



Universidad de Valladolid

Facultad de Ciencias

TRABAJO FIN DE GRADO

Grado en Física

Clasificación automática de imágenes del cielo mediante inteligencia artificial

Autor:

Sergio Alegre Fernández

Tutores:

Roberto Román Díez y Juan Carlos Antuña Sánchez

Agradecimientos

A mis padres Manuel y Charo, por enseñarme tanto y tan bien sobre la vida, por su amor, su cariño y por inculcarme una buena educación con los valores de sacrificio, esfuerzo y constancia.

A mi hermana Alba, por nuestro amor de hermanos, por ser un pilar fundamental para mí, mi profesora favorita cuando era pequeño, por su cariño y por entenderme tal como soy, siempre picroforma.

A mi pareja Carlota, por su cariño, su apoyo, su energía positiva y por hacerme sentir especial.

A mis tutores Roberto Román y Juan Carlos Antuña, por su amabilidad, su atención y su gran dedicación.

A mis compañeros del doble grado, por todo el tiempo compartido, por su apoyo para poder superar cada una de las diferentes asignaturas.

Resumen-Abstract

El objetivo principal es clasificar imágenes de cielo procedentes de una cámara de cielo mediante inteligencia artificial, para ello se dispondrá de un gran conjunto de datos inicial que será etiquetado, de forma que con ello se pueda entrenar una red neuronal que sea capaz de predecir el estado del cielo, en particular la cubierta nubosa o nubosidad, indicando el número de octas. Teniendo una gran importancia tanto en el clasificado de imágenes del pasado, como al realizar clasificaciones futuras. A lo largo de este trabajo, se han entrenado 8 modelos diferentes, obteniendo en todos ellos buenos resultados para diferentes métricas de estudio, y alcanzando tasas de acierto, al permitir errores de una octa, del 96 %.

The main objective is to classify sky images from a sky camera using artificial intelligence, for which a large set of initial data will be available that will be labeled, so that a neural network can be trained that is capable of predicting the state of the sky, in particular cloud cover or cloudiness, indicating the number of oktas. Having a great importance not only for the classification of images of the past, but also for a correct classification of future ones. Throughout this work, 8 different models have been trained, obtaining good results in all of them for different study metrics, and reaching success rates of 96 %, allowing errors of one okta.

Índice

	Página
1 Introducción	1
1.1 Las nubes	1
1.1.1 Ciclo hidrológico	2
1.1.2 Formación	3
1.1.3 Clasificación	6
1.1.4 Importancia	8
1.2 La cubierta nubosa	10
1.2.1 Equipos de medida	11
1.3. Redes Neuronales para el cálculo de la cubierta nubosa con cámaras de cielo	14
1.4. Objetivos	19
2 Instrumentación y metodología	20
2.1. Cámara de cielo	20
2.2. Ceilómetro	22
2.3. Etiquetado de las imágenes	23
2.4. Entrenamiento de la red Neuronal	25
3 Resultados	29
3.1. Error absoluto medio	30
3.2. Error medio	31
3.3. Desviación estándar	32
3.4. Raíz del error cuadrático medio	33
3.5. Histogramas	34
3.6. Matrices de confusión	36
4 Conclusiones	41
Bibliografía	43
Índice alfabético	45

Índice de figuras

1.	Esquema de un frente cálido en 3D	5
2.	Esquema de un frente frío en 3D	5
3.	Fotografías de dos equipos de medida	12
4.	Imagen de cielo de una cámara de cielo.	13
5.	Entrada y salida utilizando dos <i>kernels</i>	16
6.	Convolución con <i>stride</i> = 2 y <i>padding</i> = 0.	17
7.	Ejemplo de arquitectura de una CNN para la detección de perros, animales y pájaros en imágenes.	18
8.	Cámara de cielo OMEA 3C.	21
9.	Ceilómetro CHM15k Nimbus	23
10.	Imágenes de cámara de cielo con diferentes etiquetas asociadas.	24
11.	Comparación de imágenes de cielo con presencia de nubes altas y aerosoles.	25
12.	Interfaz de “Teachable machine 2.0” para la elección de tipo de proyecto.	26
13.	Interfaz de “Teachable machine 2.0” para la preparación de nuestros modelos.	27
14.	Histogramas de cada modelo, representando la frecuencia de las diferencias entre los valores predichos y reales.	35
15.	Matrices de confusión modelo 1.	37
16.	Matrices de confusión modelo 2.	37
17.	Matrices de confusión modelo 3.	37
18.	Matrices de confusión modelo 4.	38
19.	Matrices de confusión modelo 5.	38
20.	Matrices de confusión modelo 6.	38
21.	Matrices de confusión modelo 7.	39
22.	Matrices de confusión modelo 8.	39

Índice de tablas

1.	Distribución en altura de los pisos de nubes.	8
2.	Especificaciones de la cámara de cielo OMEA 3C de Alcor System.	22
3.	Número de imágenes de validación para cada etiqueta de número de octas.	29
4.	Notación de los modelos utilizados junto con sus parámetros.	29
5.	Valores en octas del error absoluto medio para los diferentes modelos e imágenes.	30
6.	Valores en octas del error medio para los diferentes modelos e imágenes.	32
7.	Desviación estándar para los diferentes modelos e imágenes.	33
8.	Valores en octas de la raíz del error cuadrático medio para los diferentes modelos e imágenes.	34
9.	Tasas de acierto obtenidas para cada modelo.	40

Capítulo 1

Introducción

Desde principios de la humanidad, las nubes han tenido un papel importante en la vida de los seres humanos, tal es el hecho de que a veces sus formas, sus colores y sus movimientos eran entendidos como mensajes directos de los dioses, por ejemplo para la mitología griega Néfele era una diosa hecha de nubes [3]. También han sido caracterizadas siempre por su belleza, sirviendo de relajación para el observador y como fuente de inspiración para diversas y variadas obras de arte, como pueden ser las obras pictóricas o las fotográficas.

En el caso que atañe a este trabajo, la importancia del papel de las nubes es de tal índole, que los meteorólogos expertos pueden dibujar de forma aproximada un mapa de flujos aéreos mediante la observación de las mismas, y es que está demostrado que las nubes son buenos indicadores de la dinámica atmosférica[7].

Introduciremos en este capítulo la definición de nube, sus distintos tipos de clasificación, sus diferentes procesos de formación, así como su importancia. A continuación, se tratará la cubierta nubosa y sus diferentes formas de medirla o estimarla, centrándonos finalmente en el papel y uso de la inteligencia artificial en este sentido.

1.1 Las nubes

Recordemos que la atmósfera es la envolvente gaseosa que rodea nuestro planeta, de ella es necesario destacar una de sus capas que denominamos troposfera, la cual se encuentra entre el suelo y los 7 km de altura en los polos, o los 17 km de altura en el ecuador.

En la troposfera tienen lugar la mayoría de los procesos y fenómenos meteorológicos, además presenta casi todo el vapor de agua que

contiene la atmósfera en su totalidad. Este vapor de agua procede de forma mayoritaria de la evaporación ocurrida por el agua presente en la superficie de la tierra, la cual está formada por un 71 % de agua [1].

El vapor de agua es agua en estado gaseoso, y entre sus características se encuentra que es invisible a nuestros ojos, por lo que cuando se aprecia una nube, no estamos viendo el vapor de agua (gas), sino pequeñas gotitas de agua que se han formado a partir del gas [1].

La definición oficial presente en el Atlas Internacional de Nubes elaborado por la Organización Meteorológica Mundial es la siguiente:

“Una nube es un hidrometeoro consistente en partículas diminutas de agua líquida o hielo o de ambas, suspendidas en la atmósfera y que en general no tocan el suelo. También pueden incluir partículas de agua líquida o hielo de mayores dimensiones, así como partículas líquidas no acuosas o partículas sólidas, procedentes, por ejemplo, de gases industriales, humo o polvo”

1.1.1 Ciclo hidrológico

Si consideramos el sistema integrado por la atmósfera y la Tierra, la cantidad de agua presente en dicho sistema permanece inalterada. Por ello, aunque se puedan percibir ríos que se secan en verano, embalses que llegan al máximo en invierno o zonas que se convierten en desérticas, no significan estas evidencias que la cantidad de agua presente en el sistema descrito con anterioridad, es decir, atmósfera-Tierra, haya variado, sino que significa que el agua cambia de lugar y se transforma.

Estos cambios y movimientos del agua se denominan *Ciclo hidrológico*, y presenta una importancia capital en el desarrollo de la vida de los seres vivos, pues tenemos una fuerte dependencia de ella. Por otro lado, el conjunto de lugares del planeta por donde pasa o se almacena el agua en cualquiera de sus estados posibles se denomina *Hidrosfera*, y está formada por los glaciares, mares y océanos, ríos y lagos, agua subterránea, atmósfera y biosfera [1].

Por lo tanto, el ciclo hidrológico es un proceso circular, que consta

fundamentalmente de tres pasos o etapas.

- Una gota presente en la superficie de la tierra en estado líquido o sólido pasa a la atmósfera en forma de gas (vapor de agua)
- Ese vapor de agua, que se encuentra ya en la atmósfera, se puede condensar en forma de gotitas o formar cristales de hielo, como consecuencia de alteraciones en la presión y temperatura de la atmósfera.
- Cuando estas gotas, o cristales de hielo, crecen, caen de nuevo a la superficie de la tierra en forma de precipitación.

Tras estos tres pasos, el ciclo comenzaría de nuevo, aunque para ello es fundamental la energía proporcionada por el sol, que sirve de nexo y motor entre los diferentes estados del agua.

1.1.2 Formación

La formación de las nubes se basan en los principios termodinámicos, para ello se considera que una parcela de la atmósfera que contiene vapor de agua, se puede tratar como una mezcla de dos componentes: aire seco y vapor de agua. Los factores clave para que este vapor de agua, pase a estado sólido o líquido, son la humedad (cantidad de vapor de agua en el volumen de aire que estamos considerando) y su temperatura. Cuando un volumen específico de aire a una temperatura dada, no sea capaz de soportar una cantidad de agua mayor, decimos que ese aire está saturado[2]. A mayor temperatura, menor probabilidad de saturación, es decir, el aire caliente soporta una cantidad de vapor de agua mayor que el aire frío [1].

De lo explicado anteriormente, deducimos que, para que se produzca la formación de nubes, se debe producir la saturación del aire en cuestión, y para ello se pueden considerar dos vías o canales fundamentalmente:

- Enfriamiento (bajar la temperatura de la masa de aire)
- Aumento de humedad (Incorporar más cantidad de agua a la masa de aire)

Consecuentemente, podemos agrupar los principales mecanismos de formación de nubes atendiendo a estos dos canales principales para conseguir la saturación del aire, de forma que se tiene la siguiente clasificación [1]:

1. Mecanismos de saturación por enfriamiento
 - a) Enfriamiento por ascensos
 - 1) Frentes
 - 2) Convección
 - 3) Convergencia de viento
 - 4) Orografía
 - b) Enfriamiento por irradiación
2. Mecanismos de saturación por aporte de humedad
 - a) Mezcla de masas de aire
 - b) Convergencia de humedad
 - c) Turbulencias

Se expone con más detalle el mecanismo mediante frentes y enfriamiento por irradiación.

Frentes: Son fronteras que separan dos masas de aire que presentan diferentes valores de humedad y temperatura. Una característica de estas masas de aire, con diferentes valores en estas variables, es su dificultad para mezclarse entre ellas, lo que hace que normalmente una se desplace por debajo de la otra al encontrarse.

Hablamos entonces de dos tipos de frente:

1. *Frente cálido:* Una masa de aire relativamente cálida se encuentra con una masa de aire más fría. Cuando ocurre esto, el aire cálido, por ser mucho menos denso, asciende sobre el frío en forma de suave rampa, como puede verse en la figura 1. Esta especie de rampa o plano inclinado se denomina *superficie frontal*. Al ascender, la masa disminuye de presión, por lo tanto, de acuerdo con la

ecuación de Clapeyron, disminuye de temperatura, dando lugar a la saturación. La nubosidad generada en estos frentes es de tipo estratiforme y con poco desarrollo vertical, así mismo las precipitaciones a las que da lugar son de tipo continuo y de intensidad baja o moderada.

