



Universidad de Valladolid



PROGRAMA DE DOCTORADO EN FÍSICA

TESIS DOCTORAL:

APLICACIÓN DE CÁMARAS DE TODO CIELO PARA OBTENER INFORMACIÓN ATMOSFÉRICA Y METEOROLÓGICA

Presentada por Daniel González Fernández para optar al grado de Doctor
por la Universidad de Valladolid

Dirigida por:

Dr. Roberto Román Díez

Dra. Victoria E. Cachorro Revilla

Tutor:

Dr. Roberto Román Díez



Este trabajo ha sido realizado en el
Grupo de Óptica Atmosférica de la Universidad de Valladolid

Compendio de publicaciones

- **Publicación 1**

Referencia: Román, R., González-Fernández, D., Antuña Sánchez, J. C., Herrero del Barrio, C., Herrero-Anta, S., Barreto, A., Cachorro, V. E., Doppler, L., González, R., Ritter, C., Mateos, D., Kouremeti, N., Copes, G., Calle, A., Granados-Muñoz, M. J., Toledano, C., and de Frutos, A. M. (2025). Star photometry with all-sky cameras to retrieve aerosol optical depth at night-time. *Atmospheric Measurement Techniques*. Accepted for publication. Available from: <https://doi.org/10.5194/egusphere-2025-667>

Índice de impacto (JCR): 3.2 (2023), 3.7 (5 años), Categorías:

– Meteorology & Atmospheric Sciences: 45/110 (Q2)

- **Publicación 2**

Referencia: González-Fernández, D., Román, R., Antuña-Sánchez, J. C., Cachorro, V. E., Copes, G., Herrero-Anta, S., Herrero del Barrio, C., Barreto, Á., González, R., Ramos, R., Martín, P, Mateos, D., Toledano, C., Calle, A., de Frutos, Á. (2024). A neural network to retrieve cloud cover from all-sky cameras: A case of study over Antarctica. *Quarterly Journal of the Royal Meteorological Society*, 1–19. Available from: <https://doi.org/10.1002/qj.4834>.

Índice de impacto (JCR): 3.0 (2023), 7.2 (5 años), Categorías:

– Meteorology & Atmospheric Sciences: 48/110 (Q2)

- **Publicación 3**

Referencia: González-Fernández, D., Román, R., Mateos, D., Herrero del Barrio, C., Cachorro, V. E., Copes, G., Sánchez, R., García, R. D., Doppler, L., Herrero-Anta, S., Antuña-Sánchez, J. C., Barreto, Á., González, R., Gatón, J., Calle, A., Toledano, C., and de Frutos, Á. (2024). Retrieval of Solar Shortwave Irradiance from All-Sky Camera Images. *Remote Sensing*, 16(20), 3821. Available from: <https://doi.org/10.3390/rs16203821>.

Índice de impacto (JCR): 4.2 (2023), 4.9 (5 años), Categorías:

– Geosciences, Multidisciplinary: 34/253 (Q1)

A mi familia y amigos.

Agradecimientos

En las siguientes líneas quisiera mostrar mi más sincero agradecimiento a todas las personas e instituciones sin las que esta tesis no habría sido posible.

Para empezar, me gustaría agradecer al Ministerio de Ciencia e Innovación, por el contrato predoctoral que me ha permitido realizar el doctorado, así como a la Universidad de Valladolid y a la Escuela de Doctorado por haber podido desarrollar este trabajo en esta institución.

A mis directores de tesis, el Dr. Roberto Román Díez y la Dra. Victoria E. Cachorro Revilla. A vosotros os doy las gracias por haber sido mis directores y mucho más. Gracias por haberme guiado en este camino y por haberme enseñado tanto. Victoria, eres una gran científica y un ejemplo a seguir, muchas gracias por todo y por esta oportunidad, te admiro mucho. Roberto, a ti quiero dedicarte unas palabras más personales, por todo lo que hemos compartido durante estos cinco años. Ha sido una gran experiencia trabajar contigo en esta tesis, en las prácticas de laboratorio y en todos los congresos a los que hemos ido. Pero también fuera del ambiente laboral guardo buenos momentos contigo. Muchas gracias por todo y por aguantarme (que sé que a veces es difícil), quiero que sepas que te tengo un gran aprecio, eres el mejor.

Extiendo estos agradecimientos a todo el Grupo de Óptica Atmosférica de la Universidad de Valladolid por haberme acogido durante esta etapa tan bonita. Ángel, Carlos, Ramiro y David, junto con mis directores, muchas gracias por todo lo que hacéis por este grupo y por todos sus miembros, sois mucho más que buenos “jefes”. Con vosotros, los estudiantes vamos a hombros de gigantes. También quiero agradecer a Rogelio por todo durante estos años, me alegro mucho de haberte conocido y haber trabajado contigo. Por supuesto, tengo mucho que agradecer a mis compañeros y compañeras de despacho, aunque más bien después de todo este tiempo diría amigos y amigas. Aunque no hemos coincidido todos y todas durante el mismo tiempo, hemos vivido muy buenos momentos juntos y me habéis ayudado y animado mucho en ciertos momentos. Especialmente este último año ha sido uno de los mejores que recuerdo, en gran parte gracias a vosotros y vosotras. Sara, Patri, Celia, José, Javi y Miguel, muchas gracias de corazón, sois geniales y quisiera daros un fuerte abrazo. Ha sido un placer formar parte de este grupo durante el doctorado.

También quiero mostrar mi agradecimiento a Juan Carlos, que no me olvido de ti. Roberto y tú habéis trabajado mucho conmigo y me habéis enseñado un montón de cosas. Nunca se me olvidará cuando empezamos los tres con unas “luces en el cielo” y ahora ese trabajo es parte de esta tesis. Os debo muchísimo

a los dos. Muchas gracias Juan Carlos, has sido un gran compañero y también eres un gran amigo.

Durante esta etapa he realizado algunas estancias, campañas y he asistido a congresos y cursos. En todo esto he conocido a mucha gente muy buena a la que también me gustaría mencionar y agradecer. Especialmente, realicé mi estancia de doctorado de 3 meses en la Universidad de Múnich con Claudia Emde y quisiera agradecerle, a ella y al resto del grupo de Múnich, por acogerme y enseñarme tanto durante ese tiempo.

A nivel personal, quiero mostrar mi agradecimiento a Physics League, que ha formado parte de mi vida durante tantos años. En esta asociación he vivido mucho y he conocido a gente maravillosa a la que quiero darle las gracias. En especial, a mis chiquis, que os quiero mucho.

Jamás podría olvidarme de mi familia. Quiero agradecer a mis padres, Tere y Carmelo, y a mi hermana, Sonia, por todo y porque sin ellos no habría llegado hasta aquí. Por supuesto, también le doy las gracias a toda mi familia que han sido siempre un gran apoyo a lo largo de mi vida. Muchas gracias, porque la familia es lo más importante en esta vida y sin una se haría todo mucho más difícil.

Entre toda la gente que he conocido, he tenido muchos amigos, desde el colegio y el instituto hasta la Universidad, así que muchas gracias a todos vosotros. Entre todos mis amigos, quiero agradecer en especial a los de siempre, que son muchos años ya aguantándonos. Sam, Sergio, Jony, Pablo, Michael y Chuchi, sois los mejores y nunca falláis, muchas gracias.

Por último, también quiero agradecer a ti, a quien estás leyendo esto, por haber tenido la paciencia de llegar hasta aquí, gracias.

Índice general

Resumen	vii
Abstract	ix
Acrónimos	xi
1 Introducción y fundamentos teóricos	1
1.1 La atmósfera terrestre	1
1.1.1 Gases	2
1.1.2 Aerosoles	3
1.1.3 Nubes	4
1.2 Balance Radiativo	7
1.2.1 Radiación solar	7
1.2.2 Forzamiento radiativo	9
1.2.3 Zonas polares	9
1.3 Medida de parámetros atmosféricos	10
1.3.1 Aerosoles	11
1.3.2 Nubes	13
1.3.3 Radiación solar	14
1.4 Objetivos y estructura de la tesis	15
1.4.1 Objetivos	15
1.4.2 Estructura de la tesis	16
2 Instrumentación, datos y estaciones de medida	19
2.1 Instrumentación y datos	19
2.1.1 Cámaras de todo cielo	19
2.1.2 Otros instrumentos	26
2.1.2.1 Fotómetros	27

ÍNDICE GENERAL

2.1.2.2	Observaciones de Cubierta Nubosa	30
2.1.2.3	Piranómetros	31
2.2	Estaciones de medida	33
3	Redes Neuronales	39
3.1	Redes neuronales	39
3.1.1	La Neurona	40
3.1.2	Arquitectura de redes neuronales	43
3.1.3	Entrenamiento de redes neuronales	44
3.2	Redes neuronales convolucionales	46
3.2.1	Capas de convolución	46
3.2.2	Capas de <i>pooling</i>	50
3.2.3	Capas totalmente conectadas	51
3.3	Red neuronal desarrollada	51
4	Resultados	55
4.1	Artículo 1: Star photometry with all-sky cameras to retrieve aerosol optical depth at night-time	55
4.1.1	Resumen y comentarios	55
4.2	Artículo 2: A neural network to retrieve cloud cover from all-sky cameras: a case of study over Antarctic	58
4.2.1	Resumen y comentarios	58
4.3	Artículo 3: Retrieval of solar shortwave Irradiance from all-sky camera images	60
4.3.1	Resumen y comentarios	60
5	Conclusiones y líneas futuras	63
	Bibliografía	67
	Índice de figuras	85
	Índice de tablas	89

Resumen

Las nubes y los aerosoles son dos componentes de la atmósfera que desempeñan un papel crucial en el balance energético del sistema climático al interactuar con la radiación solar y terrestre. La incertidumbre en el efecto neto de estos componentes sobre el clima continúa siendo alta, especialmente en las regiones polares, donde los datos disponibles son escasos pero fundamentales tanto a nivel local como global. Por tanto, es necesario ampliar los estudios de estos componentes y sus propiedades para reducir esta incertidumbre. Esta tesis se centra en tres parámetros atmosféricos: el espesor óptico de aerosoles (AOD del inglés *Aerosol Optical Depth*), la cubierta nubosa (CC del inglés *Cloud Cover*) y la irradiancia solar horizontal (GHI del inglés *Global Horizontal Irradiance*). Como alternativa más económica y versátil para medir los tres parámetros, se propone en esta tesis el uso de cámaras de todo cielo, capaces de capturar imágenes hemisféricas del cielo en muy poco tiempo lo que mejora la cobertura temporal. Las cámaras de todo cielo de este trabajo son parte de la red GOA-SCAN (*GOA all-sky CAmeras Network*) creada por el Grupo de Óptica Atmosférica de la Universidad de Valladolid (GOA-UVa), grupo en el que se ha realizado esta tesis doctoral.

En este contexto, se han desarrollado tres metodologías diferentes para obtener los parámetros atmosféricos mencionados, a través de las imágenes de cámaras de todo cielo. El primer método es capaz de obtener el AOD mediante la medida de la luz obtenida de múltiples estrellas a partir de imágenes nocturnas de cámaras de todo cielo. Los resultados de AOD obtenidos con este método se han comparado con las medidas de referencia tomadas por fotómetros lunares, obteniendo en la mayoría de casos un coeficiente de correlación superior a 0.90. La exactitud de este método (MBE; *Mean Bias Error*) es de aproximadamente 0.02, y la precisión (SD; *Standard Deviation*) se encuentra en un rango de 0.03 y 0.04.

Las metodologías desarrolladas para obtener tanto la CC como la GHI a partir de las imágenes del cielo, se basan en redes neuronales convolucionales (CNN del inglés *Convolutional Neural Networks*). Para el cálculo de la CC se ha diseñado la arquitectura de una CNN y se ha entrenado con un total de 49,016 imágenes diurnas que previamente han sido clasificadas con un etiquetado manual de la CC en tres estaciones distintas. Una vez entrenado este modelo, se ha comparado con observaciones de campo en una estación Antártica que no se ha usado en el entrenamiento. Como resultado de esta comparación se ha obtenido un MBE de -0.30 octas y una SD de 1.40 octas.

Una red neuronal similar se ha entrenado para obtener directamente el factor de modificación de nubes (CMF del inglés *Cloud Modification Factor*). Este factor cuantifica la transmitancia de las nubes a la GHI. Una vez entrenado el modelo se han podido reconstruir los valores de GHI a través de la estimación del CMF con la cámara y la simulación de la GHI bajo cielos sin nubes. Estos valores de GHI se han reconstruido en una estación polar y se ha observado que al comparar estos resultados con las medidas de referencia obtenidas con un piranómetro, el coeficiente de determinación (R^2) es de 0.95, el MBE del 2 % y la SD del 26 %.

Abstract

Clouds and aerosols are two atmospheric components that play a crucial role in the energy balance of the climate system by interacting with solar and terrestrial radiation. Uncertainty in the net effect of these components on climate remains high, especially in polar regions, where available data are scarce but critical both locally and globally. Therefore, expanded studies of these components and their properties are needed to reduce this uncertainty. This thesis focuses on three atmospheric parameters: aerosol optical depth (AOD), cloud cover (CC), and global horizontal irradiance (GHI).

As a more economical and versatile alternative for measuring these three parameters, this thesis proposes the use of all-sky cameras, capable of capturing hemispherical images of the sky in a very short period of time, thus improving temporal coverage. The all-sky cameras in this study are part of the GOA-SCAN (GOA all-sky Cameras Network) network created by the Group of Atmospheric Optics of the University of Valladolid (GOA-UVa), the group in which this doctoral thesis was conducted.

In this context, three different methodologies have been developed to obtain the aforementioned atmospheric parameters using all-sky camera images. The first method is capable of obtaining AOD by measuring the light obtained from multiple stars from nighttime images taken by all-sky cameras. The AOD results obtained with this method have been compared with reference measurements taken by lunar photometers, obtaining in most cases a correlation coefficient greater than 0.90. The accuracy of this method (MBE; Mean Bias Error) is approximately 0.02, and the precision (SD; Standard Deviation) ranges between 0.03 and 0.04.

The methodologies developed to obtain both the CC and GHI from sky images are based on convolutional neural networks (CNN). To calculate the CC, a CNN architecture has been designed and trained with a total of 49,016 daytime images that had been previously classified with manual CC labeling at three different stations. Once this model has been trained, it has been compared with field observations at an Antarctic station not used in training. This comparison results in an MBE of -0.30 oktas and a SD of 1.40 oktas.

A similar neural network has been trained to directly obtain the Cloud Modification Factor (CMF). This factor quantifies the transmittance of clouds to the GHI. Once the model has been trained, the GHI values have been reconstructed by estimating the CMF with the all-sky camera and simulating the GHI under cloudless skies. These GHI values have been reconstructed at a polar station and it has been observed that when comparing these results with reference measurements obtained with a pyranometer, the determination coefficient (R^2) is 0.95, the MBE is 2%, and the SD is 26%.

Acrónimos

- AEMet** Agencia Estatal de Meteorología de España
- AERONET** AErosol RObotic NETwork
- AOD** Espesor óptico de aerosoles (Aerosol Optical Depth)
- AR5** Assesment Report 5
- AR6** Assesment Report 6
- ASC** Centro espacial de Andøya (Andøya Space Center), Andøya, Noruega
- AWI** Alfred-Wegener-Institute: Helmholtz Centre for Polar and Marine Research, Alemania
- AWIPEV** Alfred Wegener Institute for Polar and Marine Research, AWI; y Polar Institute Paul Émile Victor, PEV, Svalvard, Noruega
- BCPS** Señal de píxel con corrección de fondo (Background-Corrected Pixel Signal)
- BRDF** Bi-directional Reflectance Distribution Function
- BSRN** Baseline Surface Radiation Network
- CC** Cubierta de nubes (Cloud Cover)
- CCD** Dispositivos de carga acolplada (Charged Coupled Device)
- CMF** Factor de modificación de nubes (Cloud Modification Factor)
- CMF_{GHI}** Factor de modificación de nubes para irradiancia global horizontal (Cloud Modification Factor for Global Horizontal Irradiance)
- CMIP6** Coupled Model Intercomparison Project Phase 6

ACRÓNIMOS

CMOS	Semiconductor complementario de óxido metálico (Complementary Metal-Oxide-Semiconductor)
CNN	Red neuronal convolucional (Convolutional Neural Network)
CNN-CC	Convolutional Neural Network-Cloud Cover
CNN-CMF	Convolutional Neural Network-Cloud Modification Factor
DC	Cuentas digitales (Digital Counts)
DNA	Dirección Nacional Antártica de Argentina
DNN	Red neuronal profunda (Deep Neural Network)
DU	Unidades Dobson (Dobson Units)
DWD	Servicio Meteorológico de Alemania (Deutscher Wetterdienst)
ERF	Forzamiento radiativo efectivo (Effective Radiative Forcing)
FMI	Instituto Meteorológico de Finlandia (Finnish Meteorological Institute)
FOV	Campo de visión (Field Of View)
GFAT	Grupo de Física de la Atmósfera de la Universidad de Granada (UGR), Granada, España
GHI	Irradiancia global horizontal (Global Horizontal Irradiance)
GHI_{cf}	Irradiancia horizontal global bajo condiciones sin nubes (Global Horizontal Irradiance under cloud-free conditions)
GHI_d	Irradiación global horizontal diaria (Daily Global Horizontal Irradiation)
GHI_{meas}	Irradiancia global horizontal bajo condiciones de nubes (Global Horizontal Irradiance under cloudy conditions)
GOA-SCAN	GOA all-Sky CAmeras Network
GOA-UVa	Grupo de Óptica Atmosférica de la Universidad de Valladolid, Valladolid, España
Gr	Escala de grises (Grayscale)

- GRASP** Generalized Retrieval of Atmosphere and Surface Properties, Lille, Francia
- GRUAN** The Global Climate Observing System (GCOS) Reference Upper-Air Network
- GSFC** Global Space Flight Center, NASA, Estados Unidos
- HDF5** Hierarchical Data Format, o H5
- HDR** Alto rango dinámico (High Dynamic Range)
- IA** Inteligencia Artificial
- IARC** Centro de Investigación Atmosférica de Izaña: Observatorio de Izaña de AEMet (Izaña Atmospheric Research Center: AEMet Observatory of Izaña), Tenerife, España
- IISTA-CEAMA** Instituto Interuniversitario de Investigación del Sistema Tierra - Centro Andaluz de Medio Ambiente, Granada, España
- IPCC** Grupo intergubernamental de expertos sobre el cambio climático (Intergovernmental Panel on Climate Change)
- IPEV** Institut polaire français Paul Émile Victor, Francia
- IR** Infrarrojo (Infrared)
- LOA** Laboratoto de Óptica Atmosférica (Laboratoire d' Optique Atmosphérique) de la Universidad de Lille, Francia
- LW** Onda larga (Longwave)
- MBE** Error de sesgo medio (Mean Bias Error)
- Md** Mediana (Median)
- MODIS** Moderate-Resolution Imaging Spectroradiometer
- MOL-RAO** Meteorologisches Observatorium Lindenberg – Richard-Aßmann-Observatorium: DWD Observatory Lindenberg, Lindenberg (Tauche), Alemania
- mse** Error cuadrático medio (mean square error)
- NASA** National Aeronautics and Space Administration, Estados Unidos
- NILU** Norwegian Institute for Air Research, Noruega

ACRÓNIMOS

NN	Red neuronal (Neural Network)
NST	Transmitancia espectral normalizada (Normalized Spectral Transmittance)
OD	Espesor óptico (Optical Depth)
ODF	Factor del espesor óptico (Optical Depth Factor)
OMI-DOAS	Ozone Monitoring System-Differential Optical Absorption Spectroscopy
PMOD/WRC	Physikalisch-Meteorologisches Observatorium Davos World Radiation Center, Davos, Suiza
QA	Garantía de calidad (Quality Assurance)
ReLU	Unidad lineal rectificada (Rectified Linear Unit)
RGB	Rojo-Verde-Azul (Red-Green-Blue)
RGGB	Rojo-Verde-Verde-Azul (Red-Green-Green-Blue)
RIMO	ROLO Implementation for Moon photometry Observation: open lunar reflectance model developed by GOA and AEMet/IARC
ROD	Espesor óptico de Rayleigh (Rayleigh Optical Depth)
ROLO	Robotic Lunar Observatory: lunar reflectance model of United States Geological Survey (USGS)
RTM	Modelos de transferencia radiativa (Radiative Transfer Models)
SBDART	Santa Barbara DISORT Atmospheric Radiative Transfer
SD	Desviación estándar (Standard Deviation)
SMN	Servicio Meteorológico Nacional de Argentina
SS	Señal de estrellas (Star Signal)
SW	Onda corta (Shortwave)
SZA	Ángulo solar cenital (Solar Zenith Angle)
TF	Filtro tri-banda (Tri-band Filter)
TOC	Total de ozono en columna (Total Ozone Column)

TOD	Espesor óptico total (Total Optical Depth)
TWVC	Total de vapor de agua en columna (Total Water Vapor Column)
UA	Unidad Astronómica
USI	Irradiancia de estrellas sin calibrar (Uncalibrated Star Irradiance)
USI⁰	Irradiancia de estrellas extraterrestre sin calibrar (Uncalibrated extraterrestrial Star Irradiance)
UTC	Tiempo universal coordinado (Coordinated Universal Time)
UV	Ultravioleta (Ultraviolet)
WCRP	World Climate Research Program
WMO	Organización Meteorológica Mundial (World Meteorological Organization)

Introducción y fundamentos teóricos

1.1 La atmósfera terrestre

La atmósfera terrestre es la capa gaseosa que envuelve al planeta Tierra gracias al efecto de la gravedad. La compresibilidad de estos gases y la acción de la gravedad provocan que la mayor parte de la masa de la atmósfera se concentre en las capas más bajas (Antuña-Sánchez, 2022). La atmósfera se suele dividir en cinco capas: troposfera, estratosfera, mesosfera, termosfera y exosfera. Las partes superiores donde se encuentran las zonas de transición entre estas capas se denominan tropopausa, estratopausa, mesopausa y termopausa, respectivamente (Liou, 2002).

La troposfera se extiende desde la superficie terrestre hasta una altura media de unos 12 km, siendo menor en los polos y mayor en el ecuador. Esta capa se caracteriza por un descenso de temperatura con la altura (Liou, 2002). La estratosfera, ubicada entre unos 12 y 50 km sobre la superficie del planeta, se caracteriza por una capa isotérmica desde la tropopausa hasta una cierta altitud que varía según la región del planeta (Dameris, 2015). A partir de dicha capa isotérmica la temperatura se incrementa hasta la estratopausa. De manera similar a la troposfera, las temperaturas de la mesosfera disminuyen con la altura en un rango de unos 50-85 km (Liou, 2002). A partir de esta altitud, extendiéndose hasta unos cientos de kilómetros, se encuentra la termosfera, donde las temperaturas oscilan entre 500 K y 2000 K, dependiendo del nivel de la actividad solar (Liou, 2002). A partir de dicha

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

altitud se encuentra la exosfera que es una zona de tránsito entre el espacio interplanetario y la atmósfera (Antuña-Sánchez, 2022).

La atmósfera realiza una función reguladora sobre el clima y la temperatura a través de varios procesos, y también ejerce una función protectora para las formas de vida existentes en el planeta (Wallace and Hobbs, 2006). Aunque la atmósfera está principalmente compuesta por gases, en ella también se encuentran otros componentes tales como las nubes y los aerosoles, los cuales se describen a lo largo de la siguiente sección.

1.1.1 Gases

La atmósfera está compuesta por una mezcla de gases en distintas proporciones. El nitrógeno y el oxígeno son los constituyentes mayoritarios de la atmósfera terrestre, con una concentración del 78.08 % y 20.95 %, respectivamente (Wallace and Hobbs, 2006). El Argón, cuya concentración es del 0.93 %, está presente en mayor proporción que los otros gases nobles. El vapor de agua, que representa aproximadamente el 0.25 % de la masa de la atmósfera, es un componente muy variable, con concentraciones que van desde alrededor del 0.001 %, en las regiones más frías de la atmósfera terrestre, hasta 5 % en masas de aire caliente y húmedo (Wallace and Hobbs, 2006). Prácticamente todo el vapor de agua, y por tanto las nubes y precipitaciones, se encuentra en la troposfera (Liou, 2002). El ozono también es un gas con una concentración muy variable. El ozono se encuentra principalmente en la estratosfera, en torno a un 90 %, mientras que el 10 % restante se encuentra en la troposfera (Liou, 2002; Román, 2014). También existen otros gases tanto en proporciones variables como estables. Todos estos gases interactúan directamente con la radiación solar principalmente a través de dos fenómenos: la absorción y el *scattering* de Rayleigh, también conocido como dispersión de Rayleigh.

Los gases absorben la radiación con dependencia espectral, de manera que absorben únicamente la radiación en determinadas bandas espectrales y longitudes de onda, en mayor o menor cantidad, que varían según el gas (Román, 2014). El ozono absorbe de forma significativa la radiación solar en el espectro ultravioleta (UV), por lo que desempeña un papel crucial en la protección de la Tierra contra la radiación UV (Chrysanthou and Tourpali, 2024). Algunos de los gases de la atmósfera presentan absorción en bandas correspondientes al infrarrojo (IR), por lo que absorben la radiación térmica emitida por la Tierra y reemiten una parte de esta de nuevo hacia la superficie del planeta calentándola (Wallace and Hobbs, 2006). Estos se conocen como gases de efecto invernadero y entre ellos se encuentran el vapor de agua, el dióxido de carbono y el ozono (Antuña-Sánchez, 2022).

El fenómeno del *scattering* de Rayleigh se produce cuando la longitud de onda de la radiación incidente es mayor que las partículas con la que interactúa, lo que ocurre con la

radiación solar dispersada por las moléculas de los gases de la atmósfera (Liou, 2002). En la dispersión de Rayleigh hay la misma probabilidad de que la radiación dispersada salga tanto en el mismo sentido que la incidente como en el contrario (de La Casiniere and Cachorro, 2008). La sección eficaz del *scattering* de Rayleigh presenta una dependencia espectral que es proporcional al inverso de la cuarta potencia de la longitud de onda, y por tanto, la radiación con menor longitud de onda es más dispersada (de La Casiniere and Cachorro, 2008).

1.1.2 Aerosoles

Los aerosoles atmosféricos se definen como el conjunto de partículas, sólidas o líquidas, que permanecen en suspensión en la atmósfera (Willeke *et al.*, 1993). De esta definición se excluyen las nubes, las cuales se describen en la Sección 1.1.3. Los aerosoles se suelen clasificar según su origen, distinguiendo si son naturales o antropogénicos. Entre los aerosoles naturales encontramos, por ejemplo, polvo de los desiertos, ceniza proveniente de erupciones volcánicas, cristales de sal marina, granos de polen, etc. Entre los de origen antropogénico se pueden distinguir algunos como los generados por la quema de combustibles fósiles, emisiones industriales, o los que se forman a partir de gases precursores conocidos como aerosoles secundarios (González, 2021). Debido a esto, los aerosoles presentan una gran variabilidad temporal y geográfica en sus propiedades químicas, físicas y ópticas, a diferencia de los gases cuya composición es estable y bien conocida en las distintas zonas del planeta (Seinfeld and Pandis, 2016).

También se clasifican los aerosoles según su tamaño, principalmente en dos categorías: fino y grueso. El rango de tamaños de estos varía desde centésimas de micrómetros hasta decenas de micras (González, 2021). De los dos modos mencionados, se clasifican como partículas finas las de un tamaño aproximadamente inferior a $0.5 \mu m$, donde se incluyen los modos de nucleación y acumulación. Las partículas con un tamaño superior a $0.5 \mu m$ abarcan el modo grueso (González, 2021; Toledano, 2005).

Los aerosoles pueden afectar al clima de maneras múltiples y complejas. Estos dispersan y absorben de forma directa la radiación solar modificando el balance radiativo terrestre (Boucher *et al.*, 2013). La dispersión causada por los aerosoles se produce a través del *scattering* de Mie, el cual no es tan dependiente de la longitud de onda como en el caso del *scattering* de Rayleigh en los gases y favorece más la dispersión en el mismo sentido que la radiación incidente (de La Casiniere and Cachorro, 2008). Este fenómeno por parte de los aerosoles generalmente presenta un forzamiento radiativo negativo, enfriando el planeta, mientras que la absorción de la radiación debida a estos presenta el efecto contrario (Boucher *et al.*, 2013). Los aerosoles también tienen un efecto indirecto sobre el clima, a través de su

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

interacción con las nubes. Los aerosoles actúan como núcleos de condensación de agua y de congelación de hielo, lo que hace que puedan alterar las propiedades radiativas de las nubes y su tiempo de vida, afectando también a las precipitaciones (Boucher *et al.*, 2013; Forster *et al.*, 2021).

Como se puede ver en la Figura 1.1a tanto la interacción de los aerosoles con la radiación, como con las nubes, presenta la mayor incertidumbre sobre el forzamiento radiativo efectivo (ERF del inglés *Effective Radiative Forcing*) y la temperatura global en superficie del planeta (Figura 1.1b). En la Figura 1.1c se observa el efecto neto de los aerosoles sobre el ERF. Estos datos han sido recogidos del sexto *Assesment Report (AR6)* del Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC del inglés *Intergovernmental Panel on Climate Change*; IPCC, 2021). Aunque la incertidumbre en los aerosoles en el AR6 se ha reducido con respecto al informe anterior (el AR5; IPCC, 2014), todavía sigue siendo la más alta. Por tanto, el estudio de los aerosoles atmosféricos es fundamental para reducir dicha incertidumbre y poder realizar proyecciones climáticas más precisas.

