



Universidad de Valladolid

Facultad de Ciencias

TRABAJO FIN DE GRADO

Grado en Física

Clasificación Automática de Imágenes de Cielo mediante Inteligencia Artificial

Autor: Bernardo Martínez Celda

Tutores: Roberto Román Díez y Juan Carlos Antuña Sánchez

Agradecimientos

A mis tutores, el doctor Roberto Román Díez y el doctorando Juan Carlos Antuña Sánchez, por compartir su tiempo conmigo ayudándome a planificar este trabajo.

A mis profesores de bachillerato, y en especial a Roberto, por contagiarme su pasión por la Física.

A mis compañeros del Programa de Estudios Conjunto, Mario, Pablo, Elisabet, Gabri, Elsa, Alfonso, Merino, José Antonio, y Andrea; por las momentos que hemos compartido, por su inestimable ayuda, y porque son como una familia para mí.

A mi hermana Mar, a mi pareja Laura, y a mis amigos, por haberme apoyado en todo momento y por sacar lo mejor de mí.

A mis padres, Bernardo y Marifé, por preocuparse por mí, por haber sabido aconsejarme sabiamente, y por haberme inculcado desde pequeño los valores de la constancia y la responsabilidad.

Clasificación automática de imágenes de cielo mediante inteligencia artificial

Bernardo Martínez Celda

Resumen

El trabajo se centra en la identificación de la cubierta de nubes. En primer lugar se introducen los conceptos de nubes y aerosol, y su influencia en el clima. Asimismo, se repasan los diferentes géneros de nubes y se detallan las herramientas principales para su estudio. Posteriormente se propone un método para identificar la cubierta de nubes mediante inteligencia artificial. Este método consiste en: obtener imágenes mediante una cámara de cielo, etiquetar las imágenes indicando si el sol está obstruido o no, el número de octas, y la presencia de algunos “fenómenos” como halo, aerosoles, o gotas, entre otros; y utilizar una red neuronal para obtener un clasificador que sea capaz de predecir estas etiquetas en nuevas imágenes. Una vez etiquetadas, las imágenes se dividen en dos conjuntos. El conjunto de entrenamiento está formado por las imágenes de las dos primeras semanas de cada mes, y el conjunto de validación está formado por las dos semanas restantes de cada mes. El conjunto de entrenamiento se emplea para “alimentar” la red neuronal, un algoritmo de inteligencia artificial, y el de validación se emplea para cuantificar el desempeño del clasificador generado por la red neuronal. En este trabajo se han entrenado clasificadores con diferentes configuraciones de la red neuronal, y luego se ha discutido qué combinación de parámetros del algoritmo producen mejores clasificadores.

Índice general

1. Introducción	1
1.1. Aerosoles	2
1.1.1. El papel de los aerosoles en el clima y en el cambio climático . . .	3
1.2. Nubes	3
1.2.1. El papel de las nubes en el clima y en el cambio climático	4
1.3. Clasificación de las nubes	5
1.4. Instrumentos para medir la cubierta de nubes	10
2. Instrumentación y metodología	13
2.1. Funcionamiento de la cámara de cielo	13
2.2. Etiquetado de las imágenes de cielo	16
2.3. Entrenamiento de la red neuronal	19
3. Resultados	23
3.1. Modelo Sol	23
3.2. Modelo octas	27
3.3. Modelo fenómenos	32
4. Conclusiones	35
Bibliografía	37
A. Código python	41

B. Código R

43

Índice de figuras

1.1. Nubes altas (OMM, 2021)	6
1.2. Nubes medias (OMM, 2021)	6
1.3. Nubes bajas (OMM, 2021)	7
1.4. Los diez géneros de nubes organizados por alturas (OMM, 2021)	9
2.1. Cámara de cielo instalada en el tejado de la facultad.	13
2.2. Espectro de la respuesta de (a) sensor CMOS con el filtro Bayer, (b) filtro tri-banda RGB, y (c) cámara de cielo (ambos filtros solapados). Figura tomada de Antuña-Sánchez <i>et al.</i> (2021).	14
2.3. Etiqueta Sol obstruido / despejado	16
2.4. Etiqueta con el número de octas	16
2.5. Etiquetas de los fenómenos: gotas, hielo y chimenea	17
2.6. Imágenes con la cámara sucia	17
2.7. Comparación de imágenes con aerosol y nubes altas	18
2.8. Etiquetas de los fenómenos: polvo y halo	19
2.9. Interfaz de “Teachable Machine 2.0”	20
3.1. Función de pérdida de entropía cruzada	24
3.2. Especificidad en función de la Sensibilidad para los 12 modelos “Sol”. Clase “positiva” (+1): despejado.	27
3.3. Desviación estándar en función de la media de las diferencias “etiqueta referencia” - “etiqueta predicha” de los 12 modelos “octas”.	31
3.4. Histograma con las diferencias entre las etiquetas de referencia y las predichas por el modelo “octas” entrenado con Épocas:200, Tasa de aprendizaje:0,001.	31

Capítulo 1

Introducción

Conocer la cantidad de radiación solar que incide sobre la superficie terrestre es útil por diversos motivos. En materia de salud permite calcular la dosis de radiación ultravioleta que recibe el cuerpo humano. En materia medioambiental se encuentra la necesidad de estudiar el cambio climático. El continuo desarrollo de tecnologías que utilizan energía solar hace que poder predecir la radiación que incide sobre la Tierra sea un aspecto clave para optimizar sus recursos. Especialmente en el caso de granjas de placas fotovoltaicas, donde se ha visto que la energía producida se ve muy mermada cuando el Sol está obstruido por las nubes (Beyer *et al.*, 1994; Frederick y Steele, 1995; Bartlett *et al.*, 1998; Antón *et al.*, 2011).

La radiación solar que alcanza la superficie terrestre depende de la posición del Sol y la composición de la atmósfera. Los gases de la atmósfera, las nubes y los aerosoles son los causantes de la dispersión de la luz. Los gases son responsables de la dispersión Rayleigh, mientras que las nubes y aerosoles son responsables de la dispersión Mie (Antuña-Sánchez *et al.*, 2021). De este modo, la distribución angular de la radiación está controlada por la posición del Sol y los procesos de dispersión que tienen lugar en la atmósfera.

La interacción radiación-nubes depende en gran medida del volumen, forma, espesor y composición de las nubes (Badescu, 1999). Lo mismo ocurre con los aerosoles, además la presencia de aerosoles altera las propiedades de las nubes. Todo esto hace que la detección y clasificación de las nubes sea esencial, no solo para el estudio de la radiación incidente, sino que también es fundamental para desarrollar modelos que predicen el clima y el movimiento de las nubes (Menzel, 2001; Orun *et al.*, 2000; Szantai *et al.*, 2002).

Hasta finales del siglo pasado la determinación de la cubierta de nubes se llevaba a cabo mediante observadores humanos. La cubierta de nubes solía medirse en octas, un

número entero, del cero al ocho, que representa cuantos octavos del cielo están cubiertos (0 octas cielo sin nubes; 4 octas mitad del cielo cubierto por nubes; 8 octas cielo totalmente cubierto). La creciente necesidad de obtener medidas precisas por todo el mundo hizo necesario el desarrollo de nuevos métodos para medir la cobertura nubosa (Goodman y Henderson-Sellers, 1988; Key *et al.*, 1989). Estos métodos utilizan instrumentos con base terrestre, otros están integrados en satélites, y también los hay que están ubicados en globos meteorológicos. Asimismo se han desarrollado algoritmos que, por ejemplo, permiten medir la radiancia relativa del cielo (Antuña-Sánchez *et al.*, 2021) o incluso determinar la cubierta de nubes (Román *et al.*, 2017a). Presentar algunas de las herramientas que se emplean actualmente para medir la nubosidad es el tema de la Sección 1.4.

El objetivo de este trabajo es identificar la cubierta de nubes mediante inteligencia artificial a partir de imágenes obtenidas por una cámara de cielo.

En este capítulo se realiza una breve introducción a la clasificación de las nubes, basada en la clasificación que realiza la Organización Meteorológica Mundial (OMM)¹. Previamente, tomando como referencia el séptimo capítulo de Boucher *et al.* (2013), se definirán los conceptos de *aerosol* y *nube* así como su efecto en el clima.

1.1. Aerosoles

Se denomina aerosol a un sistema de partículas sólidas o líquidas suspendidas en un medio gaseoso. Los aerosoles presentes en la atmósfera pueden ser tanto de origen natural como antropogénico².

Los principales constituyentes del aerosol atmosférico son: especies inorgánicas (sulfato, nitrato, amonio y sal marina), especies orgánicas, hollín (formado a partir de la combustión incompleta de combustibles fósiles, biocombustibles y biomasa³), especies minerales (principalmente polvo desértico) y partículas biológicas (mayormente bacterias, arqueas, esporas fúngicas, polen, virus, algas y cianobacterias).

Los aerosoles pueden afectar al clima de formas muy distintas mediante su interacción con las nubes y la radiación. A continuación se explica el efecto que tienen los aerosoles sobre el clima, así como su influencia en el cambio climático.

¹También conocida como WMO por sus siglas en inglés, World Meteorological Organization.

²De origen humano, o derivado de la actividad humana, que tiene efectos sobre la naturaleza.

³Las principales fuentes de hollín, (*black carbon* en inglés) son el tráfico rodado y los sistemas de calefacción.

1.1.1. El papel de los aerosoles en el clima y en el cambio climático

Por un lado, los aerosoles dispersan y absorben la radiación solar, lo que modifica la cantidad de radiación que alcanza la superficie terrestre. La dispersión de radiación debida al aerosol hace que el planeta sea más reflectante, tendiendo a enfriar el clima, mientras que la absorción tiene el efecto contrario, tendiendo a calentarlo. El balance entre el enfriamiento y calentamiento depende de las propiedades del aerosol y su entorno.

Por otro lado, los aerosoles sirven como núcleos de formación de hielo y condensaciones, donde se forman las cristales de hielo y gotas de agua. Además, se ha visto que la presencia de aerosoles altera las propiedades de las nubes, de tal modo que tienden a tener un mayor número de gotas pero de menor tamaño, consiguiendo que reflejen más radiación solar.

Aunque el efecto de los aerosoles en las nubes son complejos y difíciles de simular mediante modelos estadísticos, diversos estudios sugieren que la presencia de aerosoles repercute significativamente en las precipitaciones sobre ciertas regiones de la Tierra (Boucher *et al.*, 2013).

La mayoría de estudios coinciden en que, en general, el efecto de los aerosoles es enfriar el planeta. De hecho, como la emisión de aerosoles se ha visto incrementada desde la revolución industrial, esto ha contrarrestado parte del calentamiento debido al aumento de concentración de gases de efecto invernadero. Asimismo, aerosoles de grandes erupciones volcánicas que alcanzan la estratosfera, como las de El Chichón (México, 1982) y Pinatubo (Filipinas, 1991), han provocado periodos fríos que suelen durar uno o dos años (Boucher *et al.*, 2013).

1.2. Nubes

A continuación se muestra la definición de nube que aparece en OMM (2021):

Una nube es un hidrometeoro consistente en diminutas partículas de agua líquida o hielo, o de ambos, suspendidas en la atmósfera y que, por lo general, no tocan el suelo. También puede contener 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.

Conocer las clasificación de las nubes es un requisito previo para poder predecir su

comportamiento mediante modelos estadísticos, esta clasificación se desarrollará en la Sección 1.3.

Desde los primeros años de la década de los 70, la comunidad científica ha reconocido la importancia de las nubes en el clima y en el cambio climático. A continuación se presentan algunos de los efectos de las nubes sobre el clima.

1.2.1. El papel de las nubes en el clima y en el cambio climático

Las nubes afectan el sistema climático de formas muy distintas. Producen precipitaciones que son necesarias para la vida en la Tierra. Calientan la atmósfera al condensarse el vapor de agua⁴. Aunque parte del agua condensada se vuelve a evaporar, la precipitación que alcanza la superficie representa una ganancia en el calentamiento del aire. Las nubes afectan a los flujos tanto de luz solar absorbida por el planeta (calentándose la Tierra), como de radiación infrarroja emitida por el propio planeta hacia el espacio (enfriándose la Tierra). Por último, las nubes actúan como elemento de contención frente a las corrientes de aire ascendentes que pueden transportar rápidamente aire de la superficie hasta grandes alturas. Estas corrientes de aire son portadoras de energía, momento, trazas de gases y aerosoles.

Las nubes altas⁵ amplifican el calentamiento global ya que retienen parte de la radiación infrarroja emitida por el planeta, y sin embargo apenas contribuyen a filtrar la radiación que proviene del Sol.

Las nubes bajas, no obstante, tienen el efecto contrario: reflejan gran parte de la radiación solar que les llega y tienen poco efecto en la retención de radiación emitida por la Tierra. De este modo las nubes bajas contribuyen a enfriar el clima presente. El diferente comportamiento entre las nubes altas y bajas se debe a que, por un lado las nubes altas son más transparentes, y por otro lado Tierra emite en infrarrojo mientras en la radiación solar posee longitudes de onda mucho más cortas. Las nubes altas están formadas por cristales de hielo y suelen ser más transparentes que las nubes bajas (principalmente formadas por gotas de agua) debido a su espesor y a la dispersión de las partículas de hielo.