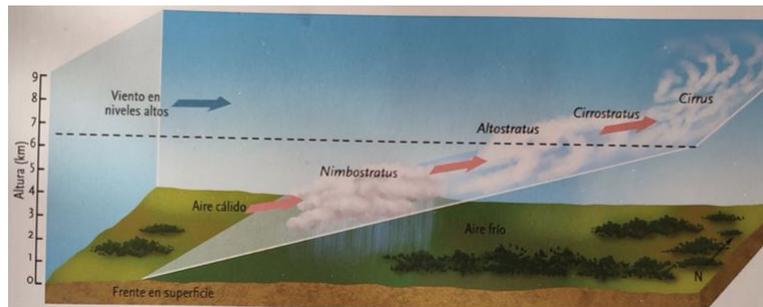


Figura 1: Esquema de un frente cálido en 3D
[1]

2. *Frente frío*: Cuando aire relativamente frío se encuentra con otra masa de aire de mayor temperatura, la masa de aire frío que es mucho más densa se introduce en forma de cuña por debajo de la masa de aire caliente, la cual asciende y satura. La superficie frontal en este caso tiene mayor inclinación, por lo que se generan nubes de gran desarrollo vertical, así como precipitaciones tipo chubasco y de gran intensidad.

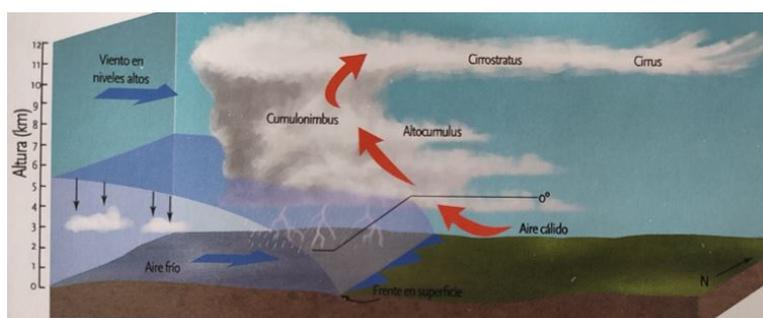


Figura 2: Esquema de un frente frío en 3D
[1]

Enfriamiento por irradiación: En otoño e invierno, y principalmente por la noche, el suelo se enfría, debido a las pérdidas de calor

por irradiación. Si no hay nubes, y el viento es leve, esta situación se agrava. Sin embargo, como el aire es mal conductor térmico, se forma un gradiente de temperatura, de forma que al aumentar de altura, la temperatura asciende en lugar de disminuir. Si la temperatura desciende hasta el punto de rocío, se formará escarcha o rocío en la superficie, así como niebla.

Para terminar esta sección, hay que mencionar, la imposibilidad de las moléculas de agua para formar gotas de nube por ellas mismas, debido a las fuerzas internas existentes en su seno. Es por ello que son necesarios, los denominados núcleos de congelación (para hielo) o de condensación (para gotas) para vencer a esas fuerzas existentes de tensión superficial. Estos núcleos de condensación presentan gran afinidad por las moléculas de agua y una gran capacidad de absorción, disminuyendo el porcentaje necesario de humedad relativa para la saturación del 300 % a relaciones inferiores al 100 %. Ejemplos de núcleos de saturación pueden ser distintas sales procedentes de gotas de agua marinas o fragmentos de polvo de desierto[1].

1.1.3 Clasificación

Dos nombres destacan en los intentos de clasificación de las nubes, Lamarck y Luke Howard.

Lamarck propuso en 1802 un nuevo proyecto donde realizó una clasificación de nubes, la cual fracasó, pues tenía un gran carácter subjetivo y además estaba realizada en lengua francesa.

Por otro lado, Luke Howard en 1802, presento en su trabajo *Sobre las modificaciones de las nubes*, una clasificación, que salvo pequeñas modificaciones, es la que se encuentra presente actualmente.

En la actualidad, el Atlas Internacional de Nubes de la OMM¹ establece una clasificación de las nubes en términos de géneros, especies, variedades, rasgos suplementarios y nubes accesorias. La identificación de una nube, sigue, por lo tanto, el sistema de nomenclatura binomial propuesto por Linneo en el siglo XVIII.

¹Organización Mundial de la Meteorología.

En su última versión, el Atlas internacional de Nubes de la OMM, distingue 10 géneros, 14 especies, 9 variedades y 9 rasgos suplementarios. Presentémoslo en más detalle [1]:

1. Género: Se basa en la característica fundamental de la nube, los 10 géneros mencionados son: *Cirrus*, *Cirrocumulus*, *Cirrostratus*, *Altoaccumulus*, *Altostratus*, *Nimbostratus*, *Stratocumulus*, *Stratus*, *Cumulus* y *Cumulonimbus*, se tratan de géneros excluyentes, una nube pertenece a uno y solo uno de los géneros mencionados.
2. Especie: Basada en peculiaridades o estructura interna de la nube en cuestión, las 14 especies son: *fibratus*, *uncinus*, *spissatus*, *castellanus*, *floccus*, *stratiformis*, *nebulosus*, *lenticularis*, *fractus*, *humilis*, *mediocris*, *congestus*, *calvus*, y *capillatus*, al igual que el género, las especies son mutuamente excluyentes.
3. Variedad: Debido a características especiales, tales como la disposición de sus elementos macroscópicos o su transparencia. Las diferentes variedades son: *intortus*, *vertebratus*, *undulatus*, *radiatus*, *lacunosus*, *duplicatus*, *translucidus*, *perlucidus*, y *opacus*. Una nube puede tener más de una variedad, luego las variedades no son excluyentes entre ellas.
4. Rasgos suplementarios y nubes accesorias: Nubes de menos tamaño que se encuentran parcial o totalmente unidas a la nube principal. Los rasgos suplementarios son los siguientes: *incus*, *mamma*, *virga*, *praecipitatio*, *arcus*, *tuba*, *pileus*, *velum*, y *pannus*. Los rasgos suplementarios no son mutuamente excluyentes, pues una nube puede presentar varios de ellos.

También es posible otra clasificación atendiendo a la altura del piso de la nube. En esta clasificación destaca el papel de la *tropopausa*, que es la frontera entre la troposfera (contiene casi todo el vapor de agua de la atmósfera) y la estratosfera. Como las nubes necesitan vapor de agua para su formación, solo aparecerán en la troposfera. Sin embargo, la tropopausa no es uniforme a lo largo del planeta, sino que varía con la latitud, se encuentra más elevada en las zonas ecuatoriales que en los polos, y también varía con las estaciones, ya que en verano se encuen-

tra más elevada que en invierno, por lo tanto, la tropopausa muestra una estructura cambiante y dinámica. Como en la troposfera, la temperatura disminuye con la altitud, y en la estratosfera la temperatura primero es constante y luego aumenta con la altitud, la tropopausa funciona como una especie de tapadera de los movimientos en sentido vertical del aire, estableciendo claramente el límite superior de la formación de nubes.

Una vez establecido el límite superior de las nubes, veamos como se clasifican las mismas, desde la superficie terrestre hasta ese límite de la tropopausa.

Esta clasificación se realiza en tres pisos y los géneros de nubes que pertenecen a cada uno de dichos pisos son:

- Piso alto: *Cirrus*, *Cirrocumulus* y *Cirrostratus*.
- Piso medio: *Altostratus*, *Altostratus* y *Nimbostratus*.
- Piso bajo: *Stratocumulus* y *Stratus*.

Por otra parte, a los *Cumulus* y *Cumulonimbus* se les conoce como nubes de desarrollo vertical y pueden ocupar varios pisos simultáneamente.

A continuación, se muestra en tabla 1 la distribución en altura aproximada de cada uno de los pisos, atendiendo a la latitud y época estacional.

Tabla 1: Distribución en altura de los pisos de nubes.

Estimación de alturas de los diferentes pisos de nubes en función de latitud y época estacional						
PISOS DE LAS NUBES	REGIONES POLARES		REGIONES TEMPLADAS		REGIONES TROPICALES	
	invierno	verano	invierno	verano	invierno	verano
Alto	4-6 km	5-8 km	6-10 km	8-13 km	8-13 km	10-18 km
Medio	2-4 km	2-5 km	3-6 km	3-8 km	3-8 km	3-10 km
Bajo	superficie-2 km		superficie 2-3 km		superficie 3-4 km	

1.1.4 Importancia

Aparte de la importancia mostrada en la sección 1.1.1, a través del ciclo hidrológico del agua, relacionando el mismo con la fuerte depen-

dencia que los seres vivos presentamos con el agua, las nubes presentan importantes papeles en otros aspectos, como pueden ser en la radiación que llega a la superficie de la tierra, estrechamente relacionada con el calentamiento global, o que las nubes pueden ser buenos indicadores de tiempo, es decir ayudan a los meteorólogos a pronosticar el tiempo con mayor exactitud. El impacto de las nubes en el cambio climático y en particular en el calentamiento global, está siendo uno de los objetos de estudio de la física atmosférica actual. Este impacto dependerá del tipo de nube, así como de su altura.

De este modo, las nubes altas, tienen un papel semejante al aire limpio, pues presentan un grado alto de transparencia a radiación de onda corta, sin embargo, absorben parte de la radiación de onda larga que va al espacio. Las nubes *Cirrus* absorben la radiación de la Tierra y posteriormente emiten radiación infrarroja de onda larga, parte hacia la superficie de la Tierra y parte hacia el exterior.

Como estas nubes son altas, y por consiguiente frías, la radiación emitida al exterior es menor que la que sería en ausencia de nubes, pues la intensidad de la emisión depende directamente de la temperatura del emisor. Por lo tanto, hay parte de la radiación que queda atrapada, haciendo que el efecto de las nubes altas y delgadas sea el de aumentar el calentamiento de la Tierra por efecto invernadero [6].

Por otro lado, las nubes bajas como los *Stratocumulus* enfrían al sistema Tierra. Como son mucho más gruesas que los *Cirrus altos*, no dejan pasar tanta energía solar en dirección a la Tierra, reflejando gran parte hacia el espacio. Además, como están más próximas a la superficie, la diferencia de temperatura respecto a las masas de aire bajas es mínima, por lo que la emisión de onda larga hacia el exterior es prácticamente igual que si no hubiera nubes, es decir, tiene un bajo efecto invernadero.

Por último, se tiene las nubes de convección continua o de desarrollo vertical como se mencionó en la sección 1.1.3, en las que se producen dos efectos, al tener su parte superior a una gran altura y por ende, a menos temperatura, la energía que radian hacia el espacio es menor que en ausencia de nubes, pero, por otro lado, al tener su parte inferior

a bajas alturas y ser gruesa, reflejan gran parte de la energía hacia el espacio, por lo tanto, ambos efectos se compensan y se puede decir que el efecto general invernadero de las *Cumulonimbus* es neutro [6].

En cuanto a la interpretación de la nube o a su uso como indicadores del tiempo, tras muchos estudios se sacan conclusiones tales como que los *Altostratus* presagian tormenta, los *Stratus* dan niebla o que los *Cumulus* son indicadores de buen tiempo[7].

1.2 La cubierta nubosa

La *cubierta nubosa*, también conocida como *cantidad de nubes* o *nubosidad*, es la proporción de cielo o de bóveda celeste cubierta por las nubes [1].

Se habla de *cubierta parcial* si nos referimos a las nubes de un determinado piso o género y total si nos referimos a la suma de las contribuciones de todos los tipos de nubes.

Normalmente, la cubierta nubosa se expresa en *octas de cielo cubierto*, indicando el número de octavos de la bóveda terrestre que están cubiertos por nubes.

En cuanto a la cuantificación de la nubosidad, se puede establecer lo siguiente [8]:

- De 0 a 1 octas, se define como cielo despejado.
- De 2 a 3 octas, se define como cielo poco nuboso.
- De 4 a 6 octas, se define como cielo nuboso.
- De 7 a 8 octas, se define como cielo cubierto.

En lo que se refiere a los términos de evolución temporal se puede establecer lo siguiente:

- Sin cambios en la nubosidad.
- Aumentar: El aumento provoca un cambio de categoría de nubosidad, hacia una superior.

- Abrirse claros: La disminución provoca un cambio de categoría hacia una nubosidad inferior.
- Intervalos nubosos: Alternancia de cielos nubosos y poco nubosos.