1.1.3 Nubes

Las nubes se forman cuando el aire húmedo se enfría, lo que permite que el vapor de agua se condense o sublime (Forster *et al.*, 2021). Las nubes se definen como hidrometeoros consistentes en pequeñas gotas de agua líquida o cristales de hielo, o de ambos, suspendidas en la atmósfera y que, por lo general, no tocan el suelo, según la organización meteorológica mundial (WMO del inglés *World Meteorological Organization*) en el Atlas Internacional de Nubes (WMO, 2017). La evolución de una nube está regida por el equilibrio entre una serie de procesos dinámicos, radiativos y microfísicos (Boucher *et al.*, 2013). Las partículas de las nubes, de un tamaño del orden de $10 \mu m$ (Quirantes Calvo and Gallego Poveda, 2011), pueden crecer hasta convertirse en otras más grandes que terminan cayendo por acción de la gravedad. Estas se clasifican como gotas de llovizna (de un tamaño de unos $0.2 mm$), gotas de lluvia (de un tamaño de unos $2 mm$, pudiendo ser de un máximo de $6 mm$), nieve (de un tamaño en el rango de $1-5 mm$) y granizo (de un tamaño de entre $5-50 mm$) (Boucher *et al.*, 2013; Forster *et al.*, 2021; Quirantes Calvo and Gallego Poveda, 2011).

Para que el vapor de agua pase a estado líquido y/o sólido formando nubes, es necesario que la parcela de aire donde se forman esté saturada de vapor, además de que en dicha parcela se encuentren suficientes núcleos de condensación y/o congelación (Quirantes Calvo and Gallego Poveda, 2011). Tomando el aire como la mezcla de gases del aire seco y el vapor de agua, que el vapor cambie de fase va a depender de la cantidad de vapor en la mezcla. La saturación se da cuando la parcela de aire donde ese encuentra el vapor de agua, no admite más cantidad de este gas. La cantidad de vapor que admite el aire depende de la

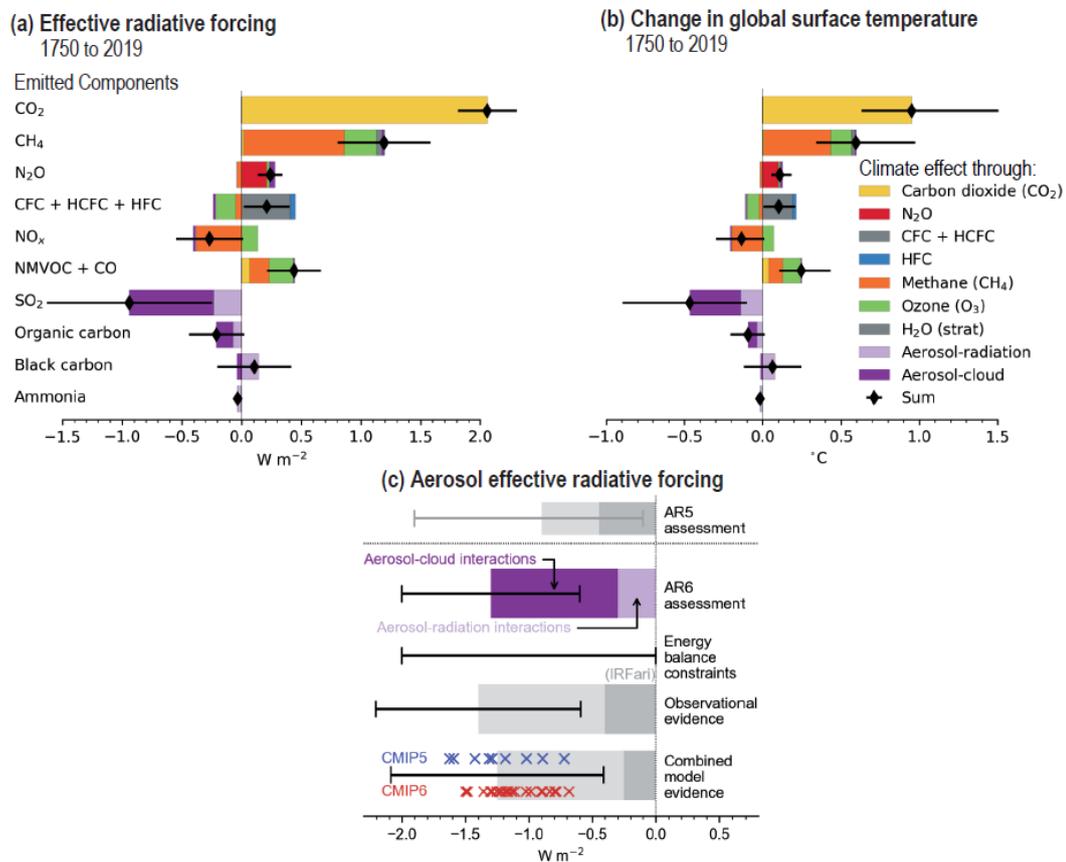


Figura 1.1: Contribución al forzamiento radiativo efectivo (a) y al cambio de la temperatura global en superficie (b) a partir de las emisiones de los componentes para el periodo de 1750-2019 basado en los modelos CMIP6 (*Coupled Model Intercomparison Project Phase 6*). Forzamiento radiativo efectivo neto de los aerosoles para el periodo de 1750-2014 a partir de diferentes líneas de evidencia (c). Figura obtenida del AR6 del IPCC (2021).

temperatura, siendo mayor cuanto mayor es la temperatura del aire. Por tanto, la saturación se consigue por dos vías principales: por enfriamiento del aire y por aumento de la humedad (Quirantes Calvo and Gallego Poveda, 2011). En estos dos grandes apartados se dividen los mecanismos de formación de las nubes, sobre los cuales se puede encontrar información detallada en Quirantes Calvo and Gallego Poveda (2011). Estos mecanismos son:

- **Saturación por enfriamiento:** enfriamiento por ascensos debidos a frentes, la convección, la convergencia de viento y la orografía, y enfriamiento por irradiación.
- **Saturación por aporte de humedad:** mezcla de masas de aire, convergencia de humedad y turbulencias.

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

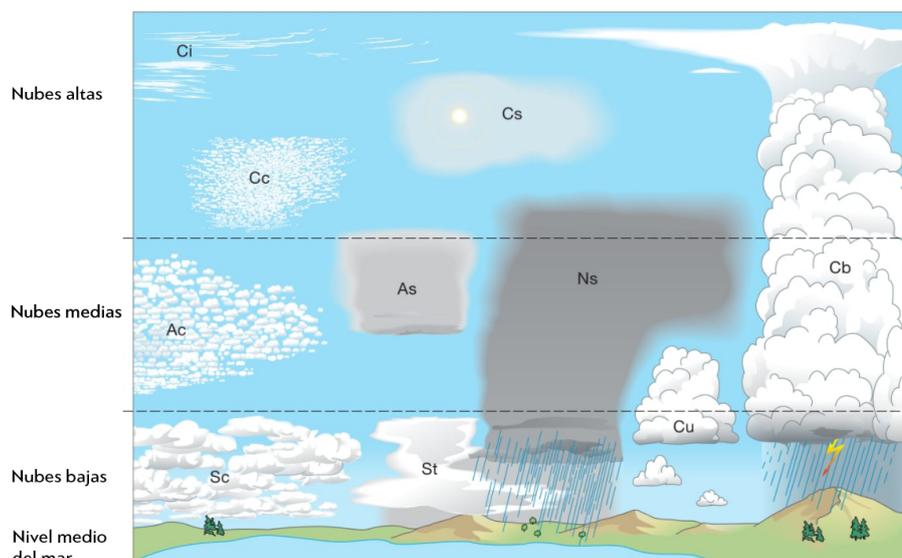


Figura 1.2: Clasificación de los 10 géneros de nubes existentes, los cuales se distribuyen en tres niveles verticales según la altitud. Estos géneros son los siguientes: Stratus (Sc), Stratocumulus (St), Cumulus (Cu), Cumulonimbus (Cb), Altostratus (As), Nimbostratus (Ns), Cirrus (Ci), Cirrocumulus (Cc) y Cirrostratus (Cs). Figura obtenida de WMO (2017).

Por lo general, las nubes se encuentran en un rango de altitudes que abarca desde el nivel del mar hasta la tropopausa. En este sentido, la troposfera se puede dividir verticalmente en tres niveles: alto, medio y bajo. Cada nivel se define por un rango de alturas en las que se observan las nubes de determinado género. Estos niveles se superponen y sus límites varían con la latitud (WMO, 2017). Según esta clasificación, en los tres niveles de altitud descritos, existen diez géneros de nubes, los cuales se muestran en la Figura 1.2. Cabe destacar que entre estos géneros hay nubes que ocupan varios niveles de altitud como es el caso de los Cumulonimbus o Nimbostratus.

El estudio de las nubes y sus propiedades es importante para comprender el cambio climático, ya que estas afectan al clima de diferentes maneras. Las nubes juegan un papel fundamental en el balance de energía del sistema Tierra-atmósfera (Boucher *et al.*, 2013; Forster *et al.*, 2021). Las nubes dispersan la radiación incidente mediante *scattering* de Mie y absorben radiación pero no de manera apreciable en el intervalo solar (Calbó *et al.*, 2005). Las nubes contienen corrientes ascendentes que pueden transportar energía, humedad, momento, gases traza y partículas de aerosol con el aire desde cerca de la superficie hasta grandes alturas (Boucher *et al.*, 2013). La precipitación que llega a la superficie del planeta muestra un efecto neto de calentamiento del aire, a pesar de que parte del agua condensada se vuelve a evaporar (Boucher *et al.*, 2013). Además, las nubes a baja altitud tienden a reflejar la energía solar entrante de vuelta al espacio, creando un efecto de enfriamiento al evitar que esta ener-

gía llegue y caliente la Tierra (Forster *et al.*, 2021). Por otro lado, las nubes más altas tienden a absorber y reemitir de vuelta a la Tierra parte de la energía que sale del planeta, lo que produce un efecto de calentamiento (Forster *et al.*, 2021). En promedio, las nubes reflejan más energía entrante que la cantidad de energía saliente que absorben, lo que resulta en un efecto de enfriamiento neto general sobre el clima actual (Forster *et al.*, 2021).

Las nubes han sido objeto de estudio desde hace mucho tiempo, y aunque existen numerosos trabajos dedicados a determinar la influencia de estas en el clima, este tema sigue representando una gran incertidumbre para los modelos climáticos y las predicciones meteorológicas (Crnivec and Mayer, 2019). Desde el AR5 del IPCC (IPCC, 2014), la comprensión de los procesos que involucran las nubes ha avanzado gracias a mejores observaciones, nuevos enfoques de análisis y una simulación numérica explícita de alta resolución de las nubes. Además, los modelos climáticos globales actuales simulan el comportamiento de las nubes mejor que los modelos anteriores, debido tanto a los avances en las capacidades computacionales como a la comprensión de los procesos (Forster *et al.*, 2021).

1.2 Balance Radiativo

1.2.1 Radiación solar

El Sol es la estrella más cercana a la Tierra y la energía que radía es la principal fuente de energía que influencia el clima del planeta (Iqbal, 1983). El Sol se comporta como un cuerpo negro con una temperatura media de 5790 K en su superficie, cuyo espectro de radiación sigue la ley de Planck (de La Casiniere and Cachorro, 2008; Liou, 2002). La irradiancia (I) se define como la potencia radiativa por unidad de superficie, siendo la que llega desde el Sol a la Tierra dependiente de la longitud de onda. La irradiancia solar extraterrestre espectral (I_0) corresponde a la irradiancia solar que llega al exterior de la atmósfera (ver Figura 1.3). Integrando la irradiancia a todo el espectro solar se obtiene la irradiancia solar total de onda corta (SW del inglés *Shortwave*). La integral de I_0 , para una distancia media Tierra-Sol de 1 UA (Unidad Astronómica), corresponde con la irradiancia SW solar extraterrestre, conocida como constante solar, y cuyo valor es de 1367 W m^{-2} (de La Casiniere and Cachorro, 2008).

La irradiancia solar extraterrestre cruza la atmósfera hasta la superficie del planeta. Una parte de esta radiación atravesará la atmósfera sin interactuar con ninguno de sus componentes, llegando en la dirección que apunta al Sol; lo que se conoce como irradiancia directa. El resto de radiación interacciona con los componentes de la atmósfera a través de los procesos anteriormente descritos de absorción y *scattering* por parte de las moléculas de los gases, los aerosoles y las nubes, por lo que la irradiancia solar es parcialmente atenuada (de La Casiniere and Cachorro, 2008; Liou, 2002). La Figura 1.3 muestra el espectro solar extraterrestre

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

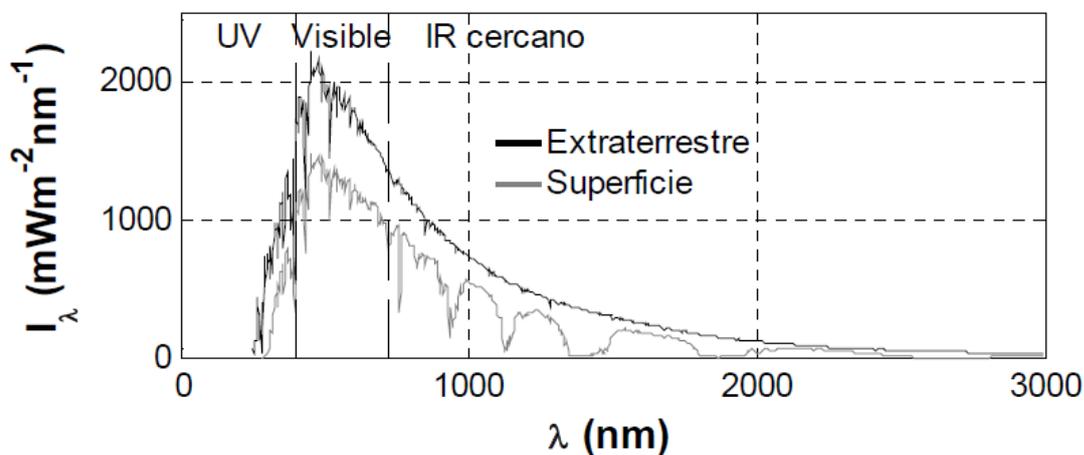


Figura 1.3: Irradiancia solar extraterrestre (negro) correspondiente a Kurucz (1992) e irradiancia solar horizontal en la superficie de la Tierra (gris), ambas en función de la longitud de onda (λ). La irradiancia en superficie corresponde a la simulación de un modelo de transferencia radiativa con valores por defecto y una altura solar de 60° . Figura obtenida de Román (2014).

(negro) y en superficie (gris) en función de la longitud de onda. En esta Figura se pueden ver, por ejemplo, bandas de absorción correspondientes a distintos gases de la atmósfera, como en el rango UV donde se observa la absorción por parte del ozono entre 200-300 nm, o alrededor de 1100 nm y 1400 nm donde se ven bandas de absorción correspondientes al vapor de agua. Estas bandas de absorción atenúan parte de la irradiancia en superficie para esas longitudes de onda. La irradiancia que interacciona con la atmósfera mediante procesos de *scattering*, como resultado, es redirigida en otras direcciones, pudiendo dirigirse de vuelta hacia el espacio o hacia la superficie terrestre en otra dirección (de La Casiniere and Cachorro, 2008). Esta radiación, conocida como difusa, puede volver a interactuar con la atmósfera mediante los mismos procesos. Cuando vuelve a producirse *scattering* esto se conoce como *scattering* múltiple, siendo el grado el número de veces que se ha producido la dispersión (de La Casiniere and Cachorro, 2008).

Se conoce como irradiancia horizontal global (GHI del inglés *Global Horizontal Irradiance*) a la irradiancia SW que llega a la superficie de la Tierra sobre un plano horizontal a nivel de suelo. La GHI es modulada a través de la posición relativa entre el Sol y el observador, siendo el factor principal el ángulo solar cenital (SZA del inglés *Solar Zenith Angle*). Esta radiación es absorbida o reflejada por la superficie terrestre, siendo la absorbida reemitida hacia la atmósfera (Liou, 2002).

1.2.2 Forzamiento radiativo

La Tierra, que también se comporta como un cuerpo negro a una temperatura determinada, emite un espectro de radiación en el rango del infrarrojo térmico $4\text{--}40\ \mu\text{m}$, en la región denominada de onda larga (LW del inglés *Longwave*; Liou, 2002).

El balance radiativo correspondiente a la diferencia entre las irradiancias netas de onda corta emitida por el Sol y de onda larga emitida por la Tierra (ver Figura 1.4), determina la temperatura del planeta y su atmósfera, ya que el equilibrio de este balance es fundamental en el sistema climático. Por lo tanto, la radiación entrante debe equilibrarse con la radiación saliente para lograr este equilibrio (Iqbal, 1983; Liou, 2002).

Cualquier factor que perturbe el equilibrio del balance radiativo, y por tanto altere el clima, se conoce como agente de forzamiento radiativo (Shine *et al.*, 1990). El forzamiento radiativo es una medida de cómo se ve influenciado el balance energético del sistema Tierra-atmósfera cuando se alteran los factores que afectan al clima (Solomon *et al.*, 2007). Este forzamiento es positivo cuando se produce un calentamiento del sistema climático, como es el caso del aumento de gases de efecto invernadero, y negativo cuando hay un enfriamiento del sistema, como en el caso de algunos aerosoles o tipos de nube (Carslaw, 2022). Este parámetro permite comparar de forma simple la respuesta del cambio climático a diversos factores, especialmente en términos de la temperatura media global (Herrero-Anta, 2021).

1.2.3 Zonas polares

La monitorización de la atmósfera en las regiones polares es crucial, ya que es bien sabido que estas áreas desempeñan un papel fundamental en el balance energético global mediante el mantenimiento de los gradientes de temperatura Norte-Sur que impulsan las circulaciones oceánicas y atmosféricas de la Tierra (Stone *et al.*, 1996). Estas áreas son muy sensibles a los cambios en el forzamiento radiativo, a la vez que presentan una gran variabilidad interna (Goosse *et al.*, 2018). En las últimas décadas se ha registrado en las regiones polares del norte un calentamiento de más del doble del promedio global. En cambio, las zonas polares del sur han experimentado un calentamiento más lento o incluso un enfriamiento en algunas áreas (ver Goosse *et al.*, 2018, y las referencias citadas en este).

Los aerosoles juegan un papel crítico en el clima de las regiones polares ya que pueden tener una influencia significativa debido a las condiciones atmosféricas y en superficie únicas de estas zonas (Law and Stohl, 2007). En estas regiones, la alta reflectividad del hielo y la nieve amplifica el impacto de los aerosoles en el balance radiativo, y la deposición de partículas que absorben la luz, como el hollín, puede acelerar el derretimiento del hielo y la nieve (Bond *et al.*, 2013; Hansen and Nazarenko, 2004). También se ha mostrado que las

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

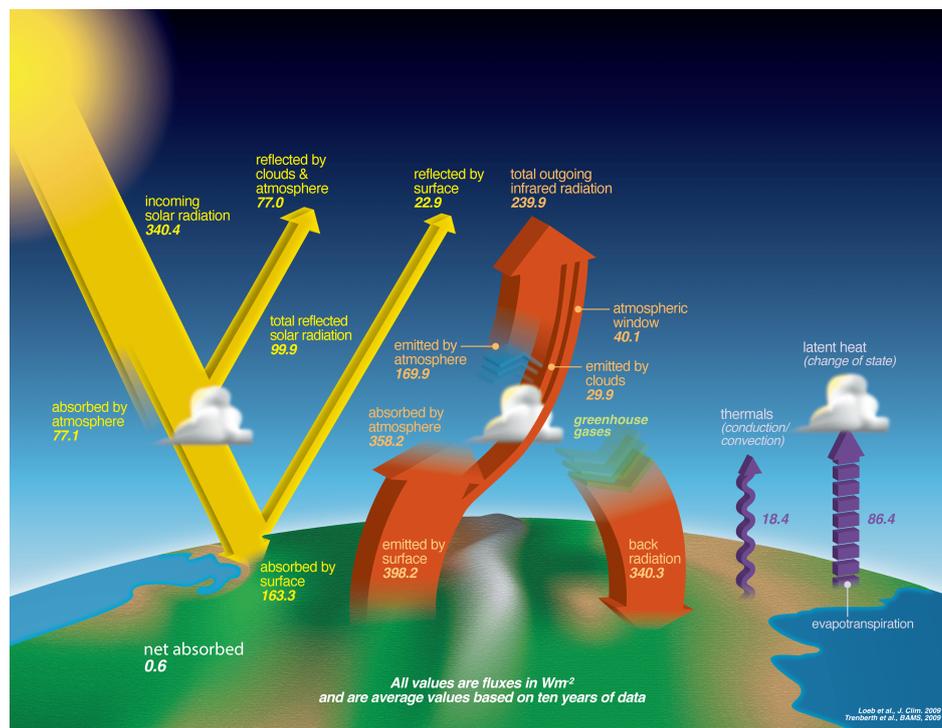


Figura 1.4: Balance radiativo de la Tierra. Figura obtenida de [<https://my.nasadata.larc.nasa.gov/basic-page/earths-energy-budget>].

nubes en estas regiones juegan un papel importante en el sistema climático, especialmente en la Antártida, tanto de manera directa en el clima de las latitudes del sur como a nivel global de manera indirecta (Lachlan-Cope, 2010, y las referencias citadas en este). El avance del conocimiento científico en estas regiones es particularmente difícil debido a la complejidad de los procesos subyacentes de cambios en sus climas (Goosse *et al.*, 2018), destacando la necesidad de realizar más investigaciones sobre este tema.

1.3 Medida de parámetros atmosféricos

La interacción de los aerosoles y las nubes con la radiación, así como su influencia en el clima, están relacionadas con sus propiedades, por lo que es necesario estudiarlas para tener una mejor comprensión de su impacto en el sistema climático. Esta tesis se centra en la medida de diferentes parámetros que pertinen estudiar determinadas propiedades de aerosoles y nubes, así como la radiación solar, los cuales son el espesor óptico de aerosoles (AOD del inglés *Aerosol Optical Depth*), la cubierta de nubes (CC del inglés *Cloud Cover*) y la GHI. A lo largo de esta sección se describen estos parámetros y el proceso de medida de los mismos.

1.3.1 Aerosoles

La atenuación de la irradiancia directa extraterrestre al llegar a la superficie de la Tierra, para una longitud de onda λ y suponiendo una atmósfera plano-paralela de una sola capa, se puede expresar mediante la ley de *Beer-Bouguer-Lambert* (Toledano, 2005):

$$I(\lambda) = I_0(\lambda) \cdot e^{-\tau(\lambda)m}, \quad (1.1)$$

donde $I(\lambda)$ es la irradiancia directa que llega a la superficie terrestre a la longitud de onda λ , $I_0(\lambda)$ es la irradiancia extraterrestre a la longitud de onda λ , $\tau(\lambda)$ es el espesor óptico total (TOD del inglés *Total Optical Depth*) de la atmósfera a la longitud de onda λ en toda la columna y m la masa óptica. La masa óptica se define como la razón entre el espesor óptico en la vertical y en la dirección del Sol con respecto al observador (Toledano, 2005). Por tanto, la masa óptica está relacionada con el SZA y se puede aproximar como la secante de este ángulo, al menos hasta unos 60° (Toledano, 2005). Existen otras relaciones más aproximadas para calcular la masa óptica, como la fórmula empírica de Kasten and Young (1989).

El TOD, que está relacionado con la extinción de la luz al atravesar la atmósfera, se descompone en la suma del espesor óptico de los distintos componentes de la atmósfera teniendo en cuenta la absorción y el *scattering*, siendo la extinción la suma de ambos (Antuña-Sánchez, 2022). Por tanto, para una longitud de onda dada, se tiene que:

$$\tau(\lambda) = \tau_g(\lambda) + \tau_R(\lambda) + \tau_n(\lambda) + \tau_a(\lambda), \quad (1.2)$$

donde τ_g y τ_R son los espesores ópticos correspondientes a la absorción y *scattering* (dispersión de Rayleigh) de los gases, respectivamente, τ_n es el espesor óptico de las nubes y τ_a el AOD, el cual está relacionado con la extinción (absorción y *scattering*) de la luz causada por los aerosoles.

El AOD es una de las propiedades más importantes de los aerosoles y sirve como un indicador de la cantidad de partículas presentes en la atmósfera, cuya variación espectral se cuantifica mediante la ley empírica de Ångström a través de la ecuación 1.3 (Ångström, 1930, 1961):

$$\tau_a(\lambda) = \beta \cdot \lambda^{-\alpha}, \quad (1.3)$$

donde $\tau_a(\lambda)$ es el AOD, λ la longitud de onda expresada en micras, β es el parámetro de turbiedad de Ångström (corresponde al AOD cuando $\lambda = 1\mu m$) y α es el exponente de Ångström (AE del inglés *Ångström Exponent*). El AE da información sobre el tamaño de las partículas de aerosol, con valores típicos entre 0 y 2.5, siendo las partículas más gruesas cuanto menor es el valor de α (González, 2021; Herrero-Anta, 2021).

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

Conociendo la irradiancia directa extraterrestre y midiendo la irradiancia directa que llega a la superficie, la cual se suele medir con fotómetros que miden apuntando directamente al Sol, se pueden calcular los valores de AOD mediante la ecuación 1.1. Para esto hay que tener en cuenta que el TOD y el AOD se relacionan mediante la ecuación 1.2, si el fotómetro está propiamente calibrado y se mida sin presencia de nubes, ya que las concentraciones de gases son bastante constantes y se puede conocer el espesor óptico de estos a cada longitud de onda. Uno de los métodos más empleados para calibrar fotómetros para obtener valores de AOD es la técnica conocida como Langley (o Langley-plot; Shaw, 1983). Este método implica medir la irradiancia solar a distintos valores de SZA, y por tanto de masa óptica, con una variación lo suficientemente rápida como para asumir que la irradiancia extraterrestre y el TOD permanecen constantes (Toledano *et al.*, 2018). Entonces, en la ecuación 1.2 los valores de I_0 y τ se mantienen constantes y, por tanto, tomando logaritmos queda la ecuación de una recta expresada según la ecuación 1.4:

$$\ln[I(\lambda)] = \ln[I_0(\lambda)] - \tau(\lambda) \cdot m, \quad (1.4)$$

donde $\tau(\lambda)$ representa la pendiente y el logaritmo de $I_0(\lambda)$ la ordenada en el origen. Realizando un ajuste por mínimos cuadrados se obtienen estos valores y se puede despejar el valor de $I_0(\lambda)$, el cual representa la constante de calibración del instrumento. Es importante destacar que esta calibración puede hacerse sin conocer los valores de I en unidades físicas (Wm^{-2}) si no que se puede poner directamente I en la señal que proporciona el fotómetro (cuentas digitales o voltaje). El ajuste proporcionará un valor de I_0 en las mismas unidades y que será efectivo para poder estimar el valor del TOD, y por tanto el AOD, sin necesidad de conocer el valor de I en Wm^{-2} .

Mediante este método y las medidas de irradiancia solar directa, se puede obtener el AOD durante el día. Sin embargo, es necesario medir el AOD también durante la noche, entre otras cosas para completar los estudios de los ciclos de aerosol (Herrero del Barrio *et al.*, 2023; Perrone *et al.*, 2022) y para el estudio de la interacción de los aerosoles con la radiación LW, especialmente en las regiones polares, en las cuales los periodos nocturnos duran meses de manera consecutiva durante la conocida noche polar. Para solventar esto, existen modelos de fotómetros capaces de medir la irradiancia lunar directa desde el cuarto creciente hasta el cuarto menguante lunar (Barreto *et al.*, 2013, 2016; Berkoff *et al.*, 2011). El mayor reto de estas mediciones es que la irradiancia lunar extraterrestre cambia de manera significativa, incluso en una sola noche, haciendo que el método de Langley no sea suficiente. Por tanto, es necesario conocer el valor de la irradiancia lunar extraterrestre en cada momento. Para ello, modelos como ROLO (*RObotic Lunar Observatory*; Kieffer and Stone, 2005) o RIMO (*ROLO Implementation for Moon's Observation*; Barreto *et al.*, 2019), se han empleado para

estimar la irradiancia lunar extraterrestre directa. Estos modelos inicialmente no proporcionaban valores de AOD con exactitud (Barreto *et al.*, 2017), pero esto se resolvió aplicando correcciones a estos modelos (González *et al.*, 2020; Román *et al.*, 2020; Uchiyama *et al.*, 2019). La fotometría lunar rellena el hueco de medidas de AOD nocturno parcialmente, ya que durante la mitad del ciclo lunar la Luna no es visible.

Otra técnica utilizada para medir el AOD en periodo nocturno y completar las series temporales es la fotometría estelar, la cual se basa en realizar medidas de la irradiancia que llegue a la Tierra procedente de distintas estrellas (Baibakov *et al.*, 2015; Ivănescu *et al.*, 2021; Pérez-Ramírez *et al.*, 2008). Para realizar estas medidas de la forma más precisa posible, los fotómetros estelares emplean un telescopio que capta la mayor cantidad de luz evitando introducir luz parásita de otras fuentes. Estos fotómetros permiten obtener el valor del AOD mediante la ley de *Beer-Bouguer-Lambert* de forma similar a los fotómetros solares, siendo calibrados por el método de Langley. También existen otros métodos, como el de las dos estrellas (Leiterer *et al.*, 1995; Pérez-Ramírez *et al.*, 2008), al disponer de varias fuentes de luz a la vez. Si bien las medidas con fotómetros estelares se utilizan para estudiar el AOD nocturno (p. ej., Graßl *et al.*, 2024), la disponibilidad de fotómetros estelares es extremadamente limitada debido, entre otras razones, a su alto coste y a que no están completamente automatizados. Actualmente, se estima que solo hay unos cinco fotómetros estelares en funcionamiento en todo el mundo para la monitorización de aerosoles (Barreto *et al.*, 2019; Román *et al.*, 2020).

