfactorio, siendo capaz de detectar objetos muy tenues y pequeños en recortes grandes, como en la **Fig. 52**. No obstante, para obtener estos resultados se tuvo que disminuir manualmente la confianza del modelo, algo que no es ideal pero es fácilmente resoluble, ampliando el dataset de entrenamiento con más recortes que contengan estos candidatos.

Por otra parte, el uso de SExtractor para generar catálogos a partir de imágenes FITS resultó muy efectivo, aunque necesitó ajustes iterativos. La automatización en la división de imágenes y la creación de catálogos fue muy útil para gestionar el volumen de datos provenientes de *Euclid*, algo que inicialmente no estaba previsto.

Entre los cambios más relevantes del proyecto se encuentran la optimización del brillo en los recortes, la inclusión de imágenes sin lentes gravitacionales para mejorar la generalización y el ajuste de hiperparámetros para balancear las métricas de precisión y recall. Las mejoras en el preprocesamiento y la ampliación del conjunto de datos mejoraron de manera clara las métricas, especialmente en la detección de lentes gravitacionales y la clasificación de galaxias espirales barradas. Sin embargo, la poca representación de la clase irregular penalizó el potencial las métricas en el modelo de clasificación. Una posible solución a este problema sería poder incluir en el dataset las futuras imágenes de galaxias irregulares que publique *Euclid*. De esta forma, se podrá saber con seguridad que pertenecen a esta clase y se podrá equilibrar con el resto de clases.

6.3. Impacto de los resultados

El modelo de detección de galaxias mediante el efecto lente gravitacional demostró ser muy sólido, tan solo limitado por la poca disponibilidad actual de imágenes de calidad. Se espera que tras la publicación masiva de datos de *Euclid* en 2026, añadiendo estas nuevas imágenes al dataset de entrenamiento, se pueda obtener un modelo muy robusto que sea generalizable a cualquier situación.

Por otra parte, se sabe que ya existen proyectos de clasificación morfológica muy potentes, como *Galaxy Zoo*, que también están basados en redes neuronales convolucionales. Además, han utilizado también variantes avanzadas de CNNs, como las redes neuronales convolucionales bayesianas, que permiten manejar la incertidumbre en las clasificaciones al proporcionar probabilidades asociadas a cada tipo morfológico [37]. Esto es particularmente útil cuando las imágenes presentan ambigüedades, como ocurrió en este trabajo. Por ejemplo, las galaxias lenticulares (clase intermedia entre elípticas y espirales) fueron englobadas por simplicidad en la clase elíptica, algo que podría ser solucionado con un proyecto como *Galaxy Zoo*. Sin embargo, con este trabajo se demuestra que no es necesario tener hardware de última generación ni acceso al software más puntero para obtener un buen modelo de clasificación morfológica, algo que puede resultar muy beneficioso para realizar proyectos de investigación personales.

Finalmente, como se mencionó en la **Sección 3.5**, el estudio de objetos de alto desplazamiento al rojo es crucial para entender la formación de las primeras galaxias y estrellas. Desarrollar un modelo basado en redes neuronales capaz de identificar estos posibles candidatos en imágenes puede ser muy útil. Conociendo la procedencia de la imagen original, por ejemplo el cúmulo de Abell 2390, y las dimensiones de los recortes generados, sería posible mapear la ubicación de un candidato identificado en un recorte hacia su posición en la imagen completa. Este proceso de reubicación permitiría dirigir telescopios de alta precisión hacia regiones específicas del cielo para realizar observaciones detalladas del espectro de estos objetos y determinar si se tratan de objetos muy antiguos. De esta forma se podrían descubrir características importantes que contribuyan a una comprensión más profunda de la estructura y evolución del universo. Además, este enfoque optimiza el uso de recursos observacionales, al priorizar candidatos prometedores y reducir el tiempo necesario al eliminar la identificación manual.