1.2.1 Equipos de medida.

Podemos clasificar los equipos de medida en dos tipos [11]. Por un lado, tenemos los equipos en superficie que permiten obtener información de un área en particular de forma bastante precisa, por otro lado, tenemos los satélites, que permiten áreas de estudio de mayor dimensión, a cambio de resolución más baja, menor detalle y mayor intervalo de error, produciendo esto que las nubes pequeñas y finas puedan no ser detectadas o incluso puedan ser confundidas con superficie terrestre.

De forma general, los instrumentos satelitales son más caros que los de superficie, a excepción del Radar en superficie, cuyo costo también es elevado.

Consecuentemente, atendiendo a lo descrito en el párrafo anterior, procedemos a establecer una clasificación de los diferentes equipos de medida y reflejar en algunas de sus categorías información relevante.

- Equipos de superficie: Aquellos fijos o incrustados a algún vehículo terrestre. Área de estudio pequeña, pero gran resolución[10].

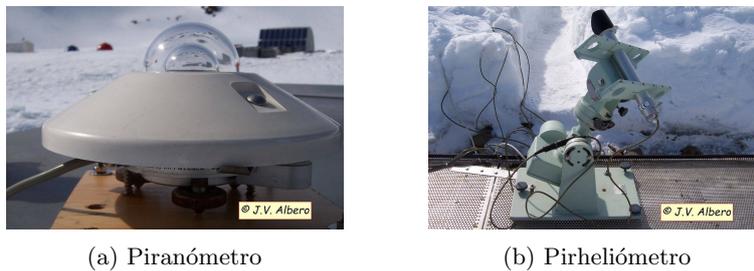
1. Medidores de irradiancia y radiómetros: Su uso se basa en que cualquier cuerpo con temperatura por encima de 0 K (cero absoluto), emiten radiación electromagnética debido a las oscilaciones moleculares. De forma que cuando la temperatura del emisor asciende, las oscilaciones mencionadas son más intensas, la intensidad de radiación crece y la longitud de onda se hace más pequeña (ver ecuación 1). Por lo que todo en la naturaleza presenta diferente espectro de emisión y esto permite distinguir en este caso particular al sol, las nubes, los edificios, etc.

Ejemplos de esos medidores son los piranómetros que miden la radiación de onda corta global, los pirradiómetros, los pirheliómetros(*véase* figura 3), fotómetros, IR pirómetros y

radiómetros que miden emisiones térmicas emitidas por las superficies de los objetos, basándose para ello en la Ley de Stefan–Boltzmann[9]:

$$E = \sigma T^4 \quad (1)$$

donde σ es la constante de Stefan-Boltzmann, T la temperatura absoluta en la superficie y E la energía emitida.



(a) Piranómetro

(b) Pirheliómetro

Figura 3: Fotografías de dos equipos de medida

2. Cámaras espectrales de cielo: Recogen fotografías del estado del cielo en el visible (*véase* la figura 4), IR o UV espectro. Las cámaras espectrales del visible clasifican las nubes atendiendo a las diferencias de color e intensidad entre los diferentes tipos de nube y el cielo. Típicamente, estas cámaras recogen imágenes de forma automática en intervalos de tiempo establecidos, pudiendo variar estos por el día y por la noche, de acuerdo al estudio particular en cuestión.

Estas cámaras permiten estudiar la nubosidad que cubre una vista de 180° . Una cámara de cielo típica tiene dos componentes, por un lado, presenta una caja resistente a la intemperie con la óptica ensamblada a ella y el segundo es el ensamblaje de control de la computadora. En el interior del ensamblaje óptico, se encuentra un sensor CCD²o CMOS³ apuntando hacia arriba.

Una disposición típica de una cámara de cielo consiste en la cámara, una lente de ojo de pez colocada en la parte supe-

²del inglés Charge-Coupled Device.

³del inglés, acrónimo de Complementary Metal Oxide Semiconductor.

rior y un cristal óptico hemisférico para proteger a la cámara del medio ambiente, en ocasiones también son usados filtros espectrales para bloquear la intensa radiación solar que incide de forma normal y directa. Otra disposición alternativa, sería tener la cámara apuntando hacia abajo, en la dirección de un espejo hemisférico que refleja el cielo en la lente.



Figura 4: Imagen de cielo de una cámara de cielo.

3. Los instrumentos de sensor remoto activo: tienen sensores activos que transmiten energía en una longitud de onda corta específica y comparan las características de lo transmitido y lo recibido[12]. Ejemplos de ellos pueden ser los radares MMWR⁴, MMCR⁵, o los ceilómetros, los cuales usan la técnica LIDAR⁶ para estimar la altura de la base de las nubes.
4. Radiosondas: Se trata de varios instrumentos electrónicos integrados en un globo meteorológico, el cual está lleno de hidrógeno o helio y alcanza altitudes de unos 30 km. El globo proporciona datos como la presión, temperatura o humedad relativa respecto a la altura, por lo que durante su ascenso, permite obtener conclusiones respecto a las nubes presentes a diferentes altitudes en ese momento.

- Equipos satélite: Área de estudio de gran tamaño, los hay geoes-

⁴del inglés MilliMeter Wave Radars

⁵del inglés MilliMeter wave Cloud Radars

⁶del inglés Light Detection And Ranging

tacionarios, helioestacionarios o geopolares.

Se equipan con un instrumento multiradiómetro denominado *imager*, de forma que permiten obtener gran variedad de información. Ejemplos: Meteosat, FY-1 [11].

1.3. Redes Neuronales para el cálculo de la cubierta nubosa con cámaras de cielo

En esta sección, de los instrumentos mencionados en el apartado anterior, nos centraremos en las cámaras de cielo, debido a sus múltiples ventajas. Por un lado, está el aspecto económico, pues las cámaras de cielo son baratas en relación con otros equipos de medida, además presentan un mantenimiento simple, por otro lado, como se puede ver en [11], presentan un gran potencial, pues sus resultados son muy buenos y su portabilidad es sencilla, ya que se puede cambiar su instalación en poco tiempo.

Tradicionalmente, se han usado algoritmos y métodos en el uso de las cámaras de cielo que consistían en identificar zonas blancas y azules, sin embargo, en la actualidad, se están implementando técnicas de inteligencia artificial, para obtener de forma eficiente la nubosidad a partir de una cámara de cielo, esto es importante para poder clasificar adecuadamente las nubes futuras, pero también para poder clasificar todos los volúmenes de datos pasados que se tengan.

Para ello, se utilizan redes neuronales convoluciones, que tras ser entrenadas, son capaces de reconocer el número de octas de la bóveda celeste con una precisión y una efectividad adecuada.

Recordemos que la convolución es una operación matemática sobre dos funciones (f , g) a través de la cual se obtiene otra función (s). Normalmente, la operación de convolución se expresa con un asterisco.

$$s(t) = (f * g)(t) = \int f(\tau)g(t - \tau)d\tau \quad (2)$$

En la terminología de las redes neuronales convolucionales, el primer argumento de la convolución (f en la ecuación 2), sería *la entrada o*

input , y el segundo argumento (*g*) sería el *filtro o kernel* , del mismo modo, la función de salida (*s*) será el *mapa de característica o feature map* [5]. En las aplicaciones usuales de machine learning, la entrada es un vector unidimensional de datos y el kernel lo es de parámetros.

Antes de presentar la estructura de estas CNN⁷, presentemos dos ventajas que presentan respecto de las redes neuronales tradicionales, y que las hacen diferenciadoras, sobre todo en el campo del reconocimiento de imágenes. Estas ventajas son las siguientes[13]:

- Conexiones dispersas: En las redes tradicionales, cada neurona está conectada a todas las neuronas de las capas anterior y posterior; sin embargo, en las CNN, se usa un *kernel* mucho más pequeño que la entrada, permitiendo que sus neuronas puedan trabajar con conexiones dispersas, es decir, están conectadas solo a un subconjunto de la capa posterior y también solo a un subconjunto de la capa anterior, haciendo que el resto de píxeles de la imagen no afecten a la salida.

La estructura y tamaño del conjunto de neuronas, la capa *i* que se conecta con una neurona de la capa *i+1* recibe el nombre de *campo receptivo local*.

- Compartición de parámetros: Para todas las neuronas ocultas de la misma capa se utilizan los mismos pesos y sesgos, por lo que todas las neuronas de la capa oculta detectan la misma característica, aunque lo hacen en diferentes partes o ubicaciones de la imagen de entrada.

Estas ventajas hacen que las CNN sean perfectas para el uso de identificación y clasificación de imágenes, ya que la compartición de parámetros, hace que la red sea invariante frente a movimientos de traslación en la entrada, por otro lado, gracias a las conexiones dispersas, permiten que las neuronas se concentren y se especialicen en un pequeño rectángulo de la imagen de entrada, haciendo que se puedan detectar bien las características de bajo nivel en las primeras capas ocultas, para después ensamblarlas y fijarse progresivamente en niveles más altos de

⁷del inglés Convolutional Neural Network.

complejidad y características [5].

A continuación, mostraremos los elementos clave de la estructura, así como diferentes técnicas de este tipo de redes neuronales[5].

- **Neurona:** Se trata de la unidad elemental, una neurona aplica una función a los valores de sus entradas procedentes de las conexiones con otras neuronas, obteniéndose un valor nuevo que tras ser procesado por lo que se denomina *función de activación* genera el valor de salida.
- **Filtro o *kernel*:** Se trata de la matriz de pesos de una capa de convolución integrada en la CNN. El *kernel* siempre tiene los mismos canales que la entrada, pero con un tamaño mucho menor. Normalmente, la entrada es una imagen en escala de grises o en color, si es una entrada RGB, la salida se obtiene de la forma siguiente:

$$R * K_1 + G * K_2 + B * K_3 \quad (3)$$

Luego, si la dimensiones de la entrada son (n_a, n_b, n_c) y las dimensiones del *kernel* son (n_k, n_k, n_c) , las dimensiones de la salida serán $(n_a - n_k + 1, n_b - n_k + 1, n)$ donde n es el número de *kernels* utilizados (véase la figura 5).

Normalmente, se utilizan un número elevado de kernels, en las CNN destinadas a clasificación de imágenes.

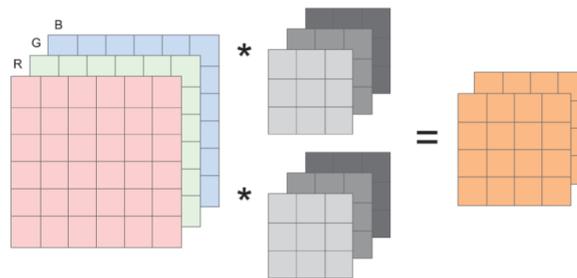


Figura 5: Entrada y salida utilizando dos *kernels*.

[5]

- ***Padding*** : Consiste en añadir ceros al borde de la entrada, de forma que la salida presente la misma dimensión que la entrada

tras aplicar la convolución.

- **Convoluciones por paso:** Se trata de una técnica en la cual el *kernel* no se aplica a celdas consecutivas de la entrada, sino que se aplica con un paso s determinado, este paso s se denomina *stride*.

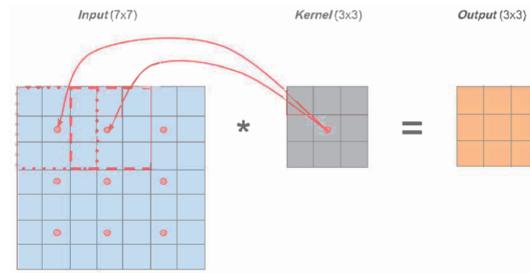


Figura 6: Convolución con $stride = 2$ y $padding = 0$.

[5]

- **Backpropagation :** Se busca ajustar los pesos de cada neurona de forma que se minimice el error, básicamente nos dice la culpa que tiene cada neurona del error global que se ha cometido.
- **Capas:** Se trata de diferentes agrupaciones de neuronas operativas en cada paso. Normalmente, se considera por convenio que el conjunto capa de convolución y capa de agrupamiento, forman una sola capa:
 1. **Capas de agrupamiento o *pooling*:** El objetivo principal de esta capa es reducir el tamaño del mapa de características, haciendo que la red sea más eficiente, pues tiene un costo operativo menor.
Entre los diferentes tipos de *pooling*, los más usados son *max-pooling*, que se queda con el máximo elemento de cada región y *average-pooling* que hace el promedio de los valores de una determinada región de celdas. Se recomienda el uso de *max-pooling*, pues es más informativa [14].
 2. **Capas totalmente conectadas:** Su objetivo es determinar las características de alto nivel que están mejor correlacionadas con las celdas en cuestión.