1.3.2 Nubes

Entre las propiedades de las nubes cabe destacar la cobertura nubosa. La CC es un importante indicador del estado del tiempo que representa la fracción del cielo cubierta por todas las nubes visibles (WMO, 2017). Se suele medir en octas, es decir, en octavos de cielo. Para ello se divide el cielo en 8 partes y se indica cuantos octavos de este están cubiertos por nubes, siendo 0 octas un cielo completamente despejado y 8 octas totalmente cubierto. Por lo general, las nubes ocupan alrededor de dos tercios de la superficie del planeta (Forster *et al.*, 2021), aunque su distribución varía en las diferentes regiones según la latitud (Warren *et al.*, 2015). En las regiones polares, desde los 60°N y 60°S hasta el polo correspondiente, la cobertura de nubes abarca un rango del 60-90%. En latitudes entre los 30°N y los 30°S la cobertura es de aproximadamente el 30%. Entorno al ecuador la cubierta de nubes oscila entre el 50-80% (Warren *et al.*, 2015).

La CC puede medirse mediante observaciones manuales por parte observadores meteorológicos, así como empleando diversa instrumentación. Entre los instrumentos se puede distinguir entre los equipos en superficie y a bordo de satélites (Tapakis and Charalambides,

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

2013). Los equipos terrestres se utilizan principalmente para medir datos de una ubicación específica, ya que tienen un campo de visión reducido, lo que limita la capacidad de monitorizar la formación de nubes y su movimiento en una amplia área del cielo. Sin embargo, dado que el estado del cielo se mide de manera local, pueden proporcionar medidas con una resolución temporal muy alta (Tapakis and Charalambides, 2013).

Entre los equipos de superficie se encuentran los de teledetección activa, tales como el lidar y el ceilómetro, que emplean un pulso láser emitido hacia la atmósfera en la vertical para medir la señal dispersada en la misma dirección y sentido contrario. Con la señal medida, se estiman tanto la CC como la altura de la base de las nubes (Costa-Surós *et al.*, 2013; Martucci *et al.*, 2010; Poyer, 2008). Entre este tipo de instrumentos también se utilizan radares de nubes, que normalmente emiten señales de microondas a la atmósfera y miden la señal reflejada de vuelta para detectar posición y velocidad de las nubes, e incluso el tipo de precipitación (Clothiaux *et al.*, 1995; Kollias *et al.*, 2007). Otro tipo de instrumentos terrestres para medir propiedades de las nubes son los radiómetros (Tapakis and Charalambides, 2013), tales como los piranómetros o fotómetros que permiten estimar la CC y otras características mediante la atenuación de la radiación solar debida a su interacción con las nubes (Mateos *et al.*, 2014; Orsini *et al.*, 2002; Vasaras *et al.*, 2001).

Por otro lado, los instrumentos a bordo de satélites (Arking and Childs, 1985; Ricciardelli *et al.*, 2008; Rossow and Schiffer, 1999; Zhao and Di Girolamo, 2006) proporcionan información a gran escala sobre las nubes, ofreciendo mayor cobertura espacial, y mediciones multiespectrales desde diferentes sensores, pero los datos proporcionados tienen baja resolución temporal en comparación con los instrumentos en superficie. El costo del equipo es un factor importante para las mediciones de nubes, ya que el uso de satélites es mucho más costoso que la mayoría de los instrumentos terrestres (ver Tapakis and Charalambides, 2013, y las referencias citadas en este).

1.3.3 Radiación solar

En la Guía de Instrumentos y Métodos de Observación Meteorológicos de la WMO (WMO, 1996) se recoge la información más completa en cuanto a instrumentos radiométricos y las magnitudes correspondientes. Esta guía recoge información muy útil sobre las medidas de radiación solar, así como del funcionamiento y diseño de redes y estaciones radiométricas. Además, ofrece una descripción de los principios científicos en los que se basan dichas mediciones, e indicaciones sobre el control de calidad, que es un elemento fundamental en las medidas de radiación. Los radiómetros meteorológicos pueden clasificarse según varios criterios, tales como el tipo de variable que se pretende medir, el campo de visión, la respuesta espectral del instrumento, el empleo principal al que se destina, etc. (García, 2011).

Este trabajo se va a centrar en los piranómetros, que son los instrumentos principales para medir la GHI, y también pueden emplearse para medir la radiación solar sobre superficies inclinadas con respecto a la horizontal, o para medir la radiación global reflejada si se sitúan en posición invertida (García, 2011; Kipp&Zonen, 2004a).

Cabe destacar que en lugares donde hay una falta de datos disponibles, las series de datos de GHI suelen reconstruirse a partir de modelos. Los modelos de transferencia radiativa (RTM del inglés *Radiative Transfer Models*) se utilizan con frecuencia para estimar la GHI en condiciones sin nubes, una estimación que también se puede obtener utilizando otros tipos de modelos empíricos (Antón Martínez, 2007). Para estas condiciones sin nubes, los resultados obtenidos por los RTM son generalmente muy precisos. Sin embargo, aparecen dificultades cuando se consideran los efectos de las nubes. Una forma de tener en cuenta los efectos de las nubes es utilizando el factor de modificación de nubes (CMF del inglés *Cloud Modification Factor*), que cuantifica la transmitancia de las nubes como el cociente de la GHI que llega a la superficie entre la GHI simulada sin nubes (Calbó *et al.*, 2005). La GHI se puede estimar con precisión como el producto del CMF y la GHI simulada sin nubes. Algunos trabajos han utilizado medidas auxiliares, como por ejemplo la duración de la luz solar medida por pirheliómetros, como un indicador de nubes para calcular el CMF y reconstruir series de GHI a largo plazo (Román *et al.*, 2014). Gracias a estas series a largo plazo de GHI medidas y reconstruidas, se ha demostrado que en el siglo XX se produjeron fenómenos globales, como los *global dimming and brightening* (Antón *et al.*, 2017; Stanhill and Cohen, 2001; Sánchez-Lorenzo *et al.*, 2009; Wild, 2009, 2012; Wild *et al.*, 2005, 2009).

1.4 Objetivos y estructura de la tesis

1.4.1 Objetivos

Debido a la importancia del estudio de los aerosoles y las nubes, así como de la monitorización de la irradiancia solar, es fundamental disponer de medidas de AOD, CC y GHI en el mayor número de localidades posibles, y especialmente en regiones polares. Sin embargo, esto no es posible en muchas ocasiones debido a la necesidad de varios instrumentos, algunos de ellos suponiendo un costo demasiado elevado, como pueden ser los fotómetros estelares. Ante esta necesidad aparece como alternativa un instrumento más asequible y versátil: las cámaras de todo cielo, o simplemente cámaras de cielo. Estas cámaras son capaces de capturar imágenes de toda la bóveda celeste tanto de día como de noche.

Las cámaras de todo cielo han demostrado ser dispositivos bastante útiles para el estudio de la atmósfera (Antuña-Sánchez, 2022). De hecho, ya se ha demostrado que con cámaras de todo cielo se puede estimar: el AOD durante el día (Cazorla *et al.*, 2008; Román *et al.*,

1. INTRODUCCIÓN Y FUNDAMENTOS TEÓRICOS

2022; Scarlatti *et al.*, 2023); y la CC mediante distintas técnicas (Calbó and Sabburg, 2008; Kazantzidis *et al.*, 2012; Kreuter *et al.*, 2009; Silva and Souza-Echer, 2016), aunque suelen presentar limitaciones, especialmente con nubes finas o alta presencia de aerosoles como el polvo del desierto (Cazorla *et al.*, 2008; Huo and Lu, 2009; Román *et al.*, 2017).

En este marco, el objetivo principal de esta tesis es desarrollar nuevas metodologías para poder determinar el AOD nocturno, la CC y la GHI a través de las imágenes de cámaras todo cielo, ya que este instrumento al ser una alternativa más económica, permitirá extender la cobertura espacial de la medida de estas magnitudes. Para llevar a cabo este objetivo general, se proponen los siguientes objetivos específicos:

- Desarrollar un método para extraer la señal correspondiente a la irradiancia de las estrellas en los píxeles de imágenes del cielo y, a través de esos valores, obtener los valores de AOD nocturnos mediante la calibración Langley.
- Validar y cuantificar las incertidumbres de los valores de AOD obtenidos con las cámaras comparándolos con los valores obtenidos de forma independiente y alternativa con fotómetros lunares en distintas localidades.
- Desarrollar y entrenar un modelo basado en una red neuronal convolucional para identificar de forma automática y precisa la CC mediante imágenes de cámaras de todo cielo.
- Estudiar la bondad del modelo propuesto para obtener los valores de CC comparándolos con medidas de campo obtenidas por observadores meteorológicos en una estación Antártica no utilizada en el entrenamiento.
- Generar y entrenar una red neuronal capaz de estimar el CMF a partir de imágenes capturadas por cámaras de todo cielo.
- Reconstruir los valores de GHI a través de los valores de CMF proporcionados por el modelo desarrollado, y compararlos con medidas independientes obtenidas con piranómetros para cuantificar las incertidumbres del método propuesto.

1.4.2 Estructura de la tesis

Esta tesis se divide en 5 capítulos. El Capítulo 1 presenta una introducción de los fundamentos teóricos necesarios para el presente trabajo. En este Capítulo 1, se muestran los objetivos de esta tesis doctoral. En el Capítulo 2 se describen los instrumentos y datos utilizados a lo largo del trabajo, así como las estaciones de medida empleadas para realizar las medidas.

El Capítulo 3 se dedica a una descripción de las redes neuronales que han sido empleadas en gran parte del trabajo. Para finalizar este capítulo se detalla el modelo de red neuronal utilizado.

Los resultados de esta tesis se presentan en el Capítulo 4, en el cual se muestran los tres artículos que componen el trabajo de esta tesis. El primer artículo presenta un nuevo método para obtener los valores de AOD en periodo nocturno a partir de la señal extraída en imágenes del cielo para diferentes estrellas (Román *et al.*, 2025). La segunda publicación presenta un modelo de inteligencia artificial, basado en una red neuronal convolucional, que permite obtener los valores de la cubierta nubosa a partir de las imágenes de las cámaras de todo cielo (González-Fernández *et al.*, 2024a). Finalmente, en el tercer artículo se presenta otro modelo, basado en una red neuronal convolucional para estimar el CMF a partir de las imágenes de todo cielo (González-Fernández *et al.*, 2024b). Este esquema presenta de manera ordenada los artículos que componen el trabajo, siguiendo un hilo argumental coherente con los objetivos de la Sección 1.4.1. Finalmente, en el Capítulo 5 se presentan las conclusiones y líneas futuras de esta tesis doctoral.

Instrumentación, datos y estaciones de medida

2.1 Instrumentación y datos

En la Sección 1.3 se describen distintos parámetros atmosféricos, así como diferentes técnicas para medirlos. En concreto se centra en la medida de determinados parámetros que juegan un papel importante en el estudio de aerosoles, nubes y radiación solar. Por tanto, esta sección se dedica a una descripción detallada de la instrumentación y técnicas utilizadas.

Esta Sección 2.1 consta de dos partes. La primera está dedicada a las cámaras de todo cielo, que constituyen el principal instrumento que se ha empleado a lo largo de todo el trabajo desarrollado. La segunda parte se dedica al resto de instrumentos y técnicas de referencia utilizadas en función del objeto de estudio.

2.1.1 Cámaras de todo cielo

Las cámaras de todo cielo son instrumentos que capturan imágenes hemisféricas de toda la bóveda celeste en la región en la que se encuentran. Estas cámaras llevan utilizándose desde finales del siglo XIX (Fassig, 1896; Süring, 1922). Estas cámaras han evolucionado desde los modelos que tomaban imágenes en películas fotográficas hasta los sensores digitales empleados hoy en día. En la era digital se introdujeron notables mejoras en el diseño de las cámaras de todo cielo, la captura de imágenes y el almacenamiento de datos, comenzando con la aparición de los dispositivos de carga acoplada (CCD del inglés *Charged Coupled*

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

Device) en la década de 1960 por parte de Willard Boyle y George Smith (invento por el que ganarían el premio Nobel de Física en 2009; Boyle and Smith, 1970). Estos sensores CCD han sido empleados en cámaras de todo cielo durante años (Bettonvil, 2006; Cazorla *et al.*, 2008; Oznovich *et al.*, 1994; Pickering, 2006; Shields *et al.*, 1998; Tirado, 2006; Widener and Long, 2004; Zhang, 2009) hasta la década de 2010, cuando los sensores CMOS (*Complementary Metal-Oxide-Semiconductor*) se empezaron a imponer sobre estos (Antuña-Sánchez *et al.*, 2015; Crispel and Roberts, 2018; Dye, 2012; Hudec *et al.*, 2011; Jechow *et al.*, 2018; Urquhart *et al.*, 2015). Todas las cámaras de todo cielo empleadas a lo largo de esta tesis incorporan sensores CMOS, como se describe más adelante.

Estos sensores capturan la intensidad de la luz recibida por los fotodiodos que forman los píxeles, proporcionando una única matriz que forma una imagen en la que no se puede discernir color, pues todos los fotodiodos son sensibles al mismo rango del espectro electromagnético. Para distinguir colores en las imágenes los sensores cuentan con filtros ópticos, superpuestos sobre ellos, que forman un mosaico de celdas con un patrón determinado. El más utilizado es el patrón Bayer (inventado por Bryce Bayer en 1974): un patrón de colores RGB (*Red-Green-Blue*; Bayer, 1976).

Los sensores de las cámaras empleadas en este trabajo cuentan con un patrón Bayer RGGB (*Red-Green-Green-Blue*), que representa una variante en la que el verde aparece dos veces por cada píxel rojo o azul como se muestra en la Figura 2.1. Esta matriz cuenta con una celda de referencia, de tamaño 2x2, que en la esquina superior izquierda empieza con un filtro rojo, seguido de un filtro verde en la misma columna. En la siguiente columna empieza con un filtro verde y el siguiente es azul. Esta celda de referencia indica que el 25 % de los píxeles son rojos, otro 25 % azules y el 50 % verdes. Cada filtro solo deja pasar la luz de las longitudes de onda correspondientes a su color. Finalmente, esta celda de referencia se repite por toda la matriz del sensor. También existen patrones Bayer cuya celda de referencia tiene otra configuración, tales como BGGR, RGBG o GRBG; siendo lo importante que cada píxel capte los fotones de un color determinado (Igual, 2017). Cabe destacar que las cuentas digitales de cada píxel forman una imagen raw, conocida como bruta o cruda, que no contiene explícitamente información del color. Para una interpretación correcta en cada píxel se realiza una interpolación de color llamada *demosaicing*. Esta técnica consigue una matriz para cada uno de los colores del patrón RGGB o similar, que combinadas resultan en la imagen final con todos los colores como se ve en la Figura 2.1. Para la aplicación de esta interpolación existen multitud de algoritmos, siendo la empleada en esta tesis una interpolación bilineal implementada en la librería *Colour-Demosaicing* (Developers, 2022). Para una información más detallada sobre ambos tipos de sensores y los filtros de color, consultar Antuña-Sánchez (2022).

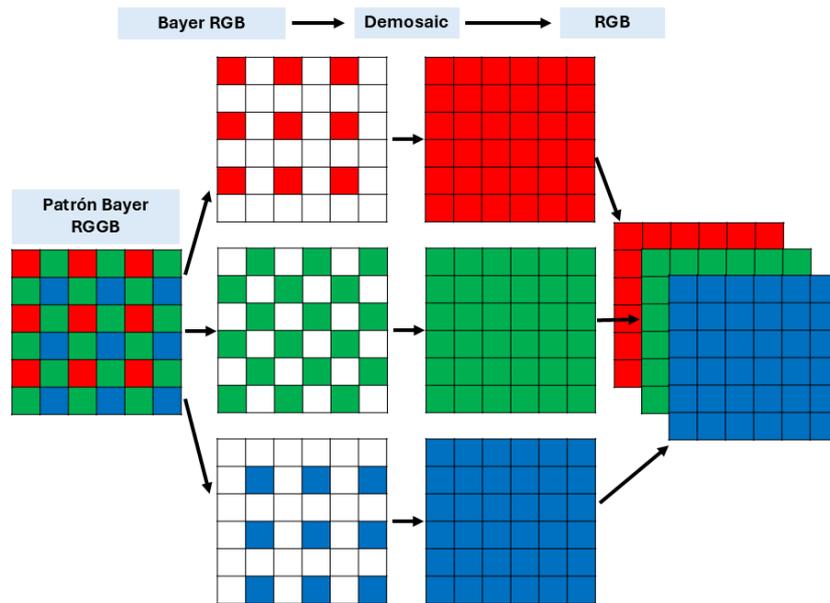


Figura 2.1: Patrón Bayer RGGB y aplicación del *demosaicing* para conseguir la matriz de color final.

Para tomar las imágenes hemisféricas de la bóveda celeste, los modelos más recientes de cámaras de todo cielo incorporan lentes *ojo de pez*, ya que estas tienen un campo de visión (FOV del inglés *Field Of View*) capaz de abarcar alrededor de los 180° o más (Sturm, 2021).

Entre las cámaras utilizadas durante el desarrollo del trabajo se distinguen tres modelos. El primero es el modelo SONA202-NF de *Sieltec Canarias S.L.* (Figura 2.2a) que cuenta con un sensor CMOS SONY IMX249 y una lente *ojo de pez* de 185° de FOV, encapsulados en una carcasa resistente a la intemperie con una cúpula de cristal (Román *et al.*, 2022). Este modelo toma imágenes de 1172×1158 píxeles de tamaño, con una resolución de 2.35 mega-píxeles y 10 bits. El sensor cuenta con un mosaico Bayer que sigue un patrón RGGB y un filtro tri-banda (TF del inglés *Tri-band Filter*) que reduce el solapamiento entre los canales de color (Antuña-Sánchez, 2022). En la Figura 2.3 se muestra la respuesta espectral, mediante la transmitancia normalizada, de los canales RGB del sensor de este modelo (ver Figura 2.3a), así como del filtro tri-banda (ver Figura 2.3b) y de la combinación de ambos filtros (ver Figura 2.3c).

Otro modelo de cámara de todo cielo empleado es el OMEA-3C de *Alcor System* (Figura 2.2b). Este modelo dispone de un sensor CMOS IMX178 de SONY que incorpora una lente *ojo de pez*, con un FOV de 180° , encapsulados en una carcasa resistente a la intemperie. Además, cuenta con una cúpula de cristal BK7 en la parte superior, un sensor externo de temperatura y humedad, así como de un sistema de calefacción interno para evitar la con-

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

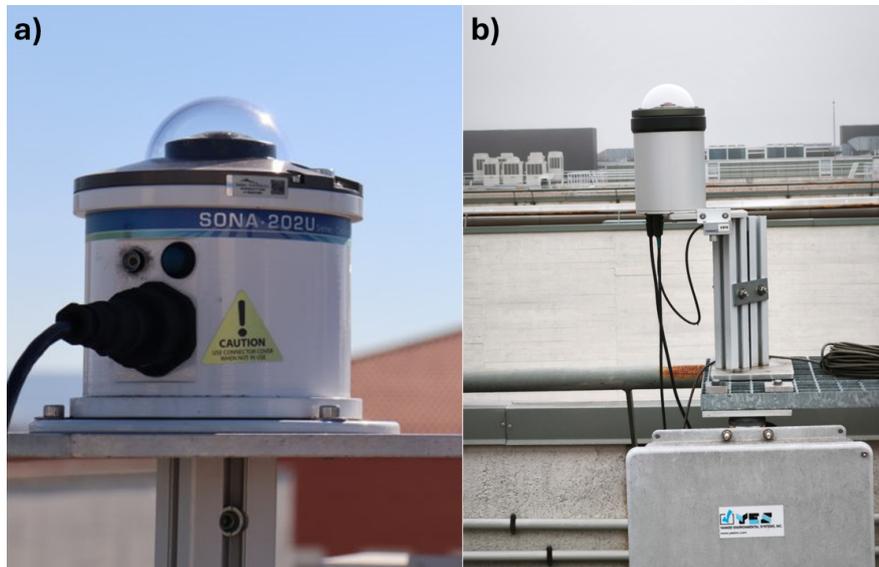


Figura 2.2: Modelos de cámaras de todo cielo: a) Modelo SONA-202NF (Figura obtenida de Antuña-Sánchez, 2022); b) Modelo OMEA-3C. Ambos modelos propiedad del GOA-UVa instalados en Valladolid.

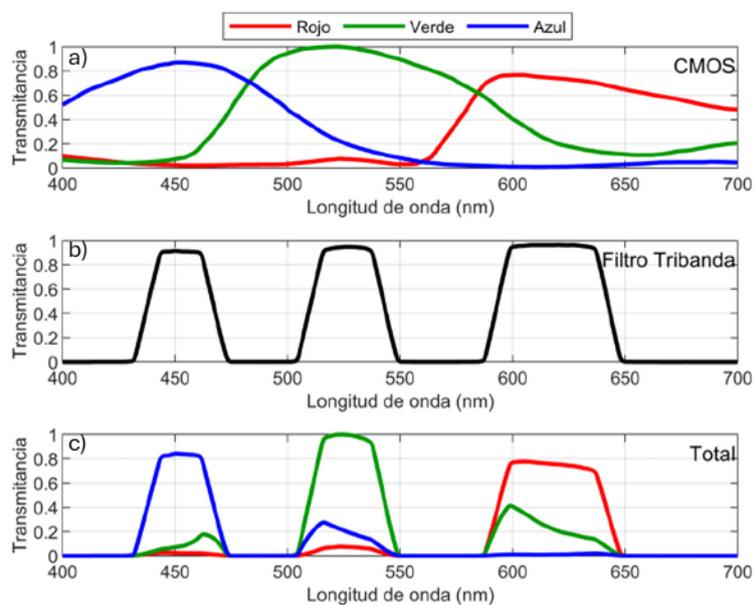


Figura 2.3: Transmitancia espectral normalizada de diferentes filtros: a) filtros Rojo, Verde y Azul (RGB) del mosaico Bayer del sensor de la cámara de todo cielo SONA-202NF, normalizada con respecto al máximo valor de entre los tres canales; b) filtro tri-banda; c) combinación de ambos filtros. Figura obtenida de Antuña-Sánchez (2022).

densación en el interior y eliminar las gotas de agua en caso de lluvia o rocío. Este sensor toma imágenes de un tamaño de 3096x2080 píxeles y una resolución de 6.44 mega-píxeles y 14 bits. También dispone de un mosaico Bayer de patrón RGGB con un filtro que bloquea la radiación infrarroja cuyas transmitancias están representadas en las Figuras 2.4a y 2.4b.

Finalmente, el tercer modelo se trata de una cámara OMEA-3C-TF. Este modelo se trata de una cámara OMEA-3C, con la única diferencia de que el filtro infrarrojo ha sido sustituido por un filtro tri-banda como el del modelo SONA-202NF. En la Figura 2.4 se muestra la transmitancia espectral normalizada (NST del inglés *Normalized Spectral Transmittance*) para los diferentes filtros de las cámaras OMEA-3C y OMEA-3C-TF. En la Figura 2.4a se puede observar la NST de los filtros RGB del sensor CMOS IMX178 que incorporan ambos modelos. En las Figuras 2.4b y 2.4c se muestra la respuesta espectral del filtro infrarrojo (del modelo OMEA-3C) y tri-banda (del modelo OMEA-3C-TF), respectivamente. Por último, en las Figuras 2.4d y 2.4e se representa la NST de la combinación de los filtros anteriores con los de color del sensor para el modelo correspondiente. En estas dos figuras también se representa la respuesta espectral en escala de grises, calculada como una combinación lineal de los canales RGB, cada uno multiplicado por un peso asignado: 0.299 (R), 0.287 (G) y 0.114 (B) (ver con más detalle en Román *et al.*, 2025).

Todas las cámaras de todo cielo utilizadas en esta tesis pertenecen a la red GOA-SCAN (*GOA all-Sky Cameras Network*) que opera alrededor del mundo en las estaciones que se describen en la Sección 2.2. Esta red ha sido creada, desarrollada y gestionada por el Grupo de Óptica Atmosférica de la Universidad de Valladolid (GOA-UVa), para el almacenamiento y procesamiento de imágenes. GOA-SCAN garantiza una escalabilidad sostenible a través del establecimiento de protocolos tanto para el proceso de medidas como para la calibración de las cámaras. De este modo, se maximiza la información recogida por las cámaras y se estandarizan y procesan los datos de manera consistente.

Las cámaras de GOA-SCAN están configuradas de modo que se toman secuencias de imágenes en un régimen de captura de multi-exposición que permite obtener una imagen final en alto rango dinámico (HDR del inglés *High Dynamic Range*). Las imágenes de cada secuencia se toman en formato raw para mayor sensibilidad, las cuales finalmente se combinan en archivos HDF5 (*Hierarchical Data Format*, o H5) para ordenar y comprimir los datos siguiendo la estructura de la red, de los que se obtienen las imágenes HDR finales.

En el caso del modelo SONA202-NF, las imágenes raw se obtienen con una resolución de 10-bits, en dos secuencias de 7 imágenes durante el día, cuyos tiempos de exposición son 0.3, 0.4, 0.6, 1.2, 2.4, 7.8 y 9.6 ms, y de 9 por la noche, con tiempos de exposición de 0.1, 0.5, 2, 4, 6, 8, 10, 12, y 14 s. Cada secuencia de multiexposición de esta cámara se toma cada 5 minutos (Antuña-Sánchez, 2022).

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

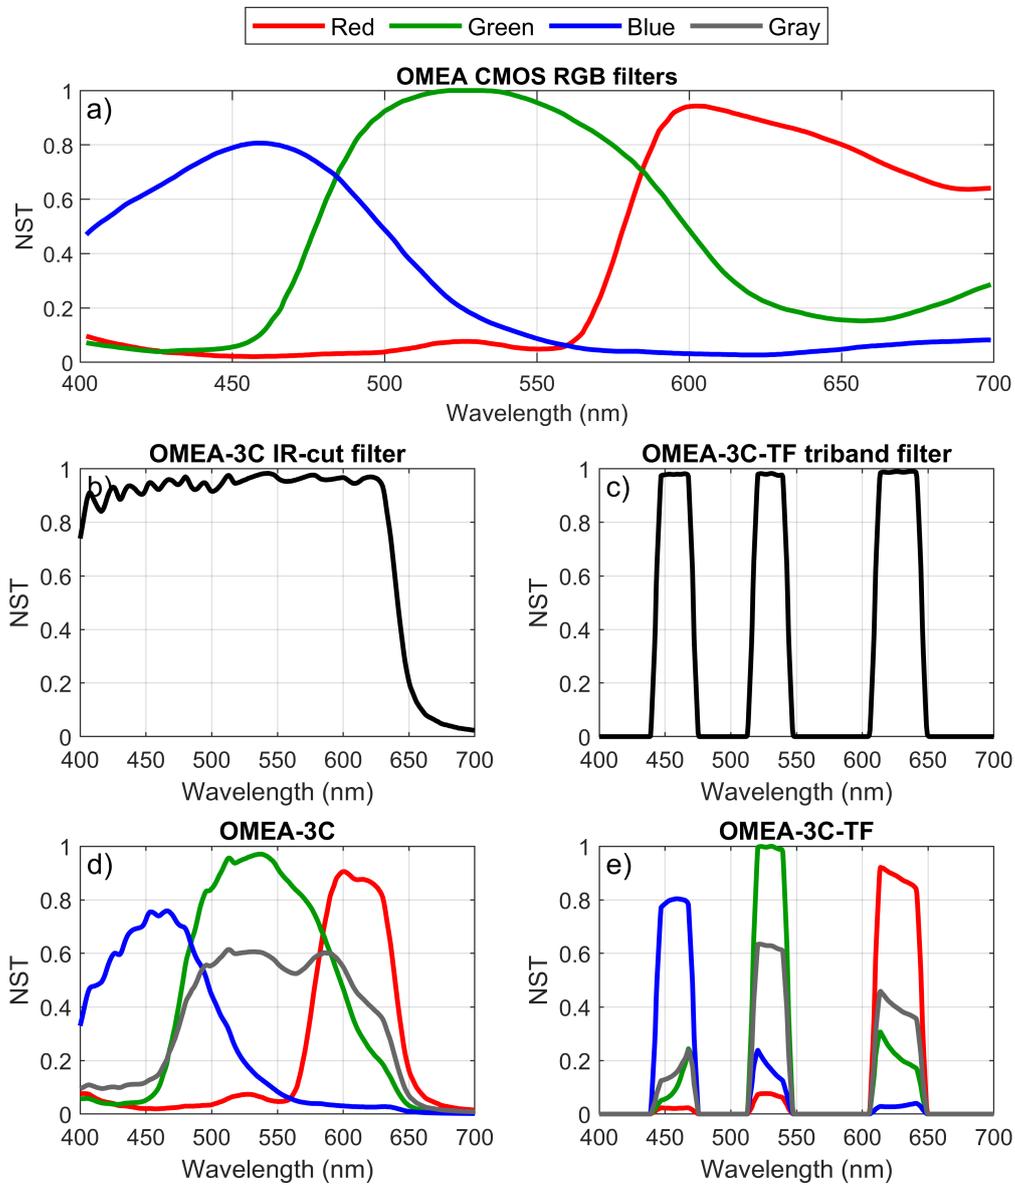


Figura 2.4: Transmitancia espectral normalizada de diferentes filtros: a) filtros Rojo, Verde y Azul (RGB) del mosaico Bayer del sensor de las cámaras de todo cielo OMEA-3C, normalizada con respecto al máximo valor de entre los tres canales; b) filtro infrarrojo incluido en el modelo OMEA-3C; c) filtro tri-banda incluido en el modelo OMEA-3C-TF; d) combinación de los filtros RGB e infrarrojo del modelo OMEA-3C; e) combinación de los filtros RGB y tri-banda del modelo OMEA-3C-TF. Los paneles d) y e) también muestran la respuesta espectral de la señal del sensor en escala de grises, la cual se calcula como una combinación de los tres canales de color cada uno con los siguientes pesos: 0.299 para el rojo, 0.587 para el verde y 0.114 para el azul. Figura obtenida de Román *et al.* (2025).