La principal ventaja de los tres modelos desarrollados en este trabajo radica en la automatización de la detección y clasificación en volúmenes masivos de datos astronómicos mediante técnicas de aprendizaje profundo. Un entrenamiento riguroso, basado en conjuntos de datos cuidadosamente etiquetados y optimizados, asegura que estos modelos sean fiables y capaces de identificar patrones complejos con alta precisión. En comparación con los métodos manuales que han sido usados tradicionalmente, requiriendo un tiempo considerable y propensos a errores en grandes conjuntos de datos, estos nuevos modelos procesan rápidamente miles de imágenes, clasificando morfologías galácticas, detectando arcos gravitacionales y señalando candidatos a objetos antiguos.

7. CONCLUSIONES

7.1. Conclusiones del trabajo

Uno de los objetivos principales del TFG era desarrollar un modelo basado en técnicas de aprendizaje profundo que fuese capaz de detectar galaxias mediante el efecto lente gravitatoria en los datos de la misión espacial *Euclid*, contribuyendo al estudio de la estructura del universo. El otro objetivo principal era el de desarrollar un modelo de clasificación morfológica de galaxias, también basado en técnicas de aprendizaje profundo. Se acabó realizando un tercer modelo, no previsto inicialmente, capaz de detectar candidatos a objetos más antiguos del universo.

Los resultados obtenidos cumplieron satisfactoriamente con este propósito. Se diseñó y entrenó un modelo basado en YOLO11-obb capaz de detectar lentes gravitacionales, identificando con precisión arcos y anillos de Einstein en imágenes de *Euclid*, como las del cúmulo Abell 2390 y la galaxia NGC 6505 (*lentev5*). La precisión del modelo alcanzó un 93 %, demostrando así la robustez del mismo.

Por otra parte, se implementó un modelo final de clasificación morfológica (*train3v2*) con cuatro clases (elíptica, espiral, espiral barrada e irregular). Se logró obtener una precisión general del modelo del 80 %, con valores que oscilaron entre el 70 % para la clase irregular y el 90 % para la clase elíptica.

Finalmente, se obtuvo un último modelo basado en la detección de objetos con un alto grado de desplazamiento al rojo, con una precisión del 85 %. De esta forma, se pudieron detectar posibles candidatos a objetos más antiguos del universo. Fue capaz de identificar estos objetos de manera correcta, aunque su principal inconveniente fue la baja confianza a las que realizó esas predicciones. Esto se podría solucionar añadiendo más imágenes de entrenamiento al dataset.

7.2. Conclusiones personales

El desarrollo de este trabajo ha resultado muy enriquecedor, no solo en el ámbito académico, sino que también ha servido para aclarar dudas acerca de mi futuro académico y confirmar que quiero continuar mi formación en el campo de la astrofísica.

En primer lugar, he tenido la oportunidad de trabajar con datos novedosos de gran relevancia en el contexto astronómico, ya que la misión *Euclid* está en pleno funcionamiento y toda la información que ofrece es de gran calidad y muy vanguardista. He podido entender los tipos de archivos que manejan este tipo de misiones, los archivos FITS, y he tenido que comprender conceptos inherentes a ellos, como su encabezado, que proporciona información clave acerca de la imagen. Por otra parte, también he podido familiarizarme con software utilizado de manera profesional en el ámbito laboral, como SExtractor. He comprendido cómo se crean los catálogos de objetos celestes y, a partir de ello, he logrado personalizar este proceso para crear mi propio catálogo de galaxias. Esto me llevó a profundizar en el significado de cada uno de los parámetros del software y a explorar cómo, al variarlos, se generan cambios en los catálogos finales. Aunque su curva de aprendizaje

es compleja, en parte por tener que trabajar desde un entorno con el sistema operativo Linux, he encontrado muy satisfactorio lograr manejar con soltura este programa y adaptar la creación de catálogos a mis necesidades particulares. Además, he trabajado con otro software muy conocido en el mundo astronómico, *Aladin*. Este ha sido especialmente útil para superponer las imágenes FITS con los catálogos creados y determinar si estos estaban correctamente configurados o si era necesario ajustar los parámetros de SExtractor para mejorarlos. Poder trabajar simultáneamente con ambos programas me ha proporcionado una mejor comprensión de cómo los astrónomos manejan este tipo de datos en la práctica.