3. Capas no lineales o de activación : Normalmente, se aplican después de cada capa de convolución, su propósito es introducir no linealidad al sistema y mejorar el problema de desaparición del gradiente. Las más utilizadas son las funciones tanh, sigmoid o ReLU, esta última aplica la función $f(x) = \max(0, x)$ a los valores de entrada, luego cambia los valores de entrada negativos por un cero, mientras que no altera el valor de los valores positivos de entrada.
4. Capas de dropout : Su función es prevenir el sobreentrenamiento u *overfitting* , para ello desactiva de forma aleatoria un número de entradas dándoles el valor cero, se usa durante la etapa de entrenamiento, pero no durante la etapa de test.

De forma que la arquitectura de una CNN es la que se muestra en la figura 7, donde se enlazan los elementos clave que hemos visto con una red neuronal multicapa tradicional y a través de la función *softmax* se le pasa las probabilidades a las neuronas de salida. El formato de las salidas tras el entrenamiento será el conocido como *one-hot-encoding* , es decir, un vector de ceros con un uno en la posición que corresponde a la etiqueta de la clasificación[15].

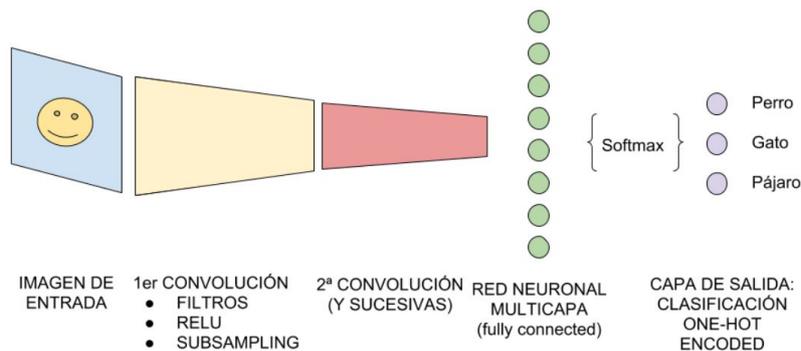


Figura 7: Ejemplo de arquitectura de una CNN para la detección de perros, animales y pájaros en imágenes.

[15].

1.4. Objetivos

En las secciones anteriores, se ha dejado clara la relevancia histórica que ha tenido la cubierta nubosa, como vía de predicción del tiempo atmosférico. También, se ha vislumbrado la introducción y posterior desarrollo de las técnicas de inteligencia artificial en las medidas de la nubosidad, en particular, las utilizadas tras obtener imágenes de cielo mediante cámaras de cielo. Es por ello, que el objetivo principal de este trabajo, se basa en valorar de forma objetiva el uso de imágenes procedentes de una cámara de cielo para obtener la cubierta nubosa mediante técnicas de inteligencia artificial.

Además, el trabajo presente aborda otros objetivos secundarios como son:

- Realizar una descripción cualitativa de los mecanismos de formación de nubes, así como de su clasificación.
- Dar a conocer los principales instrumentos de medida de la nubosidad, así como los principios físicos en los que se basa su funcionamiento.
- Destacar el papel de las CNN sobre otras redes neuronales. Ya que en la clasificación de imágenes, objetivo principal de este trabajo, presentan una gran ventaja, así como buenos resultados.
- Mostrar las diferentes herramientas y entornos de trabajo que se proporcionan en la web de forma gratuita, para el correcto desarrollo de nuestras tareas de clasificación.
- Reflejar el uso de la estadística, como vía para dar conclusiones objetivas sobre los resultados de un estudio.

Capítulo 2

Instrumentación y metodología

Para el desarrollo de este trabajo se han empleado:

- Imágenes obtenidas por la cámara de cielo OMEA 3C, del fabricante Alcor System, la cual está bajo la supervisión del “Grupo de Óptica Atmosférica” de la Universidad de Valladolid.
- Mediciones proporcionadas por el ceilómetro CHM15k Nimbus, del fabricante Lufft, perteneciente también al “Grupo de Óptica Atmosférica” de la Universidad de Valladolid.
- “Teachable Machine 2.0”, una herramienta de inteligencia artificial creada por Google, que facilita la creación de modelos de aprendizaje automático.
- “Google Colab”, un servicio de Google Research que permite al usuario escribir y ejecutar código Python, sin necesidad de configuración ni de instalación de software.
- Anaconda, una distribución libre de Python enfocada en la computación científica.

2.1. Cámara de cielo

Durante el trabajo, la cámara de cielo utilizada presentará dos ubicaciones. Estará ubicada en La Palma, España ($28,486^{\circ}$ N, $17,848^{\circ}$ E; 632 m s.n.m) desde el 06-10-2021 al 08-02-2022, mientras que se encontrará en el Centro de Investigación Atmosférica de Izaña, España ($28,30^{\circ}$ N, $16,49^{\circ}$ E; 2400 m s.n.m) desde el 08-02-2022 al 28-02-2022. La primera ubicación está motivada por el deseo de monitorizar la erupción del volcán Cumbre Vieja, situado en La Palma. Dicha instalación se realizó dentro de un marco de despliegue de instrumentación

atmosférica de muchas instituciones, gracias a la cual, se pudo observar las nubes que hubo.

El modelo de la cámara utilizada es OMEA 3C, del fabricante Alcor System (*véase* figura 8). Dicho dispositivo consiste en un sensor CMOS acoplado a una lente de pez, estando ambos elementos dentro de una cúpula impermeable y transparente de cristal.



Figura 8: Cámara de cielo OMEA 3C.

[16]

Cada imagen obtenida es la combinación HDR⁸ de varias imágenes con diferentes tiempos de exposición, el número de imágenes de la combinación HDR varía en función de la altura del sol.

A continuación, se muestran algunas especificaciones de la cámara (*véase* tabla 2), esta información ha sido extraída de la documentación oficial del fabricante[16].

⁸Por sus siglas en inglés: High Dynamic Range, técnica para mejorar la calidad de la imagen optimizando luz, contraste y color.

Tabla 2: Especificaciones de la cámara de cielo OMEA 3C de Alcor System.

Tipo sensor	Color
Campo de visión	180° x 180°
Rango de longitud de onda	350 nm a 750 nm, presenta filtro de corte IR
Resolución de la cámara	3100 x 2100 píxeles
Resolución ADC (convertor analógico digital)	14 bits
Flujo de vídeo en directo	6.5 fps USB 2.0 - 30 fps USB 3.0
Sistema Operativo	Compatible con Windows 7 y 10 (32,64 bits)
Características fuente de alimentación	24V / 3A
Peso	3,5 kilogramos
Rango operacional de temperatura	Desde -35°C a 45°C

Las imágenes HDR obtenidas por la cámara se almacenan en Nextcloud, una plataforma de alojamiento de archivos, donde posteriormente se realizará el etiquetado.

2.2. Ceilómetro

El uso de un ceilómetro en este trabajo, está motivado por su ayuda a la hora de clasificar determinadas imágenes, ya que, en ocasiones, las nubes altas son difíciles de apreciar y en otras, se pueden confundir con la presencia de aerosoles. Gracias a la información proporcionada por este instrumento, podremos determinar qué es lo que realmente se ve, se verá con más detalle en el apartado siguiente.

El modelo del ceilómetro utilizado en este trabajo es CHM15k Nimbus, del fabricante Lufft (*véase* figura 9), el cual pertenece al “Grupo de Óptica Atmosférica de la Universidad de Valladolid” y está incluido en la red ICENET⁹. Utiliza la tecnología láser de diodo pulsado LIDAR¹⁰, emite un pulso láser Nd:YAG de 1064 nm de longitud de onda y posteriormente mide la señal retrodispersada por la atmósfera a diferentes alturas, concretamente hasta 15360 m s.n.m. con una resolución de 15 m[18].

⁹Iberian Ceilometer Network. Definida en [17] como una red colaborativa con el fin de caracterizar la distribución vertical de partículas de aerosol al nivel regional de la península ibérica.

¹⁰Por sus siglas en inglés, Light Detection and Ranging.

La energía por pulso es de 8,4 μJ , con una frecuencia de repetición en el rango de 5 a 7 kHz. La divergencia del rayo láser es inferior a 0,3 mrad y la señal retrodispersada es recogida por un telescopio con campo de visión de 0.45 mrad. La señal es detectada por un fotodiodo de avalancha en modo contador de fotones[17]. La superposición del telescopio y del láser tiene lugar a 1500 m sobre el instrumento. De acuerdo con la función de superposición del fabricante, la superposición es completada al 90 % entre los 555 y 885 m s.n.m [19].



Figura 9: Ceilómetro CHM15k Nimbus [20].

2.3. Etiquetado de las imágenes de cielo

En este trabajo se procede a etiquetar, de forma manual e individualizada, las imágenes diurnas correspondientes al periodo comprendido entre el 06-10-2021 y 28-02-2022. Dichas fotografías fueron tomadas en intervalos de dos minutos desde el 06-10-2021 hasta el 03-02-2022, mientras que desde el 04-02-2022 al 28-02-2022 fueron tomadas cada 5 minutos, por lo que el número total de imágenes etiquetadas manualmente fue de 34826.

En cada una de las fotos, se identifica la nubosidad que presenta el cielo de la misma, para ello se indica el número de octavos de cielo que están cubiertos de nubes mediante 9 etiquetas (0 octas, 1 octas, 2

octas, 3 octas, 4 octas, 5 octas, 6 octas, 7 octas, 8 octas). Se trata de una medida subjetiva, ya que depende del ojo del observador, por lo que se asume un error de ± 1 octa. Además, la estrategia de clasificación que se ha utilizado es la de redondeo por exceso, pues en los casos donde las nubes no cubrían un número entero de octas, se ha indicado la etiqueta inmediatamente superior, es decir, si el cielo de una imagen está cubierto por más de 3 octas de nubes, pero menos de 4 octas, la etiqueta que se ha indicado es la de 4 octas.

A continuación, se muestra en la figura 10, cuatro ejemplos de etiquetado.

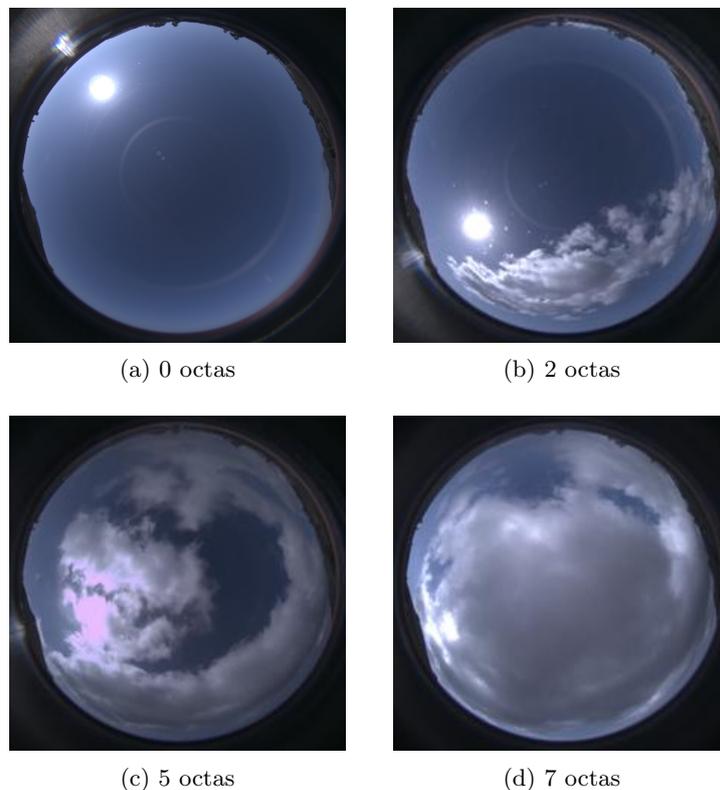
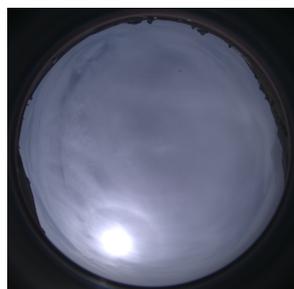


Figura 10: Imágenes de cámara de cielo con diferentes etiquetas asociadas.