En el caso del modelo OMEA-3C, este proceso se realiza mediante la aplicación *GOA-OMEA Capture*, aplicación desarrollada por el GOA-UVa (Antuña-Sánchez *et al.*, 2022), capturando secuencias de imágenes en ficheros H5 junto con toda la meta-información de la cámara. Durante el día las secuencias se configuran para diferentes tramos de SZA. Se configuran 2 escenarios diferentes en periodo nocturno: con Luna y sin ella. Por tanto, se tienen varias secuencias a lo largo de un día. Las cámaras de GOA-SCAN están configuradas para tomar las secuencias cada 5 minutos por el día y cada 2 por la noche. En el modelo OMEA-3C-TF se toman las imágenes del mismo modo que en el OMEA-3C, salvo que los tiempos de exposición de las secuencias son diferentes. Durante el día, las OMEA-3C toman las secuencias con diferentes tiempos de exposición dependiendo del SZA. De 0 a 35° los tiempos son 214, 356, 640 y 1208 μs . De 35 a 75° se añade a esta secuencia un tiempo de exposición de 2344 μs , y de 75 a 88° se añade otro tiempo más de 4616 μs . Para elevaciones más pequeñas, SZAs más grandes, se utilizan otros tiempos más dinámicos para recoger el amanecer y el anochecer, ya que el modo noche no comienza hasta que el SZA es mayor que 97°. En la OMEA-3C-TF se emplean las mismas secuencias, pero en la correspondiente al tramo de SZA en el rango de 0-35° se añade un tiempo de exposición de 2344 μs . Para el rango de 35-75° se añade a la anterior secuencia un tiempo de exposición de 4616 μs , y para el SZA entre 75-88° son los mismos que para el modelo OMEA-3C más un tiempo de 9160 μs . Los tiempos de exposición nocturnos para la cámara OMEA-3C en modo Luna son 0.1, 0.5, 2, 5, 10, 15 y 20 s, mientras que para condiciones sin Luna, los tiempos son 5, 10, 15, 20 y 30 s. Para la cámara OMEA-3C-TF estos tiempos de exposición son: 1, 5, 10, 20 y 30 s en modo Luna, y 3, 6, 12, 24 y 48 s en condiciones sin Luna. También se diferencia entre ambos modelos la configuración de la amplificación ISO por la noche, fijada a una ganancia de 10 dB para el modelo OMEA-3C y de 15 dB para el OMEA-3C-TF (para más detalles sobre la configuración de las cámaras de todo cielo de GOA-SCAN ver Antuña-Sánchez (2022) y Román *et al.* (2025)).

Los datos de las cámaras de GOA-SCAN se reciben en un servidor de almacenamiento con el software *NextCloud*, lo que permite controlar los niveles de acceso a los usuarios y compartir dichos datos de manera organizada y segura. Primero, se envían los datos al servidor según las frecuencias a las que se toman las imágenes anteriormente descritas. En el caso del modelo SONA-202NF lo que se almacena son los ficheros raw directamente, mientras que los modelos OMEA-3C envían los datos a través de la aplicación *GOA-OMEA Capture* desde la que se gestionan estas cámaras. El sistema de red permite agregar más modelos mediante un cliente desarrollado por el grupo para el envío de imágenes. Esta estructura proporciona una gran escalabilidad en los servicios y productos que se pueden ofrecer (Antuña-Sánchez, 2022).

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

Las cámaras de la red GOA-SCAN se nombran con un identificador (ID) único que sigue la siguiente estructura: “CXXX” (donde XXX corresponde con el número de cámara según el orden de instalación, p.e. C001, C002,...). Teniendo esto en cuenta, en el servidor los datos se almacenan de la siguiente manera. Llegan a la carpeta *DataUpload*, en cuyo interior se dividen los datos en subcarpetas según el ID de la cámara, el año, mes y día de la medida. Dentro de la carpeta del día se almacenan los datos en los ficheros correspondientes según la frecuencia establecida en hora UTC. En el caso del modelo SONA los ficheros raw de cada secuencia completa se convierten a un fichero H5, mientras que en el caso de los modelos OMEA se envían directamente los ficheros H5 de cada secuencia. A partir de los ficheros H5 almacenados en el servidor, tal y como se ha descrito, se generan las imágenes finales en HDR. Para esto, se emplea una librería propia que crea un mapeo tonal cuyo objetivo es poder apreciar la imagen tanto en las partes más oscuras como en las más brillantes. El algoritmo desarrollado para realizar este proceso, así como el resto de información sobre la estructura de la red y el procesamiento en el servidor, se describen de forma más detallada en Antuña-Sánchez (2022).

Finalmente, se almacenan las imágenes HDR en el servidor, a las cuales se les aplica una máscara con los datos de la estación a la que corresponden, y se les añade los logos del GOA-UVa y de la institución en la que se encuentra la cámara correspondiente. Todas las cámaras se encuentran calibradas geoméricamente mediante la aplicación ORION (Antuña-Sánchez *et al.*, 2022), la cual sirve para rotar la última imagen HDR de modo que el Norte geográfico quede en la parte superior. Además, cada 15 minutos se van juntando las imágenes HDR para generar el vídeo del día correspondiente; estos vídeos diarios también se almacenan en el servidor. Por otra parte, tanto la imagen final, con todos los datos que se acaban de describir, así como el vídeo del día correspondiente, se van mostrando en tiempo real en la página web del grupo (<https://goa.uva.es/>) en la pestaña “*Sites&Measurements*”. En la Figura 2.5 se muestra un ejemplo de la imagen que se muestra en la web del grupo para la cámara OMEA-3C-TF de la Facultad de Ciencias de la Universidad de Valladolid. En esta pestaña se despliega un menú en el cual aparecen las estaciones en las que el GOA-UVa tiene instalada instrumentación. En cada una se muestran los datos más recientes de los instrumentos correspondientes.

2.1.2 Otros instrumentos

Este trabajo se basa en el desarrollo, validación y aplicación de distintos algoritmos para la determinación de la radiación solar y de las propiedades de aerosoles y nubes, a través de las imágenes tomadas con las cámaras de todo cielo. Para la validación de los productos obtenidos por las cámaras de todo cielo se han empleado diversos instrumentos de referencia.

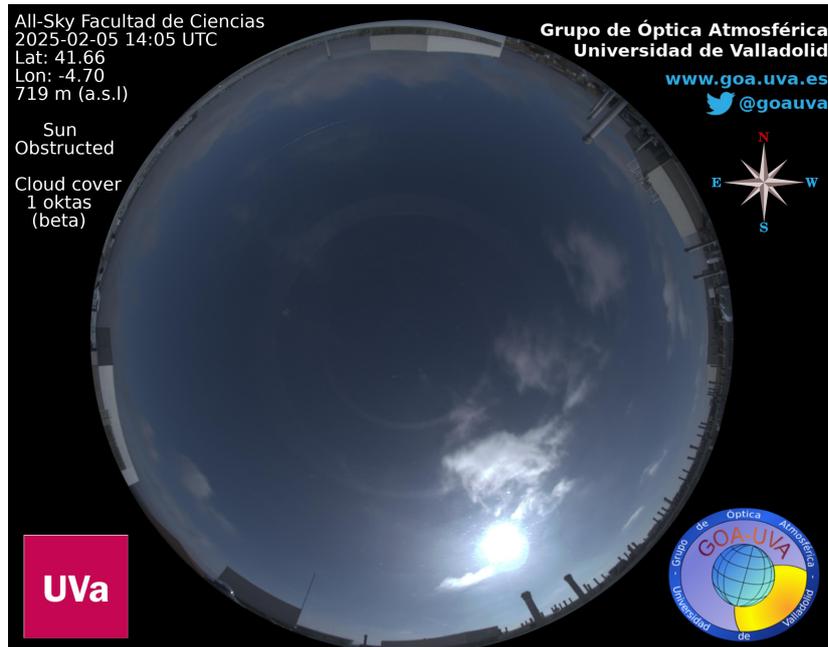


Figura 2.5: Imagen HDR mostrada en la página web del GOA-UVA (<https://goa.uva.es/>), en la pestaña “*Sites&Measurements*”. Esta imagen corresponde a la cámara OMEA-3C-TF instalada en la Facultad de Ciencias de la Universidad de Valladolid, tomada el día 5 de febrero de 2025 a las 14:05 UTC.

En lo correspondiente a las propiedades de aerosoles, el instrumento de referencia es el fotómetro. En el caso de las nubes, las medidas realizadas por observadores meteorológicos. En cuanto a la radiación solar, las medidas de referencia obtenidas con piranómetros. Por tanto, en esta sección se describen estos instrumentos y técnicas de medida.

2.1.2.1 Fotómetros

El instrumento de referencia para el estudio de los aerosoles en este trabajo es el fotómetro CE318, el cual se trata de un instrumento automático y de campo desarrollado por la compañía francesa *Cimel Electronique* (*Cimel Electronique*, 2004). Las partes de las que constan estos equipos son: una caja de control, la cual gestiona el instrumento y hace que su funcionamiento sea automático; una cabeza, en cuyo interior se encuentra una rueda de filtros interferenciales estrechos que generalmente abarcan un rango de longitudes de onda entre los 340 y 1640 nm, variando el número de canales con los que cada modelo realiza medidas según la configuración del equipo; un colimador, que evita que llegue luz parásita a los sensores que tiene en la cabeza; y un robot, el cual hace que se mueva en las direcciones acimutal y cenital permitiéndole apuntar al Sol, la Luna o a cualquier punto del cielo (*Cimel Electronique*, 2004). En la Figura 2.6a se muestran las diferentes partes del fotómetro (co-

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

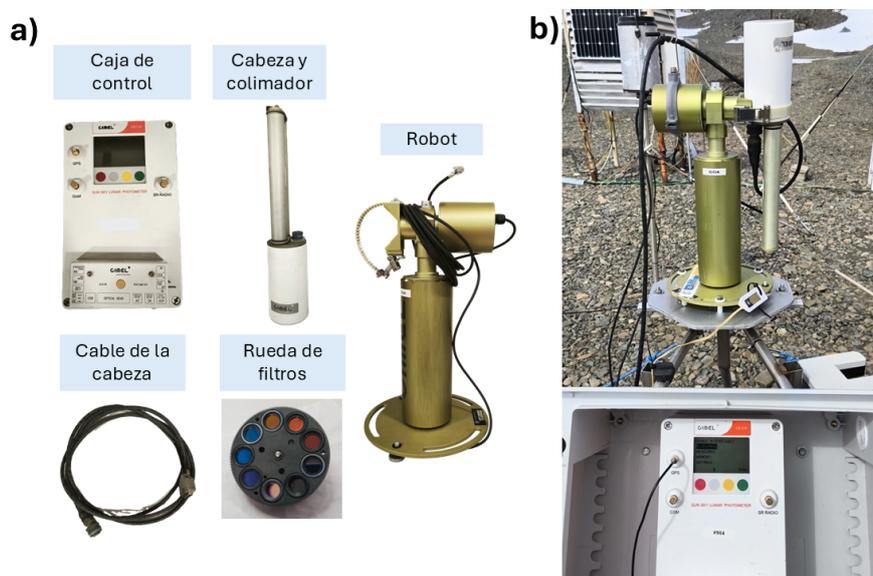


Figura 2.6: Fotómetro Cimel CE318-T. a) Partes de las que consta el instrumento: caja de control, cabeza, colimador, cable de la cabeza, rueda de filtros y robot. b) Fotómetro del GOA-UVA.

respondiendo con el modelo triple CE318-T) y en la Figura 2.6b se muestra un ejemplo de un fotómetro del GOA-UVA en operación.

Aunque existen múltiples configuraciones de los fotómetros CE318, todas ellas se pueden agrupar en 3 familias. La primera son los fotómetros estándar, que surgen en la década de 1990, hasta 2002 en versión analógica y después en versión digital. La segunda corresponde a los fotómetros extendidos, cuyos primeros modelos son del año 2002. Por último están los fotómetros triples (CE318-T), desarrollados a partir de 2013 (Barreto *et al.*, 2016), que corresponden a la versión más moderna hasta el momento y corresponden a los empleados en este trabajo. La novedad de estos equipos es la capacidad de medir irradiancia lunar para obtener propiedades de aerosoles durante la noche. En este caso, la electrónica ha mejorado sustancialmente, manteniendo un acuerdo entre modernización del instrumento y coherencia entre medidas con respecto a las versiones previas.

Estos equipos realizan dos grandes tipos de medidas: las de irradiancia del Sol, y de la Luna en el caso de los triples; y de radiancia del cielo. En el caso de las medidas de irradiancia, en ambos casos se puede obtener la atenuación de la radiación durante su paso a través de la atmósfera para calcular el AOD (González, 2021). Para las medidas de radiancia del cielo existen varias geometrías con distintos fines, con las que se obtiene la cantidad de radiación solar dispersada por aerosoles en una serie de ángulos de scattering (González, 2021). Estas medidas se utilizan en los algoritmos de inversión, junto con las medidas de AOD, para obtener propiedades microfísicas y radiativas de los aerosoles (Dubovik and King, 2000; Dubovik *et al.*, 2014; Sinyuk *et al.*, 2020).

El cimel CE318-T permite obtener el AOD en periodo diurno y nocturno mediante las medidas de irradiancia solar y lunar, respectivamente. En el caso de las medidas diurnas se emplea directamente la ley de *Beer-Bouguer-Lambert* de la Sección 1.3.1, mientras que para las medidas nocturnas además se emplean modelos empíricos, siendo ROLO el más extendido, así como su implementación RIMO. Estos modelos se emplean para conocer la irradiancia lunar extraterrestre en cada momento y poder obtener así el AOD, debido a la variación de la irradiancia lunar extraterrestre, como se describe en la Sección 1.3.1.

La red AERONET (AERosol ROBotic NETwork; <https://aeronet.gsfc.nasa.gov>; Holben *et al.*, 1998) gestionada por NASA (*National Aeronautics and Space Administration*) tiene como instrumento principal el fotómetro CE318. AERONET, red dedicada al estudio de aerosoles, fue creada en la década de 1990 por la NASA, Estados Unidos, junto con el Laboratorio de Óptica Atmosférica (LOA del francés *Laboratoire d'Optique Atmosphérique*) de la Universidad de Lille, Francia. El principal objetivo de esta red es el estudio de aerosoles atmosféricos para validar medidas de satélites de forma rutinaria en cualquier punto del planeta (González, 2021). Esta red cumplió 30 años en 2023 con alrededor de 600 estaciones de medida, repartidas en unos 100 países diferentes. AERONET se define como una federación de redes en las que cada una de dichas redes se encarga de la calibración, supervisión y mantenimiento de un conjunto de estaciones de la red. Los tres centros de calibración oficiales de los instrumentos de AERONET son el *Goddard Space Flight Center* (GSFC) de NASA, el LOA y el GOA-UVa, habiéndose incorporado el GOA-UVa como centro de calibración en 2006 debido a la dificultad en el desempeño de esta labor para solo dos centros a causa del crecimiento de la red (González, 2021).

AERONET tiene establecidos unos protocolos de calibración que deben cumplir tanto los centros de calibración como las estaciones de medida, lo que garantiza una calidad y homogeneidad en las medidas, además de la trazabilidad de los datos. Por tanto, se conoce toda la meta información asociada a la medida, así como los coeficientes de calibración de cada instrumento y medida. La versión actual de procesado de datos utilizada por AERONET es la 3 (Giles *et al.*, 2019). El acceso a estos datos es libre y gratuito.

Los dos bloques de medidas que realiza el CE318 requieren de un protocolo de calibración distinto. La calibración de las medidas de irradiancia se realiza por intercomparación con fotómetros de referencia (llamados máster), los cuales se calibran por el método de Langley, que requiere de condiciones de atmósfera limpia y estable. Esto se realiza en el observatorio de la Agencia Estatal de Meteorología (AEMet) de Izaña (Tenerife, España) y en el observatorio de Mauna Loa (Hawai, Estados Unidos; Toledano *et al.*, 2018). El segundo tipo de medidas se calibran en laboratorio mediante una esfera integrante calibrada.

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

Debido a la necesidad de evaluar los datos de los fotómetros en tiempo real y manejar grandes cantidades de datos generados por AERONET, el GOA-UVA desarrolló la herramienta de software CAELIS para ayudar en la gestión de las calibraciones en Valladolid (Fuertes *et al.*, 2018). CAELIS proporciona herramientas para la monitorización de los fotómetros, el procesamiento de los datos en tiempo real y ofrece a la comunidad científica una nueva herramienta para trabajar con estos datos (González *et al.*, 2020). Para ello, CAELIS consta de una base de datos y una interfaz web (<https://www.caelis.uva.es/>) para visualizar datos brutos y metadatos, proporciona un procesamiento de las radiancias del cielo y facilita la monitorización del rendimiento de los fotómetros (González *et al.*, 2020). Esta herramienta tiene un sistema de alarmas automáticas que permite detectar y resolver problemas técnicos en los instrumentos rápidamente (González, 2021). En este contexto, el cálculo del AOD es importante, ya que permite realizar diversas comprobaciones a los datos para garantizar la fiabilidad de las mediciones (González *et al.*, 2020). Además, CAELIS también pretende ser un marco que facilite las actividades de investigación, siendo el AOD un producto clave en el estudio de aerosoles (González *et al.*, 2020). Los datos de AOD nocturno que se han utilizado en este trabajo han sido obtenidos de CAELIS (ver Sección 4.1). Estos datos de AOD nocturno de CAELIS utilizan el modelo RIMO aplicando las correcciones propuestas por Román *et al.* (2020) como se describe en González *et al.* (2020).

2.1.2.2 Observaciones de Cubierta Nubosa

La cubierta de nubes puede medirse de diversas maneras, y con diversos instrumentos, siendo las observaciones de campo realizadas por observadores meteorológicos una de las más empleadas. Estas observaciones manuales realizadas por personas son hemisféricas e instantáneas y dependen del horizonte visible, además de que son más fiables durante el día. Hay que tener en cuenta que esta técnica tiene cierta subjetividad debida a efectos humanos de acuerdo con el manual de la WMO (WMO, 2012).

Para realizar las observaciones de nubes, la WMO marca unas pautas que deben seguir los observadores según WMO (2017). Estas son las siguientes: la estimación debe realizarse en un lugar abierto desde el que pueda verse el cielo en su totalidad; cuando esté parcialmente oculto por montañas, o por calima, niebla o humo, la CC debe estimarse desde la fracción visible; y cuando una parte del cielo esté cubierta por precipitación, dicha parte se considera tapada por una nube que está precipitando.

Puede resultar difícil realizar esta estimación si algunas de las nubes son solo parcialmente visibles o se encuentran temporalmente ocultas. Este caso suele darse cuando las nubes se presentan en bancos o en capas superpuestas. Para estimar la cantidad de nubes en esta situación, es posible hacerlo observando el cielo durante un largo periodo de tiempo debido



Figura 2.7: Piranómetros empleados para la medidas de irradiancia global horizontal: a) Modelo CMP-11, b) Modelo CM-21 (sobre el seguidor solar SOLYS-2 de la misma casa) y c) Modelo CM-22; los tres del fabricante *Kipp&Zonen*. d) Modelo EKO-MS802F de *EKO Instruments CO., LTD*.

a que nubes ocultas pueden volverse visibles. En el caso de nubes superpuestas, la suma de las diferentes cantidades de nubes puede ser mayor que la cobertura total. Los espacios entre nubes cerca del horizonte pueden no ser visibles para el observador, por lo que este solo debe considerar los espacios visibles desde su posición a la hora de realizar las estimaciones. Finalmente, en noches oscuras, solo se puede determinar la cobertura total de nubes, la cual debe basarse en la porción de cielo en la que las estrellas están veladas o completamente cubiertas por nubes (WMO, 2017).

2.1.2.3 Piranómetros

En el desarrollo de este trabajo se han empleado distintos piranómetros en distintas localidades en lo que respecta a medidas de GHI, las cuales se toman cada minuto. Los modelos utilizados son: los CMP-11, CM-21 y CM-22 del fabricante *Kipp&Zonen* (Delf, The Netherlands; *Kipp&Zonen*, 2004a,b, 2013) y el EKO-MS802F de la compañía *EKO Instruments CO., LTD* (Tokyo, Japan; *EKO Instruments CO., LTD*, 2015). En la Figura 2.7 se muestran estos modelos.

El piranómetro CMP-11 cumple con todos los criterios de especificación de la ISO-9060 para un piranómetro Estándar Secundario, además de tratarse de un instrumento que se caracteriza por 32 elementos de detección termopar de unión conectados en serie que tienen un tiempo de respuesta de menos de 5 s en un rango espectral de 285-2800 nm con una incerti-

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

dumbre de menos del 2 % (nivel de confianza del 95 %) para los valores totales de radiación diarios. El elemento de detección del equipo está situado debajo de dos cúpulas de cristal concéntricas de alta calidad que tienen un espesor de 2 mm y proporcionan una mejora en el error direccional con respecto al modelo anterior (el CMP-6), además de que la nivelación de este radiómetro también es más precisa que en dicho modelo anterior (*Kipp&Zonen*, 2013).

El CM-21 es un instrumento de alta precisión con cúpulas de alta calidad óptica que reducen el error direccional en menos de 10 Wm^{-2} . Este equipo posee una alta sensibilidad, que podría resultar en especificaciones más bajas en el sistema de adquisición de datos. También cuenta con una baja impedancia que reduce la sensibilidad al ruido y las interferencias. La respuesta a la temperatura del equipo es baja, lo que presenta una ventaja cuando se trabaja bajo condiciones climatológicas extremas. Finalmente, la incertidumbre del modelo CM-21 para los valores diarios es del 2 % con un nivel de confianza del 95 %, proporcionando un tiempo de respuesta de 5 s en un rango espectral de 305-2800 nm (*Kipp&Zonen*, 2004a).

El modelo CM-22 es un piranómetro de alta precisión con cúpulas de cuarzo, las cuales reducen el error direccional a menos de 5 Wm^{-2} debido a su alta calidad óptica. Cúpulas más anchas de 4 mm y una conductividad térmica superior de x1.5 del cuarzo mejoran el acople térmico del sensor y la parte superior del domo. Este instrumento mide en un rango espectral de 200-2800 nm, con un tiempo de respuesta de 5 s con un nivel de confianza del 95 % y una incertidumbre de hasta el 2 % para los totales diarios (*Kipp&Zonen*, 2004b). Al igual que los modelos CM-11 y CM-21 de la misma casa, el CM-22 cumple con las especificaciones de la mejor de las tres clases, “Alta Calidad”, definidas en la Guía de Instrumentos y Métodos de Observación Meteorológicos, sexta edición, de la WMO (1996). La mayoría de las especificaciones de estos modelos de *Kipp&Zonen* son el doble de buenas de lo requerido según el manual del instrumento (*Kipp&Zonen*, 2004b).

Finalmente, el piranómetro de EKO, el MS-802F, es un instrumento de alta precisión con un rango espectral de 285-3000 nm y una incertidumbre esperada de menos de $\pm 1 \%$ para los valores diarios (García *et al.*, 2019; *EKO Instruments CO., LTD*, 2015). Este modelo es un piranómetro Estándar Secundario ISO-9060 que es ampliamente utilizado como sensor de referencia para medir GHI con gran exactitud. Su carcasa de latón lo hace un sensor duradero y apto para su uso en ambientes expuestos a condiciones meteorológicas difíciles. Este dispositivo es un estándar para investigación fotovoltaica y estudios de climatología alrededor del mundo. Entre sus características principales destacan una rápida respuesta temporal con menos de 5 s y un nivel de confianza del 95 %, una compensación de la temperatura en un rango ancho, así como una cúpula de vidrio óptico de gran calidad que proporciona una respuesta coseno precisa. Cabe destacar, que existen dos versiones de este modelo, el MS-802 y el MS-802F, las cuales se diferencian únicamente en que el modelo MS-802F (que

es el empleado en este trabajo) posee un sistema de ventilación que minimiza los efectos negativos de la congelación, la nieve o el polvo en las medidas (*EKO Instruments CO., LTD*, 2015).

De acuerdo con los estándares de calibración de los fabricantes (*EKO Instruments CO., LTD*, 2015; *Kipp&Zonen*, 2025), es necesario calibrar periódicamente los piranómetros, ya que sus propiedades se van modificando con el paso del tiempo. Se recomienda calibrarlos cada dos años (*EKO Instruments CO., LTD*, 2015; *Kipp&Zonen*, 2025). Los piranómetros se calibran por comparación con otro instrumento de referencia que se calibra en el *World Radiation Center* (WRC) en Davos, Suiza (*EKO Instruments CO., LTD*, 2015; *Kipp&Zonen*, 2025).

2.2 Estaciones de medida

Los datos utilizados en este trabajo se han obtenido mediante las técnicas e instrumentos descritos en la sección anterior en diferentes estaciones de medida. Entre estos lugares se encuentran estaciones en las que el GOA-UVa tiene (o ha tenido) instrumentación instalada, así como algunos instrumentos complementarios pertenecen a otras instituciones. A lo largo de esta sección se describen tanto las estaciones de las que se han usado las medidas, como la instrumentación empleada en cada una de ellas. Dicha instrumentación corresponde a algunas de las cámaras pertenecientes a la red GOA-SCAN, fotómetros de la red AERONET y los diferentes modelos de piranómetros descritos en la sección anterior. En la Figura 2.8 se muestra un mapa con las localizaciones empleadas en este trabajo y en la Tabla 2.1 las cámaras de todo cielo de GOA-SCAN correspondientes a cada estación con su ID, así como información sobre las fechas en las que han estado operativas en las distintas estaciones de medida, las coordenadas del lugar, la institución que gestiona dicha estación y el propietario de la cámara de todo cielo.

El GOA-UVa tiene su principal estación en Valladolid (España), que se encuentra en la terraza de la Facultad de Ciencias de la Universidad de Valladolid. Valladolid es una ciudad de tamaño medio, con alrededor de 300,000 habitantes en la localidad y unos 400,000 en toda el área metropolitana. Se trata de una ciudad urbana rodeada por zonas rurales, cuyo clima se clasifica como limpio continental con veranos calurosos, inviernos fríos y ocasionales episodios de polvo procedente del Sahara (*Bennouna et al.*, 2013; *Cachorro et al.*, 2016; *Román et al.*, 2014). En esta estación el grupo posee diversa instrumentación, entre la que se encuentran las cámaras de todo cielo. Primero estuvo instalada en esta terraza la cámara modelo SONA-202NF (C002, según el ID de la red GOA-SCAN) (*Román et al.*, 2022).

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

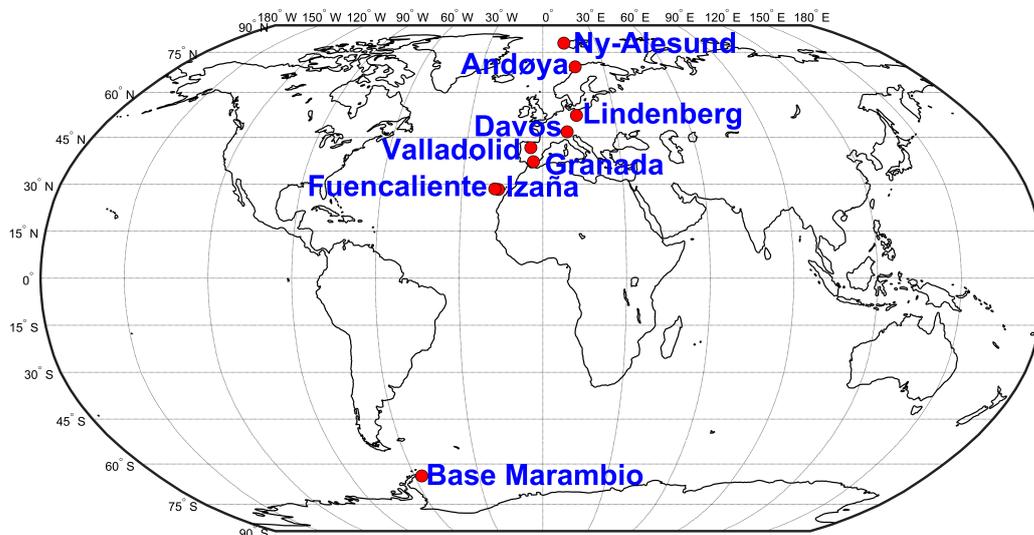


Figura 2.8: Mapa con la localización de las estaciones de medida empleadas en este trabajo. Figura obtenida de Román *et al.* (2025).

También hubo una cámara OMEA-3C (C005), la cual fue sustituida por otra del mismo modelo (C011). Por último se instaló en la estación de Valladolid el modelo OMEA-3C-TF (C013), sustituyendo a la C011, que corresponde con la única cámara de este modelo utilizada en este trabajo. También se encuentra en esta estación el piranómetro CM-21 utilizado en este trabajo, el cual está instalado sobre un seguidor solar SOLYS-2 de la misma compañía (*Kipp&Zonen*). Además, el grupo dispone de más instrumentos tales como fotómetros CE318-T (González, 2021; Herrero del Barrio *et al.*, 2023).

