

Proyecto Fin de Grado

Grado en Ingeniería de la Energía

Estimación de la atenuación de la radiación solar en condiciones de cielo nublado mediante el uso de cámaras de cielo.

Autor: Francisco José Cabello Núñez

Tutor: Manuel Antonio Silva Pérez

Dep. Ingeniería Energética
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2013



Proyecto Fin de Grado
Grado en Ingeniería de la Energía

**Estimación de la atenuación de la radiación
solar en condiciones de cielo nublado mediante
el uso de cámaras de cielo.**

Autor:

Francisco José Cabello Núñez

Tutor:

Manuel A. Silva Pérez

Profesor contratado doctor

Dep. Ingeniería Energética
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2016

Proyecto Fin de Carrera: Estimación de la atenuación de la radiación solar en condiciones de cielo nuboso mediante el uso de cámaras de cielo.

Autor: Francisco José Cabello Núñez

Tutor: Manuel A. Silva Pérez

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2016

El Secretario del Tribunal

A mi familia

A mis maestros

A mis amigos

Agradecimientos

La culminación de este proyecto supone para mí la finalización de cuatro años de grado y por tanto un cambio de ciclo en mi vida. Por ello me gustaría agradecer el apoyo que me han dado muchas personas. En primer lugar me gustaría agradecerle a mi novia Claudia su apoyo en todo momento, tanto en las mejores situaciones como en los momentos más difíciles. A mi hermano Carlos por ser para mí un ejemplo de lucha. A mis padres por su apoyo incondicional y su educación. A mis abuelos por contarme sus vivencias para que me sirvan como guía en la vida y por representar para mí la voz de la experiencia. A mis compañeros de clase por los buenos ratos que han ayudado a hacer estos cuatro años de carrera más llevaderos.

También me gustaría agradecer a Miguel Larrañeta y Sara Moreno su ayuda para sacar este proyecto adelante. Y finalmente a Manuel Silva por todo lo que me ha enseñado como profesor pero sobre todo por portarse conmigo como una excelente persona.

A todos ellos y a todos los que me han apoyado y enseñado cosas en la vida. Porque sin ellos no hubiera llegado a ser quien soy, muchísimas gracias.

Francisco José Cabello Núñez

Sevilla, 2016

Resumen

El desarrollo de este proyecto se centra en la consecución de un programa que sea capaz de estimar la disminución en la radiación solar directa normal que producirían las diferentes nubes existentes. Para ello se hará uso de una base de datos de imágenes obtenidas a partir de cámaras de cielo y de los datos de la radiación directa normal obtenidos por un pirheliómetro. Para caracterizar las nubes se extraerá información visual de las imágenes en las que aparezcan estas como pueden ser sus características de color y textura visual, para a continuación intentar relacionar estas propiedades de la nube con la disminución que dichas nubes han provocado en la radiación solar directa normal. Para obtener esta relación se hará uso de herramientas basadas en redes neuronales, las cuales darán como resultado una función que muestre dicha relación. Para el entrenamiento de estas redes neuronales se hará uso de datos históricos en los que se encuentran 55 nubes diferentes y el factor de atenuación que estas nubes han provocado.

ÍNDICE

Agradecimientos	9
Resumen	11
Índice	13
Índice de Tablas	14
Índice de Figuras	15
Notación	18
1 Introducción.	19
2 Objetivo.	21
3 Fundamentos.	22
3.1 El recurso solar.	22
3.2 Radiación solar y sus componentes.	24
3.3 Interacción de la radiación solar con la atmosfera terrestre.	26
3.4 La nube y sus tipologías.	27
3.5 Predicción de la radiación solar a muy corto plazo.	31
3.6 Análisis de imágenes en Matlab.	34
3.7 Fundamento de las redes neuronales	39
4 Instrumentación	42
5 Metodología.	45
5.1 Red neuronal clasificadora de píxeles.	45
5.1.1 Cálculo de la posición del Sol en la imagen y cálculo de la distancia de cualquier píxel al centro solar.	45
5.1.2 Aplicación del código HDR	51
5.1.3 Aplicación de la red neuronal clasificadora.	52
5.2 Red neuronal asociadora de un factor de atenuación a cada nube.	53
5.2.1 Modelo de cielo despejado y cálculo del factor de atenuación.	53
5.2.2 Calculo de las propiedades de la nube y asociación a un factor de atenuación.	54
5.2.3 Utilización de una red neuronal para el cálculo del factor de atenuación.	58
6 Resultados.	61
6.1 Resultados obtenidos en la red neuronal clasificadora de píxeles.	61
6.2 Resultados obtenidos en la red neuronal encargada de estimar el factor de atenuación que provoca una nube.	64
7 Conclusiones.	68
8 Referencias.	69