También durante el etiquetado, y como se dijo en la sección 2.2, se emplea la ayuda del ceilómetro a la hora de distinguir las nubes altas de la presencia de aerosoles. En la figura 11, se tienen dos imágenes de aspecto similar, sin embargo, la señal proporcionada por el ceilómetro,

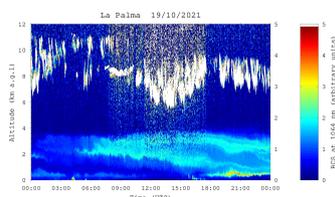
nos permite diferenciar de forma clara el fenómeno que realmente se observa.



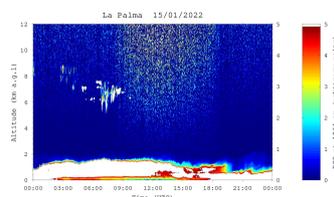
(a) Imagen con nubes altas
17:32 (UTC).



(b) Imagen con aerosol
09:52 (UTC).



(c) Medidas del ceilómetro asociada
a la figura 11.a.



(d) Medidas del ceilómetro asociada
a la figura 11.b.

Figura 11: Comparación de imágenes de cielo con presencia de nubes altas y aerosoles.

2.4. Entrenamiento de la red Neuronal

Una vez finalizado el etiquetado de las imágenes, se procede a separar las mismas en dos conjuntos. Un conjunto de entrenamiento, formado por el 90 % de las imágenes, y un conjunto de validación, formado por el 10 % de las imágenes restantes. El conjunto de entrenamiento se utiliza para entrenar a la red neuronal y que esta aprenda; por otro lado, el conjunto de validación se emplea para realizar las pruebas oportunas a nuestras redes entrenadas, y obtener las características y estadísticas de la misma, que nos permitan extraer las conclusiones buscadas. Para evitar un problema de sesgo en la formación de estos dos conjuntos, las imágenes son asociadas a cada conjunto de forma totalmente aleatoria, intentando buscar homogeneidad, en cuanto al número de oc-

tas de las imágenes presentes en cada uno de ellos, para ello se ha realizado e implementado un código Python que puede verse en el apéndice A.

Para obtener los modelos clasificadores de imágenes, se ha utilizado la herramienta “Teachable machine 2.0”, se trata de una herramienta gratuita de Google que busca difundir y acercar la inteligencia artificial a un público general. Se puede acceder a ella si se dispone de conexión a internet en el siguiente enlace: <https://teachablemachine.withgoogle.com/train>.

La interfaz de esta herramienta es sencilla, amigable e intuitiva. Tras acceder al enlace expuesto anteriormente, se seleccionará proyecto de imagen (véase figura 12), pues la herramienta permite realizar otros modelos, como pueden ser de audios, o de posturas.

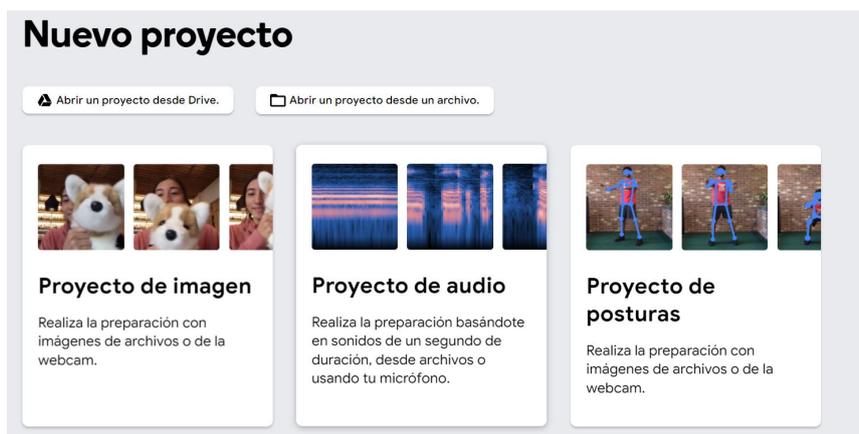


Figura 12: Interfaz de “Teachable machine 2.0” para la elección de tipo de proyecto.

Una vez elegido el tipo de proyecto, en nuestro caso proyecto de imagen, la herramienta nos permitirá preparar el entrenamiento de nuestros modelos, para ello nos muestra la interfaz presente en la figura 13.

Las imágenes del conjunto de entrenamiento se seleccionan en la parte izquierda, donde se cargarán en diferentes clases (“class”), que serán nuestras etiquetas, y así lo entenderá la red neuronal del modelo. Una vez cargadas las imágenes, se establecen los parámetros del modelo

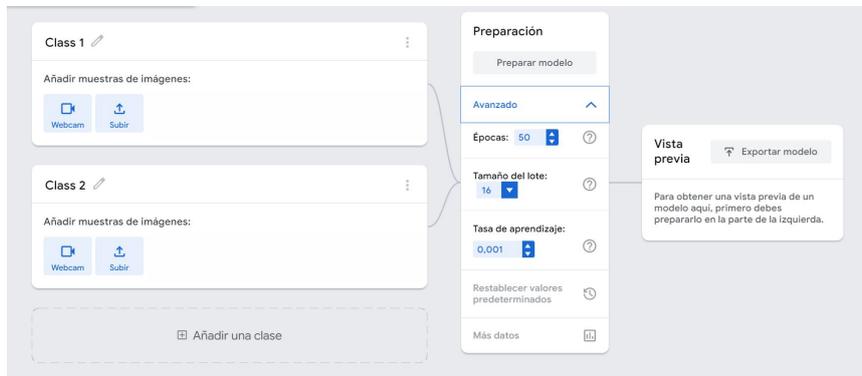


Figura 13: Interfaz de “Teachable machine 2.0” para la preparación de nuestros modelos.

en la parte central. Estos parámetros son los siguientes:

- *Épocas*: Se dice que el modelo ha completado una época cuando ha procesado todas las muestras de entrenamiento, por lo que el número de épocas indica el número de veces que cada imagen es procesada por el modelo a entrenar. Normalmente, cuanto mayor es este parámetro, mejor aprende nuestro modelo a predecir los datos. Sin embargo, un valor alto de este parámetro también puede ser la causa del sobreentrenamiento, luego encontrar un valor adecuado, es fundamental para que nuestro modelo arroje buenos resultados. Su valor por defecto es de 50.
- *Tamaño del lote*: El tamaño del lote es el conjunto de muestras que se utilizan en cada iteración de preparación, es decir, es el número de imágenes que se procesan antes de ajustar los pesos de la red neuronal. Si por ejemplo se tienen 100 imágenes y un tamaño de lote de 10, las 100 imágenes se dividirán en 10 lotes de 10, cuando todos los lotes hayan sido procesados, se habrá completado una época. El tamaño del lote siempre es menor o igual que el número de imágenes de entrenamiento. Su valor por defecto es 16.
- *Tasa de aprendizaje*: Se trata de un parámetro que limita la cantidad de información que el modelo puede aprender en cada iteración, se utiliza para evitar el fenómeno de sobreajuste, sin em-

bargo, una tasa de aprendizaje demasiado pequeña, hará que el costo computacional se eleve en gran cantidad, luego el tiempo de entrenamiento también aumentará notablemente. Pequeños cambios en este parámetro, pueden ocasionar grandes diferencias en los modelos. Su valor está comprendido entre 0 y 1, y su valor por defecto es de 0,001.

Se han realizado 8 modelos diferentes, para distintas combinaciones de los parámetros que se acaban de mencionar, con el objetivo de encontrar la combinación de los mismos que proporcionen los mejores resultados. Se han combinado los valores de **Épocas**=50, 200 con los valores de **Tamaño del lote**=16, 32 y **Tasa de aprendizaje**=0,001; 0,0001.

Tras realizar los entrenamientos de los modelos, estos se guardan y se exportan en formato “.h5”¹¹. A continuación, se cargarán los modelos en “Google Colab” haciendo gran uso de los paquetes Python Keras, Tensorflow y Numpy. Una vez cargados los modelos, se procederá a obtener la bondad de cada uno de ellos, teniendo en cuenta que la salida proporcionada por un modelo, tras procesar una imagen, es un vector de 9 columnas, donde cada entrada recoge la probabilidad que el modelo asocia a que la imagen en cuestión tenga cada etiqueta, luego recoge la probabilidad de que el cielo presente en esa imagen concreta cada posible número de octas. El código Python necesario para cargar dichos modelos, proceder a la obtención de resultados y obtener las métricas necesarias para la validación de los mismos, es el mostrado en el Apéndice B.

¹¹Un archivo H5 es un archivo de datos guardado en el formato de datos jerárquicos (HDF), es un tipo de archivo destinado al almacenamiento de grandes cantidades de datos numéricos, gráficos y de texto.

Capítulo 3

Resultados

En este capítulo se procederá a evaluar cada uno de los 8 modelos, con el fin de realizar comparaciones objetivas entre ellos, de forma que nos permita concluir si realmente las CNN son aptas para la clasificación de imágenes, y si lo son, en el caso de nuestro trabajo, cuáles son los mejores modelos de entre los empleados para dicha tarea.

Para la obtención de las diferentes métricas, siempre se compara la etiqueta predicha por el modelo en estudio, con la etiqueta real, es decir, la que hemos etiquetado. Se utilizan para esta comparación, el conjunto de imágenes de validación, separado previamente, del que se habló en el capítulo 2. Nótese, como se muestra en la tabla 3, que para cada etiqueta, el número de imágenes de validación es diferente.

Tabla 3: Número de imágenes de validación para cada etiqueta de número de octas.

Etiqueta número de octas	0	1	2	3	4	5	6	7	8
Imágenes de validación	556	496	296	206	169	237	268	424	769

Por eficiencia, se utilizará la notación indicada en la tabla 4:

Tabla 4: Notación de los modelos utilizados junto con sus parámetros.

Modelo	Épocas	Tamaño de lote	Tasa de aprendizaje
1	50	16	0,0001
2	50	32	0,0001
3	50	16	0,001
4	50	32	0,001
5	200	16	0,0001
6	200	32	0,0001
7	200	16	0,001
8	200	32	0,001

3.1. Error absoluto medio

Se trata de la métrica más directa, para la evaluación del grado de divergencia entre dos conjuntos de valores [5].

Sea N el número de imágenes validadas, \mathbf{x} el vector, de longitud N , cuyas componentes contienen el número de octas predicho para cada imagen, e \mathbf{y} el vector, de longitud N , cuyas componentes contienen el número de octas real para cada una de ellas, su expresión viene dada por:

$$\frac{1}{N} \sum_{i=1}^N |x_i - y_i|$$

Nótese, que todos los errores de las diferentes componentes, tienen el mismo peso en la contribución del error total final, además la métrica solo puede tomar valores mayores o iguales a cero debido a su expresión. A continuación, se muestra en la tabla 5, los valores obtenidos de esta métrica para cada modelo y cada etiqueta diferente, así como el valor de la misma para el conjunto de todas las imágenes de validación al ser tratadas por cada modelo de estudio.

Tabla 5: Valores en octas del error absoluto medio para los diferentes modelos e imágenes.

		ERROR ABSOLUTO MEDIO									
		IMÁGENES DE ESTUDIO									
		0 octas	1 octas	2 octas	3 octas	4 octas	5 octas	6 octas	7 octas	8 octas	Todas
MODELO	1	0,0773	0,1149	0,4662	0,4320	0,9881	0,5105	0,6716	0,3915	0,0831	0,2996
	2	0,0450	0,1146	0,4788	0,4567	0,9887	0,5109	0,6311	0,3916	0,0831	0,2943
	3	0,0881	0,1649	0,4987	0,4879	0,9999	0,5563	0,6816	0,4356	0,0945	0,3013
	4	0,0234	0,1722	0,4999	0,4345	0,9992	0,5678	0,6857	0,4256	0,0931	0,2908
	5	0,0629	0,1001	0,4176	0,4120	0,9881	0,4987	0,6481	0,3876	0,0772	0,2907
	6	0,0665	0,1875	0,2939	0,3922	0,7101	0,5696	0,6567	0,4222	0,0962	0,2930
	7	0,0629	0,1069	0,4426	0,4806	0,7278	0,6582	0,6940	0,5542	0,0780	0,3151
	8	0,0935	0,1391	0,3750	0,6602	0,7574	0,4219	0,0336	0,4009	0,0780	0,2996

Se observa, que a medida que aumenta el número de octas, el error absoluto medio primero crece y luego decrece. Esto es debido, a que los valores extremos, es decir, 0 octas y 8 octas, son dos escenarios muy bien definidos, totalmente despejado o cubierto respectivamente, mientras que los cielos parcialmente cubiertos son más variables, las

nubes pueden ocupar el cielo de muchas combinaciones distintas y es más probable desviarse del resultado final.