Muchos de los modelos desarrollados por el Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC)⁶ simulan que en el futuro, debido al calentamiento global por el aumento de los gases de efecto invernadero, habrá una disminución de la

⁴La transición de estado gaseoso a líquido (condensación) es una reacción exotérmica.

⁵La descripción de nubes altas, medias y bajas se detallará en la sección 1.3.

⁶The Intergovernmental Panel on Climate Change.

cantidad de nubes bajas (lo que causaría un aumento del calentamiento global).

1.3. Clasificación de las nubes

Las nubes se clasifican siguiendo el sistema latín *Linnaeus* de géneros y especies, el esquema de la clasificación que se utiliza hoy en día se encuentra recogido en “Atlas Internacional de las Nubes” (OMM, 2017), y adopta el sistema propuesto por Luke Howard en 1803. Dicha clasificación está basada en:

1. El género, la característica principal de la nube. Hay 10 géneros de nubes: *Cirrus*, *Cirrocumulus*, *Cirrostratus*, *Altostratus*, *Nimbostratus*, *Stratocumulus*, *Stratus*, *Cumulus*, y *Cumulonimbus*.
2. La especie, que depende de la forma de la nube y su estructura interna. Hay 14 especies de nubes: *fibratus*, *uncinus*, *spissatus*, *castellanus*, *floccus*, *stratiform*, *nebulosus*, *lenticularis*, *fractus*, *humilis*, *mediocris*, *congestus*, *calvus*, y *capillatus*.
3. La variedad, que define características especiales de la disposición y transparencia de las nubes. Hay 9 variedades de nubes: *intortus*, *vertebratus*, *undulatus*, *radiatus*, *lacunosus*, *duplicatus*, *translucidus*, *perlucidus*, y *opacus*.
4. Otros rasgos distintivos y nubes accesorias, nubes de menor tamaño que se unen a la parte principal de la nube. Hay 9 rasgos distintivos y nubes accesorias: *incus*, *mamma*, *virga*, *praecipitatio*, *arcus*, *tuba*, *pileus*, *velum*, y *pannus*.
5. La nube madre, que define el origen de la nube, en los casos donde la nube se forma a partir de otra nube.

La OMM describe los 10 géneros de nubes del siguiente modo (OMM, 2021):

- *Cirrus* (Ci): Nubes separadas, en forma de filamentos blancos y delicados, o de bancos o bandas estrechas, blancas o casi blancas. Estas nubes tienen un aspecto fibroso (parecido a cabellos) o un brillo sedoso, o ambos a la vez.
- *Cirrocumulus* (Cc): Banco, banda o capa de nubes delgados y de color blanco, sin sombras, compuestos de elementos muy pequeños en forma de gránulos, ondulaciones, etc., unidos o separados y distribuidos con mayor o menor regularidad; la mayoría de los elementos tienen una anchura aparente inferior a 1 grado.
- *Cirrostratus* (Cs): Velo nuboso transparente y blanquecino, de aspecto fibroso (parecido a cabellos) o liso, que cubre total o parcialmente el cielo y a menudo da lugar a fenómenos de halo.
- *Altostratus* (Ac): Banco, banda delgada o capa de nubes blancas o grises, o a la vez blancas y grises, que normalmente tienen sombras y están compuestos de losetas,

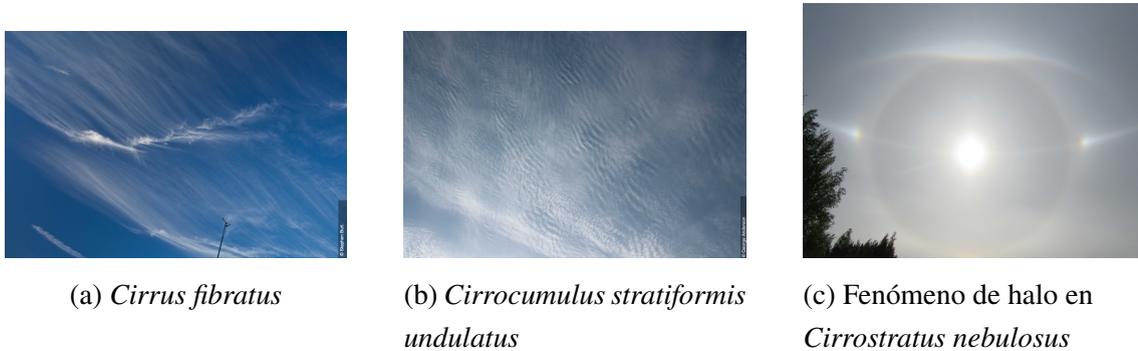


Figura 1.1: Nubes altas (OMM, 2021)

masas redondeadas, rodillos, etc. que a veces son parcialmente fibrosos o difusos y pueden estar unidos o no; la mayoría de los pequeños elementos están distribuidos regularmente y tienen por lo general una anchura aparente de entre 1 grado y 5 grados.

- *Altostratus* (As): Banda delgada o capa nubosa grisácea o azulada de apariencia estriada, fibrosa o uniforme que cubre por entero o parcialmente el cielo. Tiene partes suficientemente delgadas que permiten distinguir el Sol al menos vagamente, como a través de un vidrio deslustrado. El *Altostratus* no produce fenómenos de halo.
- *Nimbostratus* (Ns): Capa de nubes gris, a menudo oscura, con un aspecto velado por la precipitación más o menos continua de lluvia o nieve que, en la mayoría de los casos, llega al suelo. El espesor de esta capa es por todas partes suficiente para ocultar completamente el Sol.

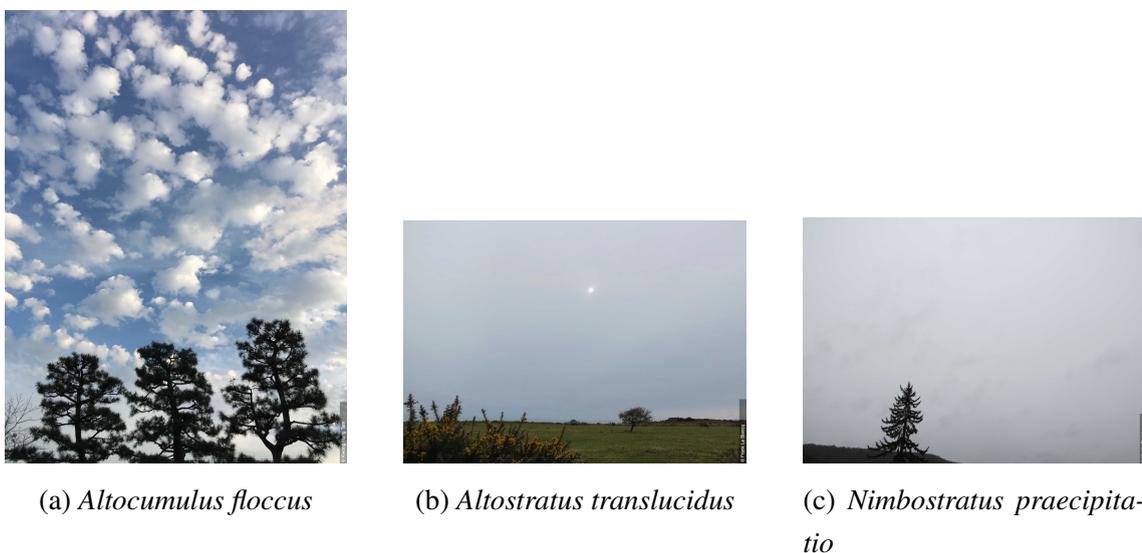


Figura 1.2: Nubes medias (OMM, 2021)

- *Stratocumulus* (Sc): Banco, banda delgada o capa de nubes, de color gris o blanquecino, o a la vez gris y blanquecino, que casi siempre tienen partes oscuras compuestas de losetas, masas redondeadas, rodillos, etc. que no son fibrosas (excepto la virga) y que pueden estar unidas o no; la mayoría de los elementos pequeños distribuidos con regularidad tienen una anchura aparente superior a 5 grados.
- *Stratus* (St): Capa de nubes generalmente gris, con una base relativamente uniforme, de la que pueden caer llovizna, nieve o cinarra. Cuando el Sol es visible a través de la capa, su contorno se distingue claramente. Los Stratus no producen fenómenos de halo, salvo quizás a temperaturas muy bajas.
- *Cumulus* (Cu): Nubes aisladas, en general densas y con contornos bien definidos, que se desarrollan verticalmente en forma de montículos, cúpulas o torres, y cuyas partes superiores protuberantes se parecen con frecuencia a una coliflor. Las partes de estas nubes iluminadas por el Sol son, en su mayoría, de un blanco brillante; su base es relativamente oscura y casi horizontal.
- *Cumulonimbus* (Cb): Nube amazacotada y densa, con un desarrollo vertical considerable, en forma de montaña o de enormes torres. Parte, al menos, de su cima es normalmente lisa, fibrosa o estriada, y casi siempre aplastada; esta parte se extiende a menudo en forma de un yunque o de un vasto penacho. Por debajo de la base de esta nube, a menudo muy oscura, aparecen con frecuencia nubes bajas desgarradas, unidas o no con ella, y precipitaciones, a veces en forma de virga⁷.



(a) *Stratocumulus stratiformis opacus*



(b) *Stratus nebulosus opacus*



(c) *Cumulus congestus* y
Stratocumulus cumulo-genitus



(d) *Cumulonimbus capillatus praecipitatio incus mamma*

Figura 1.3: Nubes bajas (OMM, 2021)

⁷Hidrometeoro que cae de una nube pero que se evapora antes de alcanzar el suelo

Además de esta clasificación por géneros y especies, la OMM también clasifica las nubes por su altitud y divide la troposfera verticalmente en tres niveles: bajo, medio y alto. Cada nivel se define por un intervalo de alturas para el que suele aparecer cierto tipos de nubes. Sin embargo este intervalo de alturas depende de la latitud (región polar, templada y tropical) como puede comprobarse en la Tabla 1.1 (OMM, 2021). De este modo, las nubes se dividen en:

- Nubes altas: *Cirrus* (Ci), *Cirrocumulus* (Cc) y *Cirrostratus* (Cs).
- Nubes medias: *Altostratus* (As) y *Nimbostratus* (Ns).
- Nubes bajas: *Cumulus* (Cu), *Stratocumulus* (Sc), *Stratus* (St) y *Cumulonimbus* (Cb).

En ocasiones, los géneros *Cumulus* y *Cumulonimbus* se consideran nubes de desarrollo vertical ya que, aunque su base se encuentre en el nivel bajo, son nubes que logran ocupar también el nivel medio y alto de la troposfera (Quirantes Calvo y Gallego Poveda, 2011).

Nivel	Región Polar	Región Templada	Región Tropical
Nubes altas	3-8 km	3-13 km	6-18 km
Nubes medias	2-4 km	2-7 km	2-8 km
Nubes bajas	Superficie-2 km	Superficie-2 km	Superficie-2 km

Tabla 1.1: Clasificación de las nubes según su altura y latitud

La Figura 1.4 muestra una representación visual de de la distribución de estos diez tipos de nubes según su altura.

También es posible clasificar las nubes según su composición (AMS, 2021), principalmente se distinguen tres clases: nubes de agua, nubes de cristales de hielo, y nubes mixtas. Las nubes de la primera clase están compuestas de gotas de agua (ordinarias o superenfriadas), las de la segunda clase están formadas completamente por cristales de hielo, y las nubes mixtas son nubes compuestas por una mezcla de gotas de agua y cristales de hielo. De entre los distintos géneros de nubes, los únicos que son siempre de cristales de hielo son los géneros cirrus y cirrostratus. Las nubes del género cirrocumulus pueden ser mixtas y solamente las del género cumulonimbus son siempre mixtas. Las nubes del género altostratus son casi siempre mixtas, aunque ocasionalmente pueden ser de agua. El resto de géneros (altocumulus, cumulus, stratus, nimbostratus y stratocumulus) son nubes de agua que ocasionalmente pueden ser mixtas.

Además de los diez géneros de nubes descritos previamente, también es conveniente considerar la niebla y las estelas. Aunque tienen características similares a las nubes, tienen orígenes distintos.