ÍNDICE DE TABLAS

Tabla 1 - Clasificación de las nubes basándonos en su altitud para las diferentes regiones polares. (Ahrens, NOAA – National Weather Service, website).	28
Tabla 2 - Variedades y especies de los diez tipos de nubes más comunes. (WMO – World Meteorological Organization, 1956).	30
Tabla 3 – Parámetros de entrada a la red neuronal clasificadora de píxeles.	45
Tabla 4 – Propiedades de la imagen utilizadas para caracterizar la nube.	55
Tabla 5 – Matriz de entrada de la red neuronal clasificadora de nubes.	60

ÍNDICE DE FIGURAS

Figura 1- Energía solar recibida en un año y reservas de energía presentes en la Tierra.	23
Figura 2 – Caracterización de la radiación solar mostrando la irradiancia espectral para las diferentes longitudes de onda del espectro solar.	24
Figura 3 – Diferentes componentes de la radiación solar.	25
Figura 4 – Representación de las diferentes componentes de la radiación solar para un día claro. [2]	26
Figura 5 - Clasificación de los diferentes tipos de nubes.	29
Figura 6 – Representación de la gama de colores mediante el modelo HSV.	35
Figura 7 – Explicación de la propiedad rango de la imagen.	37
Figura 8 – Proceso seguido para crear la matriz GLCM.	38
Figura 9 – Representación del funcionamiento básico de una neurona.	40
Figura 10 – Especificaciones técnicas y fotografía del pirheliómetro CHP1 de Kipp & Zonen Citar fabricante y manual.	42
Figura 11 – Especificaciones técnicas de la cámara Q-25M de Mobotix.	43
Figura 12 – Imagen de la cámara Q-25M de Mobotix.	44
Figura 13 – Plano de la Escuela Superior de Ingenieros y la localización de los instrumentos usados en este proyecto.	44
Figura 14 – Coordenadas con las que se definen un píxel en una imagen.	48
Figura 15 – Representación de las coordenadas polares en la imagen y de los valores α y R .	49
Figura 16 – Muestra de las coordenadas cartesianas en la imagen centras en el centro de la cámara.	50
Figura 17 – Combinación de dos imágenes a través del uso del código HDR para lograr una imagen con mejor visibilidad.	52
Figura 18 – Representación del método de localización para detectar puntos de interés	57
Figura 19 – Localización de la nube que provoca la disminución de la radiación solar.	57
Figura 20 – Matrices de confusión obtenidas como resultado de la actuación de la red neuronal clasificadora de píxeles.	61
Figura 21 – Imagen obtenida por la cámara de cielo a la cual se le aplicará la red neuronal clasificadora de píxeles.	63
Figura 22 – Imagen resultado obtenida tras aplicar la red neuronal clasificadora de píxeles.	63
Figura 23 – Valores de la regresión obtenida en las diferentes etapas de la red neuronal clasificadora de nubes.	65
Figura 24 – Histograma de errores obtenidos en los resultados de la red neuronal clasificadora de nubes.	66
Figura 25 – Matrices de confusión obtenidas como resultado de la actuación de la red neuronal clasificadora de nubes.	67

Notación

S	Entropía de una textura
p_i	Intensidad del pixel “i” en escala de gris
TO	Tiempo oficial
\log_2	Logaritmo en base 2
y_i	Salida de una unidad neuronal
w_i	Peso otorgado por la unidad neuronal
h	Hora
min	Minuto
Γ	Angulo diario
n	Ordinal del día del año
Et	Parámetro de la ecuación del tiempo
TSV	Tiempo solar verdadero
λ	Coordenada terrestre longitud
λ_s	Longitud de referencia
w	Ángulo horario
δ	Declinación
sen	Función seno
O_z	Ángulo cenital
ϕ	Latitud
Az	Angulo acimutal.
cos	Función coseno
r	Coordenada radial
θ	Coordenada angular
α	Angulo formado entre el sur y el eje x positivo de la imagen
x	Coordenada del eje de abcisas
y	Coordenada del eje de ordenada
d	Distancia del pixel estudiado al pixel que representa al centro del sol
Ebn	Irradiancia normal directa
I_{cs}	Constante solar
A	Parámetro que modela los fenómenos de absorción en la atmosfera
B	Parámetro que modela los fenómenos de dispersión en la atmosfera
m_R	Masa óptica relativa de aire
k	Factor de atenuación
DNI	Radiación solar directa normal

1 INTRODUCCIÓN.

Un modelo energético sostenible sería aquel caracterizado por unos patrones de producción y consumo que compatibilizaran el desarrollo económico, social y ambiental, satisfaciendo las necesidades energéticas de las generaciones presentes sin comprometer las posibilidades de las generaciones futuras para atender sus propias necesidades. Para que ello sea posible, el modelo energético debe tener en cuenta tres elementos básicos:

- Seguridad energética: Debe garantizar la continuidad del suministro a precios razonables para los consumidores.
- Competitividad: No debe suponer un peligro para la competitividad de la economía, y su crecimiento.
- Sostenibilidad ambiental: La producción y el consumo de energía no deben suponer un impacto inasumible para el entorno.