Esto hace, por lo tanto, que los valores medios, como son 3, 4 y 5 octas, presenten un error absoluto medio mayor. Nótese, que el valor obtenido para el total de las imágenes no es la media de los diferentes valores para cada etiqueta vista de forma individual, ya que el número de imágenes de cada etiqueta en el set de validación, no es el mismo.

En lo relativo a la comparación entre los distintos modelos, se observa una gran igualdad en el comportamiento de todos ellos frente a las distintas imágenes, siendo quizá, los modelos 4 y 5 los que presentan unos mejores resultados, pues en la mayoría de los casos son los que menor error absoluto medio presentan.

3.2. Error medio

Ahora, en lugar de calcular el valor absoluto de las diferencias, se calculará las diferencias entre el valor predicho y el real para cada imagen, obteniendo la media de estas diferencias sobre el conjunto de imágenes de estudio en cada caso. Es importante notar, que al contrario de lo que ocurre con el error absoluto medio, se pueden obtener valores nulos y negativos, pues se van compensando las predicciones por exceso y las de por defecto, haciendo que su efecto total pueda ser cualquier valor real.

Se trata de una métrica utilizada para estimar *la exactitud*, ya que determina cuán de cerca el valor predicho se encuentra respecto al valor real [22]. Su expresión, siguiendo con la notación introducida en la sección anterior, es la siguiente:

$$\frac{1}{N} \sum_{i=1}^N (x_i - y_i)$$

Mostramos a continuación en la tabla 6, los resultados obtenidos, siendo los casos de estudio, los contemplados con la métrica anterior. Nótese, que la bondad del modelo estará relacionada siguiendo la información de esta métrica, con la proximidad a cero de la misma, pues un valor de 0, reflejaría una gran exactitud.

Tabla 6: Valores en octas del error medio para los diferentes modelos e imágenes.

		ERROR MEDIO									
		IMÁGENES DE ESTUDIO									
		0 octas	1 octas	2 octas	3 octas	4 octas	5 octas	6 octas	7 octas	8 octas	Todas
MODELO	1	-0,0773	-0,0464	-0,0270	-0,0922	-0,2189	-0,1308	-0,1493	-0,0943	0,0832	0,0517
	2	-0,0450	-0,0403	-0,0878	0,0097	-1,1265	0,0042	0,0112	0,0660	0,1560	-0,0196
	3	-0,0881	-0,0827	-0,0743	0,0243	-0,1538	-0,0886	-0,1866	-0,1085	0,0962	0,0514
	4	-0,0234	0,0323	-0,1453	-0,2573	-0,1775	-0,0253	0,0858	0,1415	0,1352	-0,0170
	5	-0,0629	-0,0343	-0,1149	-0,1893	-0,1479	0,0295	-0,0560	0,1061	0,1144	0,0073
	6	-0,0665	-0,1109	-0,0777	-0,0485	-0,1183	0,0295	-0,0522	0,0165	0,0962	0,0208
	7	-0,0629	-0,0343	-0,0642	0,0146	-0,0414	0,1350	0,1642	-0,0259	0,0780	-0,0146
	8	-0,0935	-0,0867	-0,0507	-0,2330	-0,1775	-0,0169	0,7425	0,0047	0,0780	0,0354

Se observa claramente que para valores de octas bajos, nuestros modelos infraestiman el resultado (valores negativos), mientras que para los valores altos de octas, ocurre lo contrario, los modelos sobrestiman el resultado. Nótese, que en el caso de 0 octas y 8 octas, el signo del error medio es trivial, pues la etiqueta de 0 octas solo se puede sobrestimar y la de 8 octas infraestimar.

También se concluye, que al aumentar la tasa de aprendizaje, el error medio disminuye, lo mismo ocurre al aumentar el número de épocas.

A la vista de estos resultados, se puede deducir que todos los modelos presentan una gran exactitud, pues su error medio es muy próximo a cero, siendo los modelos 5 y 7 los que mejor exactitud presentan en general.

3.3. Desviación estándar

A veces es importante estudiar *la precisión*, es decir, el grado en el que la repetición de una medición bajo las mismas condiciones muestra los mismos resultados. Esta precisión es estimada mediante la desviación estándar, que sirve de reflejo de la dispersión de los datos en torno a la media de los mismos [22]. Su expresión es la siguiente:

$$\sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}}$$

En la tabla 7, se muestran los resultados obtenidos para esta métrica. La primera observación relevante se trata de que, en la mayoría de los casos, su valor es menor que 1, luego la idea de cometer un error de ± 1 octa, es válida y queda contrastada. En la línea de las otras métricas, los valores extremos presentan una menor dispersión que los valores centrales. Los mejores modelos son el 5 y el 6, aunque todos los modelos presentan resultados muy parecidos.

Tabla 7: Desviación estándar para los diferentes modelos e imágenes.

		DESVIACIÓN ESTÁNDAR									
		IMÁGENES DE ESTUDIO									
		0 octas	1 octas	2 octas	3 octas	4 octas	5 octas	6 octas	7 octas	8 octas	Todas
MODELO	1	0,4482	0,4917	0,7729	0,9010	1,1890	0,9454	0,9850	0,6627	0,4526	0,6932
	2	0,4153	0,4984	0,7661	0,9295	1,1266	0,9346	0,9080	0,6446	0,5648	0,6965
	3	0,5136	0,5743	0,7406	0,9626	1,1041	1,1421	1,0414	0,6276	0,4125	0,7244
	4	0,2425	0,4295	0,8398	0,7925	1,1112	0,8466	0,8081	0,9234	0,5420	0,6951
	5	0,4341	0,3490	0,7357	0,9180	1,1243	0,9431	0,9227	0,8471	0,4545	0,6921
	6	0,4956	0,5479	0,7147	0,9125	1,0136	0,9341	1,0245	0,7119	0,4094	0,6910
	7	0,4085	0,3714	0,8049	0,8330	1,1006	1,0014	1,0523	0,9476	0,3906	0,7159
	8	0,4629	0,5184	0,7628	0,9675	1,0897	0,8367	0,9664	0,7980	0,3906	0,6959

3.4. Raíz del error cuadrático medio

El objetivo fundamental del estudio de esta métrica, es el de penalizar los residuos grandes [5], lo que no ocurre con las métricas vistas con anterioridad. De hecho, si el modelo aproxima de forma correcta un número elevado de imágenes, pero comete errores importantes en otras de ellas, la penalización de esta métrica es muy superior respecto de las tratadas con anterioridad. Su expresión vendría dada por:

$$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2}$$

Se trata, al igual que el error medio absoluto, de una métrica que solo puede tomar valores mayores o iguales a cero.

En la tabla 8, se muestran los valores obtenidos de la raíz cuadrada del erro cuadrático medio, haciendo que lo valores mostrados sean en octas, facilitando la comparación e interpretación de los mismos. Observamos, nuevamente, la tendencia creciente de los errores hacia los números intermedios de octas, siendo mínimos en los valores extremos 0 y 8.

Tabla 8: Valores en octas de la raíz del error cuadrático medio para los diferentes modelos e imágenes.

		RAÍZ DEL ERROR CUADRÁTICO MEDIO									
		IMÁGENES DE ESTUDIO									
		0 octas	1 octas	2 octas	3 octas	4 octas	5 octas	6 octas	7 octas	8 octas	Todas
MODELO	1	0,4548	0,4548	0,7534	0,9058	1,2089	0,9346	0,9960	0,6694	0,4503	0,6922
	2	0,6922	0,6922	0,8170	0,9551	1,2129	0,9281	0,9666	0,6703	0,4807	0,6884
	3	0,6884	0,6884	0,8292	0,9474	1,2211	0,9387	0,9770	0,6918	0,4750	0,6997
	4	0,6997	0,6997	0,8352	0,9424	1,2172	0,9435	0,9960	0,6986	0,4567	0,6746
	5	0,6746	0,6746	0,7467	0,8947	1,1668	0,9238	0,9551	0,6466	0,4503	0,6905
	6	0,5000	0,5590	0,7190	0,9138	1,0205	0,9346	1,0258	0,7121	0,4205	0,6913
	7	0,4134	0,3730	0,8075	0,8332	1,1014	1,0105	1,0650	0,9479	0,3983	0,7160
	8	0,4723	0,5256	0,7645	0,9951	1,1041	0,8369	0,9912	0,7980	0,3983	0,6968

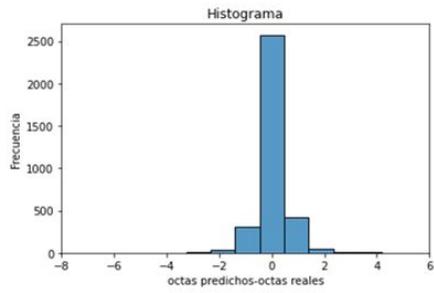
Para los valores intermedios de octas, los mejores modelos son 6 y 8. Para 0 y 8 octas, destacan los modelos 6 y 7. Por otro lado, el modelo 2 es el que presenta mejores resultados, al analizar todas las situaciones a la vez.

3.5. Histogramas

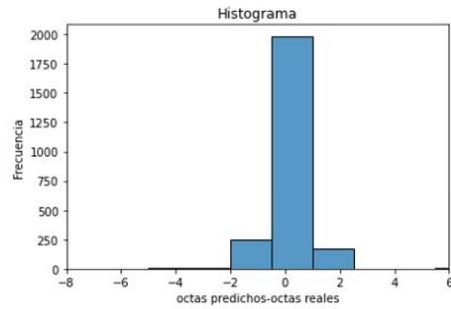
A continuación, se muestran los histogramas de cada modelo realizados con la librería “matplotlib” de Python. En el eje x se tienen la diferencias entre el número de octas predicho y el real, mientras que en el eje y, se muestra la cantidad de imágenes que presentan la diferencia en cuestión, es decir, la frecuencia absoluta. Los histogramas nos permitirán verificar la información proporcionada por la desviación estándar sobre la dispersión de los valores predichos, lo ideal sería que hubiera una gran concentración en torno a cero, ya que significaría un número elevado de diferencias nulas y poca dispersión.

Se puede apreciar en la figura 14 como los valores se concentran en torno al 0, decayendo la frecuencia absoluta de forma progresiva hacia valores más extremos del eje x.

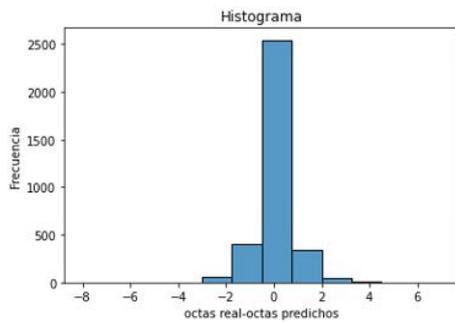
Además, los modelos 3 y 7 presentan una mayor dispersión, pues la frecuencia absoluta en los valores extremos es mayor, luego está en concordancia con lo obtenido en los resultados de la desviación estándar.