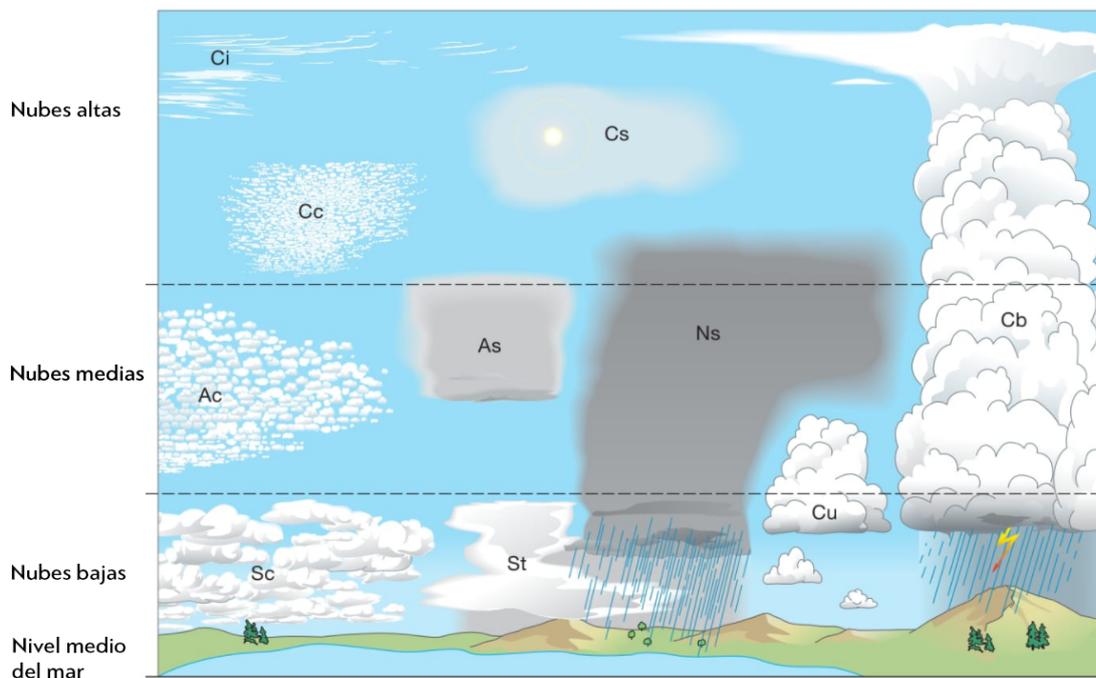


Figura 1.4: Los diez géneros de nubes organizados por alturas (OMM, 2021)

La niebla se forma frecuentemente cerca de masas de agua próximas a la superficie de la Tierra, y en otros lugares donde se mezcla aire frío con aire caliente y viceversa. Se forma a partir de gotas de agua en suspensión y reduce la visibilidad en la superficie de la Tierra (Ahrens, 2000).

Las estelas o rastros de vapor son nubes artificiales que se generan debido a la condensación de vapor de agua que se produce de los gases de escape de las aeronaves. Estos gases tienen temperaturas muy altas, y cuando entran en contacto con el aire frío del entorno forman nubes de gotas de agua microscópicas. Si el aire está suficientemente frío entonces estas estelas pueden estar formadas de pequeños cristales de hielo. La formación de una estela depende del nivel de humedad en la atmósfera y la altitud a la que viaja el avión. Las estelas son el homólogo artificial de los cirros, ya que éstos son nubes altas con la misma forma. Del mismo modo que los cirros, las estelas reflejan parte de la radiación solar que les llega. Las estelas pueden afectar al clima local ya que persisten durante varias horas si la humedad relativa del aire es alta (Ahrens, 2000; DeGrand *et al.*, 2000; Minnis *et al.*, 2004).

La correcta clasificación de las nubes es un requisito básico para predecir su movimiento y la cantidad de radiación solar que pasa a través de ellas por diversos motivos:

- Cada tipo de nube refleja un porcentaje distinto de la radiación incidente.

- Hay una correlación directa entre la radiación solar que deja pasar una nube y su opacidad.
- Los cristales de hielo y las gotas de agua tienen un efecto distinto en los procesos de dispersión de la radiación.
- Debido a que cada tipo de nube se forma a una determinada altura, su movimiento puede ser distinto ya que a diferentes alturas las corrientes de aire pueden ser distintas, dando lugar a nubes moviéndose con distinta velocidad y dirección.

1.4. Instrumentos para medir la cubierta de nubes

El propósito de esta sección es, siguiendo el trabajo de Tapakis y Charalambides (2013), mostrar algunos de los instrumentos que se emplean hoy en día para medir la cobertura nubosa. Esencialmente se distinguen dos tipos de equipos, aquellos con base terrestre y los instalados en satélites. Los instrumentos con base terrestre se utilizan principalmente para tomar datos de un lugar específico, mientras que los satélites se emplean para medir datos sobre zonas extensas como continentes. La desventaja de los equipos de tierra es que tienen un campo de visión limitado, lo que les imposibilita realizar un seguimiento de la formación y el desplazamiento de las nubes. No obstante, el hecho de que estos equipos estén fijos puede volverse una ventaja. Estos instrumentos pueden medir de forma precisa, sobre una ubicación concreta, la variación en la radiación solar que incide sobre la Tierra debida a la presencia de nubes. Por contra, si bien los satélites proporcionan medidas a gran escala, estas medidas tienen baja resolución temporal y pueden tener errores (Dybbroe *et al.*, 2005; Heinle *et al.*, 2010; Ricciardelli *et al.*, 2008).

Los equipos de tierra se dividen en cuatro grupos. El primero de ellos incluye los instrumentos diseñados para medir la irradiancia como los piranómetros, y también los radiómetros, cuyo propósito es medir la radiación incidente de una determinada longitud de onda. La idea detrás del diseño de estos instrumentos se fundamenta en que todo cuerpo con una temperatura superior al cero absoluto emite radiación electromagnética, y que el espectro de esta radiación puede utilizarse para distinguir diferentes objetos, como por ejemplo el Sol, las nubes, moléculas de aire, tierra, mar, hielo, etc. El segundo grupo de los equipos de tierra está formado por las cámaras de cielo que fotografían el cielo en el espectro visible, infrarrojo o ultravioleta. El tercer grupo incluye radares que miden la retrodispersión de una señal electromagnética emitida por el propio aparato. Estos instrumentos miden la diferencia de tiempo entre la emisión y recepción de la señal, así como la pérdida de intensidad de la señal, para determinar la posición de las nubes (Kato *et al.*, 2001; Feister *et al.*, 2010). Los ceilómetros forman parte de este tercer grupo, se

emplean para indicar la altura de la base de una o varias capas de nubes. El último de estos cuatro grupos es la radiosonda, un dispositivo electrónico incorporado en globos meteorológicos que permite monitorizar las nubes. Un globo meteorológico se llena con helio para que alcance una altitud de más de 30km. La radiosonda incluye sensores capaces de medir temperatura, presión del aire y humedad relativa. Durante su camino ascendente, la radiosonda detecta nubes aportando información sobre las mismas como la altura de su base, el espesor y la altura de la parte superior de la nube. La mayor ventaja de las radiosondas es que pueden detectar múltiples capas de nubes en cada nivel de la atmósfera. Más aún, el desplazamiento horizontal del globo indica la velocidad y dirección del viento que mueve las nubes en cada capa de la atmósfera.

De entre los equipos de tierra destacan las cámaras de cielo por su fácil instalación, mantenimiento y bajo coste. Esto hace que puedan instalarse en muchas ubicaciones y cubrir una extensa área. Las cámaras de cielo son dispositivos utilizados para capturar imágenes de la bóveda celeste. Normalmente están formadas por un dispositivo de carga acoplada CCD⁸ o un sensor CMOS⁹, junto con una lente de ojo de pez.

El uso que más frecuentemente se le da a las cámaras de cielo es detectar la cubierta de nubes (Tapakis y Charalambides, 2013), aunque también se han empleado en tareas más complejas como la predicción de la irradiancia solar (Alonso-Montesinos *et al.*, 2015; Barbieri *et al.*, 2017), deducir la radiancia del cielo y medidas de luminiscencia (Román *et al.*, 2012; Tohsing *et al.*, 2013), y medir propiedades de los aerosoles (Cazorla *et al.*, 2008; Román *et al.*, 2017b), entre otros. Si bien las cámaras de cielo son menos precisas que otros fotómetros, también es cierto que son capaces de obtener un mapeado hemisférico de la radiancia del cielo en un corto periodo de tiempo. Además los sensores de las cámaras pueden ajustarse variando los tiempos de exposición y ganancia, obteniendo imágenes de gran resolución. Estas propiedades, junto con las mencionadas en el párrafo anterior, hacen de las cámaras de cielo un instrumento que merece ser estudiado tanto para ser aplicado como complemento de otros radiómetros (Román *et al.*, 2017a), como para ser combinado con algoritmos de inteligencia artificial.

La mayoría de los algoritmos diseñados para utilizarse con cámaras de cielo tratan de entrenar clasificadores que sepan reconocer píxeles de nubes (Koehler *et al.*, 1991; Long *et al.*, 2006; Calbó y Sabburg, 2008; Kreuter *et al.*, 2009). Estos algoritmos se basan en la blancura de los píxeles cuantificada mediante el cociente de los canales rojo y azul¹⁰ (rojo / azul). Los clasificadores obtenidos poseen un valor umbral de modo que los píxeles

⁸Por sus siglas en inglés, Charge-Coupled Device

⁹Acrónimo de Complementary Metal Oxide Semiconductor

¹⁰Los colores de un píxel pueden darse en formato RGB, indicando la intensidad de color rojo, verde y azul que tiene ese píxel.

con un cociente menor que éste se consideran libres de nubes, y los píxeles con cociente mayor que dicho valor umbral se consideran píxeles nubosos.

En la actualidad se ha avanzado en el reconocimiento de objetos en fotografías gracias a la inteligencia artificial (Hastie *et al.*, 2009). Por ello resulta interesante estudiar la aplicación de esta técnica para resolver el problema de identificar nubes en imágenes tomadas por una cámara de cielo. En este contexto se plantea el objetivo principal de este trabajo, analizar la posibilidad de utilizar fotografías obtenidas por una cámara de cielo para reconocer la cubierta de nubes mediante inteligencia artificial.

Capítulo 2

Instrumentación y metodología

Para llevar a cabo el trabajo se han empleado imágenes tomadas por la cámara de cielo SONA202-NF (Sieltec Canarias S.L.) controlada por el “Grupo de Óptica Atmosférica” de la Universidad de Valladolid; la herramienta de inteligencia artificial diseñada por Google “Teachable Machine 2.0”, así como “Google Colab” un servicio *cloud* de Google que permite programar Python desde un navegador web sin necesidad de instalar ningún software, y también el software RStudio para programar en R.

2.1. Funcionamiento de la cámara de cielo

La cámara empleada para tomar las fotografías está ubicada en el tejado de la facultad de Ciencias de la Universidad de Valladolid, España ($41,6636^\circ$ N, $4,7058^\circ$ W; 705 m s.n.m.).



Figura 2.1: Cámara de cielo instalada en el tejado de la facultad.

El modelo de esta cámara de cielo es SONA202-NF (Sieltec Canarias S.L.)¹. Este dispositivo es un prototipo que esencialmente consiste en un sensor CMOS acoplado con una lente de pez, ambos encapsulados en una funda impermeable con una cúpula transparente de cristal. La cámara está calibrada horizontalmente para recibir la radiancia de toda la bóveda celeste. El sensor CMOS es un SONY IMX249 y está configurado para capturar imágenes de 1172x1158 píxeles con una resolución de 10 bits. Este sensor tiene un filtro Bayer con un mosaico de patrón RGGB: la mitad de los píxeles son principalmente sensibles al verde (G, *green* en inglés), un cuarto de ellos es sensible al rojo (R, *red*), y el cuarto restante lo es al azul (B, *blue*). El espectro de la respuesta de este filtro, obtenido del manual proporcionado por el fabricante del sensor, se corresponde con la Figura 2.2(a). Un filtro adicional RGB tri-banda, cuyo espectro de respuesta provisto por el fabricante puede verse en la Figura 2.2(b), se ha dispuesto sobre el filtro Bayer del sensor para así reducir el ancho de banda de los colores. La Figura 2.2(c) muestra la respuesta espectral de la cámara de cielo al combinar los dos filtros, puede verse que el canal de los colores rojo, verde y azul son más estrechos que sin el filtro tri-banda. Asimismo se aprecia que este filtro adicional reduce el solapamiento entre los tres canales, aunque no lo elimina por completo.

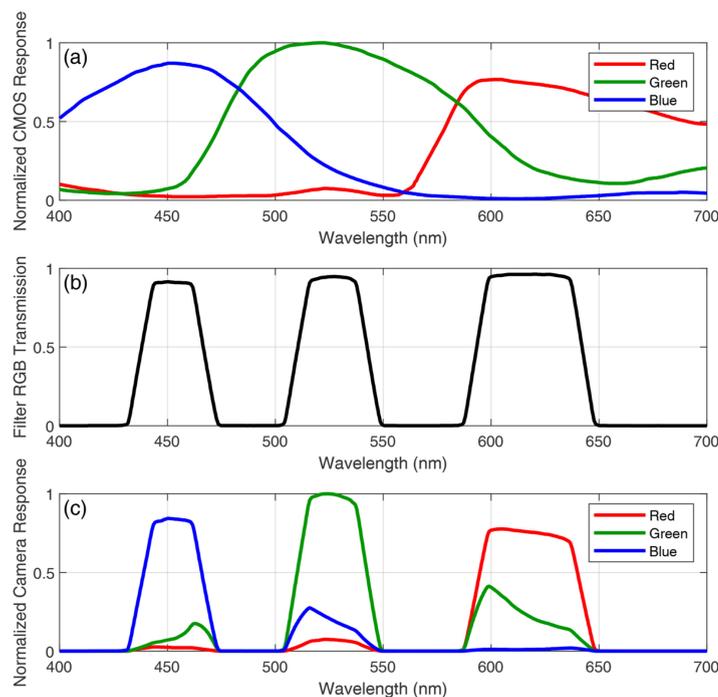


Figura 2.2: Espectro de la respuesta de (a) sensor CMOS con el filtro Bayer, (b) filtro tri-banda RGB, y (c) cámara de cielo (ambos filtros solapados). Figura tomada de Antuña-Sánchez *et al.* (2021).