Como consecuencia de la erupción del volcán Tajogaite (La Palma, España), la cámara C005 que estuvo en Valladolid se trasladó al parque natural de Cumbre Vieja en La Palma y fue instalada en la estación de Fuencaliente en La Palma (Bedoya-Velásquez *et al.*, 2022). La instalación de esta cámara formó parte de un despliegue de instrumentación sin precedentes en lo que respecta a la monitorización del evento, el cual fue coordinado por la Agencia Estatal de Meteorología de España (AEMet) (Córdoba-Jabonero *et al.*, 2023; García *et al.*, 2022; Milford *et al.*, 2023; Sicard *et al.*, 2022). Esta cámara estuvo monitorizando las nubes y aerosoles emitidos por la erupción durante casi cuatro meses. El dispositivo se encontraba configurado de tal manera que tomaba las imágenes HDR cada 2 minutos en periodo diurno para una mayor resolución (a diferencia del resto de modelos OMEA-3C que capturan las imágenes cada 5 minutos durante el día). Durante este periodo, el GOA-UVa también dispuso en esta estación de un fotómetro CE318-T y de un ceilómetro CHM15k (*Lufft manufacturer*) que se enviaron desde Valladolid para la monitorización de este evento. La isla de La Palma posee un clima subtropical cuyas temperaturas se mantienen suaves durante todo el año.

Después de monitorizar la erupción, el GOA-UVa trasladó la cámara de todo cielo C005 de La Palma al Centro de Investigación Atmosférica de Izaña, el cual se trata de una estación de alta montaña gestionada por AEMet en Tenerife (Islas Canarias, España), en las cercanías del Teide. Este observatorio normalmente se encuentra bajo una fuerte capa de inversión de temperatura cuasi-permanente y consecuentemente libre de la influencia antropogénica local con condiciones estables y pristinas (Barreto *et al.*, 2022; Cuevas *et al.*, 2022; Román *et al.*, 2020; Toledano *et al.*, 2018). Estas condiciones hacen que el observatorio de Izaña sea idóneo para calibrar fotómetros de AERONET mediante el método Langley, entre ellos, los fotómetros máster del GOA-UVa. Además, el Centro de Investigación Atmosférica de Izaña es una estación que forma parte de la red BSRN (*Baseline Surface Radiation Network*) desde 2009, la cual está implementada por el WCRP (*World Climate Research Program*) con el apoyo de la WMO. Entre las medidas básicas de las estaciones de la BSRN se encuentra la GHI, por lo que este tipo de medidas forman parte del programa BSRN en Izaña y pueden consultarse a través del siguiente enlace: <https://doi.pangaea.de/10.1594/PANGAEA.968676>. Las medidas empleadas en este trabajo (Sección 4.3), que corresponden con las del enlace, fueron tomadas con el piranómetro EKO MS-802NF (descrito en la Sección 2.1.2.3) que se encuentra instalado en esta estación desde el 11 de noviembre de 2016 (García *et al.*, 2019).

La cámara C011 que se encontraba en la estación de Valladolid, se trasladó al Instituto Interuniversitario de Investigación del Sistema Tierra en Andalucía (IISTA) en Granada. La estación de Granada, gestionada por el Grupo de Física Atmosférica de la Universidad de Granada (GFAT-UGR), se encuentra en dicha ciudad del sureste de la Península Ibérica. Esta ciudad, similar en tamaño y habitantes a Valladolid, se trata de una ciudad de tamaño medio no industrializada, rodeada por montañas de más de 1000 m (Valenzuela *et al.*, 2012). Las condiciones cuasi-continentales que prevalecen en este lugar son responsables de las diferentes temperaturas estacionales, provocando inviernos fríos y veranos calurosos. Debido a la cercanía de esta ciudad con el norte de África, los episodios de polvo procedente del Sahara son bastante frecuentes (Valenzuela *et al.*, 2012). En esta estación también se cuenta con un fotómetro CE318-T como parte de la red AERONET, cuyas medidas han sido empleadas en este trabajo.

Otro lugar donde el grupo tiene una cámara de todo cielo es en el observatorio de Lindenberg (Tauche, Alemania). En esta localidad al noreste de la región alemana de Brandeburgo (una tierra llana y verde, parcialmente boscosa), a unos 50 km al sureste de las afueras de Berlín, lejos de la costa y con una influencia predominantemente continental, se encuentra el *Meteorologisches Observatorium Lindenberg–Richard-Assmann-Observatorium* (MOL-RAO). Este observatorio pertenece al Departamento de Investigación y Desarrollo del Ser-

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

vicio Meteorológico Alemán (DWD del alemán *Deutscher Wetterdienst*). Se trata de una estación histórica, desde 1905, para la toma de medidas meteorológicas y atmosféricas que hoy en día se ha convertido en un “supersite”, tanto para las medidas meteorológicas como para las de parámetros atmosféricos y los procesos físicos de la atmósfera, desde la capa límite hasta la estratosfera. El MOL-RAO es una estación BSRN desde 1994. El GOA-UVa ha tenido dos cámaras OMEA-3C (C006 y C009) midiendo en esta estación. Además de los datos de las cámaras, en esta tesis se han empleado las medidas de AOD del fotómetro CE318-T y de GHI del piranómetro CM-22 instalados en esta estación.

La estación del *Physikalisch-Meteorologisches Observatorium Davos* (PMOD) en Davos, designada como WRC, se encuentra en la región montañosa de los Alpes orientales de Suiza (Karanikolas *et al.*, 2024). La zona no tiene contaminación local significativa. Los aerosoles pueden llegar a la zona desde otras partes de Europa debido a su proximidad a varios países europeos y durante episodios de fuerte transporte de polvo del Sahara (Karanikolas *et al.*, 2024). Esta estación, además de dirigir la red GAW-PFR, cuenta con diversa instrumentación entre la que se encuentran una cámara de todo cielo (modelo OMEA-3C, cuyo ID en GOA-SCAN es el C038) y un fotómetro CE318-T de la red AERONET. La cámara de esta estación, cuyo propietario es el PMOD/WRC, es la única de este trabajo que no pertenece al GOA-UVa.

Además de en las estaciones descritas, el GOA-UVa gestiona instrumentos en estaciones polares como parte del trabajo de los proyectos POLARMOON, ePOLAAR y TRIPOLI. Esta instrumentación se encuentra tanto en el Ártico como en la Antártida. El grupo gestiona un fotómetro CE318-T y una cámara de todo cielo OMEA-3C en cada una de estas estaciones. En el desarrollo de este trabajo han sido empleadas medidas tomadas en las estación ártica de Ny-Ålesund (Noruega), la estación sub-ártica de Andøya (Noruega), así como en la estación Antártica de Marambio.

La estación ártica de Ny-Ålesund, en el archipiélago de Svalvard, se trata de la estación más septentrional habitada del mundo. El clima típico de este lugar es de tundra (Herrero-Anta, 2021). Ny-Ålesund alberga la base de investigación ártica francoalemana AWIPEV (*Alfred Wegener Institute for Polar and Marine Research*, AWI; y *Polar Institute Paul Emile Victor*, PEV) (Herrero-Anta, 2021). Esta estación acoge proyectos de investigación y series de observación a largo plazo, contando con diversa instrumentación científica gestionada por entidades de distintas nacionalidades que se dedican al estudio de diversas disciplinas (Herrero-Anta, 2021). En colaboración con el AWI, el GOA-UVa instaló un fotómetro CE318-T en 2017 y una cámara OMEA-3C (C004). En el trabajo de esta tesis se han empleado tanto las imágenes de la cámara a partir de que se comenzó a utilizar la aplicación *GOA-OMEA Capture*, como las medidas de AOD del fotómetro.

La estación sub-ártica en la que el GOA-UVa posee instrumentación corresponde a la de Andøya Space Center (ASC, Andenes), la cual está situada a unos 300 km del círculo polar ártico en la costa norte de Noruega (Rodríguez *et al.*, 2011). En esta latitud las noches son claras entre finales de abril y finales de agosto, mientras que el Sol no sale desde principios de diciembre hasta mediados de enero, durante la llamada noche polar (Rodríguez *et al.*, 2011). Gracias a la corriente del Golfo las temperaturas son suaves todo el año (Rodríguez *et al.*, 2011). En esta estación, perteneciente al *Norwegian Institute for Air Research* (NILU), el GOA-UVa instaló la cámara C005 que se encontraba en el Centro de Investigación Atmosférica de Izaña. Además de la cámara de todo cielo, en esta estación se cuenta con un fotómetro CE-318T de la red AERONET.

El grupo instaló en la Antártida la mencionada instrumentación en la estación Argentina de Marambio en 2018, en colaboración con el Servicio Meteorológico Nacional (SMN) de Argentina. La estación de Marambio se encuentra en la isla de Marambio al noreste de la punta de la Península Antártica (González *et al.*, 2020). Se trata de una estación permanente, por lo que abre todo el año, y por tanto la instrumentación del grupo permanece midiendo en esta localización de manera indefinida gracias a la colaboración del grupo con la dotación argentina de esta estación. Ambos dispositivos llevan operativos desde la misma fecha, aunque las imágenes de la cámara (C003) utilizadas a lo largo del trabajo corresponden al periodo desde Agosto de 2020 en adelante, cuando se comenzó a utilizar la aplicación *GOA-OMEA Capture* para capturar dichas imágenes. Tanto la cámara como el fotómetro se encuentran instalados en la terraza del Pabellón Científico, localizado en el centro de la estación entre el aeródromo y los edificios de la estación. Este laboratorio pertenece al SMN y es compartido con la Dirección Nacional Antártica (DNA) de Argentina (González *et al.*, 2020). Además de los dispositivos del GOA-UVa, también se han utilizado los datos del piránometro CMP-11 instalado en esta estación, la cual cuenta con gran variedad de equipos enfocados en estudios atmosféricos mediante diferentes técnicas. Finalmente, de la estación de Marambio también se han empleado medidas de la cubierta de nubes realizadas por observadores meteorológicos.

2. INSTRUMENTACIÓN, DATOS Y ESTACIONES DE MEDIDA

Tabla 2.1: Información detallada sobre la localización y el periodo de medición de cada cámara de todo cielo de la red GOA-SCAN utilizada en este trabajo. La fecha Presente corresponde a 22 de enero de 2025. Tabla adaptada de Román *et al.* (2025).

ID Cámara	Modelo Cámara	Fecha Inicio	Fecha Fin	Estación	País	Latitud (°N)	Longitud (°E)	Altitud (m s.n.m.)	Responsable Estación	Propietario Cámara
C002	SONA-202NF	2018-07-11	2022-05-29	Valladolid	España	41.663	-4.706	710	GOA-UVa	GOA-UVa
C003	OMEA-3C	2018-01-26	Presente	Marambio	Antártida, Argentina	-64.240	-56.625	200	SMN	GOA-UVa
C004	OMEA-3C	2018-10-09	Presente	Ny-Ålesund	Noruega	78.923	11.923	38	AWI	GOA-UVa
C005	OMEA-3C	2020-07-16	2021-09-27	Valladolid	España	41.663	-4.706	710	GOA-UVa	GOA-UVa
C005	OMEA-3C	2021-10-06	2022-01-24	Fuencaliente	España	28.487	-17.849	630	AEMet	GOA-UVa
C005	OMEA-3C	2022-02-04	2023-02-15	Izaña	España	28.309	-16.499	2365	AEMet	GOA-UVa
C005	OMEA-3C	2023-04-18	Presente	Andøya	Noruega	69.278	16.009	380	ASC	GOA-UVa
C006	OMEA-3C	2020-07-29	2021-02-12	Lindenberg	Alemania	52.209	14.121	120	DWD	GOA-UVa
C009	OMEA-3C	2021-02-12	Presente	Lindenberg	Alemania	52.209	14.121	120	DWD	GOA-UVa
C011	OMEA-3C	2021-10-05	2024-01-11	Valladolid	España	41.663	-4.706	710	GOA-UVa	GOA-UVa
C011	OMEA-3C	2024-03-04	Presente	Granada	España	37.164	-3.605	673	GFAT-UGR	GOA-UVa
C013	OMEA-3C-TF	2023-06-27	Presente	Valladolid	España	41.663	-4.706	710	GOA-UVa	GOA-UVa
C038	OMEA-3C	2024-04-19	Presente	Davos	Suiza	46.813	9.844	1584	PMOD-WRC	PMOD-WRC

Redes Neuronales

3.1 Redes neuronales

Dentro del campo de la inteligencia artificial (IA), se encuentra el aprendizaje automático, también conocido como *machine learning*, que se basa en modelos en los que las máquinas extraen conocimiento a partir de los datos que se les proporciona de entrada (Bosch Rué *et al.*, 2019). Existen multitud de técnicas y modelos que permiten aprender a partir de un conjunto de datos, como modelos de regresión o modelos estadísticos. En muchos casos, estos modelos son capaces de aprender patrones a partir de los datos, pero no son capaces de aprender conceptos abstractos y complejos a partir de esos datos (Bosch Rué *et al.*, 2019).

Entonces, el *deep learning* surge como un subconjunto del *machine learning* en el que los modelos de aprendizaje son capaces de representar esos conceptos complejos y abstractos a partir de otros más sencillos de manera jerarquizada en múltiples capas, lo que le da el nombre debido a la profundidad que pueden presentar dichas capas (Bosch Rué *et al.*, 2019). Aunque existen otros modelos de aprendizaje automático que también son capaces de componer conceptos a partir de una jerarquía de conceptos más simples (Goodfellow *et al.*, 2016), actualmente el concepto de *deep learning* se asocia con las redes neuronales (NN del inglés *Neural Networks*), las cuales representan el estado del arte en el *deep learning* (Bosch Rué *et al.*, 2019).

Estos modelos se utilizan para una gran variedad de aplicaciones en distintas ramas de la ciencia y la tecnología (Abiodun *et al.*, 2018, 2019). Entre estas aplicaciones se encuentra la predicción de parámetros atmosféricos y meteorológicos (Hong *et al.*, 2004; Olcese *et al.*, 2015; Xie *et al.*, 2020; Yadav and Chandel, 2014). En esta tesis doctoral se ha utilizado una

3. REDES NEURONALES

red neuronal convolucional (CNN del inglés *Convolutional Neural Network*) desarrollada para la predicción de la CC y el CMF a partir de imágenes de todo cielo, lo que se presenta en los artículos de las Secciones 4.2 y 4.3. Las CNN suelen emplearse en el reconocimiento de imágenes debido a que han demostrado un gran funcionamiento en esta tarea (Fukushima, 1980; Krizhevsky *et al.*, 2012; Masuda *et al.*, 2019; Onishi and Sugiyama, 2017).

3.1.1 La Neurona

Las redes neuronales son un conjunto de algoritmos inspirados en el mecanismo de comunicación de la neurona biológica que han demostrado ser una buena aproximación a problemas donde el conocimiento es impreciso o variable en el tiempo, siendo su capacidad de aprender lo que las convierte en algoritmos adaptativos y elaborados a la vez (Bosch Rué *et al.*, 2019). Una red neuronal consiste en un conjunto de capas de elementos más básicos, las neuronas, conectados entre sí (Shalev-Shwartz and Ben-David, 2014). Una neurona es la unidad elemental de la red, la cual aplica una función determinada a los valores de sus entradas procedentes de las conexiones con otras neuronas, obteniendo un valor conocido como la salida de la neurona (Bosch Rué *et al.*, 2019).

Cada neurona tiene un conjunto de valores de entrada, $X = \{x_1, x_2, \dots, x_n\}$, donde cada una de estas entradas está ponderada por un conjunto de pesos, $W^i = \{w_1^i, w_2^i, \dots, w_n^i\}$. Entonces, el valor de w_j^i denota la importancia del valor de entrada x_j que llega a la neurona i procedente de la neurona j . La neurona combina los valores de entrada, aplicando sobre ellos una función de entrada z_i , y procesa el resultado mediante una función de activación que modula el valor de las entradas para generar la salida y_i . Este valor generalmente se propaga a las conexiones de la neurona i con otras neuronas o bien se emplea como valor de salida de la red (Bosch Rué *et al.*, 2019). En la Figura 3.1 se muestra el esquema del modelo de neurona.

Entre las funciones de entrada, la más utilizada es la suma ponderada, que se representa según la siguiente ecuación 3.1:

$$z(x) = \sum_{j=1}^n x_j w_j^i + b^i. \quad (3.1)$$

Aunque existen otras y la elección de la función de entrada depende del problema y de los datos empleados (Bosch Rué *et al.*, 2019). Se suele añadir el sesgo (*bias*) b^i que está relacionado con el valor umbral de la función de activación y representa la parte invariante de la predicción de la neurona (Aggarwal *et al.*, 2018). El umbral de activación indica el valor a partir del cual la entrada hace que la neurona se active, lo que corresponde al caso en el que la salida alimenta la entrada de la siguiente capa (Rasamoelina *et al.*, 2020). El *bias*

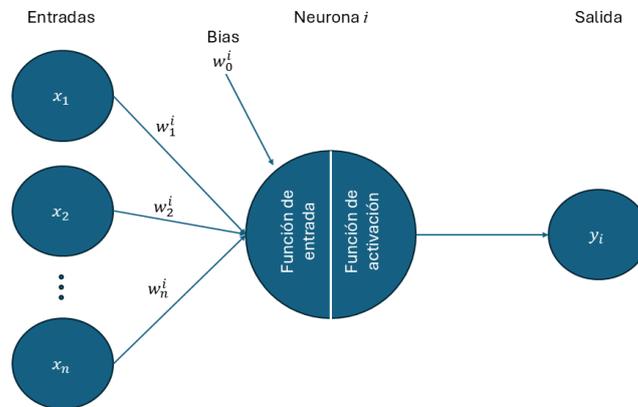


Figura 3.1: Esquema de una neurona: los valores del conjunto de parámetros de entrada X , ponderado cada uno con su respectivo peso del conjunto W^i , se combinan mediante una función de entrada en la neurona i . Finalmente, esta procesa el resultado mediante una función de activación para obtener la salida y_i .

se añade como el peso w_0^i de una entrada cuyo valor corresponde a $x_0 = 1$, como se muestra en la Figura 3.1. Una vez combinados los valores de entrada con sus respectivos pesos, se aplica la función de activación de la neurona al resultado obtenido para generar el valor de salida introduciendo no linealidad al modelo. Entre estas funciones las más destacadas son:

- Función escalón:

$$y(z) = \begin{cases} 0 & \text{si } z \geq 0, \\ 1 & \text{si } z < 0. \end{cases} \quad (3.2)$$

La salida de esta función también puede ser $\{-1, 1\}$. Combinando esta función de activación con la suma ponderada como función de entrada, se obtiene la neurona conocida como perceptrón, que es una estructura propuesta por Rosenblatt (1962). Esta estructura tiene su relevancia histórica ya que se considera la primera red neuronal, aunque debido a sus limitaciones como la incapacidad de clasificar clases no separables linealmente, no es muy utilizada en la actualidad (Matich, 2001). En consecuencia de las funciones utilizadas, la salida del perceptrón es un valor binario (Bosch Rué *et al.*, 2019).

- Función sigmoide:

3. REDES NEURONALES

$$y(z) = \frac{1}{1 + e^{-z/\rho}}, \quad (3.3)$$

donde ρ es el parámetro que determina la forma de la curva, actuando como un separador que hace más o menos suave la salida. Utilizando la suma ponderada como función de entrada junto con la sigmoide como función de activación, se obtiene la neurona sigmoide que es muy utilizada en la actualidad (Bosch Rué *et al.*, 2019). Debido a la combinación de estas funciones, su salida es un valor continuo en el rango $[0, 1]$. La salida de esta neurona tiene cierta similitud con la del perceptrón, pero presentando mayor suavidad al permitir valores intermedios. Esta suavidad es crucial, ya que significa que pequeños cambios en los pesos y el sesgo producen un pequeño cambio en la salida, lo que permite que sea más fácil definir como afectan estos cambios a la salida de la neurona (Bosch Rué *et al.*, 2019).

- Tangente hiperbólica:

$$y(z) = \tanh(z) = \frac{\sinh(z)}{\cosh(z)} = \frac{e^z - e^{-z}}{e^z + e^{-z}}. \quad (3.4)$$

Esta función de activación proporciona a una neurona un comportamiento similar al de la función sigmoide, con la diferencia de que la salida es un valor continuo en el rango $[-1, 1]$ en este caso (García-Pajares, 2024).

- Función rectificadora:

$$y(z) = \max(0, z). \quad (3.5)$$

Esta función, también conocida como función rampa, se calcula obteniendo la parte positiva de su argumento. Empleando esta función de activación con la suma ponderada como función de entrada, la neurona resultante se conoce como unidad lienal rectificadora (ReLU del inglés *Rectified Linear Unit*). Esta neurona es de las más importantes y utilizadas en las redes neuronales profundas (DNN del inglés *Deep Neural Networks*) (Bosch Rué *et al.*, 2019). El resultado de combinar ambas funciones da como salida de esta neurona un valor continuo en el rango $[0, +\infty]$.

3.1.2 Arquitectura de redes neuronales

Las neuronas, así como los parámetros que afectan a la configuración de estas tales como las funciones de entrada o activación, se organizan en capas formando la arquitectura de las redes neuronales (Bosch Rué *et al.*, 2019). En el caso más simple, una red neuronal consiste en una única neurona conectada a todas la entradas disponibles y con una única salida como la mostrada en la Figura 3.1. En la Figura 3.2 se muestra un esquema generalizado de una red neuronal, en el que se ve que estas cuentan con tres tipos de capas:

- Capa de entrada: Esta recibe los valores del conjunto X de entrada.
- Capas intermedias: Estas capas se conocen también como capas ocultas y son las que procesan los datos que reciben de la capa anterior y devuelven como salida los valores de entrada de la siguiente capa (Longarela-Fuente, 2025). En el caso más simple, que se conoce como red monocapa, solo hay una capa oculta formada por un conjunto variable de neuronas (Shalev-Shwartz and Ben-David, 2014). Cuando hay más de una capa oculta, estas redes multicapa se denominan redes neuronales profundas, que son las que representan la columna vertebral de los algoritmos de *deep learning* basados en redes neuronales (Bosch Rué *et al.*, 2019). De las funciones de activación descritas, la función rectificadora se popularizó debido a que permite un mejor entrenamiento de estas redes DNN y actualmente es la más popular (Glorot *et al.*, 2011).
- Capa de salida: Esta última capa da el resultado de la predicción de la red. Como se ve en la Figura 3.2, el número de neuronas que hay en la capa de salida puede ser muy variado, dependiendo del problema de estudio. Por ejemplo, en un caso de clasificación binaria se emplea una neurona. Sin embargo, en casos de clasificación en m grupos se suelen utilizar m neuronas que indican la pertenencia a cada clase (Bosch Rué *et al.*, 2019; Longarela-Fuente, 2025).

El hecho de añadir más neuronas y capas a una red generalmente aumenta el poder y la capacidad de predicción, así como la capacidad de separación de dicha red. Aunque esto aumenta el coste computacional y la tendencia a la sobrespecialización, que se conoce por su nombre en inglés *overfitting*, lo que hace que la red pierda capacidad para predecir valores fuera del conjunto de entrenamiento (Bosch Rué *et al.*, 2019). Aunque no hay un criterio fijo a la hora de añadir capas y neuronas a una red, éstas se van ajustando en base a la evaluación del modelo, aumentando el número si el modelo no se ajusta bien y disminuyendo si hay sobreajuste, siendo común utilizar un número de neuronas en las capas ocultas en un rango de una y dos veces el número de entradas de la red (Bosch Rué *et al.*, 2019). En el caso

3. REDES NEURONALES

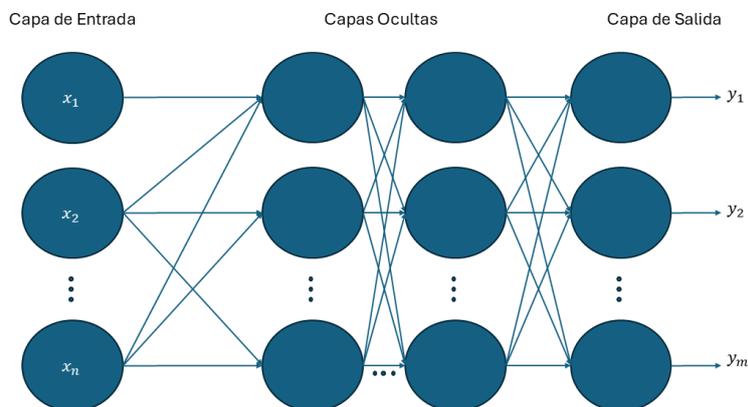


Figura 3.2: Esquema general de red neuronal.

de que todas las neuronas de una capa estén conectadas con las de la siguiente, la red se denomina como totalmente conectada.

3.1.3 Entrenamiento de redes neuronales

Los errores cometidos por una red neuronal se pueden considerar como una retroalimentación que requiere ajustar los pesos entre neuronas, con el fin de mejorar la precisión de sus predicciones. A través de ajustes sucesivos, entrenando la red con múltiples datos, ésta perfecciona su capacidad de generalizar; es decir, predecir correctamente salidas para entradas no vistas anteriormente (Aggarwal *et al.*, 2018). Primero se escoge una función de coste, o pérdida, que calcule los mencionados errores entre las salidas del modelo y los valores reales del conjunto de datos de entrenamiento. Entre estas funciones destacan la de error cuadrático medio (*mse* del inglés *mean square error*) y la función de entropía cruzada (*cross entropy*).

La función *mse* viene expresada por la ecuación 3.6:

$$mse = \frac{1}{n} \sum_{i=1}^n (y_{real}^i - y_{pred}^i)^2, \quad (3.6)$$

donde n es el número total de clases, y_{real}^i es el valor real y y_{pred}^i el predicho por la red. Esta función de coste, empleada mayormente en problemas de regresión, es más sensible a errores grandes por lo que se emplea para penalizar más los casos en los que la predicción se aleja más de valor real que los casos en los que los valores son cercanos al real aunque sean ligeramente distintos (Longarela-Fuente, 2025).

La función de entropía cruzada se expresa según la ecuación 3.7:

$$H(p, q) = - \sum_i p(x_i) \log(q(x_i)), \quad (3.7)$$

donde $p(x_i)$ es la distribución de probabilidad de los valores reales y $q(x_i)$ la de los valores predichos por la red, siendo la suma sobre todas las clases i . En definitiva, con esta función se trata de minimizar las diferencias entre ambas distribuciones de probabilidad, siendo bastante eficaz en problemas de clasificación. En el caso de problemas binarios, en los que el modelo genera valores de salida 0 o 1, esta función no solo penaliza las predicciones incorrectas, sino también las que tienen baja certeza (Longarela-Fuente, 2025). En el caso de problemas de clasificación multiclase, se utiliza una variante de esta función, la cual se conoce como función de entropía cruzada categórica (*categorical cross entropy*). Esta versión se expresa mediante la ecuación 3.8:

$$H(p, q) = - \sum_{i=1}^C y_{real}^i \log(y_{pred}^i), \quad (3.8)$$

donde y_{real}^i es un valor binario, que corresponde a un 1 si la clase i es correcta y un 0 si no lo es, y_{pred}^i es la probabilidad predicha para la clase i y C el número total de clases.

Una vez definida la función de coste se puede medir la certeza de las predicciones de la red para unos pesos y sesgos dados y reajustar estos parámetros para mejorar las predicciones. Para medir dicha certeza, analizando la función de coste, lo que se busca es llegar al mínimo global de esta función. Los puntos críticos de una función, máximos y mínimos, son aquellos en los que la derivada es nula. El punto será un mínimo local cuando la función es menor en dicho punto que en los más cercanos y un máximo local en caso contrario Goodfellow *et al.* (2016). También hay que tener en cuenta que los puntos críticos que no son ni máximos ni mínimos son puntos de silla de la función. Un punto que obtiene el valor más bajo absoluto de la función es el mínimo global buscado. Entonces, lo que se hace es, partiendo de un punto inicial arbitrario, analizar las derivadas de la función y moverse por ella con pequeños cambios buscando el mínimo global (Goodfellow *et al.*, 2016). Para esto se utiliza el concepto del gradiente de la función que almacena la información sobre la pendiente en cada dirección mediante las derivadas parciales en función de los parámetros. Este vector indica como actualizar estos parámetros para encontrar el punto deseado, lo que se expresa mediante la ecuación 3.9:

$$\theta = \theta - \eta \nabla_{\theta} f(\theta) \quad (3.9)$$

donde θ es el vector de parámetros que se trata de ajustar, $\nabla_{\theta} f(\theta)$ es el gradiente de la función de coste y η el parámetro conocido como tasa de aprendizaje (*Learning Rate*), la

3. REDES NEURONALES

cual controla el tamaño de los pasos en cada iteración (Longarela-Fuente, 2025). Cada vez que se completan todas la iteraciones una vez, es decir, que se han utilizado todos los datos del conjunto de entrenamiento, se dice que ha pasado una época (Longarela-Fuente, 2025). En las redes multicapa se tiene el inconveniente de no saber con certeza los valores correctos de cada salida de las capas ocultas (Bosch Rué *et al.*, 2019). Por tanto, para aplicar el método del descenso del gradiente se requiere de lo que se conoce como método de retropropagación (*backpropagation*), que se basa en dos pasos: (1) una propagación hacia adelante basada en introducir una instancia de entrenamiento y obtener la salida de la red, y (2) una propagación hacia atrás consistente en calcular el error de la capa de salida y propagarlo a todas las neuronas de las capas ocultas (Bosch Rué *et al.*, 2019). Este método se detalla en Longarela-Fuente (2025).

3.2 Redes neuronales convolucionales

Las redes neuronales convolucionales (LeCun *et al.*, 1989) son un tipo de redes para procesar datos con tipología de cuadrícula, como las imágenes (Bosch Rué *et al.*, 2019). Las CNN están compuestas por ciertos tipos de capas, siendo las más relevantes las capas de convolución ya que se basan en el empleo de esta operación, que apiladas forman la arquitectura de estas redes (O’Shea and Nash, 2015). Entre estas capas este trabajo se va a centrar en las de convolución, las de agrupamiento o *pooling* y las totalmente conectadas.