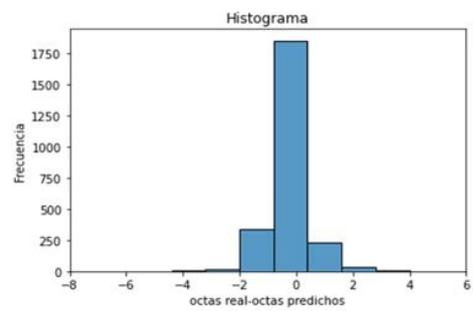
(a) Modelo 1



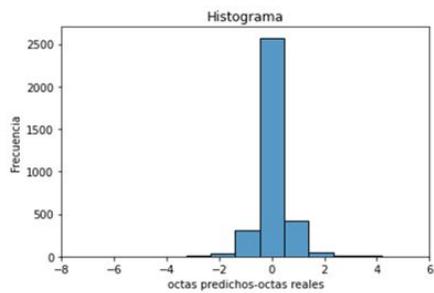
(b) Modelo 2



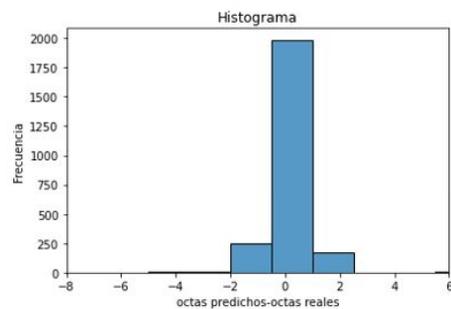
(c) Modelo 3



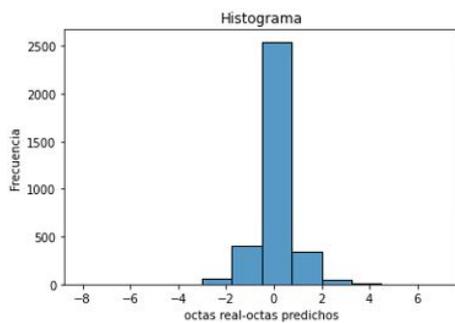
(d) Modelo 4



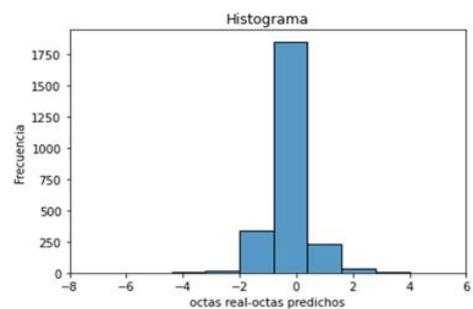
(e) Modelo 5



(f) Modelo 6



(g) Modelo 7



(h) Modelo 8

Figura 14: Histogramas de cada modelo, representando la frecuencia de las diferencias entre los valores predichos y reales.

Se concluye, de forma clara, que todos los modelos son una buena herramienta de clasificación, presentando un gran comportamiento, sin grandes diferencias entre ellos. Aunque bien es cierto, que en los modelos 2 y 6 se aprecia alguna diferencia grande cerca de 6 octas.

3.6. Matrices de confusión

Una matriz de confusión es una herramienta muy utilizada en la inteligencia artificial que permite visualizar el desempeño de los modelos entrenados, destaca por su claridad y fácil interpretación. Cada entrada de la matriz en la posición i,j , representa el número de imágenes con etiqueta i , para los que el modelo ha predicho una etiqueta j . Por lo tanto, los mejores modelos serán aquellos cuyos elementos diagonales presenten los valores más elevados, pues el valor predicho y el valor real coincidirán. Además, se ha añadido un mapa de calor en cada una de ellas, que permite obtener conclusiones acerca de la magnitud relativa de cada entrada en cuestión frente al total de entradas, de forma rápida y visual.

A continuación, se muestran dos matrices de confusión para cada modelo (Figuras 15-22), una no normalizada (estándar) y la otra normalizada por filas, es decir, las entradas de la matriz de confusión normalizada que se presenta, indican el porcentaje de asignación para cada etiqueta que el modelo otorga para cada posible etiqueta de entrada, luego los elementos de la diagonal en esta matriz de confusión normalizada nos proporcionará la tasa de acierto para cada etiqueta de entrada en cada caso.

Una vez más, se observa esa diferencia entre los resultados obtenidos para valores extremos e intermedios. Esta conclusión se extrae de forma muy visual gracias al mapa de calor, mostrando tonalidades azules y, por lo tanto, valores bajos en las zonas intermedias de la matriz, mientras que se aprecian tonalidades rojas en los extremos de la diagonal principal de la misma.

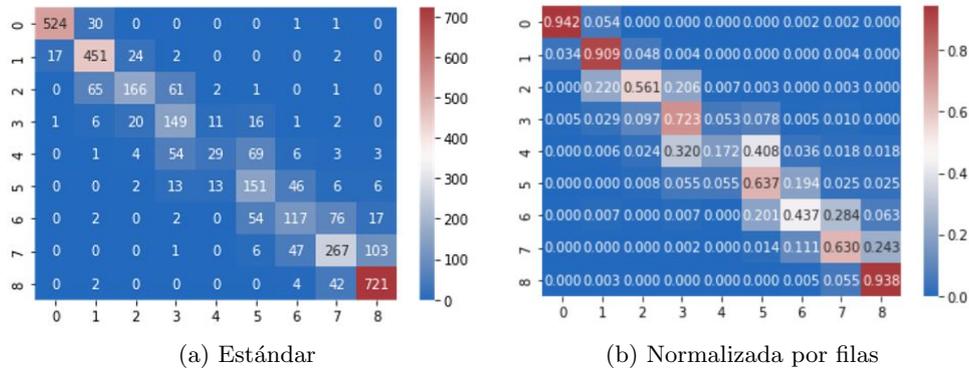


Figura 15: Matrices de confusión modelo 1.

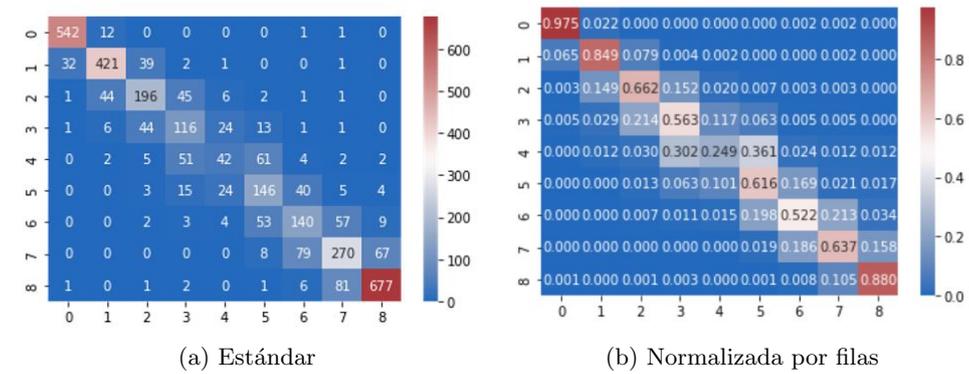


Figura 16: Matrices de confusión modelo 2.

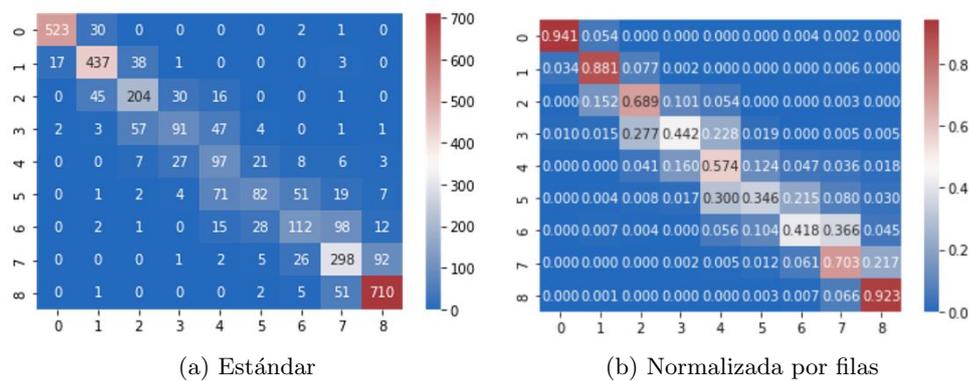


Figura 17: Matrices de confusión modelo 3.

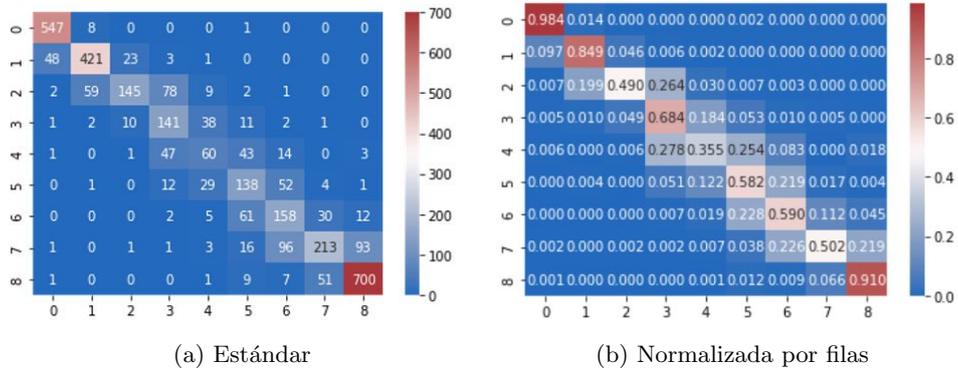


Figura 18: Matrices de confusión modelo 4.

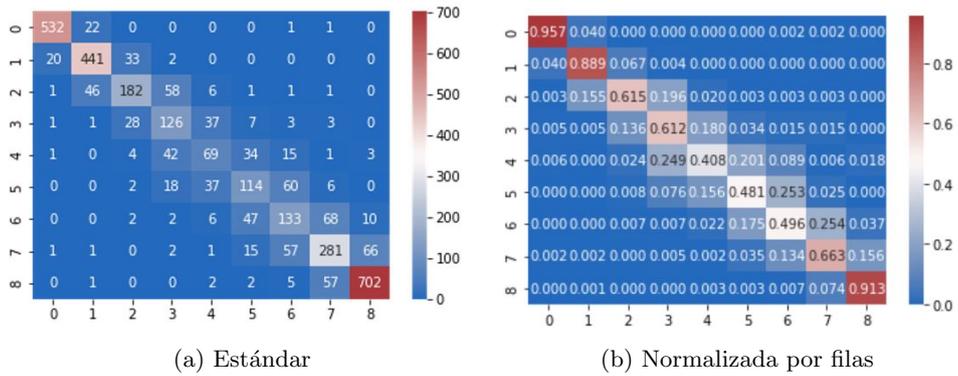


Figura 19: Matrices de confusión modelo 5.

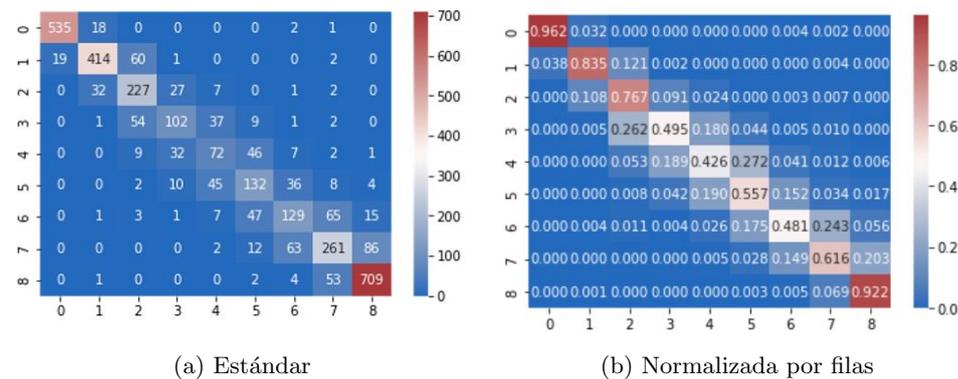


Figura 20: Matrices de confusión modelo 6.

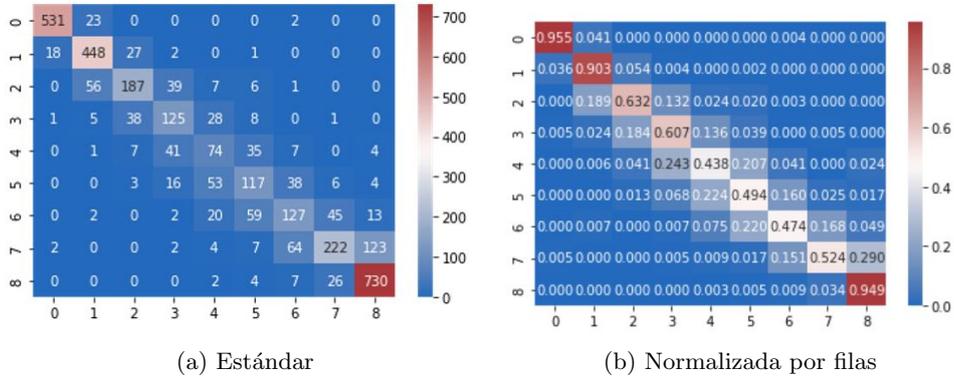


Figura 21: Matrices de confusión modelo 7.