¹Todas sus características están detalladas en Antuña-Sánchez *et al.* (2021)

Este sensor CMOS permite tomar fotografías con diferentes tiempos de exposición. Esta cámara está configurada para tomar fotografías en formato *raw*² cada 5 minutos con diferentes tiempos de exposición. La configuración de los tiempos de exposición empleada para la fase diurna, que es en la que se centra este trabajo, es la siguiente: $t_1 = 0,3\text{ms}$, $t_2 = 0,4\text{ms}$, $t_3 = 0,6\text{ms}$, $t_4 = 1,2\text{ms}$, $t_5 = 2,4\text{ms}$, $t_6 = 4,8\text{ms}$, y $t_7 = 9,6\text{ms}$.

Las 7 imágenes capturadas a distintos tiempos de exposición son utilizadas para crear una imagen única en alto rango dinámico (HDR)³. A esta imagen HDR se le aplica un mapeado de tono y un balance de blancos fijo para que en la imagen HDR final se puedan apreciar bien las zonas más oscuras y las más saturadas, y se vea con un color realista. Estas imágenes HDR obtenidas por la cámara se almacenan en un servidor gestionado con Nextcloud⁴, donde se realizará el etiquetado y la adquisición de las imágenes.

²Es un formato de archivo digital de imágenes que contiene la totalidad de los datos de la imagen tal y como ha sido captada por el sensor digital de la cámara, sin pérdida de información.

³Por sus siglas en inglés; High Dinamyc Range

⁴Se trata de una plataforma de alojamiento de archivos, puede obtenerse más información en <https://nextcloud.com.es>

2.2. Etiquetado de las imágenes de cielo

Esta etapa del trabajo consiste en etiquetar manualmente las imágenes diurnas correspondientes a los meses de enero a junio del año 2019. Las fotografías se tomaron en intervalos de cinco minutos, por lo que se han etiquetado aproximadamente 26.000 imágenes.

Las etiquetas de las imágenes se dividen en tres clases:

1. **Sol obstruido / despejado:** Sol obstruido indica que el Sol está cubierto (total o parcialmente) por nubes (Figura 2.3a). Sol despejado indica que 5° alrededor del sol no se encuentra ningún obstáculo (Figura 2.3b).



(a) Sol obstruido



(b) Sol despejado

Figura 2.3: Etiqueta Sol obstruido / despejado

2. **Número de octas:** del 0 al 8 indica cuantos octavos del cielo están cubiertos por nubes (Figura 2.4). Al ser una medida subjetiva, ya que depende de la percepción del observador, se asume un error de ± 1 octa.



(a) 3 octas



(b) 5 octas



(c) 7 octas

Figura 2.4: Etiqueta con el número de octas

3. **Fenómenos:** una misma imagen puede presentar varios de los siguientes fenómenos,
- **Gotas:** indica la presencia de gotas de agua en la cúpula que protege la cámara (Figura 2.5a).
 - **Hielo:** indica la presencia de hielo en la cúpula de la cámara (Figura 2.5b).
 - **Chimenea:** cerca del tejado de la facultad hay una chimenea, esta etiqueta se añade si sale humo de la misma (Figura 2.5c).

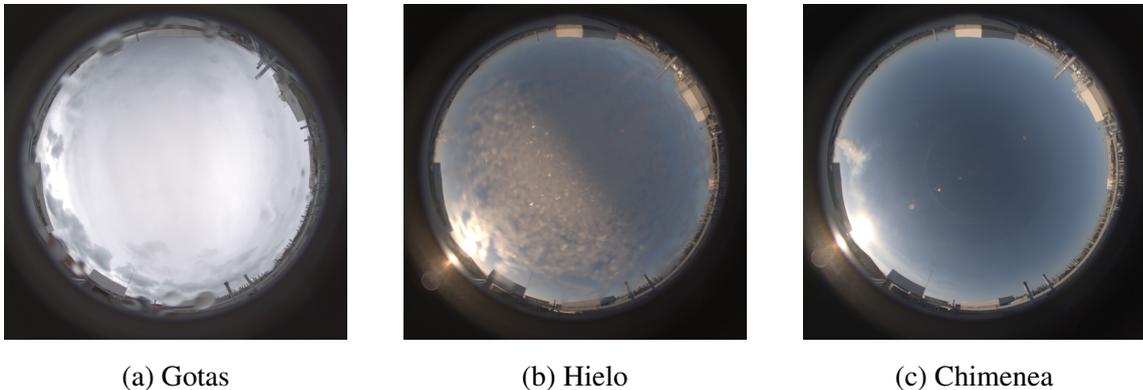


Figura 2.5: Etiquetas de los fenómenos: gotas, hielo y chimenea

- **Sucio:** indica si la cámara está sucia (Figura 2.6a). La cámara se ensucia con el transcurrir de los días debido a las lluvias, polvo, hielo, y pequeños animales como arañas (Figura 2.6b) y pájaros (Figura 2.6c). Una buena labor de mantenimiento es importante para obtener imágenes nítidas del cielo.



Figura 2.6: Imágenes con la cámara sucia

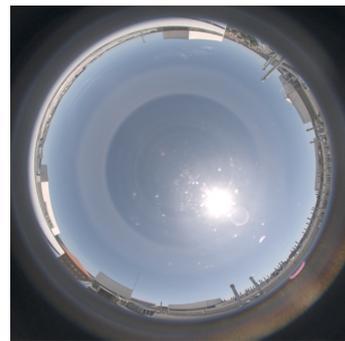
- **Aerosoles:** indica la presencia de aerosoles, se caracteriza porque reduce la visibilidad del Sol, impidiendo ver una figura nítida del mismo, y porque tiñen la imagen de un tono blanquecino. También se puede advertir porque entre imágenes consecutivas la capa de aerosol se mueve como si fuera una capa

de neblina. Si la cámara está sucia entonces tampoco es posible obtener una imagen nítida del Sol, por lo que hay que prestar atención para no confundirse. Asimismo, es posible confundir la presencia de aerosoles con nubes altas, para sortear esta dificultad es posible apoyarse en la información que proporciona el ceilómetro (Figura 2.7).

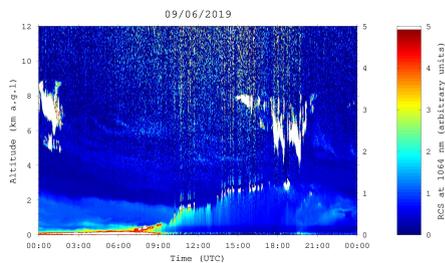
En la Figura 2.7 se incluye la señal corregida de rango obtenida por el ceilómetro, situado en la terraza de la facultad, en función del tiempo y la altura. Los valores saturados (color blanco) corresponden a nubes.



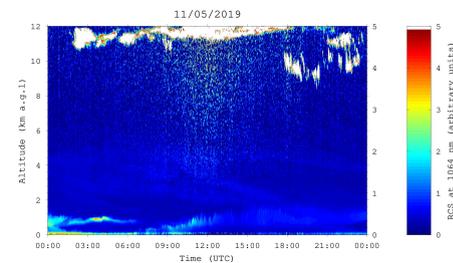
(a) Imagen con aerosol, 10:00 (UTC)



(b) Imagen con nubes altas, 13:35 (UTC)



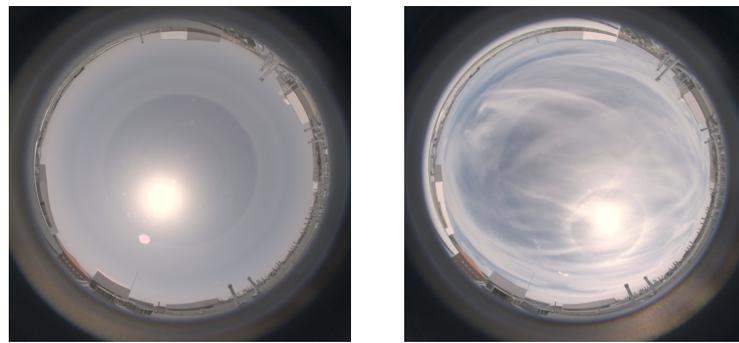
(c) Medidas del ceilómetro asociado a la Figura 2.7a



(d) Medidas del ceilómetro asociado a la Figura 2.7b

Figura 2.7: Comparación de imágenes con aerosol y nubes altas

- **Polvo:** indica la presencia de polvo en suspensión en la atmósfera, o calima. Generalmente se trata de polvo que proviene del Sahara (Cachorro *et al.*, 2016). El polvo, al tratarse de partículas más gruesas, se distingue del resto de aerosoles en las imágenes porque además de reducir la visibilidad también dilata la figura del Sol (Figura 2.8a).
- **Halo:** Este fenómeno aparece como un anillo luminoso blanco, o casi blanco, de 22° de radio, cuya fuente de luz está en el centro (Figura 2.8b). En ocasiones, en función de la cantidad de nubes cirriformes presente, solamente una parte del círculo es visible.



(a) Imagen con polvo

(b) Imagen con halo

Figura 2.8: Etiquetas de los fenómenos: polvo y halo

2.3. Entrenamiento de la red neuronal

Una vez se ha realizado el etiquetado de imágenes, éstas se dividen en los conjuntos de entrenamiento y validación. El conjunto de entrenamiento se utiliza para entrenar una red neuronal, y el de validación se empleará más adelante para cuantificar el desempeño del modelo entrenado.

Una red neuronal es un algoritmo de aprendizaje automático. En este caso se utiliza una red neuronal para entrenar modelos que sean capaces de clasificar las imágenes de cielo según:

1. Si el Sol está obstruido o no.
2. El número de octas que cubre el cielo.
3. El fenómeno predominante en la imagen, si lo hay.

Se ha utilizado la herramienta de Google “Teachable Machine 2.0” para obtener estos modelos. El acceso a esta herramienta es totalmente gratuito y solo precisa de conexión a internet. Se puede acceder mediante el siguiente enlace: <https://teachablemachine.withgoogle.com/train/image>.

La interfaz de “Teachable Machine 2.0” (Figura 2.9) es muy sencilla: las imágenes del conjunto de entrenamiento se seleccionan en la parte izquierda, los parámetros de entrenamiento se escogen en la parte central y pulsando “preparar modelos” se inicia el entrenamiento. Una vez finalizado éste se puede exportar desde la parte derecha.

Los parámetros de entrenamiento son:

- Épocas: cuando el modelo ha procesado todas las muestras de entrenamiento se

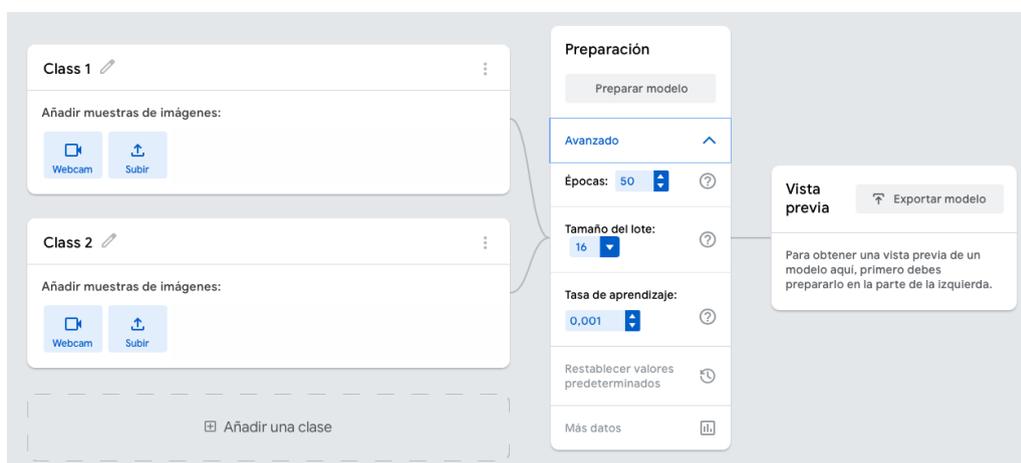


Figura 2.9: Interfaz de “Teachable Machine 2.0”

dice que ha completado una época. Este parámetro determina el número de veces que se procesan las muestras de entrenamiento. Por lo general, cuanto mayor es el número, mejor aprenderá el modelo a predecir nuevos datos. Sin embargo un valor muy elevado podría causar el fenómeno de sobreajuste (también conocido como *overfitting*): el modelo se centra en aprender *demasiado* bien la clasificación de las imágenes de entrenamiento, pero empeora su desempeño en imágenes nuevas (que no formaban parte del conjunto de entrenamiento). También podría ocurrir que por más que se aumente el número de épocas, el modelo no mejora. Por lo tanto se trata de un parámetro cuya elección debe realizarse cuidadosamente. Su valor por defecto es 50.

- **Tamaño del lote:** un lote es un conjunto de imágenes que se usan en una iteración del modelo. Por ejemplo, si tenemos 80 imágenes y un tamaño de lote de 16, entonces las 80 imágenes se dividirán en 5 lotes de 16 imágenes. Cuando el modelo procese los 5 lotes se completará una época. Según la documentación proporcionada por los desarrolladores de esta herramienta, a diferencia del parámetro anterior, éste no es un parámetro relevante para mejorar la eficacia del modelo. Su valor por defecto es 16.
- **Tasa de aprendizaje:** es un valor comprendido entre 0 y 1. El entrenamiento del modelo es un proceso iterativo, en cada iteración el modelo aprende algo nuevo a partir del conjunto de entrenamiento que le permite mejorar su capacidad predictiva. La tasa de aprendizaje limita la cantidad de información que puede aprender el modelo en cada iteración. Este parámetro se emplea para evitar el fenómeno de sobreajuste. Sin embargo una tasa de aprendizaje muy pequeña hará que el modelo aprenda muy lentamente, aumentando el coste computacional. Se trata de un parámetro que debe ajustarse correctamente, pequeños cambios pueden afectar enormemente a la eficacia del modelo. Su valor por defecto es 0,001.