3.2.1 Capas de convolución

La capa de convolución juega un papel fundamental en el funcionamiento de las CNN (O’Shea and Nash, 2015). Para entender la importancia de esta capa, primero hay que partir del concepto de convolución. La convolución se trata de una operación matemática sobre dos funciones, f y g , que produce una tercera función, s , que expresa como una es modificada por la otra al desplazarse sobre ella una distancia t (Bosch Rué *et al.*, 2019). Denotando la operación de convolución con un asterisco y teniendo en cuenta que en el caso de imágenes los datos son discretos, ésta se expresa según la ecuación 3.10:

$$s(t) = (f * g) = \sum_{\tau=-\infty}^{\tau=\infty} f(\tau)g(t - \tau)d\tau. \quad (3.10)$$

En la terminología de las redes convolucionales, la función f de la ecuación 3.10 se refiere a la entrada, la función g es el filtro, conocido como *kernel*, y la función s la salida. En el contexto de las CNN, a la función s de salida se le llama mapa de características

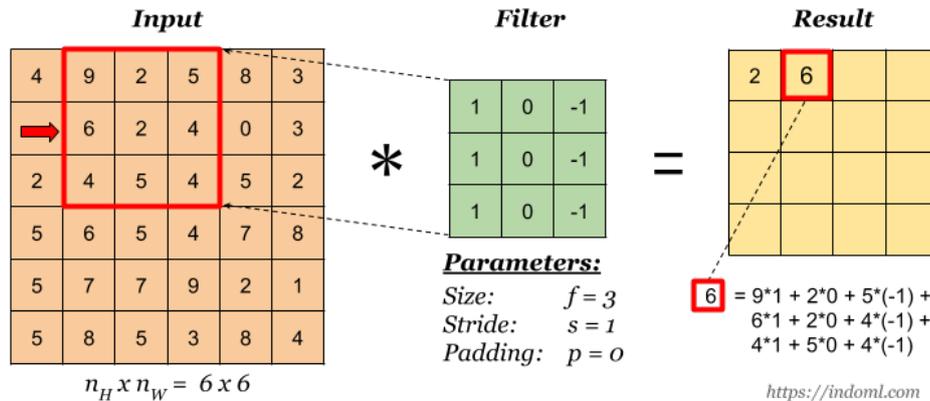


Figura 3.3: Ejemplo sobre la aplicación de la operación de convolución que reduce a la salida la dimensión de la matriz de entrada. Figura obtenida de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>

(Dumoulin and Visin, 2016). En la capa de convolución son importantes los conceptos de *kernel*, convolución por pasos (*strides*) y *padding* que se detallan a continuación.

El *kernel*, o filtro, es la matriz de pesos de una capa de convolución dentro de una CNN (Bosch Rué *et al.*, 2019). La matriz del *kernel*, que es de menor dimensión, se aplica sobre la matriz del mapa de característica de entrada en la región en la que se superponen. Se calcula el producto de los elementos superpuestos de ambas matrices y se suman obteniendo el elemento de salida en la posición correspondiente de la matriz de salida, que da como resultado una matriz reducida con respecto a la de entrada. Esto se repite hasta obtener el mapa de características de salida completo, como se muestra en la Figura 3.3. En este ejemplo se muestra una matriz de entrada con dimensión 6x6 a la que se aplica un *kernel* de tamaño 3x3, que como resultado de la convolución se obtiene una salida con dimensión 4x4.

En el caso de imágenes RGB la convolución se hace en 3D, siendo las dimensiones la altura, anchura y los tres canales RGB de la imagen (Bosch Rué *et al.*, 2019; Dumoulin and Visin, 2016). En este caso, se tendrían tres matrices de entrada, una por cada canal de color de la imagen, a las que se aplica un *kernel* compuesto de 3 matrices ya que deben tener el mismo número de canales aunque se pueda aplicar a la entrada más de un *kernel* (Bosch Rué *et al.*, 2019). En la Figura 3.4 se muestra un ejemplo similar al de la Figura 3.3 con la diferencia de que tanto la entrada como el *kernel* son tridimensionales. En este caso, la dimensión de dichas matrices incluyen la profundidad, además de la altura y anchura del caso bidimensional.

Se pueden aplicar tantos *kernels* como sea necesario según la salida deseada, ya que puede ser de interés obtener diferentes características (Dumoulin and Visin, 2016). En la Figura 3.5 se muestra un ejemplo en el que se aplican tres *kernels* de dimensión 3x3x3 a una

3. REDES NEURONALES

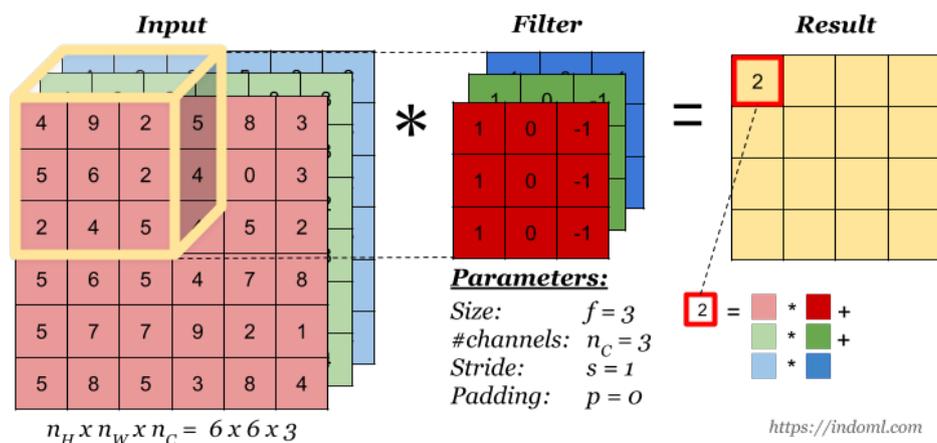


Figura 3.4: Ejemplo de convolución en tres dimensiones, donde la entrada y el *kernel* añaden la dimensión de profundidad, que debe ser la misma para ambas matrices, con respecto al caso bidimensional. La profundidad indica el número de canales, como por ejemplo en el caso de una imagen RGB serían los canales de color rojo, verde y azul. Figura obtenida de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>

entrada de $6 \times 6 \times 3$. Como resultado de esta operación, el mapa de características a la salida tiene una dimensión de $4 \times 4 \times 2$. Entonces, al aplicar una convolución se reduce la dimensión de la entrada en altura y anchura, pero al aplicar más de un *kernel* la salida tiene mayor profundidad debido a que se obtienen más características.

Esta operación de convolución se puede aplicar también por pasos utilizando lo que se conoce como *stride*. En lugar de aplicar el *kernel* en cada celda de la entrada (*stride* = 1) se puede hacer con un paso distinto. Por ejemplo, si se elige un *stride* de 2, la convolución se aplicaría en las celdas con un salto de 2, tanto en la dimensión horizontal como en la vertical (Bosch Rué *et al.*, 2019), como se muestra en la Figura 3.6. En el ejemplo mostrado, el mismo *kernel* de 3×3 de los ejemplos anteriores con un *stride* de 2 aplicado sobre la misma entrada de 3×3 , proporciona una salida de dimensión 2×2 . La operación de convolución sirve para reducir la dimensión de los datos de entrada y ganar eficiencia en los tiempos de ejecución, con el coste de perder alguna característica en la salida. Por tanto, aplicar la convolución con un paso, o *stride* mayor que 1 puede ser más eficiente, aunque hay que tener en cuenta el equilibrio entre la reducción de los datos de entrada y las características de salida que se pierden (Bosch Rué *et al.*, 2019).

Tanto el *kernel* como el *stride* reducen la dimensión de la salida de la capa de convolución. En las redes neuronales profundas se intenta no reducir la dimensión rápidamente. Para esto, se puede aplicar un *kernel* pequeño, además de que es común aplicar lo que se llama el *zero-padding* para mantener la dimensión. Esta técnica de *zero-padding* consiste en añadir

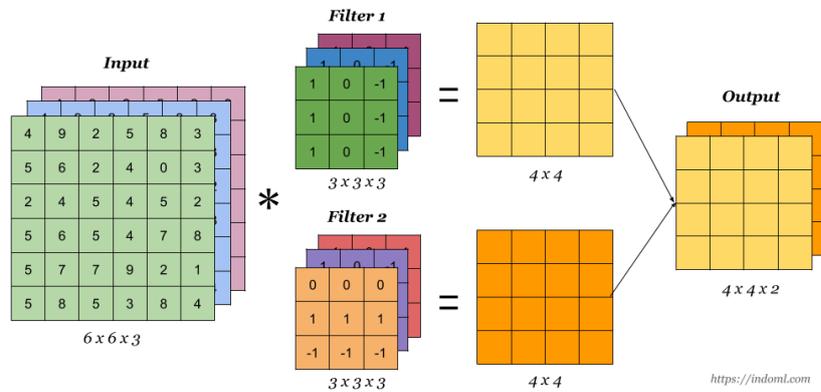


Figura 3.5: Aplicación de dos *kernels* en un operación de convolución, lo que proporciona mayor profundidad a la salida que aplicando únicamente un *kernel*. Figura obtenida de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>

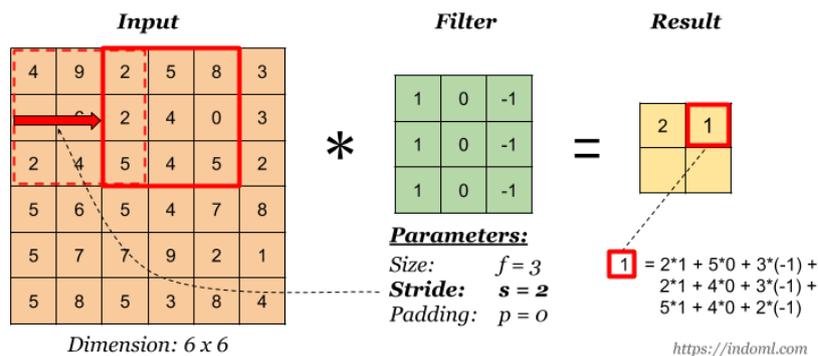


Figura 3.6: Aplicación de una convolución utilizando con un *stride* de 2 para reducir más a la salida la dimensión de la matriz de entrada. Figura obtenida de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>

3. REDES NEURONALES

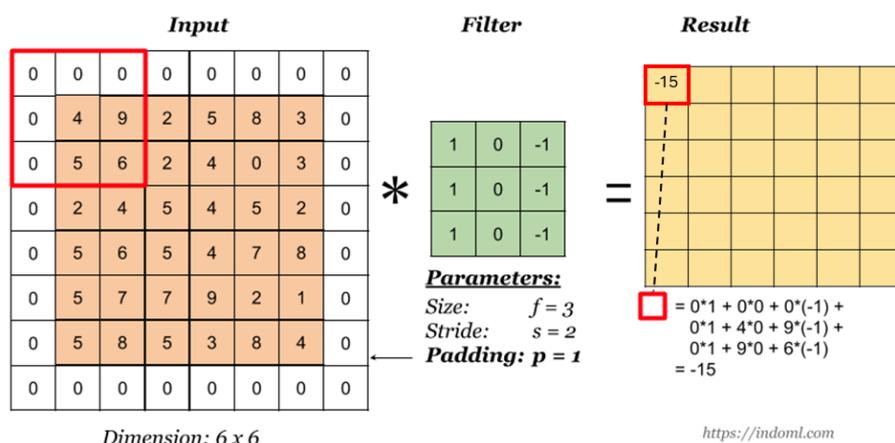


Figura 3.7: Aplicación de una convolución utilizando el *zero-padding* que rellena con ceros los bordes de la entrada para mantener la dimensión original a la salida. Figura obtenida de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>

ceros al borde la entrada, manteniendo la dimensión a la salida tras aplicar la convolución (Bosch Rué *et al.*, 2019). En la Figura 3.7 se muestra un ejemplo del *padding* en el que al añadir los ceros al borde de la matriz de entrada, cuya dimensión inicial es de 6x6, a la salida se obtiene una matriz de 6x6 tras aplicar un *kernel* de tamaño 3x3.

Junto con la capa de convolución, que representaría la capa de entrada que realiza operaciones lineales equivalentes a la suma ponderada de los datos de entrada, es muy habitual aplicar una capa de activación que introduce la no linealidad al sistema (Bosch Rué *et al.*, 2019). La función más utilizada en esta capa de activación es la ReLU, introducida en la Sección 3.1, ya que hace que la red sea capaz de entrenar más rápido sin afectar a la precisión final del modelo (Bosch Rué *et al.*, 2019). En la ecuación 3.5 se puede observar que esta capa de activación ReLU cambia los valores negativos por 0, incrementando las propiedades no lineales del modelo y de toda la red, sin que esto afecte a los campos receptivos de la capa de convolución (Krizhevsky *et al.*, 2010).

3.2.2 Capas de *pooling*

Después de las capas convolucionales se emplean las capas de *pooling*, que reducen el tamaño de los mapas de características al utilizar alguna función para condensar subregiones, como tomar el valor máximo o promedio (Dumoulin and Visin, 2016). El *pooling* funciona deslizando una ventana a lo largo de la entrada y aplicando una función de agrupación al contenido de cada región. En cierto sentido, el *pooling* funciona de forma muy similar a una

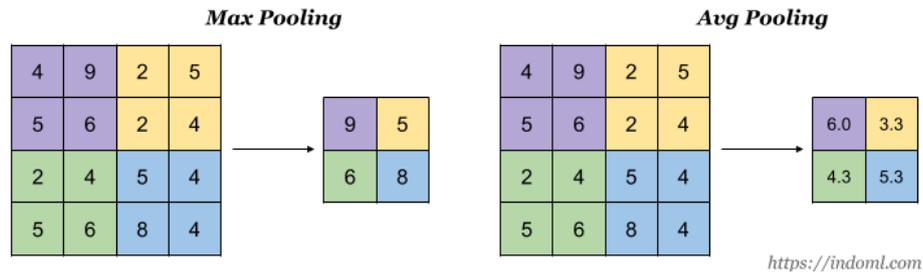


Figura 3.8: Capas de *pooling*. En el panel izquierdo se muestra el caso de aplicar sobre la entrada la operación de *max-pooling* que toma a la salida el valor máximo de cada región coloreada. En el panel derecho se aplica la misma operación cambiando la función máximo por el promedio, lo que se conoce como *average-pooling*. Figura obtenida de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>

convolución discreta, pero reemplaza la combinación lineal descrita por el *kernel* con otra función (Dumoulin and Visin, 2016). La función más utilizada en estas capas es la función máximo, lo que se conoce como *max-pooling* (Bosch Rué *et al.*, 2019), como el ejemplo mostrado en el panel de la izquierda de la Figura 3.8. En este caso, la ventana de 2x2 que se desliza por la entrada de 4x4, devuelve a la salida el valor máximo de cada subregión, como se aprecia en las regiones coloreadas. Hay otro tipo de operación, aunque no se utiliza tanto, que es el *average-pooling*, la cual calcula el promedio de los valores en lugar del máximo (Bosch Rué *et al.*, 2019), como se aprecia en el panel derecho de la Figura 3.8.

3.2.3 Capas totalmente conectadas

Al final de las CNN se suelen insertar una o varias capas totalmente conectadas. Estas capas, que tienen conectada cada salida de la capa anterior con todas sus entradas, devuelven como salida un vector cuya dimensión es el número de clases que el modelo tiene que escoger. Las salidas que reciben de la capa anterior representan un mapa de características de alto nivel. Lo que hacen estas capas es devolver la probabilidad de que la característica recibida pertenezca a una clase u otra. Por ejemplo, si se quieren identificar perros en una imagen, estas capas devolverían valores altos en los mapas que representen características de alto nivel como patas o cola (Bosch Rué *et al.*, 2019).

3.3 Red neuronal desarrollada

El modelo elegido en esta tesis doctoral para estimar la CC y el CMF a partir de las imágenes del cielo diurno ha sido una CNN. La arquitectura de la CNN propuesta (ver Figura 3.9), ha

3. REDES NEURONALES

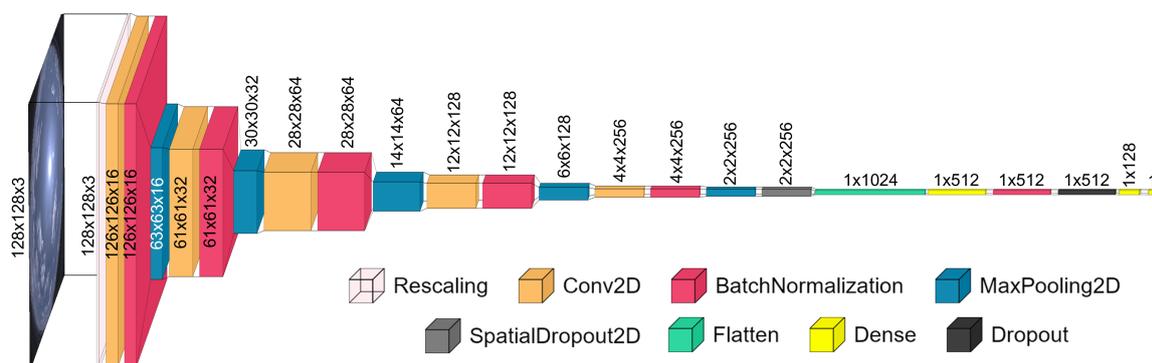


Figura 3.9: Esquema de la arquitectura de la red neuronal convolucional desarrollada. Figura obtenida de (González-Fernández *et al.*, 2024a).

La CNN ha sido diseñada utilizando *Keras* (Chollet *et al.*, 2015), la interfaz de programación de aplicaciones de Python de la plataforma de aprendizaje automático *TensorFlow* (Abadi *et al.*, 2015). La diferencia entre ambos modelos es el número de clases con el que se entrenan, ya que para el CMF se utilizan 130 clases en el entrenamiento en lugar de las 9 clases de la CC. Ambos modelos están diseñados para tener una última neurona que proporciona un único número de salida. En el caso del CMF la salida se ha acotado a un valor entre 0.01 y 1.30, mientras que en el caso de la CC la salida se ha acotado a un número entero entre 0 y 8 octas. Esto se ha hecho para limitar la salida de ambos modelos al rango de valores con los que se ha entrenado.

La CNN se ha configurado para recibir como entrada imágenes HDR del cielo con un tamaño de $128 \times 128 \times 3$ píxeles, donde la tercera dimensión (tamaño = 3) representa el color de la imagen (rojo, verde y azul). Por tanto, primero es necesario redimensionar las imágenes antes de ejecutar el modelo. La primera capa de la red es de reescalado, la cual divide la señal de 8 bits (0-255) de cada píxel de la imagen de entrada por 255 para normalizar la señal a un valor entre 0 y 1. Las siguientes tres capas son las siguientes: la primera se trata de una capa convolucional en dos dimensiones (*Conv2D*) con 16 filtros y un tamaño de *kernel* de 3×3 , donde la función ReLU se utiliza como función de activación y no se emplea el *zero-padding* para rellenar con ceros, lo que implica una reducción de 2 píxeles en ancho y alto después de la convolución. La segunda es una capa de normalización (*BatchNormalization*), que aplica una transformación que mantiene el valor medio de la salida cerca de cero y la desviación estándar cerca de uno (Ioffe and Szegedy, 2015). La tercera se trata de una capa *max-pooling* (*MaxPooling2D*), que reduce las dimensiones espaciales de entrada tomando el valor máximo en una ventana de 2×2 píxeles. Estas tres capas aparecen conectadas consecutivamente cuatro veces más, duplicando el número de filtros de la capa de convolución cada vez. Este proceso reduce la altura y la anchura de las imágenes del cielo filtradas, aumentando la

profundidad de las matrices, para extraer mapas de características de la imagen.

Después de la última capa *max-pooling*, que proporciona 256 imágenes con un tamaño de 2×2 , se agrega una capa de descarte bidimensional (*SpatialDropout2D*), pero solo se aplica durante el entrenamiento de la red, eliminando aleatoriamente el 20 % de todos los mapas de características bidimensionales (Tompson *et al.*, 2015). El *Dropout* es una técnica para prevenir el *overfitting* que involucra la desactivación de neuronas (con sus conexiones de entrada y salida) en el entrenamiento. Esto introduce ruido al proceso de aprendizaje, ayudando a evitar el *overfitting* (Longarela-Fuente, 2025). Luego, una vez que se obtienen los mapas de características, la salida de la CNN en este punto se redimensiona a una dimensión, en este caso a 1024 valores, con otra capa (*Flatten*) para iniciar una capa completamente conectada. La siguiente capa es una capa regular densamente conectada (*Dense*), que proporciona una salida de 512 valores utilizando ReLU como función de activación. Esta salida también se normaliza mediante una capa *BatchNormalization*, que está conectada directamente con otra capa *Dropout* que quita aleatoriamente el 20 % de los valores que llegan a la capa durante el entrenamiento. Por último, la CNN tiene dos capas densamente conectadas: la primera con 128 neuronas y una función de activación ReLU; la segunda y última capa con una función de activación lineal y una sola neurona de salida, que proporciona un número que representa la CC o el CMF, dependiendo del modelo que se esté considerando, de la imagen del cielo utilizada como entrada. Este resultado final se redondea a un número entero entre 0 y 8 octas en el caso de la CC, mientras que para el CMF se obtiene un número en el rango de 0.01 hasta 1.30, para tener un valor adecuado similar al utilizado en la clasificación.

Esta CNN ha sido entrenada en ambos casos con parte de las imágenes clasificadas del cielo. El resto de las imágenes se han utilizado para calcular el rendimiento de la CNN en cada caso. Las imágenes del cielo se han dividido en tres conjuntos de datos. Los conjuntos de entrenamiento y validación forman parte del proceso de entrenamiento del modelo, donde el conjunto de validación corresponde a la muestra de datos utilizada para proporcionar una evaluación objetiva del ajuste del modelo en el conjunto de datos de entrenamiento después de cada época mientras se ajustan los parámetros del modelo para hacer un entrenamiento dinámico. El conjunto de prueba es la muestra de datos utilizada para proporcionar una evaluación objetiva del modelo final.

Una vez formados los conjuntos de datos, se entrenan ambos modelos siguiendo un método similar. La función de pérdida elegida en el entrenamiento es la *mse*. Esta función se ha utilizado en lugar de otras, ya que se ha considerado que el modelo debe penalizar más los casos en los que los valores predichos están más alejados de la referencia etiquetada que los casos en los que los valores predichos y de referencia están más cerca incluso cuando no son los mismos. El entrenamiento se ha realizado mediante lotes, cada uno con un tamaño de 32,

3. REDES NEURONALES

cada lote formado por 32 imágenes. El optimizador utilizado es el algoritmo de *Adam* (estimación de momento adaptativo; Kingma and Ba, 2014) con una tasa de aprendizaje inicial de 0.001. Esta tasa de aprendizaje se reduce dinámicamente dividiéndola entre 10 cuando la métrica de pérdida del conjunto de validación no mejora en cinco épocas consecutivas, lo que se calcula con *Keras* mediante *ReduceLROnPlateau*. El entrenamiento se ha configurado para detenerse cuando el valor de pérdida del conjunto de validación no mejora después de 10 épocas consecutivas, mediante *early_stopping*, tratando de evitar un sobreajuste de la red. Con esta configuración se ha entrenado la CNN en ambos casos, presentando en las Secciones 4.2 y 4.3 los modelos correspondientes a la estimación de la CC y del CMF, así como los resultados obtenidos por estos.

Resultados

4.1 Artículo 1: Star photometry with all-sky cameras to retrieve aerosol optical depth at night-time

4.1.1 Resumen y comentarios

Los aerosoles atmosféricos juegan un papel importante en el sistema climático terrestre, ya que afectan al balance radiativo de diversas maneras. Sin embargo, el impacto de los aerosoles en el clima tiene una gran incertidumbre. En consecuencia, el estudio de los aerosoles y de sus propiedades es fundamental para reducir dicha incertidumbre. Entre las propiedades de estas partículas, este trabajo se centra en el AOD.

El AOD se suele medir mediante fotómetros, a través de la irradiancia solar directa que llega a la superficie del planeta, proporcionando amplias series de datos durante el día. Para completar los ciclos y tener una mayor continuidad es necesario medir esta propiedad de los aerosoles durante la noche, especialmente en las zonas polares debido a la ausencia de luz solar durante periodos de tiempo bastante prolongados. Existen modelos de fotómetros capaces de medir el AOD durante la noche mediante medidas de la irradiancia lunar, lo que completa parcialmente las series de datos, ya que la Luna no es visible durante la mitad de su ciclo. Para una mayor cobertura temporal se emplean fotómetros estelares, que aprovechan la irradiancia de la estrellas. Sin embargo, hay muy pocos de estos instrumentos debido a su coste y complejidad.

Las cámaras de todo cielo ofrecen una alternativa más económica, lo que puede proporcionar una gran cobertura espacial. También ofrecen una gran cobertura temporal debido a

4. RESULTADOS

que se configuran para tomar imágenes hemisféricas de la bóveda celeste cada pocos minutos, y permiten obtener la irradiancia de múltiples estrellas a la vez. Con todo esto, se puede calcular el AOD nocturno y complementar a las medidas de los fotómetros.

En este trabajo se propone y desarrolla una nueva metodología para llevar a cabo esta tarea, empleando ocho cámaras de todo cielo en nueve localidades diferentes configuradas para obtener imágenes del cielo cada 2 minutos durante la noche. Para extraer la señal de la luz de cada estrella de una lista predefinida de 56 estrellas a partir de los datos brutos de las cámaras de todo cielo, se elimina la luz de fondo, se seleccionan los píxeles de cada estrella y se extrae la señal correspondiente de estos. A continuación, se realiza la calibración Langley de los instrumentos para cada estrella y canal de color, con lo que se puede obtener el TOD. El siguiente paso es calcular la longitud de onda efectiva para cada canal de la cámara. Después, se calcula el AOD restando la contribución de los gases atmosféricos al TOD. Una vez obtenido el AOD bruto, se aplican diferentes criterios para promediar y filtrar las nubes, asegurando la calidad de las series temporales de AOD. Estas series obtenidas mediante la metodología desarrollada se comparan con medidas independientes de AOD realizadas con fotómetros lunares ubicados en las nueve estaciones junto a las cámaras de todo cielo correspondientes.

Los resultados obtenidos muestran en general que el AOD obtenido con el método propuesto presenta una correlación con los valores de referencia, alcanzando a menudo un coeficiente de correlación superior a 0.90. Los valores de AOD obtenidos con las cámaras, que presentan una precisión en un rango de 0.03 y 0.04, tienden a sobreestimar a los de referencia en aproximadamente 0.02. La concordancia entre estos datos varía con la longitud de onda y disminuye en latitudes altas, lo que probablemente sea consecuencia del menor rendimiento del método de Langley en estas zonas. Por otra parte, los valores de AOD se ajustan bien en las transiciones entre el día y la noche obtenidas por los fotómetros solares al representar la evolución temporal de las series de datos, lo que demuestra su fiabilidad. A pesar de la ligera sobreestimación, los valores de AOD obtenidos con este nuevo método se aproximan a los valores reales de referencia y ofrecen cobertura durante toda la noche, sin necesidad de la presencia de la Luna.

A continuación se presenta el trabajo que detalla la metodología desarrollada, mostrando los resultados obtenidos y el análisis de los mismos.

Referencia: Román, R., González-Fernández, D., Antuña Sánchez, J. C., Herrero del Barrio, C., Herrero-Anta, S., Barreto, A., Cachorro, V. E., Doppler, L., González, R., Ritter, C., Mateos, D., Kouremeti, N., Copes, G., Calle, A., Granados-Muñoz, M. J., Toledano, C., and de Frutos, A. M. (2025). Star photometry with all-sky cameras to retrieve aerosol optical

4.1 Artículo 1: Star photometry with all-sky cameras to retrieve aerosol optical depth at night-time

depth at night-time. Atmospheric Measurement Techniques. Accepted for publication. DOI: <https://doi.org/10.5194/egusphere-2025-667>

4.2 Artículo 2: A neural network to retrieve cloud cover from all-sky cameras: a case of study over Antarctic

4.2.1 Resumen y comentarios

Las nubes juegan un papel importante en el balance radiativo del sistema que forman la Tierra y la atmósfera, debido a que interactúan con la radiación solar y terrestre. La influencia de las nubes en el clima representa una gran incertidumbre para las predicciones meteorológicas y modelos climáticos, por lo que es necesario estudiar las nubes y sus propiedades, especialmente en las zonas polares debido a que ocupan una gran parte de las mismas. Una de sus propiedades más importantes es la cobertura nubosa, en cuyo estudio destacan las medidas manuales realizadas por observadores meteorológicos.

Tratando de automatizar las medidas de la CC, se emplean distintos instrumentos entre los que se encuentran las cámaras de todo cielo que han demostrado ser bastante eficaces. Normalmente se usan algoritmos que requieren de umbrales fijos y presentan limitaciones para discernir ciertos tipos de nubes y altas cargas de aerosoles. Sin embargo, con el auge de las redes neuronales convolucionales, que han resultado ser especialmente útiles en problemas con imágenes, se presenta la oportunidad de desarrollar una metodología para el estudio de la CC sin necesidad de dichos umbrales. En consecuencia, en este trabajo se ha desarrollado un modelo basado en una CNN para la predicción de la CC a partir de imágenes diurnas de dos modelos de cámaras de todo cielo, el cual se denomina CNN-CC.