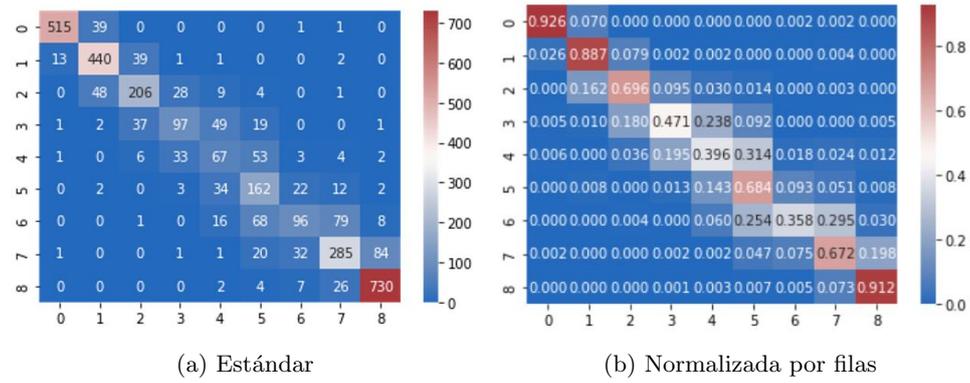


Figura 22: Matrices de confusión modelo 8.

Mostraremos a continuación en la tabla 9, la tasa de acierto total de cada modelo en tanto por uno, es decir, el cociente entre el número de imágenes predichas correctamente (la suma de la diagonal de la matriz de confusión estándar) y el total de imágenes, a esta tasa de acierto la denotaremos como tasa de acierto 1. Así mismo, se mostrará la tasa de acierto de cada modelo, pero considerando en el numerador las imágenes predichas correctamente y aquellas con solo un error de ± 1 octa (la suma de los elementos diagonales de la matriz de confusión, así como de sus elementos contiguos), la denotaremos como tasa de acierto 2. El objetivo será ver si la tasa de acierto 2 es muy grande, pues contempla el error cometido por el observador durante el etiquetado.

	MODELO							
	1	2	3	4	5	6	7	8
Tasa de acierto 1	0,753	0,745	0,757	0,737	0,754	0,754	0,748	0,759
Tasa de acierto 2	0,967	0,946	0,959	0,961	0,963	0,965	0,957	0,959

Tabla 9: Tasas de acierto obtenidas para cada modelo.

Se concluye que, al igual que para las métricas estudiadas, los modelos 5 y 6, resultan ser los más ventajosos para la clasificación de imágenes, pues presentan las mayores tasas de acierto. Por otro lado, destacar la elevada tasa de acierto 2, pues para el error que se permite, debido a que se considera que el propio observador lo comete en el etiquetado, se obtienen tasas de acierto expresadas en porcentaje, del 96 %.

Capítulo 4

Conclusiones

En este trabajo se ha propuesto un método de reconocimiento de la nubosidad mediante inteligencia artificial, para ello se han utilizado imágenes obtenidas por una cámara de cielo, las cuales fueron tratadas por una red neuronal convolucional para predecir la nubosidad presente en las mismas.

Se han entrenado 8 modelos, combinando diferentes características que pueden presentar las CNN y se han extraído las siguientes conclusiones:

- Todos los modelos entrenados presentan buenos resultados frente a las métricas siguientes: error absoluto medio, error medio, raíz del error cuadrático medio y desviación estándar. Las diferencias entre unos y otros son pequeñas, siendo los modelos 5 y 6, con 200 épocas y 0,0001 de tasa de aprendizaje, los que presentan unos resultados generales mejores, deduciendo que el valor más alto de épocas y la menor tasa de aprendizaje, favorecen la obtención de mejores resultados en nuestro estudio en particular.
- Se cumple la premisa de partida, pues los resultados muestran que el error medio cometido es menor que una octa, que se suponía el error por parte del observador.
- Los modelos tienen tasas de acierto aceptables; además, cuando se consideran también como correctas, aquellas imágenes con error de solo una octa, las tasas de acierto obtenidas son muy elevadas, con valor del 96 % de acierto.
- Todos los modelos presentan mayor dispersión para cielos parcialmente despejados (3-6 octas), pues su etiquetado presenta mayor subjetividad, por lo que al entrenar la red, esta se encontrará que imágenes casi similares, tienen etiquetas diferentes, provocando

que el modelo obtenido presente peores resultados para ese tipo de imágenes.

El método sugerido en este trabajo, es un método económico, de fácil instalación, montaje y transporte. De hecho, esto permite crear una red de cámara de cielo, que se pueda extender por una región amplia, para que así, nos permita obtener el estado de la cubierta nubosa en diferentes puntos interconectados entre sí a tiempo real.

Como debilidad de este método está el tiempo necesario para el etiquetado de las imágenes, pues para el entrenamiento de los modelos se etiquetaron 34826 imágenes de una en una, además, en ocasiones, se requirió de la ayuda del ceilómetro para precisar el número de octas correctas.

A la vista de los resultados obtenidos, se trata de un método muy bueno para la clasificación de imágenes de cielo. Entre sus aplicaciones se encuentra el obtener el estado de la cubierta nubosa del cielo en el instante, así como eliminar imágenes almacenadas procedentes de la cámara de cielo, cuyas características no sean relevantes para un posible estudio que se quiera realizar, optimizando así el almacenamiento de las imágenes y, por lo tanto, la capacidad de memoria del sistema donde se encuentren.

Como líneas de trabajo futuras se propone el estudio de la velocidad y dirección del viento en una región concreta, mediante el movimiento de las nubes presentes en las imágenes de la cámara de cielo, pudiendo ser entrenada una CNN para ello, y obteniendo al instante el viento que había en la región de estudio hace escasos minutos. Otra posible línea de estudio sería la probabilidad de precipitación, en relación con la tonalidad de las nubes presentada en las imágenes.

Referencias

- [1] QUIRANTES CALVO JOSÉ A. y GALLEGO POVEDA JOSÉ A., *Atlas de nubes y meteoros*, primera edición, Torrelavega, España, Cantabria Tradicional S.L., 2011.
- [2] ROGERS R.R., *Física de las nubes*, Editorial Reverté, 1977.
- [3] SMITH,W., *A Dictionary of Greek and Roman biography and mythology*, Boston,Little, Brown Co., 1867.
- [4] OMM, *International Cloud Atlas:Manual on the observation of clouds and other meteors*,2017.
- [5] BOSCH RUÉ ANNA ,CASAS ROMA JORDI y LOZANO BAGÉN TONI *Deep Learning, principios y fundamentos*, primera edición,UOC,2019.
- [6] ACTA BIOQUÍMICA CLÍNICA LATINOAMERICANA,*Las nubes y el ciclo de la energía* [Internet],2012,[citado el 12 de junio de 2022],p:35-39. Disponible en: <https://www.redalyc.org/articulo.oa?id=53559383004>.
- [7] GARCÍA DE PEDRAZA L.y GARCÍA VEGA J. *Las nubes como indicadores del tiempo*, Núm. 20/84 HD, Ministerio de Agricultura, Pesca y Alimentación,1984.
- [8] AGENCIA ESTATAL DE METEOROLOGÍA, *Manual de uso de términos meteorológicos*, Edición 2015,imprensa de Aemet,2014.
- [9] WALLACE JOHN M. y HOBBS PETER V. *Atmospheric Science. An introductory survey*, second edition, University of Washington,2016.
- [10] HEINLE A.,MACKE A.y SRIVASTAV A. *Automatic cloud classification of whole sky images. Atmospheric Measurement Techniques*,2010,p 557-567.
- [11] TAPAKIS R. y CHARALAMBIDES A.G. *Equipment and methodologies for cloud detection and classification: A review*, Cyprus University of Technology, Department of Environmental Science and Technology,2012.

- [12] CAMPBELL J.B. y WYNNE R.H. *Introduction to Remote Sensing*, fifth edition, The Guilford Press, New York, 2011.
- [13] BENGIO Y. GOODFELLOW I. y COURVILLE A. *Deep Learning*, Cambridge, MA: Mit press, 2016-
- [14] SIMON HAYKIN. *Neural Networks and Learning Machines*, Pearson, 1993.
- [15] BAGNATO JUAN I. *Convolutional Neural Networks: La Teoría explicada en Español* [Internet]. Aprendemachinelearning.com, 2018 [citado el 13 de junio de 2022]. Disponible en: <https://www.aprendemachinelearning.com/como-funcionan-las-convolutional-neural-networks-vision-por-ordenador/>
- [16] ALCOR SYSTEM OMEA “All Sky” Camera, *Installation and user manual*, Octubre 2021.
- [17] CAZORLA, A., CASQUERO-VERA, J. A., ROMÁN, R., GUERRERO-RASCADO, J. L., TOLEDANO, C., CACHORRO, V. E., ORZA, J. A. G., CANCELLO, M. L., SERRANO, A., TITOS, G., PANDOLFI, M., ALASTUEY, A., HANRIEDER, N., ALADOS-ARBOLEDAS, L *Near-real-time processing of a ceilometer network assisted with sun-photometer data: monitoring a dust outbreak over the Iberian Peninsula*, *Atmos. Chem. Phys.*, 17, 11861–11876, <https://doi.org/10.5194/acp-17-11861-2017>, 2017.
- [18] ROMÁN, ROBERTO; BENAVENT OLTRA, JOSÉ ANTONIO; CASQUERO VERA, JUAN ANDRÉS; LOPATIN, A.; CAZORLA CABRERA, ALBERTO; LYAMANI, H.; DENJEAN, C.; FUENTES, D.; PÉREZ RAMÍREZ, DANIEL; TORRES, B.; TOLEDANO, CARLOS; DUBOVIK, O.; CHAMORRO, V. E.; FRUTOS, A.; OLMO REYES, FRANCISCO JOSÉ; ALADOS ARBOLEDAS, LUCAS. *Retrieval of aerosol profiles combining sunphotometer and ceilometer measurements in GRASP code*, *Atmospheric Research*, vol. 204, p:161-177, 2018.
- [19] HEESE B., FLENTJE H. ALTHAUSEN D. ANSMANN A. FREY S. *Ceilometer lidar comparison: backscatter coefficient retrieval*

- and signal-to-noise ratio determination* Atmospheric Measurement Techniques, 3, 1763–1770, 2010.
- [20] LUFFT *User Manual Lufft CHM 15k Ceilometer*, 2021.
- [21] MARTÍNEZ CELDA, B. *Trabajo de fin de grado: Clasificación automática de imágenes de cielo mediante inteligencia artificial*, Uvadoc, 2021.
- [22] TAYLOR JOHN R. *An introduction to error analysis, the study of uncertainties in physical measurements*, 1997.

Índice alfabético

- average-pooling, 17
- backpropagation, 17
- campo receptivo local, 15
- capa, 17
 - de agrupamiento, 17
 - dropout, 18
 - no lineal, 18
 - totalmente conectada, 17
- CCD, 12
- ceilómetro, 22
- ciclo hidrológico, 2
- CMOS, 12
- CNN, 15
- convolución, 14
- cubierta nubosa, 10
- cubierta parcial, 10
- cámara de cielo, 12
- equipos de superficie, 11
- equipos satélite, 13
- error absoluto medio, 30
- error cuadrático medio, 33
- error medio, 31
- especie, 7
- frente, 4
 - cálido, 4
 - frío, 5
- función de activación, 16
- género, 7
- HDR, 21
- hidrosfera, 2
- histogramas, 34
- imager, 14
- input, 15
- kernel, 15
- LIDAR, 13
- mapa de características, 15
- matrices de confusión, 36
- max-pooling, 17
- neurona, 16
- nube, 2
- núcleos de condensación, 6
- octas, 10
- OMM, 6
- one-hot-encoding, 18
- overfitting, 18
- padding, 16
- pooling, 17
- softmax, 18
- superficie frontal, 4
- tamaño del lote, 27
- tasa de aprendizaje, 27
- tropopausa, 7
- troposfera, 1
- variedad, 7
- épocas, 27