Por otro lado, este trabajo ha marcado mi primera toma de contacto con el mundo de las técnicas de aprendizaje profundo. Antes de este proyecto, solo había oído hablar de manera superficial sobre estos temas, pero nunca había experimentado con ellos. Dado que es un campo en pleno auge, este trabajo fue la oportunidad perfecta para comenzar a explorarlos. A diferencia de otros modelos, recopilar información sobre YOLO fue sencillo gracias a la gran documentación disponible online. A pesar de que poner en marcha los primeros modelos resultó algo complicado debido a las numerosas optimizaciones que requirió mi ordenador, una vez configurado el proceso se volvió más fluido. Al analizar los primeros resultados, pude apreciar el enorme potencial de estas técnicas, no solo en astrofísica, sino en cualquier ámbito.

La mayor satisfacción de este trabajo fue observar cómo, tras refinar los modelos poco a poco, estos comenzaron a detectar con mayor precisión los objetos de interés. Probar los modelos en imágenes completamente independientes del dataset de entrenamiento y ver cómo eran capaces de predecir correctamente este tipo de estructuras fue verdaderamente emocionante, evidenciando su claro potencial en aplicaciones astronómicas.

Aunque estas técnicas son relativamente recientes, han demostrado sobradamente su amplio potencial y creo que su incorporación continua y futura en campos como la astrofísica acelerará de manera exponencial nuevos descubrimientos.

8. FUTURAS LÍNEAS DE TRABAJO

En primer lugar, para poder mejorar los resultados obtenidos, es fundamental ampliar y diversificar el conjunto de datos. El bajo número de instancias de lentes gravitacionales, galaxias irregulares y objetos de alto desplazamiento al rojo limita la capacidad de generalización del modelo, por lo que la incorporación de imágenes de *Euclid* u otras misiones espaciales mejoraría la representatividad y robustez de las predicciones.

Una línea de investigación ambiciosa para el modelo de clasificación morfológica (train3v2) sería implementar una subclasificación detallada de las categorías existentes. Aunque con el conjunto actual de datos actual esta posibilidad es inviable, un modelo capaz de distinguir subtipos dentro de las clases principales sería altamente valioso. Por ejemplo, para las galaxias elípticas, se podría entrenar el modelo para clasificarlas según la secuencia de Hubble, desde las *E0* hasta las *E7*, como se muestra en la **Fig. 6**. De manera similar, en las galaxias espirales, se podría diferenciar entre los tipos de barras y clases intermedias, como se ilustra en las **Figs. 8-10**. Además, la incorporación de nuevas clases, como las galaxias lenticulares (con subclasificaciones *S0*, *SA0*, *SB0*) o las galaxias enanas, que constituyen el tipo de galaxia más abundante en el universo, enriquecerían el modelo. Esto requeriría un conjunto de datos mucho más extenso y un etiquetado manual detallado, pero haría que este modelo de clasificación morfológica fuese mucho más completo.

Por otra parte, el modelo de detección de lentes gravitacionales fuertes se diseñó para identificar patrones reconocibles como arcos y anillos de Einstein. Sin embargo, uno de los objetivos principales de la misión *Euclid* es estudiar el efecto de lente gravitacional débil [8], que produce distorsiones más sutiles en las formas de las galaxias de fondo. Aunque estos patrones no tienen una morfología tan bien definida y por tanto son más difíciles de detectar por los modelos, los millones cantidad de datos que *Euclid* generará ofrece una oportunidad única. Una futura línea de trabajo consistiría en desarrollar un modelo basado en YOLO capaz de interpretar estas distorsiones sutiles mediante una incorporación de datos masiva. Se podría acabar teniendo un modelo que fuese capaz de detectar tanto lentes débiles como lentes fuertes.