Para el desarrollo de este modelo se emplean 49,016 imágenes en tres localidades españolas diferentes, Valladolid, Izaña y La Palma. Las imágenes del conjunto empleado han sido clasificadas, según su valor de la CC, de manera manual por investigadores especializados. El modelo se ha entrenado con parte de esas imágenes y se ha evaluado con el resto que no han sido empleadas en el entrenamiento, formando estos dos conjuntos con las imágenes separadas aleatoriamente. La evaluación del conjunto de prueba muestra que el modelo estima la CC coincidiendo con los valores de referencia en más del 93 % de los casos en el rango de error de ± 1 octa. Analizando los estadísticos de la evaluación de este modelo, el *mean bias error* (MBE) es de 0.007 octas, y la desviación estándar (SD del inglés *Standard Deviation*) tiene un valor de 0.674 octas. Representando ambos parámetros frente al AOD y el exponente de Ångström, en diferentes intervalos, se muestra que la bondad de este modelo no depende ni del tipo ni de la cantidad de aerosoles presentes en la atmósfera.

Finalmente, se ha evaluado el rendimiento del modelo mediante su aplicación en imágenes del cielo capturadas en la estación Antártica de Marambio, que no ha sido utilizada en el

4.2 Artículo 2: A neural network to retrieve cloud cover from all-sky cameras: a case of study over Antarctic

entrenamiento. Las predicciones del modelo en esta estación se han comparado con las medidas manuales de referencia realizadas por observadores meteorológicos en un periodo de unos tres años. El resultado de esta comparación revela que el modelo subestima ligeramente las observaciones, presentando un MBE de -0.3 octas.

También se realiza un estudio calculando como se distribuyen los valores mensuales y anuales de la CC en esta estación. Con una media anual de 5.5 octas, que presenta una SD de aproximadamente 3.1 octas, también se obtiene que el 46.5 % de las observaciones anuales corresponden a un cielo totalmente cubierto, especialmente en el mes de enero, incrementándose hasta un 64.5 %. También se ha realizado un análisis similar calculando la distribución de la CC obtenida por horas, el cual revela que no se observan ciclos diurnos excepto para algún mes concreto.

A continuación se presenta el artículo en el que se detalla el modelo desarrollado, presentando la arquitectura de la CNN, así como detallando el entrenamiento y evaluación del modelo.

Referencia: González-Fernández, D., Román, R., Antuña-Sánchez, J. C., Cachorro, V. E., Copes, G., Herrero-Anta, S., Herrero del Barrio, C., Barreto, Á., González, R., Ramos, R., Martín, P, Mateos, D., Toledano, C., Calle, A., de Frutos, Á. (2024). A neural network to retrieve cloud cover from all-sky cameras: A case of study over Antarctica. *Quarterly Journal of the Royal Meteorological Society*, 1–19. DOI: <https://doi.org/10.1002/qj.4834>.

4.3 Artículo 3: Retrieval of solar shortwave Irradiance from all-sky camera images

4.3.1 Resumen y comentarios

El Sol es la principal fuente de energía de la Tierra. Por tanto, resulta importante la monitorización de la radiación proveniente de esta estrella, especialmente en las regiones polares ya que estas áreas juegan un papel fundamental en el balance energético del sistema climático. Este trabajo se centra en la GHI, cuyas medidas de referencia se realizan con piranómetros, destacando que en caso de falta de datos disponibles se pueden usar modelos para reconstruir las series. Para tener en cuenta los efectos de las nubes sobre la GHI, se necesita conocer el CMF, que cuantifica la transmitancia de las nubes. La GHI se puede estimar como el producto del CMF y la GHI simulada sin nubes.

Con todo esto, se propone el uso de una CNN para estimar el valor del CMF a partir de imágenes de cámaras de todo cielo. Gracias a la estimación del CMF se puede reconstruir el valor de GHI mediante el método explicado.

Para este propósito, se han seleccionado un total de 237,669 imágenes del cielo emparejadas con medidas de GHI obtenidas mediante piranómetros en Valladolid, Izaña (ambas en España) y Lindenberg (Alemania). Este conjunto de datos se divide aleatoriamente en conjuntos de entrenamiento y de prueba, excluyéndose este último del modelo de entrenamiento para validarlo utilizando las mismas ubicaciones. Los datos con los que se entrena al modelo corresponden a los valores de CMF que se han obtenido a partir de los valores de GHI medidos por los piranómetros y las simulaciones de GHI en condiciones de cielo despejado. Las simulaciones se han realizado empleando las herramientas de transferencia radiativa del paquete de software *libRadtran-2.0.5*. Las imágenes del conjunto de entrenamiento se han clasificado en intervalos de valores de CMF en el rango de 0.01 hasta 1.30, cada 0.01.

Tras el entrenamiento del modelo, el cual se ha llamado CNN-CMF, se realiza una comparación del conjunto de datos de prueba con las medidas de referencia de irradiancia correspondientes obtenidas con los piranómetros. Los valores de CMF obtenidos por el modelo CNN-CMF, se convierten a medidas de GHI de nuevo para realizar esta comparación. Mediante un ajuste lineal, se muestra que el coeficiente de determinación (R^2) es de 0.99. El análisis de los estadísticos basados en el MBE y la SD de las diferencias entre las predicciones del modelo y la irradiancia de los piranómetros da resultados cercanos al -2% y al 9% , respectivamente. El MBE indica una ligera subestimación del modelo CNN-CMF en comparación con los valores de referencia.

4.3 Artículo 3: Retrieval of solar shortwave Irradiance from all-sky camera images

Finalmente, se evalúa el rendimiento del modelo en la estación Antártica de Marambio, ubicación no utilizada en el proceso de entrenamiento. Una comparación similar entre la GHI predicha por el modelo y la medida por los piranómetros da un resultado de un R^2 de 0.95, con un MBE de alrededor del 2 % y una SD de aproximadamente el 26 %. Si bien la precisión proporcionada por la SD en la estación de Marambio es menor, el MBE muestra que la exactitud del modelo es similar a la de resultados previos, pero con una ligera sobreestimación de la GHI. Esta sobreestimación muestra una dependencia con el ángulo solar cenital, aumentando cuando este ángulo disminuye y al contrario. Finalmente, el coeficiente de determinación mejora hasta un valor de 0.99, y el MBE y la SD se sitúan en torno al 3 % y el 11 %, respectivamente, cuando se utiliza el modelo CNN-CMF para estimar los valores diarios de irradiación solar de onda corta horizontal.

A continuación se puede ver detallado el trabajo del artículo correspondiente al modelo CNN-CMF. En este se detalla el desarrollo, entrenamiento y evaluación del modelo, así como se presentan y analizan los principales resultados de la aplicación del modelo a la estación de Marambio.

Referencia: González-Fernández, D., Román, R., Mateos, D., Herrero del Barrio, C., Cachorro, V. E., Copes, G., Sánchez, R., García, R. D., Doppler, L., Herrero-Anta, S., Antuña-Sánchez, J. C., Barreto, Á., González, R., Gatón, J., Calle, A., Toledano, C., and de Frutos, Á. (2024). Retrieval of Solar Shortwave Irradiance from All-Sky Camera Images. *Remote Sensing*, 16(20), 3821. DOI: <https://doi.org/10.3390/rs16203821>.

Conclusiones y líneas futuras

A lo largo de esta tesis se ha demostrado el potencial y la versatilidad de las cámaras de todo cielo para estimar diferentes parámetros atmosféricos. Se han desarrollado nuevas metodologías que permiten determinar el espesor óptico de aerosoles (AOD del inglés *Aerosol Optical Depth*) nocturno, la cubierta de nubes (CC del inglés *Cloud Cover*) y la irradiancia global horizontal (GHI del inglés *Global Horizontal Irradiance*) mediante las imágenes tomadas por cámaras de todo cielo. Los resultados obtenidos muestran que estas cámaras proporcionan una buena aproximación en caso de no disponer de datos de los instrumentos y técnicas de referencia para determinar los mencionados parámetros atmosféricos, como en el caso de las regiones polares en las que es particularmente difícil realizar medidas debido a las condiciones climáticas que presentan. Las principales conclusiones de esta tesis se enumeran a continuación:

1. La metodología desarrollada demuestra el potencial de las cámaras de todo cielo para extraer la luz de diferentes estrellas que llega a la Tierra a partir de imágenes del cielo nocturno, y usar esta luz para calcular el AOD mediante la metodología propuesta en esta tesis, basada en el método de calibración Langley.
2. Una intercomparación con medidas independientes de fotómetros lunares en nueve localidades distintas ha revelado que el AOD obtenido con la nueva metodología propuesta correlaciona con los valores de referencia con valores de correlación superiores a 0.90 en la mayoría de casos. De esta comparación también se concluye que este nuevo método sobrestima ligeramente el AOD (en torno a 0.02) con una precisión aproximadamente entre 0.03 y 0.04. Este método ha demostrado ser útil para detectar cambios

5. CONCLUSIONES Y LÍNEAS FUTURAS

temporales en el AOD, así como para monitorizar este parámetro de manera continua durante toda la noche, independientemente de la luz de la Luna, lo que ofrece una oportunidad para completar las series de datos nocturnas de AOD.

3. El modelo CNN-CC, desarrollado para estimar la CC a partir de imágenes diurnas de cámaras de todo cielo, no muestra una clara dependencia en su rendimiento con el tipo de cámara o su ubicación. Por tanto, podría aplicarse a imágenes de otras cámaras de todo cielo. La evaluación del modelo CNN-CC frente a observaciones de campo en la estación de Marambio (Argentina), muestra una ligera subestimación del modelo con un MBE (*Mean Bias Error*) de -0.3 octas y una SD (*Standard Deviation*) de 1.4 octas.
4. El rendimiento del modelo CNN-CC es ligeramente superior al de otros métodos basados en cámaras de todo cielo y destaca por su capacidad para estimar correctamente la CC incluso en condiciones de alta presencia de aerosoles, donde otros modelos tienden a clasificarlas erróneamente como nubladas. Sin embargo, tiende a subestimar la nubosidad en presencia de nubes altas y finas, como los cirros.
5. Los valores de GHI se pueden estimar a partir de imágenes del cielo aplicando a estas imágenes el modelo CNN-CMF, desarrollado en esta tesis, para calcular el CMF (*Cloud Modification Factor*), y multiplicando ese factor por la GHI simulada sin nubes. Gracias a una comparación con medidas independientes, se puede concluir que esta nueva metodología predice la GHI con una ligera sobreestimación de alrededor del 2 %, la cual es mayor para los valores de SZA (*Solar Zenith Angle*) más bajos y menor para los valores de SZA más altos. Los resultados mejoran, obteniendo un MBE del orden del 3 % y una SD de alrededor del 11 %, para los valores diarios (GHI_d).
6. Aunque la obtención de medidas radiométricas mediante piranómetros sigue siendo la mejor manera de monitorizar la radiación solar y detectar posibles cambios y tendencias, este trabajo concluye que, si se pueden obtener imágenes del cielo, estas proporcionan un buen indicador para estimar la GHI y la GHI_d en estaciones donde las medidas de piranómetros no están disponibles.

Del trabajo de esta tesis doctoral, se plantean las siguientes líneas futuras de investigación para mejorar las metodologías desarrolladas:

1. En el caso de la nueva metodología para estimar el AOD nocturno a través de imágenes del cielo, se quieren mejorar los algoritmos de filtrado de datos y los métodos de calibración en las estaciones de alta latitud, para las cuales el método de Langley parece presentar ciertas limitaciones. Se recomienda probar otros modelos de cámaras

que tengan menor anchura espectral, y seguir validando la metodología propuesta en diferentes estaciones con distintas condiciones atmosféricas.

2. Se pretende promover la utilización del modelo CNN-CC con imágenes de otras estaciones, para validar e incluso reentrenar el modelo. También se quiere instar al uso del modelo para estimar directamente la CC en las estaciones respectivas. Además, se pretende clasificar un conjunto de imágenes nocturnas para entrenar el modelo CNN-CC no solo para predecir la CC durante el día sino también durante la noche.
3. Se quiere fomentar el uso del modelo CNN-CMF propuesto para su aplicación en otras investigaciones y zonas, en la reconstrucción de series temporales de GHI, así como para comparar el modelo con medidas en otras estaciones y cuantificar mejor la incertidumbre de este modelo. Por último, se pretende utilizar una serie de imágenes del cielo a largo plazo para reconstruir los valores de GHI y comprobar si este modelo es capaz de predecir las tendencias tal y como se observaron en el pasado durante el *global brightening* o el *global dimming*.

Bibliografía

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., Mané, D., Monga, R., Moore, S., Murray, D., Olah, C., Schuster, M., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viégas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y., and Zheng, X. (2015). TensorFlow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org. 52
- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., and Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, **4**, 11. 39
- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Umar, A. M., Linus, O. U., Arshad, H., Kazaure, A. A., Gana, U., and Kiru, M. U. (2019). Comprehensive review of artificial neural network applications to pattern recognition. *IEEE Access*, **7**, 158820–158846. 39
- Aggarwal, C. C. *et al.* (2018). *Neural networks and deep learning*, volume 10. Springer. 40, 44
- Angström, A. (1930). On the atmospheric transmission of sun radiation II. *Geogr Annales*, **H 11**, 1301–1308. 11
- Angström, A. (1961). Techniques of determining the turbidity of the atmosphere. *Tellus*, **13**, 214–223. 11
- Antón Martínez, M. (2007). *Modelos empíricos para la estimación de la irradiancia solar ultravioleta*. Ph.D. thesis, Universidad de Extremadura. 15
- Antuña-Sánchez, J. C. (2022). *Configuración y Metodología para el Uso de Cámaras de Todo Cielo en la Obtención de Parámetros Atmosféricos*. Ph.D. thesis, Universidad de Valladolid. 1, 2, 11, 15, 20, 21, 22, 23, 25, 26, 85, 86

BIBLIOGRAFÍA

- Antuña-Sánchez, J. C., Díaz, N., Estevan, R., de Frutos, A., and Antuña-Marrero, J. C. (2015). Cloud camera design using a Raspberry Pi. *Optica Pura y Aplicada*, **48**(3), 199–205. 20
- Antuña-Sánchez, J. C., Román, R., Bosch, J. L., Toledano, C., Mateos, D., González, R., Cachorro, V., and de Frutos, A. (2022). ORION software tool for the geometrical calibration of all-sky cameras. *PLOS ONE*, **17**(3), 1–17. Publisher: Public Library of Science. 25, 26
- Antón, M., Román, R., Sanchez-Lorenzo, A., Calbó, J., and Vaquero, J. (2017). Variability analysis of the reconstructed daily global solar radiation under all-sky and cloud-free conditions in madrid during the period 1887–1950. *Atmospheric Research*, **191**. 15
- Arking, A. and Childs, J. (1985). Retrieval of cloud cover parameters from multispectral satellite images. *Journal of Climate & Applied Meteorology*, **24**(4), 322–333. 14
- Baibakov, K., O' Neill, N. T., Ivanescu, L., Duck, T. J., Perro, C., Herber, A., Schulz, K.-H., and Schrems, O. (2015). Synchronous polar winter starphotometry and lidar measurements at a high arctic station. *Atmospheric Measurement Techniques*, **8**(9), 3789–3809. 13
- Barreto, A., Cuevas, E., Damiri, B., Guirado, C., Berkoff, T., Berjón, A. J., Hernández, Y., Almansa, F., and Gil, M. (2013). A new method for nocturnal aerosol measurements with a lunar photometer prototype. *Atmospheric Measurement Techniques*, **6**(3), 585–598. 12
- Barreto, A., Cuevas, E., Granados-Muñoz, M.-J., Alados-Arboledas, L., Romero, P. M., Gröbner, J., Kouremeti, N., Almansa, A. F., Stone, T., Toledano, C., Román, R., Sorokin, M., Holben, B., Canini, M., and Yela, M. (2016). The new sun-sky-lunar cimel ce318-t multiband photometer – a comprehensive performance evaluation. *Atmospheric Measurement Techniques*, **9**(2), 631–654. 12, 28
- Barreto, Á., Román, R., Cuevas Agulló, E., Berjón, A., Almansa Rodríguez, A. F., Toledano, C., González, R., Pérez, H., Yballa, C., Blarel, L., *et al.* (2017). Assessment of nocturnal aerosol optical depth from lunar photometry at the izaña high mountain observatory. *Atmospheric Measurement Techniques*, **10**(8), 3007–3019. 13
- Barreto, A., Román, R., Cuevas, E., Pérez-Ramírez, D., Berjón, A., Kouremeti, N., Kazadzis, S., Gröbner, J., Mazzola, M., Toledano, C., Benavent-Oltra, J. A., Doppler, L., Jurysek, J., Almansa, F., Victori, S., Maupin, F., Guirado-Fuentes, C., González, R., Vitale, V., Goloub, P., Blarel, L., Alados-Arboledas, L., Woolliams, E., Greenwell, C., Taylor, S.,

- Antuña, J. C., and Yela, M. (2019). Evaluation of night-time aerosol optical depth measurements and lunar irradiance models in the frame of the first multi-instrument nocturnal intercomparison campaign. *Atmospheric Environment*, **202**, 190–211. 12, 13
- Barreto, A., García, R. D., Guirado-Fuentes, C., Cuevas, E., Almansa, A. F., Milford, C., Toledano, C., Expósito, F. J., Díaz, J. P., and León-Luis, S. F. (2022). Aerosol characterisation in the subtropical eastern north atlantic region using long-term aeronet measurements. *Atmos. Chemis. Phys.*, **22**(17), 11105–11124. 35
- Bayer, B. E. (1976). Color imaging array. 20
- Bedoya-Velásquez, A. E., Hoyos-Restrepo, M., Barreto, A., García, R. D., Romero-Campos, P. M., García, O., Ramos, R., Roininen, R., Toledano, C., Sicard, M., and Ceolato, R. (2022). Estimation of the mass concentration of volcanic ash using ceilometers: Study of fresh and transported plumes from la palma volcano. *Remote Sensing*, **14**(22). 34
- Bennouna, Y., Cachorro, V., Torres, B., Toledano, C., Berjón, A., de Frutos, A., and Alonso Fernández Coppel, I. (2013). Atmospheric turbidity determined by the annual cycle of the aerosol optical depth over north-center spain from ground (aeronet) and satellite (modis). *Atmospheric Environment*, **67**, 352 – 364. 33
- Berkoff, T. A., Sorokin, M., Stone, T., Eck, T. F., Hoff, R., Welton, E., and Holben, B. (2011). Nocturnal Aerosol Optical Depth Measurements with a Small-Aperture Automated Photometer Using the Moon as a Light Source. *Journal of Atmospheric and Oceanic Technology*, **28**(10), 1297–1306. 12
- Bettonvil, F. (2006). A digital all-sky camera. Conference Name: Proceedings of the International Meteor Conference, 24th IMC, Oostmalle, Belgium, 2005 Pages: 90-98 ADS Bibcode: 2006pimo.conf...90B. 20
- Bond, T. C., Doherty, S. J., Fahey, D. W., Forster, P. M., Berntsen, T., DeAngelo, B. J., Flanner, M. G., Ghan, S., Kärcher, B., Koch, D., Kinne, S., Kondo, Y., Quinn, P. K., Sarofim, M. C., Schultz, M. G., Schulz, M., Venkataraman, C., Zhang, H., Zhang, S., Bellouin, N., Guttikunda, S. K., Hopke, P. K., Jacobson, M. Z., Kaiser, J. W., Klimont, Z., Lohmann, U., Schwarz, J. P., Shindell, D., Storelvmo, T., Warren, S. G., and Zender, C. S. (2013). Bounding the role of black carbon in the climate system: A scientific assessment. *Journal of Geophysical Research: Atmospheres*, **118**(11), 5380–5552. 9
- Bosch Rué, A., Casas-Roma, J., and Lozano Bagén, T. (2019). *Deep learning: principios y fundamentos*. Editorial UOC. 39, 40, 41, 42, 43, 46, 47, 48, 50, 51

BIBLIOGRAFÍA

- Boucher, O., Randall, D., Artaxo, P., Bretherton, C., Feingold, G., Forster, P., Kerminen, V.-M., Kondo, Y., Liao, H., Lohmann, U., and others (2013). Clouds and aerosols. In *Climate change 2013: the physical science basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, pages 571–657. Cambridge University Press. 3, 4, 6
- Boyle, W. S. and Smith, G. E. (1970). Charge Coupled Semiconductor Devices. *Bell System Technical Journal*, **49**(4), 587–593. 20
- Cachorro, V. E., Burgos, M. A., Mateos, D., Toledano, C., Bennouna, Y., Torres, B., de Frutos, A. M., and Herguedas, A. (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**(13), 8227–8248. 33
- Calbó, J. and Sabburg, J. (2008). Feature Extraction from Whole-Sky Ground-Based Images for Cloud-Type Recognition. *Journal of Atmospheric and Oceanic Technology*, **25**(1), 3–14. 16
- Calbó, J., Pagès, D., and González, J.-A. (2005). Empirical studies of cloud effects on uv radiation: A review. *Reviews of Geophysics*, **43**(2). 6, 15
- Carslaw, K. S. (2022). Chapter 2 - aerosol in the climate system. In K. S. Carslaw, editor, *Aerosols and Climate*, pages 9–52. Elsevier. 9
- Cazorla, A., Olmo, F., and Alados-Arboledas, L. (2008). Using a sky imager for aerosol characterization. *Atmospheric Environment*, **42**(11), 2739–2745. Vienna Visibility Conference 2006. 15, 16, 20
- Chollet, F. *et al.* (2015). Keras. <https://keras.io>. 52
- Chrysanthou, A. and Tourpali, K. (2024). Ozone as a uv filter. In *Reference Module in Earth Systems and Environmental Sciences*. Elsevier. 2
- Clothiaux, E., Miller, M., Albrecht, B., Ackerman, T., Verlinde, J., Babb, D., Peters, R., and Syrett, W. (1995). An evaluation of a 94-ghz radar for remote sensing of cloud properties. *Journal of Atmospheric and Oceanic Technology*, **12**(2), 201–229. 14
- Costa-Surós, M., Calbó, J., González, J., and Martin-Vide, J. (2013). Behavior of cloud base height from ceilometer measurements. *Atmospheric Research*, **127**, 64–76. 14
- Crispel, P. and Roberts, G. (2018). All-sky photogrammetry techniques to georeference a cloud field. *Atmospheric Measurement Techniques*, **11**(1), 593–609. 20

- Crnivec, N. and Mayer, B. (2019). Quantifying the bias of radiative heating rates in numerical weather prediction models for shallow cumulus clouds. *Atmospheric Chemistry and Physics*, **19**, 8083–8100. 7
- Cuevas, E., Milford, C., Barreto Velasco, A., Bustos Seguela, J. J. d., García Rodríguez, O. E., García Cabrera, R. D., Marrero, C., Prats Porta, N., Ramos López, R., Redondas, A., *et al.* (2022). Izaña atmospheric research center. activity report 2019-2020. *WMO/GAW*, (No. 276). available at: https://izana.aemet.es/wp-content/docs/Izana_Report_2019_2020.pdf. 35
- Córdoba-Jabonero, C., Sicard, M., África Barreto, Toledano, C., López-Cayuela, M. A., Gil-Díaz, C., García, O., Carvajal-Pérez, C. V., Comerón, A., Ramos, R., Muñoz-Porcar, C., and Rodríguez-Gómez, A. (2023). Fresh volcanic aerosols injected in the atmosphere during the volcano eruptive activity at the cumbre vieja area (la palma, canary islands): Temporal evolution and vertical impact. *Atmos. Environ.*, **300**, 119667. 34
- Dameris, M. (2015). Stratosphere/troposphere exchange and structure | tropopause. In G. R. North, J. Pyle, and F. Zhang, editors, *Encyclopedia of Atmospheric Sciences (Second Edition)*, pages 269–272. Academic Press, Oxford, second edition edition. 1
- de La Casiniere, A. and Cachorro, V. (2008). *La Radiación Solar en el Sistema Tierra-Atmósfera*. Ediciones Universidad de Valladolid. 3, 7, 8
- Developers, C. (2022). Colour - Demosaicing 0.2.2 documentation. 20
- Dubovik, O. and King, M. (2000). A Flexible Inversion Algorithm for Retrieval of Aerosol Optical Properties from Sun and Sky Radiance Measurements. *J. Geophys. Res.*, **105**(D16), 20,673–20,696. 28
- Dubovik, O., Lapyonok, T., Litvinov, P., Herman, M., Fuertes, D., Ducos, F., Lopatin, A., Chaikovsky, A., Torres, B., Derimian, Y., Huang, X., Aspetsberger, M., and Federspiel, C. (2014). Grasp: a versatile algorithm for characterizing the atmosphere. *SPIE: Newsroom*. 28
- Dumoulin, V. and Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*. 47, 50, 51
- Dye, D. G. (2012). Looking skyward to study ecosystem carbon dynamics. *Eos, Transactions American Geophysical Union*, **93**(14), 141–143. _eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1029/2012EO140002>. 20

BIBLIOGRAFÍA

- Fassig, O. L. (1896). Automatic cloud photography. *Monthly Weather Review*. 19
- Forster, P., Storelvmo, T., Armour, K., Collins, W., Dufresne, J.-L., Frame, D., Lunt, D., Mauritsen, T., Palmer, M., Watanabe, M., Wild, M., and Zhang, H. (2021). The earth's energy budget, climate feedbacks and climate sensitivity. In *Climate change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, pages 923–1054. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA. 4, 6, 7, 13
- Fuertes, D., Toledano, C., González, R., Berjón, A., Torres, B., Cachorro, V. E., and de Frutos, A. M. (2018). Caelis: software for assimilation, management and processing data of an atmospheric measurement network. *Geoscientific Instrumentation, Methods and Data Systems*, 7(1), 67–81. 30
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36, 193–202. 40
- García, O., Suárez, D., Cuevas, E., Ramos, R., Barreto, A., Hernández, M., Quintero, V., Toledano, C., Sicard, M., Córdoba-Jabonero, C., Riz, V., Roininen, R., López, C., Vilches, J., Weiss, M., Carreño, V., Taquet, N., Boulesteix, T., Fraile, E., Torres, C., Prats, N., Alcántara, A., León, S., Rivas, P., Álvarez, O., Parra, F., de Luis, J., González, C., Armas, C., Romero, P., de Bustos, J., Redondas, A., Marrero, C., Milford, C., Román, R., González, R., López-Cayuela, M., Carvajal-Pérez, C., Chinae, N., García, R., Almansa, F., González, Y., Bullón, F., Poggio, M., Rivera, C., Bayo, C., and Rey, F. (2022). La erupción volcánica de la palma y el papel de la agencia estatal de meteorología. *Revista Tiempo y Clima*, 5(76). 34
- García, R. D., Cuevas, E., Ramos, R., Cachorro, V. E., Redondas, A., and Moreno-Ruiz, J. A. (2019). Description of the baseline surface radiation network (bsrn) station at the Izaña observatory (2009–2017): measurements and quality control/assurance procedures. *Geoscientific Instrumentation, Methods and Data Systems*, 8(1), 77–96. 32, 35
- García, R. D. (2011). *Aplicación de modelos de transferencia radiativa para el control operativo del programa BSRN (Baseline Surface Radiation Network) del Centro de Investigación Atmosférica de Izaña*. Ph.D. thesis, Universidad de Valladolid, Agencia Estatal de Meteorología (AEMet). 14, 15
- García-Pajares, S. (2024). Segmentación semántica multicategoría de imágenes todo cielo mediante redes neuronales. *Graduate Thesis, Universidad de Valladolid*. 42

- Giles, D. M., Sinyuk, A., Sorokin, M. G., Schafer, J. S., Smirnov, A., Slutsker, I., Eck, T. F., Holben, B. N., Lewis, J. R., Campbell, J. R., Welton, E. J., Korkin, S. V., and Lyapustin, A. I. (2019). Advancements in the aerosol robotic network (aeronet) version 3 database – automated near-real-time quality control algorithm with improved cloud screening for sun photometer aerosol optical depth (aod) measurements. *Atmospheric Measurement Techniques*, **12**(1), 169–209. 29
- Glorot, X., Bordes, A., and Bengio, Y. (2011). Deep sparse rectifier neural networks. In G. Gordon, D. Dunson, and M. Dudík, editors, *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, volume 15 of *Proceedings of Machine Learning Research*, pages 315–323, Fort Lauderdale, FL, USA. PMLR. 43
- González, R., Toledano, C., Román, R., Fuertes, D., Berjón, A., Mateos, D., Guirado-Fuentes, C., Velasco-Merino, C., Antuña-Sánchez, J. C., Calle, A., Cachorro, V. E., and de Frutos, A. M. (2020). Daytime and nighttime aerosol optical depth implementation in caelis. *Geoscientific Instrumentation, Methods and Data Systems*, **9**(2), 417–433. 13, 30
- González, R. (2021). *Desarrollo de nuevos métodos de procesado de datos de redes fotométricas para el análisis de propiedades del aerosol atmosférico*. Ph.D. thesis, Universidad de Valladolid. 3, 11, 28, 29, 30, 34
- González, R., Toledano, C., Román, R., Mateos, D., Asmi, E., Rodríguez, E., Lau, I. C., Ferrara, J., D’Elia, R., Antuña-Sánchez, J. C., Cachorro, V. E., Calle, A., and Ángel M de Frutos (2020). Characterization of stratospheric smoke particles over the antarctica by remote sensing instruments. *Remote Sensing*, **12**(22). 37
- González-Fernández, D., Román, R., Antuña-Sánchez, J. C., Cachorro, V. E., Copes, G., Herrero-Anta, S., Herrero-del Barrio, C., Barreto, A., González, R., Ramos, R., Martín, P., Mateos, D., Toledano, C., Calle, A., and de Frutos, A. M. (2024a). A neural network to retrieve cloud cover from all-sky cameras: a case of study over antarctic. *Quarterly Journal of the Royal Meteorological Society*, **764**(150), 4631–4649. 17, 52, 87
- González-Fernández, D., Román, R., Mateos, D., Herrero del Barrio, C., Cachorro, V., Copes, G., Sánchez, R., García, R., Doppler, L., Herrero-Anta, S., Antuña-Sánchez, J. C., Barreto, A., González, R., Gatón, J., Calle, A., Toledano, C., and de Frutos, A. M. (2024b). Retrieval of solar shortwave irradiance from all-sky camera images. *Remote Sensing*, (16), 3821. 17
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>. 39, 45