En este contexto resulta coherente plantearse una búsqueda de parámetros óptimos para entrenar el modelo. Se han realizado 12 entrenamientos para cada tipo de modelo (hay un tipo modelo para cada clase de etiqueta) combinando los siguientes valores: Épocas = 50, 100, 150, 200 y Tasa de aprendizaje = 0,001, 0,005, 0,01.

Una vez entrenados y exportados los modelos, éstos se utilizan en la plataforma “Google Colab” que permite programar Python desde cualquier navegador web (se requiere conexión a internet). Se utilizan los modelos generados para realizar predicciones sobre el conjunto de validación y se genera un fichero .csv con los resultados. Nótese que la predicción de cada modelo consiste en un vector cuyas componentes son las probabilidades que éste asigna a cada etiqueta. Por ejemplo, en el caso del modelo entrenado para predecir el número de octas, éste devuelve un vector de nueve componentes con las probabilidades de las nueve etiquetas posibles. Por último, estos ficheros se abren con el programa RStudio donde se evalúan los diferentes modelos según su desempeño. Esto permite determinar qué combinación de parámetros es la más adecuada para cada tipo de modelo. Los códigos de Python y R diseñados para realizar esta tarea se encuentran en el Anexo.

Capítulo 3

Resultados

Para cada clase de etiqueta (Sol, octas y fenómeno) se han obtenido 12 modelos combinando diferentes valores de los parámetros Épocas y Tasa de aprendizaje, tal y como se dijo en el capítulo anterior. En este capítulo se evaluarán estos modelos y se discutirá cuál es la mejor combinación de parámetros para cada clase de etiqueta.

3.1. Modelo Sol

Antes de presentar los resultados de esta clase de modelo se considera oportuno introducir una serie de conceptos:

- Exactitud: en problemas de clasificación binaria, representa la probabilidad de clasificar correctamente una muestra. Se calcula como el cociente entre el número de muestras clasificadas correctamente y el número de muestras total.
- IC 95 %: se trata del intervalo de 95 % de confianza para la estimación de la exactitud.
- Sensibilidad: representa la probabilidad de que un individuo con la etiqueta +1 se clasifique correctamente. Es el cociente entre el número de muestras clasificadas *correctamente* con +1 y el número de muestras con la etiqueta +1. En este caso la etiqueta +1 se corresponde con “Sol despejado” .
- Especificidad: representa la probabilidad de que un individuo con la etiqueta -1 se clasifique correctamente. Es el cociente entre el número de muestras clasificadas *correctamente* con -1 y el número de muestras con la etiqueta -1. En este caso la etiqueta -1 se corresponde con “Sol obstruido” .
- Pérdida logística: es el resultado de evaluar la función de pérdida logística (3.1) sobre el conjunto de prueba. Es de gran utilidad para comparar modelos de clasificación.

Dada una imagen con la etiqueta y , con $y \in \{-1, +1\}$, recuérdese que el clasificador devuelve un vector $(1-p, p)$ donde p es la probabilidad de que esa imagen pertenezca a la clase $y = +1$. Para esa imagen y esa predicción, el error dado por la función de pérdida logística se calcula como:

$$L(y, p) = - \left(\frac{y+1}{2} \ln(p) - \frac{y-1}{2} \ln(1-p) \right). \quad (3.1)$$

Nótese que esta función de pérdida tiene en cuenta la probabilidad asignada por el clasificador para la etiqueta correcta. De este modo si la probabilidad de la etiqueta correcta se encuentra próxima a 1 entonces la función toma valores próximos a cero. Por contra, cuanto menor sea la probabilidad asignada a la categoría correcta, mayor penalización obtendrá. En la Figura 3.1 se ha representado la función $-\ln(x)$ con $0 < x \leq 1$, donde puede advertirse la importancia que tiene no sólo clasificar correctamente una imagen, sino de hacerlo asignando a la etiqueta correcta una alta probabilidad. Para evaluar esta función de pérdida sobre un conjunto de imágenes, se evalúa la función en cada una de las imágenes del conjunto y luego se toma la media aritmética.

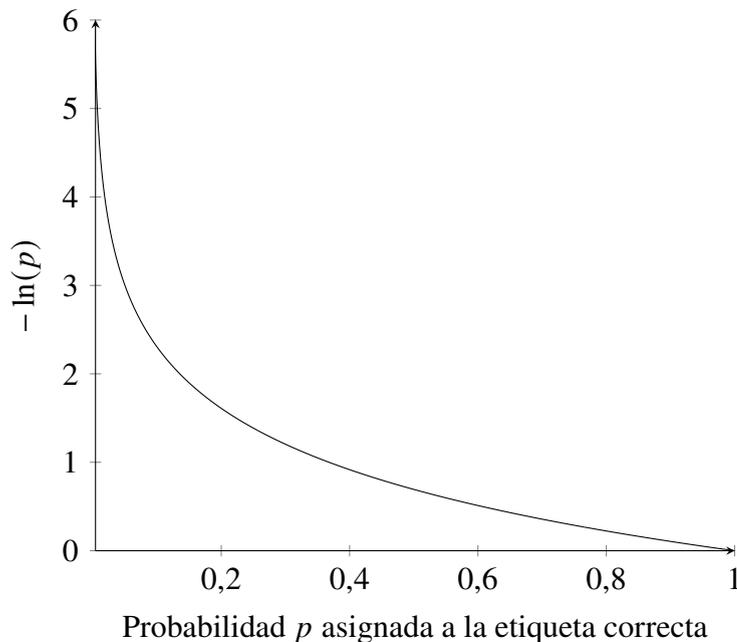


Figura 3.1: Función de pérdida de entropía cruzada

Los resultados de los modelos entrenados para predecir la etiqueta “Sol” se encuentran en las Tablas 3.1-3.5.

En primer lugar cabe destacar que la mayoría de los modelos tienen una exactitud estimada ligeramente superior a 90 %, y un intervalo de 95 % de confianza estrecho, lo

Exactitud				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	0,8805	0,9165	0,8701
	100	0,9177	0,9064	0,9173
	150	0,9181	0,8684	0,9167
	200	0,9020	0,9212	0,9083

Tabla 3.1: Exactitud de los modelos “Sol”

IC 95 %				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	(0,8741, 0,8866)	(0,911, 0,9217)	(0,8634, 0,8764)
	100	(0,9123, 0,9229)	(0,9007, 0,9119)	(0,9118, 0,9225)
	150	(0,9127, 0,9233)	(0,8618, 0,8749)	(0,9112, 0,9219)
	200	(0,8962, 0,9076)	(0,9158, 0,9263)	(0,9026, 0,9138)

Tabla 3.2: Intervalo de 95 % de confianza para la exactitud estimada en 3.1

Sensibilidad				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	0,7164	0,8368	0,6545
	100	0,8834	0,9317	0,8657
	150	0,8573	0,6800	0,8377
	200	0,8611	0,8909	0,7815

Tabla 3.3: Sensibilidad de los modelos “Sol”

Especificidad				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	0,9610	0,9556	0,9758
	100	0,9346	0,8939	0,9426
	150	0,9480	0,9610	0,9555
	200	0,9221	0,9360	0,9706

Tabla 3.4: Especificidad de los modelos “Sol”

Pérdida logística				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	0,5494	0,3287	0,2643
	100	0,6169	0,6486	0,4459
	150	0,8527	1,0864	0,4873
	200	1,2213	1,2439	0,4571

Tabla 3.5: Pérdida logística de los modelos “Sol”

que significa que esta estimación es muy buena. No obstante, la exactitud por sí sola no basta para evaluar si un modelo es mejor que otro. Por ejemplo, supóngase que se tiene un modelo que etiqueta todas las imágenes como “Sol obstruido”, y en el conjunto de entrenamiento hay 100 imágenes de las cuales 90 tienen la etiqueta “Sol obstruido”, en ese caso el clasificador tendría una exactitud del 90 % y sin embargo se trata de un clasificador absurdo. Es por ello que resulta fundamental comparar otras medidas como la sensibilidad y la especificidad de los modelos.

En el conjunto total de imágenes etiquetadas, el número de imágenes con la etiqueta “Sol obstruido” es muy superior al de imágenes con la etiqueta “Sol despejado”. Por este motivo se espera que los modelos posean una especificidad alta, los modelos se entrenan para buscar patrones en las imágenes y cuando deben clasificar una nueva imagen lo que hacen es buscar estos patrones en las nuevas imágenes. Por ello, si el número de imágenes con el Sol obstruido es superior, entonces aprenderán a reconocerlas mejor que las imágenes con el Sol despejado.

En las Tablas 3.3 y 3.4 se aprecia que aquellos modelos con una especificidad muy alta poseen una sensibilidad muy inferior al resto. Lo ideal en este caso es hallar un modelo que posea un equilibrio entre sensibilidad y especificidad, con este fin en la Figura 3.2 se ha representado la especificidad frente a la sensibilidad de los 12 modelos.

La Figura 3.2 permite apreciar cuáles son los modelos más equilibrados, los entrenados con los parámetros: Épocas:100, Tasa de aprendizaje:0,001, y Épocas:200, Tasa de aprendizaje:0,005; dos de los cuatro modelos con mayor exactitud.

También, en la Tabla 3.5 se observa que, por lo general, tomar un número de épocas mayor aumenta el valor de la función de pérdida logística, mientras que tomar una tasa de aprendizaje mayor reduce el valor de esta función. Hay que tener en cuenta que esta medida favorece a los modelos con una alta especificidad ya que en el conjunto de validación hay 3456 imágenes con la etiqueta “sol obstruido” y 7034 imágenes con la etiqueta “sol despejado”. No obstante, esta medida sirve para descartar aquellos modelos cuyas

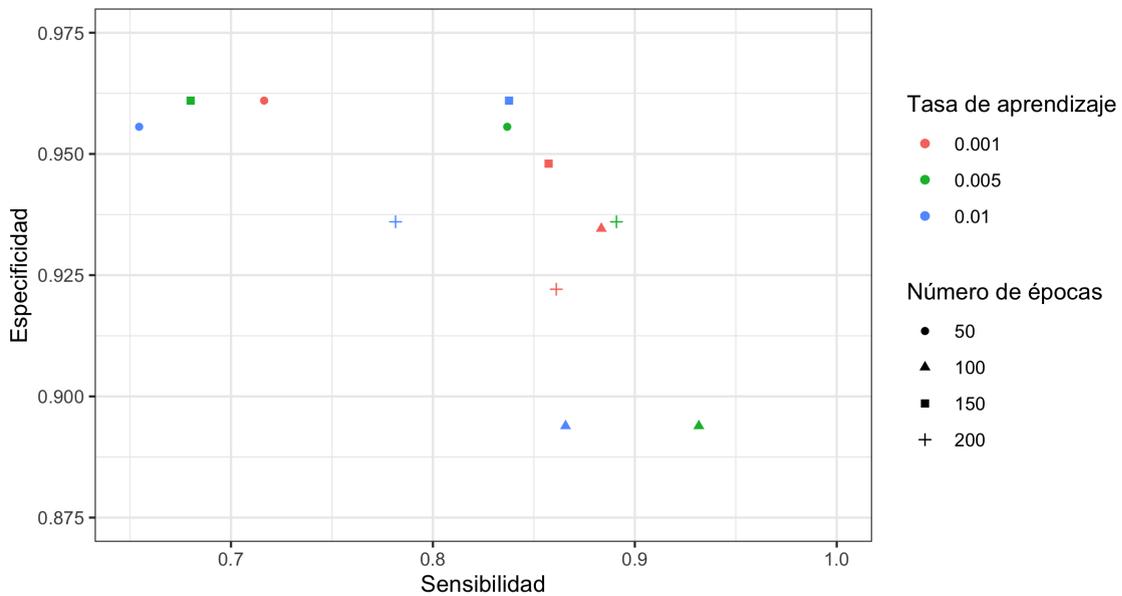


Figura 3.2: Especificidad en función de la Sensibilidad para los 12 modelos “Sol”. Clase “positiva” (+1): despejado.

predicciones no se realizan con gran certeza, como el modelo entrenado con los parámetros Épocas:200, Tasa de aprendizaje:0,005. Un valor elevado de la función de pérdida logística indica que, por lo general, la probabilidad que el modelo asigna a la etiqueta correcta se encuentra alejada del 1.

Por lo expuesto hasta ahora, se concluye que la mejor combinación de parámetros para entrenar el modelo “Sol” es: Épocas:100, Tasa de aprendizaje:0,001.