Para avanzar en la detección de candidatos a objetos con alto desplazamiento al rojo, una línea de investigación futura sería integrar datos multi-longitud de onda, combinando imágenes ópticas de *Euclid* con observaciones en el infrarrojo cercano (NIR) del Telescopio Espacial James Webb. En este trabajo, los candidatos han sido seleccionados en base a su color rojo intenso en imágenes de falso color, lo cual sirve como un indicador visual del posible desplazamiento al rojo, aunque no implica necesariamente una emisión intrínsecamente brillante en el infrarrojo. Sin embargo, a medida que el universo se expande, la luz emitida por galaxias distantes se desplaza hacia longitudes de onda más largas, situándose en el infrarrojo [38]. Por tanto, esta combinación de bandas permitiría al modelo actual capturar características espectrales más completas y mejorar la identificación de estos objetos lejanos.

Referencias

- [1] Ellis RS. Gravitational lensing: a unique probe of dark matter and dark energy. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2010 Mar;368(1914):967-87. Available from: <https://royalsocietypublishing.org/doi/10.1098/rsta.2009.0209>.
- [2] Schneider P, Kochanek CS, Wambsganss J. Gravitational lensing: strong, weak and micro. Berlin New York: Springer; 2006.
- [3] Focardi P, Rossetti E. Spectroscopic identification of 25 disk galaxy candidate gravitational lenses in the SDSS. *Astronomy & Astrophysics*. 2015 Sep;581:A99. Available from: <http://www.aanda.org/10.1051/0004-6361/201526364>.
- [4] Metcalf RB, Meneghetti M, Avestruz C, Bellagamba F, Bom CR, Bertin E, et al. The strong gravitational lens finding challenge. *Astronomy & Astrophysics*. 2019 May;625:A119. Available from: <https://www.aanda.org/10.1051/0004-6361/201832797>.
- [5] Petrillo CE, Tortora C, Chatterjee S, Vernardos G, Koopmans LVE, Verdoes Kleijn G, et al. Finding strong gravitational lenses in the Kilo Degree Survey with Convolutional Neural Networks. *Monthly Notices of the Royal Astronomical Society*. 2017 Nov;472(1):1129-50. Available from: <http://academic.oup.com/mnras/article/472/1/1129/4082220/Finding-strong-gravitational-lenses-in-the-Kilo>.
- [6] Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. 2016 May. ArXiv:1506.02640 [cs]. Available from: <http://arxiv.org/abs/1506.02640>.
- [7] Yang H, Zhang B, Cai J, Qu H, Zheng A, Hao J, et al. An automatic detection method for small size dwarf galaxy candidates. *Astronomy & Astrophysics*. 2025 Apr;696:A130. Available from: <https://www.aanda.org/10.1051/0004-6361/202453042>.
- [8] Laureijs R, Amiaux J, Arduini S, Auguères JL, Brinchmann J, Cole R, et al. Euclid Definition Study Report. 2011 Oct. Version Number: 1. Available from: <https://arxiv.org/abs/1110.3193>.
- [9] Zhang Z, Shan H, Li N, Wei C, Yao J, Ban Z, et al. FORKLENS: Accurate weak-lensing shear measurement with deep learning. *Astronomy & Astrophysics*. 2024 Mar;683:A209. Available from: <https://www.aanda.org/10.1051/0004-6361/202345903>.
- [10] Pearce-Casey R, Nagam BC, Wilde J, Busillo V, Ulivi L, Andika IT, et al. *Euclid* : Searches for strong gravitational lenses using convolutional neural nets in Early Release Observations of the Perseus field. *Astronomy & Astrophysics*. 2025 Apr;696:A214. Available from: <https://www.aanda.org/10.1051/0004-6361/202453152>.