BIBLIOGRAFÍA

- Goosse, H., Kay, J., Armour, K., Bodas-Salcedo, A., Chepfer, H., Docquier, D., Jonko, A., Kushner, P., Lecomte, O., Massonnet, F., Park, H.S. Pithan, F., Svensson, G., and Vancoppenolle, M. (2018). Quantifying climate feedbacks in polar regions. *Nat Commun*, **9**(1), 1919. 9, 10
- Graßl, S., Ritter, C., Wilsch, J., Herrmann, R., Doppler, L., and Román, R. (2024). From polar day to polar night: A comprehensive sun and star photometer study of trends in arctic aerosol properties in ny-Ålesund, svalbard. *Remote Sensing*, **16**(19). 13
- Hansen, J. and Nazarenko, L. (2004). Soot climate forcing via snow and ice albedos. *Proceedings of the National Academy of Sciences*, **101**(2), 423–428. 9
- Herrero-Anta, S. (2021). *Análisis de la presencia de una pluma de aerosol mineral en el ártico detectada mediante fotometría solar*. Master's thesis, Universidad de Valladolid. 9, 11, 36
- Herrero del Barrio, C., Mateos, D., Román, R., González, R., Herrero-Anta, S., González-Fernández, D., Calle, A., Toledano, C., Cachorro, V. E., and Ángel Máximo De Frutos Baraja (2023). Analysis of daytime and night-time aerosol optical depth from solar and lunar photometry in valladolid (spain). *Remote Sensing*, **15**(22). 12, 34
- Holben, B. N., Eck, T. F., Slutsker, I., Tanré, D., Buis, J. P., Setzer, A., Vermote, E., Reagan, J. A., Kaufman, Y. J., Nakajima, T., Lavenu, F., Jankowiak, I., and Smirnov, A. (1998). AERONET – a federated instrument network and data archive for aerosol characterization. *Remote Sens. Environ.*, **66**, 1–16. 29
- Hong, Y., Hsu, K.-L., Sorooshian, S., and Gao, X. (2004). Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. *Journal of Applied Meteorology*, **43**(12), 1834 – 1853. 39
- Hudec, R., Spurny, M., Krizek, M., Rerabek, M., Pata, P., and Klima, M. (2011). Low-Cost Optical All-Sky Monitoring Camera: Further Developments and Tests. *AIP Conference Proceedings*, **1358**(1), 377–380. Publisher: American Institute of Physics. 20
- Huo, J. and Lu, D. (2009). Cloud determination of all-sky images under low-visibility conditions. *Journal of Atmospheric and Oceanic Technology*, **26**(10), 2172 – 2181. 16
- Igual, J. (2017). *Ruido, sensores y exposición PARTE I: Fundamentos del ruido en fotografía digital*. 20

- Ioffe, S. and Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. 52
- IPCC (2014). Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [IPCC, Technical report, Intergovernmental Panel on Climate Change, Geneva, Switzerland. 4, 7
- IPCC (2021). Climate Change 2021: Synthesis Report. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [IPCC, Technical report, Intergovernmental Panel on Climate Change, Geneva, Switzerland. 4, 5, 85
- Iqbal, M. (1983). *An introduction to solar radiation*. Academic Press, Inc. 7, 9
- Ivănescu, L., Baibakov, K., O’Neill, N. T., Blanchet, J.-P., and Schulz, K.-H. (2021). Accuracy in starphotometry. *Atmospheric Measurement Techniques*, **14**(10), 6561–6599. 13
- Jechow, A., Ribas, S. J., Domingo, R. C., Hölker, F., Kolláth, Z., and Kyba, C. C. M. (2018). Tracking the dynamics of skyglow with differential photometry using a digital camera with fisheye lens. *Journal of Quantitative Spectroscopy and Radiative Transfer*, **209**, 212–223. 20
- Karanikolas, A., Kouremeti, N., Campanelli, M., Estellés, V., Momoi, M., Kumar, G., Nyeki, S., and Kazadzis, S. (2024). Intercomparison of aerosol optical depth retrievals from gaw-pfr and skynet sun photometer networks and the effect of calibration. *Atmospheric Measurement Techniques*, **17**(20), 6085–6105. 36
- Kasten, F. and Young, A. T. (1989). Revised Optical Air Mass Tables and Approximation Formula. *Appl. Opt.*, **28**, 4735–4738. 11
- Kazantzidis, A., Tzoumanikas, P., Bais, A., Fotopoulos, S., and Economou, G. (2012). Cloud detection and classification with the use of whole-sky ground-based images. *Atmospheric Research*, **113**, 80–88. 16
- Kieffer, H. H. and Stone, T. C. (2005). The spectral irradiance of the moon. *The Astronomical Journal*, **129**(6), 2887. 12
- Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 54

BIBLIOGRAFÍA

- Kollias, P., Clothiaux, E., Miller, M., Albrecht, B., Stephens, G., and Ackerman, T. (2007). Millimeter-wavelength radars: new frontier in atmospheric cloud and precipitation research. *Bulletin of the American Meteorological Society*, **88**(10), 1608–1624. 14
- Kreuter, A., Zangerl, M., Schwarzmann, M., and Blumthaler, M. (2009). All-sky imaging: a simple, versatile system for atmospheric research. *Appl. Opt.*, **48**(6), 1091–1097. 16
- Krizhevsky, A., Nair, V., and Hinton, G. (2010). Cifar-10 (canadian institute for advanced research). URL <http://www.cs.toronto.edu/kriz/cifar.html>, **5**(4), 1. 50
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc. 40
- Kurucz, R. L. (1992). Model Atmospheres for Population Synthesis. In B. Barbuy and A. Renzini, editors, *The Stellar Populations of Galaxies*, International Astronomical Union / Union Astronomique Internationale, pages 225–232, Dordrecht. Springer Netherlands. 8, 85
- Lachlan-Cope, T. (2010). Antarctic clouds. *Polar Research*, **29**, 150–158. 10
- Law, K. S. and Stohl, A. (2007). Arctic air pollution: Origins and impacts. *Science*, **315**(5818), 1537–1540. 9
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, **1**(4), 541–551. 46
- Leiterer, U., Naebert, A., Naebert, T., and Alekseeva, G. (1995). A new star photometer developed for spectral aerosol optical thickness measurements in lindenbergl. *Contributions to atmospheric physics*, **68**. 13
- Liou, K. N. (2002). *An Introduction to Atmospheric Radiation*. Academic Press, second edition. 1, 2, 3, 7, 8, 9
- Longarela-Fuente, B. (2025). Redes Neuronales Convolucionales para detectar la cubierta de nubes en el cielo. *Graduate Thesis, Universidad de Valladolid*. 43, 44, 45, 46, 53
- Martucci, G., Milroy, C., and O’Dowd, C. (2010). Detection of cloud-base height using jenoptik chm15k and vaisala cl31 ceilometers. *Journal of Atmospheric and Oceanic Technology*, **27**(2), 305–318. 14

- Masuda, R., Iwabuchi, H., Schmidt, K., Damiani, A., and R., K. (2019). Retrieval of Cloud Optical Thickness from Sky-View Camera Images using a Deep Convolutional Neural Network based on Three-Dimensional Radiative Transfer. *Remote Sensing*, **11**, 1962. 40
- Mateos, D., Pace, G., Meloni, D., Bilbao, J., di Sarra, A., de Miguel, A., Casasanta, G., and Min, Q. (2014). Observed influence of liquid cloud microphysical properties on ultraviolet surface radiation. *Journal of Geophysical Research: Atmospheres*, **119**(5), 2429–2440. 14
- Matich, D. J. (2001). Redes neuronales: Conceptos básicos y aplicaciones. *Universidad Tecnológica Nacional, México*, **41**. 41
- Milford, C., Torres, C., Vilches, J., Gossman, A.-K., Weis, F., Suárez-Molina, D., García, O. E., Prats, N., Barreto, A., García, R. D., Bustos, J. J., Marrero, C. L., Ramos, R., China, N., Boulesteix, T., Taquet, N., Rodríguez, S., López-Darias, J., Sicard, M., Córdoba-Jabonero, C., and Cuevas, E. (2023). Impact of the 2021 la palma volcanic eruption on air quality: Insights from a multidisciplinary approach. *Sci. Total Environ.*, **869**, 161652. 34
- Olcese, L. E., Palancar, G. G., and Toselli, B. M. (2015). A method to estimate missing aeronet aod values based on artificial neural networks. *Atmospheric Environment*, **113**, 140–150. 39
- Onishi, R. and Sugiyama, D. (2017). Deep convolutional neural network for cloud coverage estimation from snapshot camera images. *SOLA*, **13**, 235–239. 40
- Orsini, A., Tomas, C., Calzolari, F., Nardino, M., and Cacciari, A. and Georgiadis, T. (2002). Cloud cover classification through simultaneous ground-based measurements of solar and infrared radiation. *Atmospheric Research*, **61**, 251–275. 14
- O’Shea, K. and Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*. 46
- Oznovich, I., Yee, R., Schiffler, A., McEwen, D. J., and Sofko, G. J. (1994). The all-sky camera revitalized. *Applied Optics*, **33**(30), 7141–7150. Publisher: Optica Publishing Group. 20
- Perrone, M. R., Lorusso, A., and Romano, S. (2022). Diurnal and nocturnal aerosol properties by aeronet sun-sky-lunar photometer measurements along four years. *Atmospheric Research*, **265**, 105889. 12
- Pickering, T. E. (2006). The MMT all-sky camera. In *Ground-based and Airborne Telescopes*, volume 6267, pages 448–454. SPIE. 20

BIBLIOGRAFÍA

- Poyer, A. (2008). Evaluation of an MPL cloud detection algorithm as a reference for ceilometer testing within the ASOS PI program. In *American Meteorological Society, 88th Annual Meeting, Sterling, Virginia*, pages 1–6. 14
- Pérez-Ramírez, D., Aceituno, J., Ruiz, B., Olmo, F., and Alados-Arboledas, L. (2008). Development and calibration of a star photometer to measure the aerosol optical depth: Smoke observations at a high mountain site. *Atmospheric Environment*, **42**(11), 2733–2738. Vienna Visibility Conference 2006. 13
- Quirantes Calvo, J. A. and Gallego Poveda, J. A. (2011). *Atlas de Nubes y Meteoros*. Torrelavega, Editorial de Urueña, Castilla Tradicional S.L. y Cantabria tradicional S.L. 4, 5
- Rasamoelina, A. D., Adjailia, F., and Sinčák, P. (2020). A review of activation function for artificial neural network. In *2020 IEEE 18th world symposium on applied machine intelligence and informatics (SAMI)*, pages 281–286. IEEE. 40
- Ricciardelli, E., Romano, F., and 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**(6), 2741–2760. 14
- Rodríguez, E., Toledano, C., Cachorro, V. E., Ortiz, P., Stebel, K., Berjón, A., Blindheim, S., Gausa, M., and de Frutos, A. M. (2011). Aerosol characterization at the sub-Arctic site Andenes (69N, 16E), by the analysis of columnar optical properties. *Quart. J. Roy. Met. Soc. (in press)*. 37
- Román, R., González, R., Toledano, C., Barreto, A., Pérez-Ramírez, D., Benavent-Oltra, J. A., Olmo, F. J., Cachorro, V. E., Alados-Arboledas, L., and de Frutos, A. M. (2020). Correction of a lunar-irradiance model for aerosol optical depth retrieval and comparison with a star photometer. *Atmospheric Measurement Techniques*, **13**(11), 6293–6310. 13, 30, 35
- Román, R., Antuña Sánchez, J. C., Cachorro, V. E., Toledano, C., Torres, B., Mateos, D., Fuertes, D., López, C., González, R., Lapionok, T., Herreras-Giralda, M., Dubovik, O., and de Frutos, A. M. (2022). Retrieval of aerosol properties using relative radiance measurements from an all-sky camera. *Atmospheric Measurement Techniques*, **15**(2), 407–433. 15, 21, 33

- Román, R., González-Fernández, D., Antuña Sánchez, J. C., Herrero del Barrio, C., Herrero-Anta, S., Barreto, A., Cachorro, V. E., Doppler, L., González, R., Ritter, C., Mateos, D., Kouremeti, N., Copes, G., Calle, A., Granados-Muñoz, M. J., Toledano, C., and de Frutos, A. M. (2025). Star photometry with all-sky cameras to retrieve aerosol optical depth at night-time. *Atmospheric Measurement Techniques*. *Accepted for publication*. 17, 23, 24, 25, 34, 38, 86, 89
- Román, R. (2014). *Reconstrucción y análisis de la radiación ultravioleta eritemática en la Península Ibérica desde 1950*. Ph.D. thesis, Universidad de Valladolid. 2, 8, 85
- Román, R., Bilbao, J., and de Miguel, A. (2014). Uncertainty and variability in satellite-based water vapor column, aerosol optical depth and angström exponent, and its effect on radiative transfer simulations in the iberian peninsula. *Atmospheric Environment*, **89**, 556 – 569. 15, 33
- Román, R., Cazorla, A., Toledano, C., Olmo, F., Cachorro, V., de Frutos, A., and Alados-Arboledas, L. (2017). Cloud cover detection combining high dynamic range sky images and ceilometer measurements. *Atmospheric Research*, **196**, 224–236. 16
- Rosenblatt, F. (1962). Principles of neurodynamics. *Perceptrons and the theory of brain mechanisms*. 41
- Rossow, W. and Schiffer, R. (1999). Advances in understanding clouds from isccp. *Bulletin of the American Meteorological Society*, **80**(11), 2261. 14
- Scarlatti, F., Gómez-Amo, J. L., Valdelomar, P. C., Estellés, V., and Utrillas, M. P. (2023). A machine learning approach to derive aerosol properties from all-sky camera imagery. *Remote Sensing*, **15**(6). 16
- Seinfeld, J. H. and Pandis, S. N. (2016). *Atmospheric chemistry and physics: from air pollution to climate change*. OCLC: 929985301. 3
- Shalev-Shwartz, S. and Ben-David, S. (2014). *Neural Networks*, page 228–242. Cambridge University Press. 40, 43
- Shaw, G. E. (1983). Sun photometry. *Bull. Am. Meteorol. Soc.*, **64**, 4–10. 12
- Shields, J., Johnson, R., Karr, M., and Wertz, J. (1998). Automated day/night whole sky imagers for field assessment of cloud cover distributions and radiance distributions. In *Tenth symposium on meteorological observations and instrumentation*. American Meteorological Society. 20

BIBLIOGRAFÍA

- Shine, K. P., Derwent, R. G., Wuebbles, D. J., Morcrette, J. J., and Apling, A. J. (1990). Radiative forcing of climate. In *In Climate change: The IPCC scientific assessment*, pages 41–68. Cambridge University Press. 9
- Sicard, M., Córdoba-Jabonero, C., Barreto, A., Welton, E. J., Gil-Díaz, C., Carvajal-Pérez, C. V., Comerón, A., García, O., García, R., López-Cayuela, M.-A., Muñoz-Porcar, C., Prats, N., Ramos, R., Rodríguez-Gómez, A., Toledano, C., and Torres, C. (2022). Volcanic eruption of cumbre vieja, la palma, spain: A first insight to the particulate matter injected in the troposphere. *Remote Sens.*, **14**(10). 34
- Silva, A. A. and Souza-Echer, M. P. (2016). Ground-based observations of clouds through both an automatic imager and human observation. *Meteorological Applications*, **23**(1), 150–157. 16
- Sinyuk, A., Holben, B. N., Eck, T. F., Giles, D. M., Slutsker, I., Korokin, S., Schafer, J. S., Smirnov, A., Sorokin, M., and Lyapustin, A. (2020). The aeronet version 3 aerosol retrieval algorithm, associated uncertainties and comparisons to version 2. *Atmospheric Measurement Techniques*, **13**(6), 3375–3411. 28
- Solomon, S., Qin, D., Manning, M., Chen, Z., Marquis, M., Averyt, K. B., Tignor, M., and Miller, H. L., editors (2007). *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press. 9
- Stanhill, G. and Cohen, S. (2001). Global dimming: A review of the evidence for a widespread and significant reduction in global radiation. *Agric. For. Meteorol.*, (107), 255–278. 15
- Stone, R., Mefford, T., Dutton, E., Longenecker, D., Halter, B., and Endres., D. (1996). Surface radiation and meteorological measurements: January 1992 to December 1994. *NOAA Data Report ERL-CMDL-11*, page 81pp. 9
- Sturm, P. (2021). Fisheye lens. in computer vision: A reference guide. *Cham: Springer International Publishing*, pages 476–478. 21
- Sánchez-Lorenzo, A., Calbó, J., Brunetti, M., and Deser, C. (2009). Dimming/brightening over the iberian peninsula: Trends in sunshine duration and cloud cover and their relations with atmospheric circulation. *J. Geophys. Res.*, (114), D00D09. 15
- Süring, R. (1922). *Photogrammetrische Wolkenforschung in Potsdam in den Jahren 1900 bis 1920*. 19

- Tapakis, R. and Charalambides, A. (2013). Equipment and methodologies for cloud detection and classification: A review. *Solar Energy*, **95**, 392–430. 13, 14
- Cimel Electronique (2004). *Suphotometer User manual version 4.6*. Cimel Electronique, Paris. 27
- EKO Instruments CO., LTD (2015). *Instruction Manual Pyranometer MS-802/402/410/602 With Ventilator: MS-802F/402F Version: 9*. EKO Instruments CO., LTD, Tokyo, Japan. 31, 32, 33
- Kipp&Zonen (2004a). *Instruction Manual CM21 Precision Pyranometer*. Kipp & Zonen, Delft the Netherlands. 15, 31, 32
- Kipp&Zonen (2004b). *Instruction Manual CM22 Precision Pyranometer*. Kipp & Zonen, Delft the Netherlands. 31, 32
- Kipp&Zonen (2013). *Instruction Manual CMP Series Pyranometer/CMA Series Albedometer*. Kipp & Zonen, Delft the Netherlands. 31, 32
- Kipp&Zonen (30/04/2025). *Calibration Standards* <https://www.kippzonen.com/ProductGroup/112/Calibration-Standards>. 33
- Tirado, A. J. C. (2006). Cámara digital nocturna y sus aplicaciones para la observación automática de todo el cielo. 20
- Toledano, C. (2005). *Climatología de los aerosoles mediante la caracterización de propiedades ópticas y masas de aire en la estación ÉI Arenosillo de la red AERONET*. Ph.D. thesis, Universidad de Valladolid. 3, 11
- Toledano, C., González, R., Fuertes, D., Cuevas, E., Eck, T. F., Kazadzis, S., Kouremeti, N., Gröbner, J., Goloub, P., Blarel, L., Román, R., Barreto, A., Berjón, A., Holben, B. N., and Cachorro, V. E. (2018). Assessment of sun photometer langley calibration at the high-elevation sites mauna loa and izaña. *Atmospheric Chemistry and Physics*, **18**(19), 14555–14567. 12, 29, 35
- Tompson, J., Goroshin, R., Jain, A., LeCun, Y., and Bregler, C. (2015). Efficient object localization using convolutional networks. 53
- Uchiyama, A., Shiobara, M., Kobayashi, H., Matsunaga, T., Yamazaki, A., Inei, K., Kawai, K., and Watanabe, Y. (2019). Nocturnal aerosol optical depth measurements with modified sky radiometer pom-02 using the moon as a light source. *Atmospheric Measurement Techniques*, **12**(12), 6465–6488. 13

BIBLIOGRAFÍA

- Urquhart, B., Kurtz, B., Dahlin, E., Ghonima, M., Shields, J. E., and Kleissl, J. (2015). Development of a sky imaging system for short-term solar power forecasting. *Atmospheric Measurement Techniques*, **8**(2), 875–890. 20
- Valenzuela, A., Olmo, F. J., Lyamani, H., Antón, M., Quirantes, A., and Alados-Arboledas, L. (2012). Aerosol radiative forcing during african desert dust events (2005–2010) over southeastern spain. *Atmos. Chem. Phys.*, **12**, 10331–10351. 35
- Vasaras, A., Bais, A., Feister, U., and Zerefos, C. (2001). Comparison of two methods for cloud flagging of spectral uv measurements. *Atmospheric Research*, **57**, 31–42. 14
- Wallace, J. M. and Hobbs, P. V. (2006). *Atmospheric Science: An Introductory Survey*. Elsevier. Google-Books-ID: HZ2wNtDOU0oC. 2
- Warren, S., Eastman, R., and Hahn, C. (2015). Clouds and Fog | Climatology. In *Encyclopedia of Atmospheric Sciences*, pages 161–169. Elsevier. 13
- Widener, K. and Long, C. (2004). All sky imager. 20
- Wild, M. (2009). Global dimming and brightening: A review. *J. Geophys. Res.*, (114), D00D16. 15
- Wild, M. (2012). Enlightening global dimming and brightening. *Bull. Amer. Meteor. Soc.*, (93), 27–37. 15
- Wild, M., Gilgen, H., Roesch, A., Ohmura, A., Long, C. N., Dutton, E. G., Forgan, B., Kallis, A., Russak, V., and Tsvetkov, A. (2005). From dimming to brightening: Decadal changes in solar radiation at earth’s surface. *Science*, (308), 847–850. 15
- Wild, M., Trüssel, B., Ohmura, A., Long, C. N., Dutton, E. G., König Langlo, G., and Tsvetkov, A. (2009). Global dimming and brightening: An update beyond 2000. *J. Geophys. Res.*, (114), D00D13. 15
- Willeke, K., Baron, P. A., and Martonen, T. (1993). *Aerosol measurement: principles, techniques, and applications*, volume 876. Van Nostrand Reinhold New York. 3
- WMO (1996). *Guía de Instrumentos y Métodos de Observación Meteorológicos, Sexta Edición WMO-No.8*. 14, 32
- WMO (2012). *Recommended Methods for Evaluating Cloud and Related Parameters*. WWRP/WGNE Joint Group on Forecast Verification Research (JWGFVR), World Weather Research Programme (WWRP) 2012-1. 30

- WMO (2017). Atlas Internacional de Nubes. <https://cloudatlas.wmo.int/home.html>. 4, 6, 13, 30, 31, 85
- Xie, W., Liu, D., Yang, M., Chen, S., Wang, B., Wang, Z., Xia, Y., Liu, Y., Wang, Y., and Zhang, C. (2020). Segcloud: a novel cloud image segmentation model using a deep convolutional neural network for ground-based all-sky-view camera observation. *Atmospheric Measurement Techniques*, **13**(4), 1953–1961. 39
- Yadav, A. K. and Chandel, S. (2014). Solar radiation prediction using artificial neural network techniques: A review. *Renewable and Sustainable Energy Reviews*, **33**, 772–781. 39
- Zhang, L. (2009). *Durham All-Sky Camera (DAC)*. Master's thesis, Durham University. 20
- Zhao, G. and Di Girolamo, L. (2006). Cloud fraction errors for trade wind cumuli from eosterra instruments. *Geophysical Research Letters*, **33**(20), L20802. 14

Índice de figuras

1.1	Contribución al forzamiento radiativo efectivo (a) y al cambio de la temperatura global en superficie (b) a partir de las emisiones de los componentes para el periodo de 1750-2019 basado en los modelos CMIP6 (<i>Coupled Model Intercomparison Project Phase 6</i>). Forzamiento radiativo efectivo neto de los aerosoles para el periodo de 1750-2014 a partir de diferentes líneas de evidencia (c). Figura obtenida del AR6 del IPCC (2021).	5
1.2	Clasificación de los 10 géneros de nubes existentes, los cuales se distribuyen en tres niveles verticales según la altitud. Estos géneros son los siguientes: Stratus (Sc), Stratocumulus (St), Cumulus (Cu), Cumulonimbus (Cb), Alto-cumulus (Ac), Altostratus (As), Nimbostratus (Ns), Cirrus (Ci), Cirrocumulus (Cc) y Cirrostratus (Cs). Figura obtenida de WMO (2017).	6
1.3	Irradiancia solar extraterrestre (negro) correspondiente a Kurucz (1992) e irradiancia solar horizontal en la superficie de la Tierra (gris), ambas en función de la longitud de onda (λ). La irradiancia en superficie corresponde a la simulación de un modelo de transferencia radiativa con valores por defecto y una altura solar de 60°. Figura obtenida de Román (2014).	8
1.4	Balance radiativo de la Tierra. Figura obtenida de [https://myasadata.larc.nasa.gov/basic-page/earths-energy-budget].	10
2.1	Patrón Bayer RGGB y aplicación del <i>demosaiicing</i> para conseguir la matriz de color final.	21
2.2	Modelos de cámaras de todo cielo: a) Modelo SONA-202NF (Figura obtenida de Antuña-Sánchez, 2022); b) Modelo OMEA-3C. Ambos modelos propiedad del GOA-UVa instalados en Valladolid.	22

ÍNDICE DE FIGURAS

2.3	Transmitancia espectral normalizada de diferentes filtros: a) filtros Rojo, Verde y Azul (RGB) del mosaico Bayer del sensor de la cámara de todo cielo SONA-202NF, normalizada con respecto al máximo valor de entre los tres canales; b) filtro tri-banda; c) combinación de ambos filtros. Figura obtenida de Antuña-Sánchez (2022).	22
2.4	Transmitancia espectral normalizada de diferentes filtros: a) filtros Rojo, Verde y Azul (RGB) del mosaico Bayer del sensor de las cámaras de todo cielo OMEA-3C, normalizada con respecto al máximo valor de entre los tres canales; b) filtro infrarrojo incluido en el modelo OMEA-3C; c) filtro tri-banda incluido en el modelo OMEA-3C-TF; d) combinación de los filtros RGB e infrarrojo del modelo OMEA-3C; e) combinación de los filtros RGB y tri-banda del modelo OMEA-3C-TF. Los paneles d) y e) también muestran la respuesta espectral de la señal del sensor en escala de grises, la cual se calcula como una combinación de los tres canales de color cada uno con los siguientes pesos: 0.299 para el rojo, 0.587 para el verde y 0.114 para el azul. Figura obtenida de Román <i>et al.</i> (2025).	24
2.5	Imagen HDR mostrada en la página web del GOA-UVa (https://goa.uva.es/), en la pestaña “ <i>Sites&Measurements</i> ”. Esta imagen corresponde a la cámara OMEA-3C-TF instalada en la Facultad de Ciencias de la Universidad de Valladolid, tomada el día 5 de febrero de 2025 a las 14:05 UTC.	27
2.6	Fotómetro Cimel CE318-T. a) Partes de las que consta el instrumento: caja de control, cabeza, colimador, cable de la cabeza, rueda de filtros y robot. b) Fotómetro del GOA-UVa.	28
2.7	Piranómetros empleados para la medidas de irradiancia global horizontal: a) Modelo CMP-11, b) Modelo CM-21 (sobre el seguidor solar SOLYS-2 de la misma casa) y c) Modelo CM-22; los tres del fabricante <i>Kipp&Zonen</i> . d) Modelo EKO-MS802F de <i>EKO Instruments CO., LTD.</i>	31
2.8	Mapa con la localización de las estaciones de medida empleadas en este trabajo. Figura obtenida de Román <i>et al.</i> (2025).	34
3.1	Esquema de una neurona: los valores del conjunto de parámetros de entrada X , ponderado cada uno con su respectivo peso del conjunto W^i , se combinan mediante una función de entrada en la neurona i . Finalmente, esta procesa el resultado mediante una función de activación para obtener la salida y_i	41
3.2	Esquema general de red neuronal.	44

3.3	Ejemplo sobre la aplicación de la operación de convolución que reduce a la salida la dimensión de la matriz de entrada. Figura obtenida de https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/	47
3.4	Ejemplo de convolución en tres dimensiones, donde la entrada y el <i>kernel</i> añaden la dimensión de profundidad, que debe ser la misma para ambas matrices, con respecto al caso bidimensional. La profundidad indica el número de canales, como por ejemplo en el caso de una imagen RGB serían los canales de color rojo, verde y azul. Figura obtenida de https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/	48
3.5	Aplicación de dos <i>kernels</i> en un operación de convolución, lo que proporciona mayor profundidad a la salida que aplicando únicamente un <i>kernel</i> . Figura obtenida de https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/	49
3.6	Aplicación de una convolución utilizando con un <i>stride</i> de 2 para reducir más a la salida la dimensión de la matriz de entrada. Figura obtenida de https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/	49
3.7	Aplicación de una convolución utilizando el <i>zero-padding</i> que rellena con ceros los bordes de la entrada para mantener la dimensión original a la salida. Figura obtenida de https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/	50
3.8	Capas de <i>pooling</i> . En el panel izquierdo se muestra el caso de aplicar sobre la entrada la operación de <i>max-pooling</i> que toma a la salida el valor máximo de cada región coloreada. En el panel derecho se aplica la misma operación cambiando la función máximo por el promedio, lo que se conoce como <i>average-pooling</i> . Figura obtenida de https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/	51
3.9	Esquema de la arquitectura de la red neuronal convolucional desarrollada. Figura obtenida de (González-Fernández <i>et al.</i> , 2024a).	52

Índice de tablas

2.1	Información detallada sobre la localización y el periodo de medición de cada cámara de todo cielo de la red GOA-SCAN utilizada en este trabajo. La fecha Presente corresponde a 22 de enero de 2025. Tabla adaptada de Román <i>et al.</i> (2025).	38
-----	--	----