3.2. Modelo octas

A diferencia del caso anterior, aquí no resulta tan interesante utilizar la función de pérdida logística. El problema no es tanto el número de etiquetas, sino la naturaleza de la clasificación. Por ejemplo, no habría problema en utilizar esta función para evaluar un clasificador que se ha entrenado para reconocer animales en una fotografía. Por lo general éstos son muy distintos y si el modelo se ha entrenado con un gran conjunto de imágenes, no tendrá muchas dudas a la hora de clasificarlos (otorgándole una gran probabilidad a la etiqueta correcta). No obstante en el caso del número de octas la cosa es bien distinta, el número de octas que hay en el cielo es una medida subjetiva (depende del observador) y se asume un error de ± 1 octa, por lo que imágenes del cielo con 3 y 4 octas son muy similares. Esto hace que en muchos casos el clasificador distribuya la probabilidad entre

varias etiquetas “contiguas”. Es decir, supóngase que se tiene una imagen del cielo con 3 octas, el clasificador (si está bien entrenado) reconocerá que esa imagen es similar a otras que ya ha visto durante el entrenamiento y que tenían entre dos y cuatro octas. En lugar de asignarle una probabilidad muy alta a la etiqueta 3 octas, en ocasiones tenderá a repartir esta probabilidad entre las etiquetas de 2, 3 y 4 octas. En consecuencia, al repartirse la probabilidad, la función de pérdida tomará valores más altos.

Asimismo, aunque se tuviese en cuenta lo indicado en el párrafo anterior, hay otro inconveniente para utilizar esta función de pérdida en el caso presente. Resulta que hay imágenes cuyo número de octas es muy difícil de reconocer, como por ejemplo imágenes de cielo crepuscular o imágenes con nubes altas. En estos casos el modelo suele equivocarse llegando a asignar un 0 a la probabilidad de la etiqueta correcta, en un caso así la función de pérdida logística toma un valor infinito arruinando la evaluación del modelo. Aunque esto no es algo frecuente, basta con que ocurra una vez para perturbar la medida. Por este motivo se ha propuesto un método alternativo para evaluar estos modelos.

Para evaluar estos modelos se ha tomado, para cada una de las imágenes del conjunto de validación, la diferencia entre la etiqueta de referencia de la imagen y la predicha por el modelo. Para la etiqueta predicha por el modelo se ha tomado aquella que tiene asignada mayor probabilidad. Posteriormente se ha realizado un histograma con estas diferencias y se ha comprobado que siguen una distribución de Gauss¹. Finalmente se ha calculado la media y también la desviación estándar de esta diferencia para caracterizar el comportamiento del modelo. La media sirve para estimar la exactitud²: *determina cuán cerca se encuentra el valor predicho del valor real*; y la desviación estándar se ha tomado como estimación de la precisión: *determina el grado en que la repetición de una medición en las mismas condiciones muestra los mismos resultados* (Taylor y Thompson, 1998).

Nótese que aunque los términos *exactitud* y *precisión* puedan parecer sinónimos en el ámbito coloquial, en el uso del método científico tienen connotaciones muy distintas. Por ejemplo, si se comete un error sistemático al tomar medidas en un experimento, al aumentar el tamaño muestral generalmente aumenta la precisión; pero no lo hace la exactitud. De forma alternativa, eliminar los errores sistemáticos aumenta la exactitud, pero no influye en la precisión.

En las Tablas 3.6 y 3.7 se muestran los valores de la media y la desviación estándar de cada modelo. Las entradas de los modelos entrenados con los parámetros *Épocas:200, Tasa de aprendizaje:0,005* y *Épocas:200, Tasa de aprendizaje:0,01* se encuen-

¹También conocida como distribución normal.

²No confundir con el concepto de exactitud en problemas de clasificación binaria que se introdujo en la sección anterior.

tran vacías. Esto se debe a que se realizaron tres entrenamientos con cada una de estas combinaciones y en los tres casos se obtuvo un modelo defectuoso. El modelo que se obtenía no generaba predicciones sobre nuevas imágenes y se concluyó que esta combinación de parámetros no era adecuada para entrenar el modelo “octas”.

Media / octas				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	-0,0792	-0,1469	-0,1838
	100	-0,0318	0,0991	-0,0075
	150	-0,1149	-0,0495	-0,0582
	200	0,0376		

Tabla 3.6: Media de las diferencias “etiqueta referencia” - “etiqueta predicha” de los modelos “octas”

Desviación Estándar / octas				
Tasa de aprendizaje		0,001	0,005	0,01
Épocas	50	1,0794	1,1084	1,1379
	100	1,1114	1,0911	1,1354
	150	1,1574	1,0518	1,1396
	200	1,0802		

Tabla 3.7: Desviación estándar de las diferencias “etiqueta referencia” - “etiqueta predicha” de los modelos “octas”

Estos resultados revelan que los modelos son bastante exactos y que sus predicciones, por lo general, se encuentran dentro del margen de error (± 1 octa) que se asume en la determinación de las octas. Para ilustrar esta afirmación se va a estimar la probabilidad de que uno de estos clasificadores etiquete una imagen con un error superior a 1 octa. Sea X la variable que representa diferencias calculadas, asumiendo el comportamiento normal de X , tomando $\mu = -0,0535$ octas (el valor medio de los valores que aparecen en la Tabla

3.6), y $\sigma = 1,1093$ octas (el valor medio de los valores que aparecen en la Tabla 3.7):

$$\begin{aligned}
 \Pr[|X| \geq 2] &= \Pr[X \leq -2, X \geq 2] \\
 &\leq \Pr[X \leq -2] + \Pr[X \geq 2] \\
 &= \Pr\left[\frac{X - \mu}{\sigma} \leq -\frac{2 + \mu}{\sigma}\right] + \Pr\left[\frac{X - \mu}{\sigma} \geq \frac{2 - \mu}{\sigma}\right] \\
 &= \Pr\left[Z \leq -\frac{2 + \mu}{\sigma}\right] + \Pr\left[Z \geq \frac{2 - \mu}{\sigma}\right] \\
 &= \Pr\left[Z \geq \frac{2 + \mu}{\sigma}\right] + \Pr\left[Z \geq \frac{2 - \mu}{\sigma}\right] \\
 &= 2 - \Pr\left[Z < \frac{2 + \mu}{\sigma}\right] + \Pr\left[Z < \frac{2 - \mu}{\sigma}\right] \\
 &\approx 2 - \Pr\left[Z \leq \frac{2 + \mu}{\sigma}\right] + \Pr\left[Z \leq \frac{2 - \mu}{\sigma}\right] \\
 &\approx 2 - \Pr[Z \leq 1,75] - \Pr[Z \leq 1,85] = 2 - 0,9599 - 0,9678 = 0,0723,
 \end{aligned}$$

donde Z es una variable que sigue una distribución normal $N(0, 1)$, y el valor de las probabilidades se ha tomado de una tabla normal estándar³. Aquí se aprecia la importancia de escoger un modelo con una menor desviación estándar, cuanto menor sea σ , menor será la probabilidad de etiquetar una muestra con un error superior a una octa.

Para localizar los modelos con media próxima a 0 (alta exactitud) y menor desviación estándar (alta precisión), se ha decidido representar la desviación estándar frente a la media de los clasificadores entrenados con diferentes parámetros (Figura 3.3):

En la Figura 3.3 se ha representado una recta vertical discontinua de color gris que corta el eje horizontal en $x = 0$. De este modo se puede comparar de forma visual las diferentes medias de los modelos. Analizando este gráfico se aprecia que, generalmente, para un mismo número de Épocas, cuanto mayor es el valor de la Tasa de aprendizaje, peor es la precisión de los modelos.

Finalmente se concluye que el mejor de estos modelos es el entrenado con los parámetros Épocas:200, Tasa de aprendizaje:0,001, ya que es el tercer modelo más preciso y el modelo con mayor exactitud. En la Figura 3.4 se ha representado el histograma con las diferencias entre las etiquetas de referencia y las predichas por este modelo. Asimismo, se ha dibujado la curva de una distribución normal con media = 0,04 octas y desviación estándar = 1,08 octas, para apreciar cómo las diferencias siguen dicha distribución normal.

³https://es.wikipedia.org/wiki/Tabla_normal_estandar, última vez consultado: 25/06/2021

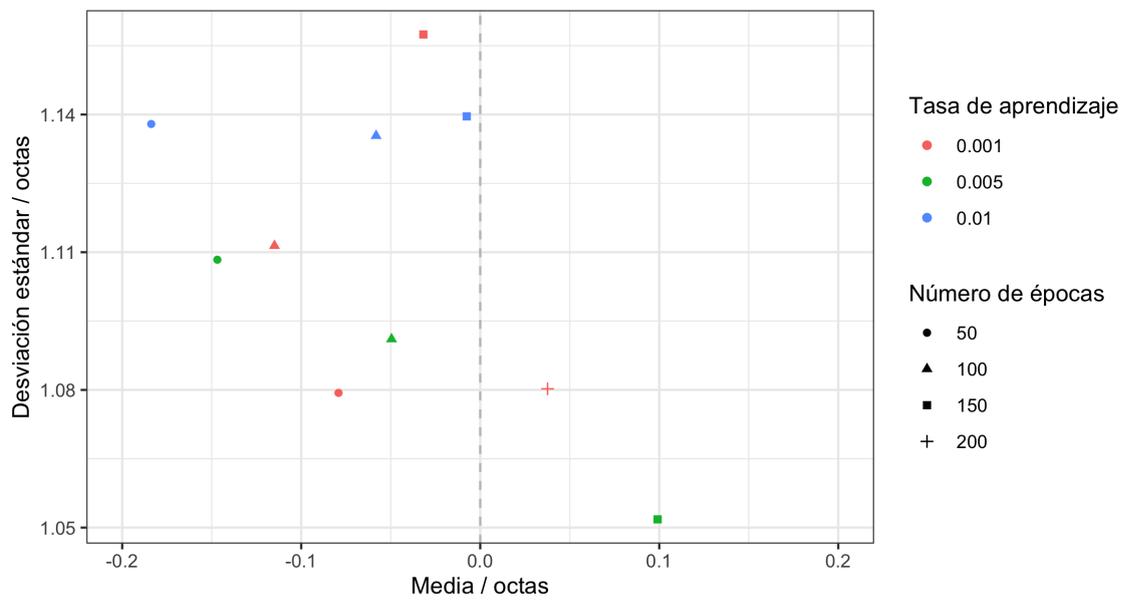


Figura 3.3: Desviación estándar en función de la media de las diferencias “etiqueta referencia” - “etiqueta predicha” de los 12 modelos “octas”.

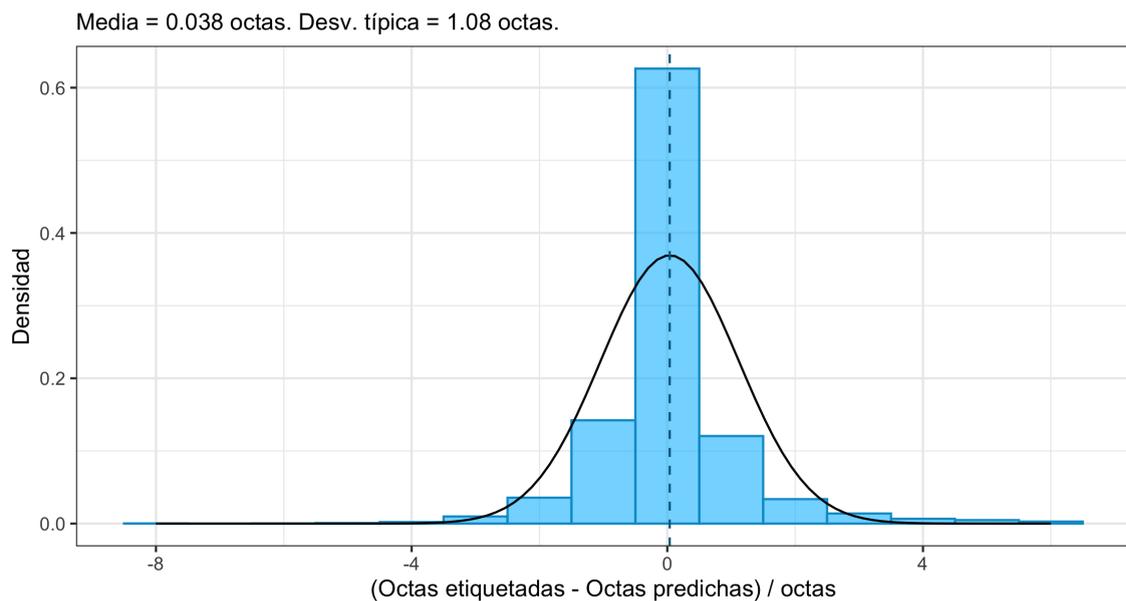


Figura 3.4: Histograma con las diferencias entre las etiquetas de referencia y las predichas por el modelo “octas” entrenado con Épocas:200, Tasa de aprendizaje:0,001.

Se ha querido estudiar en más detalle este modelo, asumiendo que las diferencias siguen una distribución normal con media = 0,04 octas y desviación estándar = 1,08 octas, la probabilidad de clasificar una imagen con un error de 2 octas o más es 6,8 %. Este valor puede compararse con el cociente de imágenes en las que este modelo comete un error de 2 o más octas, y el número total de imágenes: $805/12998 \cdot 100 \approx 6,2 \%$. Se concluye que este modelo, con alta probabilidad, no cometerá errores de más de una octa al realizar predicciones sobre nuevas imágenes.