- [11] Euclid Collaboration, Quilley L, Damjanov I, de Lapparent V, Paulino-Afonso A, Sánchez HD, et al. Euclid Quick Data Release (Q1). Exploring galaxy morphology across cosmic time through Sersic fits. 2025 Mar. Available from: <https://arxiv.org/abs/2503.15309>.
- [12] Mellier Y, Abdurro'uf, Acevedo Barroso JA, Achúcarro A, Adamek J, Adam R, et al. Euclid: I. Overview of the Euclid mission. *Astronomy & Astrophysics*. 2025 Apr;697:A1. Available from: <http://dx.doi.org/10.1051/0004-6361/202450810>.
- [13] Cuillandre JC, Bolzonella M, Boselli A, Marleau FR, Mondelin M, Sorce JG, et al. Euclid: Early Release Observations – Overview of the Perseus cluster and analysis of its luminosity and stellar mass functions. *Astronomy & Astrophysics*. 2025 Apr;697:A11. Available from: <http://dx.doi.org/10.1051/0004-6361/202450808>.
- [14] Euclid's view of the Perseus cluster of galaxies;. Available from: https://www.esa.int/Science_Exploration/Space_Science/Euclid/Euclid_s_view_of_the_Perseus_cluster_of_galaxies.
- [15] Narayan R, Bartelmann M. Lectures on Gravitational Lensing. 1996 Oct. Version Number: 2. Available from: <https://arxiv.org/abs/astro-ph/9606001>.
- [16] Lewin S. A Star Explosion Times 4: Supernova Image Quadrupled in Rare Sight. *Space*. 2017 Apr. Available from: <https://www.space.com/36530-rare-supernova-quadruple-image-gravitational-lens.html>.
- [17] Mo H, Van den Bosch F, White S. Galaxy formation and evolution. Cambridge: Cambridge University Press; 2010. OCLC: 646069565.
- [18] Buta RJ. Galaxy Morphology. 2011 Feb. Version Number: 1. Available from: <https://arxiv.org/abs/1102.0550>.
- [19] Phys - Lecture on galaxies;. Available from: <https://hedberg.ccnysites.cuny.edu/viewers/slides.php?course=astrophysics&topic=galaxies&l=cal#/10>.
- [20] Manzano B, Ribas I, editors. Galaxias Elípticas e Irregulares. vol. 26 of Atlas del Cosmos. Barcelona: RBA Coleccionables; 2018. OCLC: 1055861297.
- [21] Manzano B, Ribas I, editors. El Universo Infrarrojo. vol. 30 of Atlas del Cosmos. Barcelona: RBA Coleccionables; 2018. OCLC: 1055861297.
- [22] Barton EJ, Bullock JS, Cooray A, Kaplinghat M. First light and reionization: A conference summary. *New Astronomy Reviews*. 2006 Mar;50(1-3):1-12. Available from: <http://dx.doi.org/10.1016/j.newar.2005.11.024>.
- [23] Davies LJM, Maraston C, Thomas D, Capozzi D, Wechsler RH, Busha MT, et al. Detecting massive galaxies at high redshift using the Dark Energy Sur-