3.3. Modelo fenómenos

En las otras dos clases de modelos, los clasificadores asignaban exactamente una etiqueta a cada imagen. Los modelos de la clase “Sol” reconocían si el Sol estaba despejado o no. Los modelos de la clase “octas” trataban de predecir el número de octas que había en la imagen. Sin embargo la cosa cambia en los modelos de la clase “fenómenos”, ahora cada imagen pueden tener una o varias etiquetas. En una misma imagen puede suceder que, por ejemplo, la cámara esté sucia y haya presencia de aerosoles; o que se vea el humo de la chimenea y haya gotas, etc. No obstante el clasificador está diseñado para devolver un vector de probabilidades, donde cada componente es la probabilidad asociada a una etiqueta. Esto supone un cambio a la hora de asignar la etiqueta predicha por el clasificador. En los modelos anteriores bastaba con tomar la etiqueta que tenía mayor probabilidad. De hacer eso mismo en este modelo se estaría limitando el número de fenómenos que el clasificador es capaz de detectar. Para solventar se ha decidido asignar a cada imagen aquellas etiquetas cuya probabilidad emitida por el clasificador es superior a cierto valor umbral. Se ha escogido como valor umbral 0,3 ya que ninguna imagen del conjunto de validación tenía más de tres etiquetas de la categoría “fenómenos”.

A continuación se presenta la evaluación de un modelo de esta clase, concretamente el entrenado con *Épocas:50*, *Tasa de aprendizaje:0,001*. Para cada tipo de etiqueta se ha obtenido el cociente entre el número de imágenes que han sido asignadas con esa etiqueta correctamente, y el número total de imágenes que tenían esa etiqueta como referencia (esto es la sensibilidad respecto de esa etiqueta); y el cociente entre el número de imágenes que, correctamente, no han sido asignadas con esa etiqueta, y el número de imágenes que no tenían esa etiqueta de referencia (esto es la especificidad respecto de esa etiqueta). Estos valores pueden encontrarse en la Tabla 3.8.

Respecto de una etiqueta, la sensibilidad cuantifica qué tan bien reconoce el modelo esa etiqueta, mientras que la especificidad determina qué tan bien descarta el modelo esa

Etiquetas	Aerosoles	Chimenea	Gotas	Halo	Hielo	Polvo	Sucio
Sensibilidad	0.7872	0.4605	0.6663	0.7553	0.01724	0.0952	0.8806
Especificidad	0.7350	0.9867	0.9962	0.9869	1	0.9476	0.7759

Tabla 3.8: Sensibilidad y especificidad para las distintas etiquetas del modelo “fenómenos” entrenado con Épocas:50, Tasa de aprendizaje:0,001.

etiqueta. Una alta sensibilidad significa que el modelo reconoce la etiqueta fácilmente. Sin embargo una baja especificidad significa que el modelo se confunde y asigna esa etiqueta a imágenes que no debería.

Analizando la Tabla 3.8 se extraen varias conclusiones. Por un lado se observa que el modelo no es capaz de reconocer cuando hay polvo o hielo en una imagen, esto es comprensible debido a que la cantidad de imágenes en las que aparece hielo o polvo es minúscula. El modelo tampoco llega a detectar cuando aparece el humo de la chimenea en la imagen, esto puede deberse a que la columna de humo que sale de la chimenea puede presentar formas muy distintas, en ocasiones es muy pequeña, en otras muy grande; además el humo de la chimenea puede confundirse con una nube. Por otro lado, si bien el modelo es bastante acertado detectando cuando la cámara está sucia o cuando hay aerosol, también se aprecia que posee una especificidad algo deteriorada respecto de estas etiquetas. Una explicación para esto podría ser que el modelo confunde cuando el sol está sucio y cuando hay presencia de aerosoles. Por último, puede verse que el modelo identifica razonablemente bien el fenómeno de halo, y algo peor el de gotas.

En este apartado no se desarrollará una comparación de los modelos entrenados con diferentes parámetros ya que los resultados son mejorables. En su lugar se detallarán los motivos por los que este tipo de modelos no son tan buenos, y en el Capítulo 4 se propondrá una solución para una futura línea de trabajo.

Para entender el porqué este tipo de modelos no da tan buenos resultados como los modelos de “Sol” y “octas” es necesario comentar como se entrenan estos clasificadores. El tipo de clasificador que entrena la red neuronal desarrollada por Google en “Teachable Machine 2.0” es un clasificador multiclase. Este algoritmo entrena un clasificador a partir de un conjunto de imágenes, donde se supone que cada imagen está etiquetada con una (y solo una) clase, y el clasificador se entrena para que cuando vea una nueva imagen sea capaz de decir con qué probabilidad pertenece a una de esas clases. En este trabajo esto se ha realizado correctamente para los modelos de “Sol” y “octas”. Ahora bien, a mayores, se ha tratado de entrenar el modelo proporcionándole imágenes que pertenecían a diferentes clases (fenómenos) para analizar si esta red era capaz de entrenar modelos que pudiesen reconocer varios fenómenos en la misma imagen. La respuesta es que con este conjunto

de imágenes esto no es posible, hay fenómenos muchísimo más frecuentes que otros, y algunos fenómenos no están bien definidos. Por ejemplo, el halo está bien determinado, las gotas o el hielo también; sin embargo faltaría definir a partir de qué tamaño se puede considerar que se observa humo de la chimenea, o cuándo se considera que la cámara está sucia, para así reducir el factor subjetividad a la hora de asignar esta clase de etiquetas.

Capítulo 4

Conclusiones

En este trabajo se ha propuesto un método para reconocer la cubierta de nubes mediante inteligencia artificial utilizando imágenes obtenidas por una cámara de cielo. Se han entrenado modelos para reconocer si el Sol está obstruido o no, para estimar el número de octas, y para detectar otros fenómenos como la presencia de aerosoles, gotas, o halo, entre otros; estos modelos han sido evaluados y se han extraído las siguientes conclusiones:

- Modelo “Sol”: se ha obtenido un modelo que posee una exactitud de 91,77%. Si bien es posible entrenar modelos con una exactitud ligeramente superior, este modelo es el más equilibrado en términos de sensibilidad y especificidad.
- Modelo “octas”: se ha obtenido un modelo que con mucha probabilidad ($\approx 94\%$) estimará el número de octas que hay en la imagen con un margen de error de una octa.
- Modelo “fenómenos”: se han obtenido modelos que son capaces de reconocer cuando aparece el fenómeno de halo de forma razonable, pero confunden cuando la cámara está sucia y cuando hay aerosoles o polvo.

Se trata de un método para identificar la cubierta de nubes que es económico y de fácil instalación. Esto hace que sea posible instalar una red de cámaras de cielo para estudiar una región extensa y que se pueda conocer el estado del cielo en tiempo real. Asimismo, es posible utilizar los modelos “Sol” y “octas” para etiquetar las imágenes de cielo a medida que éstas se almacenan en el servidor. De este modo se podría construir una base de datos que podría emplearse en futuros estudios. Por otro lado, se quiere subrayar el hecho de que en este trabajo lo que más tiempo ha llevado es etiquetar manualmente, una a una, las 26.000 imágenes que se han empleado para entrenar y evaluar los modelos. No obstante, una vez se ha realizado este etiquetado, estas imágenes con sus etiquetas están alojadas en

un servidor y se utilizarán en futuras investigaciones.

Por último, como futuras líneas de trabajo se propone estudiar qué posiciones del sol son más favorables para entrenar estos modelos. También se propone probar redes neuronales que entrenen modelos multi-etiqueta¹, estos son capaces de reconocer varios objetos en una misma imagen y podrían ser de gran utilidad a la hora de predecir uno o varios fenómenos simultáneamente en las imágenes de cielo.

¹No confundir con modelos multiclase, éstos asocian una imagen con una clase, pero no están entrenados para asociar una imagen con varias clases.

Bibliografía

- Ahrens, D. (2000). An introduction to weather, climate and the environment. *Meteorology Today*, sixth edit.
- Alonso-Montesinos, J., Batlles, F. J., y Portillo, C. (2015). Solar irradiance forecasting at one-minute intervals for different sky conditions using sky camera images. *Energy Conversion and Management*, 105.
- AMS, A. M. S. (2021). Cloud classification - glossary of meteorology. https://glossary.ametsoc.org/wiki/Cloud_classification. Última visita: 2021-06-17.
- Antuña-Sánchez, J. C., Román, R., Cachorro, V. E., Toledano, C., López, C., González, R., Mateos, D., Calle, A., y Ángel M. De Frutos (2021). Relative sky radiance from multi-exposure all-sky camera images. *Atmospheric Measurement Techniques*, 14.
- Antón, M., Gil, J. E., Cazorla, A., Fernández-Gálvez, J., Foyo-Moreno, I., Olmo, F. J., y Alados-Arboledas, L. (2011). Short-term variability of experimental ultraviolet and total solar irradiance in southeastern Spain. *Atmospheric Environment*, 45.
- Badescu, V. (1999). Correlations to estimate monthly mean daily solar global irradiation: Application to Romania. *Energy*, 24.
- Barbieri, F., Rajakaruna, S., y Ghosh, A. (2017). Very short-term photovoltaic power forecasting with cloud modeling: A review.
- Bartlett, J. S., Áurea M. Ciotti, Davis, R. F., y Cullen, J. J. (1998). The spectral effects of clouds on solar irradiance. *Journal of Geophysical Research: Oceans*, 103.
- Beyer, H. G., Hammer, A., Luther, J., Poplawska, J., Stolzenburg, K., y Wieting, P. (1994). Analysis and synthesis of cloud pattern for radiation field studies. *Solar Energy*, 52.
- Boucher, O., Randall, D., Artaxo, P., Bretherton, C., Feingold, G., Forster, P., Kerminen, V.-M., Kondo, Y., Liao, H., Lohmann, U., Rasch, P., Satheesh, S., Sherwood, S., Stevens, B., y Zhang, X. (2013). IPCC, 2013: Climate change 2013: The physical science basis.

- contribution of working group i to the fifth assessment report of the intergovernmental panel on climate change. *IPCC, AR5*.
- Cachorro, V. E., Burgos, M. A., Mateos, D., Toledano, C., Bennouna, Y., Torres, B., Ángel M. De Frutos, y Álvaro Herguedas (2016). Inventory of african desert dust events in the north-central iberian peninsula in 2003-2014 based on sun-photometer-aeronet and particulate-mass-emep data. *Atmospheric Chemistry and Physics*, 16.
- Calbó, J. y Sabburg, J. (2008). Feature extraction from whole-sky ground-based images for cloud-type recognition. *Journal of Atmospheric and Oceanic Technology*, 25.
- Cazorla, A., Olmo, F. J., y Alados-Arboledas, L. (2008). Using a sky imager for aerosol characterization. *Atmospheric Environment*, 42.
- DeGrand, J. Q., Carleton, A. M., Travis, D. J., y Lamb, P. J. (2000). A satellite-based climatic description of jet aircraft contrails and associations with atmospheric conditions, 1977-79. *Journal of Applied Meteorology*, 39.
- Dybbroe, A., Karlsson, K. G., y Thoss, A. (2005). Nwcsaf avhrr cloud detection and analysis using dynamic thresholds and radiative transfer modeling. part ii: Tuning and validation. *Journal of Applied Meteorology*, 44.
- Feister, U., Möller, H., Sattler, T., Shields, J., Görsdorf, U., y Güldner, J. (2010). Comparison of macroscopic cloud data from ground-based measurements using vis/nir and ir instruments at lindenbergl, germany. *Atmospheric Research*, 96.
- Frederick, J. E. y Steele, H. D. (1995). The transmission of sunlight through cloudy skies: an analysis based on standard meteorological information. *Journal of Applied Meteorology*, 34.
- Goodman, A. H. y Henderson-Sellers, A. (1988). Cloud detection and analysis: A review of recent progress. *Atmospheric Research*, 21.
- Hastie, T., Tibshirani, R., y Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- Heinle, A., Macke, A., y Srivastav, A. (2010). Automatic cloud classification of whole sky images. *Atmospheric Measurement Techniques*, 3.
- Kato, S., Mace, G. G., Clothiaux, E. E., Liljegren, J. C., y Austin, R. T. (2001). Doppler cloud radar derived drop size distributions in liquid water stratus clouds. *Journal of the Atmospheric Sciences*, 58.

- Key, J. R., Maslanik, J. A., y Barry, R. G. (1989). Cloud classification from satellite data using a fuzzy sets algorithm: A polar example. *International Journal of Remote Sensing*, 10.
- Koehler, T. L., Johnson, R. W., y Shields, J. E. (1991). Status of the whole sky imager database. *Proc. Cloud Impacts on DOD Operations and Systems, El Segundo, CA, USA, Department of Defense*, pp. 77–80.
- Kreuter, A., Zangerl, M., Schwarzmann, M., y Blumthaler, M. (2009). All-sky imaging: A simple, versatile system for atmospheric research. *Applied Optics*, 48.
- Long, C. N., Sabburg, J. M., Calbó, J., y Pagès, D. (2006). Retrieving cloud characteristics from ground-based daytime color all-sky images. *Journal of Atmospheric and Oceanic Technology*, 23.
- Menzel, W. P. (2001). Cloud tracking with satellite imagery: From the pioneering work of ted fujita to the present. *Bulletin of the American Meteorological Society*, 82.
- Minnis, P., Ayers, J. K., Palikonda, R., y Phan, D. (2004). Contrails, cirrus trends, and climate. *Journal of Climate*, 17.
- OMM, O. M. M. (2017). International cloud atlas: Manual on the observation of clouds and other meteors.
- OMM, O. M. M. (2021). Clouds definitions | international cloud atlas. <https://cloudatlas.wmo.int/es/clouds-definitions.html>. Última visita: 2021-06-10.
- Orun, A. B., Natarajan, K., y Aslan, Z. (2000). A comparative study of meteosat, ecmwf, and radiosonde wind vectors at istanbul. *Remote Sensing of Environment*, 72.
- Quirantes Calvo, J. A. y Gallego Poveda, J. A. (2011). Atlas de nubes y meteoros. *Cantabria Tradicional, sl*, 599.
- Ricciardelli, E., Romano, F., y Cuomo, V. (2008). Physical and statistical approaches for cloud identification using meteosat second generation-spinning enhanced visible and infrared imager data. *Remote Sensing of Environment*, 112.
- Román, R., Antón, M., Cazorla, A., Miguel, A. D., Olmo, F. J., Bilbao, J., y Alados-Arboledas, L. (2012). Calibration of an all-sky camera for obtaining sky radiance at three wavelengths. *Atmospheric Measurement Techniques*, 5.
- Román, R., Cazorla, A., Toledano, C., Olmo, F. J., Cachorro, V. E., de Frutos, A., y Alados-Arboledas, L. (2017a). Cloud cover detection combining high dynamic range sky images and ceilometer measurements. *Atmospheric Research*, 196.