- vey. *Monthly Notices of the Royal Astronomical Society*. 2013 Sep;434(1):296-312. Available from: <http://academic.oup.com/mnras/article/434/1/296/994567/Detecting-massive-galaxies-at-high-redshift-using>.
- [24] O'Shea K, Nash R. *An Introduction to Convolutional Neural Networks*. 2015 Dec. ArXiv:1511.08458 [cs]. Available from: <http://arxiv.org/abs/1511.08458>.
- [25] Holwerda BW. *Source Extractor for Dummies v5*. 2005 Dec. ArXiv:astro-ph/0512139. Available from: <http://arxiv.org/abs/astro-ph/0512139>.
- [26] Cuillandre JC, Bertin E, Bolzonella M, Bouy H, Gwyn S, Isani S, et al. *Euclid: Early Release Observations – Programme overview and pipeline for compact- and diffuse-emission photometry*. *Astronomy and Astrophysics*. 2025 Apr;697:A6. Available from: <http://dx.doi.org/10.1051/0004-6361/202450803>.
- [27] Las Cumbres Observatory. *FITS Headers*; Available from: <https://lco.global/documentation/data/fits-headers/>.
- [28] Ultralytics. *Cajas delimitadoras orientadas*; Available from: <https://docs.ultralytics.com/es/tasks/obb/>.
- [29] Sapkota R, Qureshi R, Calero MF, Badjugar C, Nepal U, Poulouse A, et al. *YOLOv12 to Its Genesis: A Decadal and Comprehensive Review of The You Only Look Once (YOLO) Series*. 2025 Feb. ArXiv:2406.19407 [cs]. Available from: <http://arxiv.org/abs/2406.19407>.
- [30] Ultralytics. *Visión general de los conjuntos de datos de detección de objetos*; Available from: <https://docs.ultralytics.com/es/datasets/detect>.
- [31] Ultralytics. *Configuración*; Available from: <https://docs.ultralytics.com/es/usage/cfg>.
- [32] Ultralytics. *Profundización en las métricas de rendimiento*; Available from: <https://docs.ultralytics.com/es/guides/yolo-performance-metrics>.
- [33] M Walmsley, M Huertas-Company, J -C Cuillandre. *Strong gravitational lenses captured by Euclid*; Available from: https://www.esa.int/ESA_Multimedia/Images/2025/03/Strong_gravitational_lenses_captured_by_Euclid.
- [34] O'Riordan CM, Oldham LJ, Nersesian A, Li T, Collett TE, Sluse D, et al. *Euclid : A complete Einstein ring in NGC 6505*. *Astronomy & Astrophysics*. 2025 Feb;694:A145. Available from: <https://www.aanda.org/10.1051/0004-6361/202453014>.
- [35] Nagam BC, Barroso JAA, Wilde J, Andika IT, Manjón-García A, Pearce-Casey R, et al. *Euclid: Finding strong gravitational lenses in the Early Release Observations using convolutional neural networks*. arXiv; 2025. Version Number: 1. Available from: <https://arxiv.org/abs/2502.09802>.

- [36] Ultralytics. Aumento de datos mediante Ultralytics YOLO;. Available from: <https://docs.ultralytics.com/es/guides/yolo-data-augmentation>.
- [37] Walmsley M, Smith L, Lintott C, Gal Y, Bamford S, Dickinson H, et al. Galaxy Zoo: probabilistic morphology through Bayesian CNNs and active learning. Monthly Notices of the Royal Astronomical Society. 2019 Oct;491(2):1554–1574. Available from: <http://dx.doi.org/10.1093/mnras/stz2816>.
- [38] Hogg DW. Distance measures in cosmology. 2000 Dec. ArXiv:astro-ph/9905116. Available from: <http://arxiv.org/abs/astro-ph/9905116>.

9. ANEXOS

9.1. Resultados adicionales

Se adjunta un link que contiene resultados adicionales de los modelos de clasificación de galaxias y de la detección de lentes.

<https://docs.google.com/presentation/d/1STsjlCH3uBAr165KwTX4WE7LLcHDoq7S/edit?usp=sharing&oid=109265089283978724746&rtpof=true&sd=true>



9.2. Códigos

A continuación se adjunta un link y un código QR con todos los códigos usados en el TFG y sus explicaciones correspondientes:

<https://github.com/Antama01/Codigos-TFG>



9.3. Declaración de uso de IA

- **Redacción académica.**

Herramienta: ChatGPT

Función: Refinar el texto escrito por mi mediante las instrucciones de redacción de la guía del TFG.

Prompt: "Refina el siguiente texto escrito por mi sin cambiar su contenido, ajustándote a las siguientes instrucciones: Aquí introduje las intrucciones del estilo de redacción de la guía "

- **Códigos en Python**

Herramienta: Copilot y ChatGPT

Función: Solucionar algún error puntual de la elaboración del código que yo no entienda

Prompt: " En la línea (...) de mi código (...) me está saliendo el siguiente error (...). Explícame cuál es el motivo de dicho error y como podría solucionarlo."