- Román, R., Torres, B., Fuertes, D., Cachorro, V. E., Dubovik, O., Toledano, C., Cazorla, A., Barreto, A., Bosch, J. L., Lapyonok, T., González, R., Goloub, P., Perrone, M. R., Olmo, F. J., de Frutos, A., y Alados-Arboledas, L. (2017b). Remote sensing of lunar aureole with a sky camera: Adding information in the nocturnal retrieval of aerosol properties with grasp code. *Remote Sensing of Environment*, 196.
- Szantai, A., Désalmand, F., y Desbois, M. (2002). A method for the construction of cloud trajectories from series of satellite images. *International Journal of Remote Sensing*, 23.
- Tapakis, R. y Charalambides, A. G. (2013). Equipment and methodologies for cloud detection and classification: A review.
- Taylor, J. R. y Thompson, W. (1998). An introduction to error analysis: The study of uncertainties in physical measurements. *Physics Today*, 51.
- Tohsing, K., Schrempf, M., Riechelmann, S., Schilke, H., y Seckmeyer, G. (2013). Measuring high-resolution sky luminance distributions with a ccd camera. *Applied Optics*, 52.

Apéndice A

Código python

```
import tensorflow.keras
from PIL import Image, ImageOps
import numpy as np
import os
import time
import numpy
# Disable scientific notation for clarity
np.set_printoptions(suppress=True)
# Load the model
modelSol = tensorflow.keras.models.load_model('/content/drive/Modelos_sol/modelo4c.h5',
        compile=False)
modelOctas = tensorflow.keras.models.load_model('/content/drive/Modelos_octas/modelo4c.h5',
        compile=False)
modelFenomeno = tensorflow.keras.models.load_model('/content/drive/Modelos_fenómeno/modelo4c.h5',
        compile=False)
validarFolder = os.listdir('/content/drive/MyDrive/Validar')
result = np.array([[[]]])
start = time.time()
i = 0
for content in validarFolder[1:10]:
    # Create the array of the right shape to feed into the keras model
    # The 'length' or number of images you can put into the array is
    # determined by the first position in the shape tuple, in this case 1.
    data = np.ndarray(shape=(1, 224, 224, 3), dtype=np.float32)
    image = Image.open(os.path.join("/content/drive/MyDrive/Validar", content))
    #resize the image to a 224x224 with the same strategy as in TM2:
    #resizing the image to be at least 224x224 and then cropping from the center
    size = (224, 224)
    image = ImageOps.fit(image, size, Image.ANTIALIAS)
    #turn the image into a numpy array
    image_array = np.asarray(image)
    # Normalize the image
    normalized_image_array = (image_array.astype(np.float32) / 127.0) - 1
    # Load the image into the array
    data[0] = normalized_image_array
    # run the inference
    predictionSol = modelSol.predict(data)
    predictionOctas = modelOctas.predict(data)
    predictionFenomeno = modelFenomeno.predict(data)
```

```
name = np.array([[content]])
row = np.hstack((name, predictionSol, predictionOctas, predictionFenomeno))
if result.size == 0:
    result = row
else:
    result = np.vstack((result, row))
i += 1
print("round " + str(i) + " out of " + str(len(validarFolder)))
end = time.time()
print("Time elapsed: " + str(end - start))
numpy.savetxt("resultadosc4.csv", result, fmt = "%s", delimiter=";")
```

Apéndice B

Código R

```
# Cargamos las librerías
library(tidyverse)
library(caret)
library(tictoc)
library(MLmetrics)
library(colors)
library(ggplot2)
data <- read.csv("/Users/bernardo/Desktop/TFG Fisica/Resultados/resultadosb1.csv",
                header = FALSE, sep = ";")
solNames <- c("obstruido", "despejado")
octasNames <- c(0:8) %>% as.character()
fenomenoNames <- c("aerosoles", "chimenea", "gotas", "halo", "hielo", "polvo", "sucio")
colnames(data) <- c("Nombre", solNames, octasNames, fenomenoNames)
data1 <- data %>% select(Nombre, c(2:3))
data2 <- data %>% select(Nombre, c(4:12))
data3 <- data %>% select(Nombre, c(13:19))
predicted <- list(sol = data1, octas = data2, fenomeno = data3)
rm(data1, data2, data3)
# Esta función asigna la etiqueta con mayor probabilidad
myFun <- function(x){which.max(x)}
# Predicciones modelo Sol Obstruido / Despejado
sol <- data$Nombre %>% as.data.frame()
sol$assigned <- NA
sol$assigned <- apply(predicted$sol[,-1], 1, myFun)
sol$assigned <- solNames[sol$assigned]
colnames(sol)[1] <- "Nombre"
# Predicciones modelo Octas
octas <- data$Nombre %>% as.data.frame()
octas$assigned <- NA
octas$assigned <- apply(predicted$octas[,-1], 1, myFun)
octas$assigned <- octasNames[octas$assigned]
colnames(octas)[1] <- "Nombre"
# Predicciones modelo Fenómeno (multiclase)
fenomeno_multi <- predicted$fenomeno
fenomeno_multi[,-1] <- fenomeno_multi[,-1] > 0.3
# Lectura de las etiquetas "reales"
# Modelo Sol
validarSol <- read.csv("/Users/bernardo/Desktop/TFG Fisica/Etiquetas Validar/validar_sol.csv",
                    header = FALSE, sep = ",")
```

```

colnames(validarSol) <- c("Nombre", "Etiqueta")
sol <- left_join(sol, validarSol) %>% filter(!Etiqueta == "")
sol %>% select(-Nombre) %>% table() %>% confusionMatrix()
rm(validarSol)
# Modelo Octas
validarOctas <- read.csv("/Users/bernardo/Desktop/TFG Fisica/Etiquetas Validar/validar_octas.csv",
                        header = FALSE, sep = ",")
colnames(validarOctas) <- c("Nombre", "Etiqueta")
octas <- left_join(octas, validarOctas) %>% filter(!Etiqueta == "")
octas %>% select(-Nombre) %>% table() %>% confusionMatrix()
rm(validarOctas)
octas$dif <- as.numeric(octas$Etiqueta) - as.numeric(octas$assigned)
mean(octas$dif) #es esperable obtener una media 0
sd(octas$dif) #es esperable obtener una desv tip cercana a 1
sqrt(mean((octas$dif)^2))
ggplot(octas, aes(x = dif)) +
  geom_histogram(aes(y=..density..), binwidth = 1, bins = 9, color = "deepskyblue3",
                 fill = "deepskyblue1", alpha = 0.6 ) +
  stat_function(fun = dnorm, args = list(mean = mean(octas$dif), sd = sd(octas$dif))) +
  geom_vline(aes(xintercept = mean(dif)), color = "deepskyblue4", linetype = "dashed") +
  labs( title = "Histograma de la diferencia de octas",
        subtitle = paste0("Media = ", round(mean(octas$dif), 3),
                          " octas. Desv. típica = ", round(sd(octas$dif), 3), " octas."),
        x = "Octas etiquetadas - Octas predichas",
        y = "Densidad") +
  theme_bw()
ggsave("CompModOctas3.png", path = "/Users/bernardo/Desktop/TFG Fisica/Figuras/Resultados/Octas",
        width = 15.02, height = 8.094, scale = 0.5)
(nrow(filter(octas, dif > 1))/nrow(octas))*100
# Modelo Fenómeno
validarFenomeno <- read.csv("/Users/bernardo/Desktop/TFG Fisica/Etiquetas Validar/validar_fenomeno.csv",
                            header = FALSE, sep = ",",
                            col.names = paste0("V",seq_len(4)), fill = TRUE)
validarFenomeno$Etiqueta <- paste0(
  validarFenomeno$V2, validarFenomeno$V3, validarFenomeno$V4
)
validarFenomeno <- validarFenomeno[-c(2,3,4)]
colnames(validarFenomeno)[1] <- "Nombre"
fenomeno_multi <- left_join(fenomeno_multi, validarFenomeno) %>% filter(!Etiqueta == "")
rm(validarFenomeno)
#Queremos crear una función para evaluar el modelo de fenómenos en cada tipo de etiqueta.
myFun_fenomeno <- function(x){
  tipo <- fenomenoNames[x]
  print(paste0("Fenómeno seleccionado: ", tipo))
# labeled <- str_detect(fenomeno$Etiqueta, tipo)
# predicted <- str_detect(fenomeno$assigned, tipo)
  labeled <- str_detect(fenomeno_multi$Etiqueta, tipo)
  predicted <- fenomeno_multi[x+1]
  cbind(predicted, labeled) %>% as.data.frame()
  %>% table() %>% confusionMatrix(positive = "TRUE")
}
# Por ejemplo, para el halo:
myFun_fenomeno(2)
#Evaluación de los modelos con CROSS ENTROPY
# 1) Nos quedamos con las predicciones de los individuos cuya etiqueta conocemos
predicted$sol <- semi_join(predicted$sol, sol)
predicted$octas <- semi_join(predicted$octas, octas)
predicted$fenomeno <- semi_join(predicted$fenomeno, fenomeno_multi, by = "Nombre")

```

```

# 2) Vamos a crear, para cada individuo un vector con la etiqueta (correcta)
trueLabels <- predicted
# Modelo Sol
trueLabels$sol$obstruido <- "obstruido"
trueLabels$sol$despejado <- "despejado"
trueLabels$sol[,-1] <- trueLabels$sol[,-1] == sol$Etiqueta
# Modelo Octas
for(i in 2:length(colnames(trueLabels$octas))){
  trueLabels$octas[i] <- octasNames[i-1]
}
trueLabels$octas[,-1] <- trueLabels$octas[,-1] == octas$Etiqueta
# Modelo Fenómeno
for(i in 2:length(colnames(trueLabels$fenomeno))){
  trueLabels$fenomeno[i] <- fenomenoNames[i-1]
}
for(i in 1:nrow(trueLabels$fenomeno)){
  for(j in 2:ncol(trueLabels$fenomeno))
    trueLabels$fenomeno[i,j] <- str_detect(fenomeno_multi$Etiqueta[i], trueLabels$fenomeno[i,j])
}
trueLabels$fenomeno[,-1] <- apply(trueLabels$fenomeno[,-1], 2, function(x){as.logical(as.factor(x))})
# 3) Esta función me sirve para cualquier modelo (x = etiqueta, y = predicted)
myFun_logloss <- function(x, y){
  n <- ncol(x)
  save <- rep(0,nrow(x))
  for(i in 2:n){
    vector_logloss <- -x[,i]*log(y[,i])
    if(sum(is.infinite(vector_logloss) > 0)){
      #view(rbind(x[is.infinite(vector_logloss),], y[is.infinite(vector_logloss),]))
      #permite detectar las posibles anomalías
    }
    save <- save + vector_logloss
  }
  mean(save, na.rm = TRUE)
}
# 4) Generamos las evaluaciones (cálculo del error logloss)
myFun_logloss(trueLabels$sol, predicted$sol)
myFun_logloss(trueLabels$octas, predicted$octas)
myFun_logloss(trueLabels$fenomeno, predicted$fenomeno)
# IMP: destacar que el error logloss no está entre 0 y 1, sino que toma
# valores en (0, +infinito)
#Agrupación Octas
octas[,-1] <- octas[,-1] %>% apply(2, as.numeric)
octas$estadoPred <- NA
octas$estadoPred[octas$assigned < 3] <- "Fine"
octas$estadoPred[3 <= octas$assigned & octas$assigned < 6] <- "Party Cloudy"
octas$estadoPred[6 <= octas$assigned & octas$assigned < 8] <- "Cloudy"
octas$estadoPred[octas$assigned == 8] <- "Overcast"
octas$estadoEtiqu <- NA
octas$estadoEtiqu[octas$Etiqueta < 3] <- "Fine"
octas$estadoEtiqu[3 <= octas$Etiqueta & octas$Etiqueta < 6] <- "Party Cloudy"
octas$estadoEtiqu[6 <= octas$Etiqueta & octas$Etiqueta < 8] <- "Cloudy"
octas$estadoEtiqu[octas$Etiqueta == 8] <- "Overcast"
niveles <- c("Fine", "Party Cloudy", "Cloudy", "Overcast")
octas$estadoPred <- octas$estadoPred %>% factor(niveles)
octas$estadoEtiqu <- octas$estadoEtiqu %>% factor(niveles)
octas %>% select(estadoPred, estadoEtiqu) %>% table %>% confusionMatrix()

```