El modelo energético actual se caracteriza por un crecimiento constante del consumo energético, basado en recursos finitos, principalmente combustibles fósiles por lo tanto un sistema energético basado exclusivamente en el aprovechamiento de estos recursos fósiles no sería un modelo sostenible ya que al ser elementos finitos en nuestro planeta no podríamos asegurar el suministro energético en un futuro.

Es destacable que una economía basada en el consumo de recursos energéticos fósiles finitos (gas, carbón y petróleo) verá comprometida su competitividad ante el previsible crecimiento tendencial que experimentarán los precios de las materias primas energéticas. Por otro lado, en el caso de las economías fuertemente dependientes del exterior para cubrir sus necesidades energéticas (como es el caso de España), al riesgo de la elevación de precio, se añade el de interrupción del suministro ante eventuales situaciones de diversa índole que ocurran en los países exportadores.

Por el lado de la sostenibilidad ambiental, la evolución del consumo energético implica un incremento de las emisiones de Gases de Efecto Invernadero (GEI) muy superior al necesario para limitar el incremento de la temperatura global a 2 °C.

Debido a estos y otros factores, varios estudios llegan a la conclusión de que el sistema energético actual basado en los combustibles fósiles es un sistema insostenible.

En definitiva, la insostenibilidad del modelo hace necesario la puesta en marcha con celeridad de medidas que conlleven una profunda transformación del modelo energético [1]. Múltiples agencias y organismos ofrecen datos fehacientes que constatan la necesidad de la búsqueda de soluciones que

pasan por el uso de energías renovables. Esta preocupación social se puede ver plasmada en políticas y hechos recientes como pueden ser las políticas europeas del Horizonte 2020 o la cumbre del clima de París.

Por ello un camino a seguir para lograr un modelo energético sostenible pasa por el uso de las energías renovables. Estos recursos alternativos presentan varias virtudes, entre ellas:

- En general son tecnologías no emisoras de CO₂.
- Se basan en recursos autóctonos por lo que reducen la dependencia exterior.
- En algunos casos (como el solar) disponen de un recurso prácticamente “inagotable”.

En el caso de España una alternativa energética de gran interés es el caso del recurso solar, debido a su abundancia en esta zona geográfica. El recurso solar cuya fuente, el Sol, es en la actualidad la más abundante, presenta un inconveniente y es que su naturaleza discontinua dificulta su aprovechamiento. Por ello es de vital importancia el estudio de este recurso para poder realizar una predicción y estimación para llegar a conocer la variación e intermitencias de este [2]. De esta forma poder utilizar estos estudios en los sistemas basados en el aprovechamiento de la energía de solar para la producción de energía eléctrica para anticiparnos a los acontecimientos y poder mejorar así la eficiencia y gestión de ellos facilitando por lo tanto la penetración en el mercado de este tipo de sistemas de producción de energía alternativos. Un sistema de aprovechamiento de la energía solar para su conversión en energía eléctrica que es importante de destacar es el caso de las centrales termosolares. Dichas centrales aprovechan la energía solar mediante la concentración de la componente directa de la radiación para su posterior conversión a energía térmica y finalmente mediante la utilización de un bloque de potencia generar energía eléctrica [4]. Por ello el proyecto que se muestra a continuación puede ser importante para este tipo de sistemas ya que su objeto es el estudio de la componente directa de la radiación solar y su predicción.

2 OBJETIVO.

Este proyecto tiene como objetivo la caracterización de los diferentes tipos de nubes basándose en la utilización de imágenes de cámara de cielo para posteriormente a través de los datos medidos por un pirheliómetro, asociarle a los diferentes grupos de nubes un valor de atenuación el cual refleja la disminución que estas nubes provocan en la radiación solar directa. Para ello, se hará un análisis de las imágenes obtenidas por las cámaras de cielo con el objeto de extraer información de las nubes que se observan, como pueden ser sus propiedades de color y de textura. Para lograr una mejor caracterización de la nube se hará uso de las redes neuronales a través de las cuales en primer lugar realizaremos una clasificación de píxeles en la que se analizarán las propiedades de cada píxel para clasificarlo y lograr de forma autónoma que se clasifique un píxel en una de las cuatro tipologías que se definen: nube densa, nube tenue, cielo despejado o píxel perteneciente al disco solar. Una vez realizada esta primera función clasificadora de píxeles, se empleará para definir qué cantidad de píxeles pertenecientes a una determinada nube se encuentra en cada uno de los tipos definidos. Junto con otras propiedades de la imagen nube se procederá a realizar una caracterización de esta. Con la ayuda de un modelo de cielo despejado y las medidas reales de un pirheliómetro se calculará la atenuación que ha provocado cada nube caracterizada y se le asociará a cada una un factor de atenuación. Finalmente con todo el conjunto de nubes caracterizadas y su factor de atenuación asociado, se procederá al entrenamiento de otra red neuronal, la cual asociará estos dos conceptos y a partir de la cual se obtendrá una función resultado con el objeto de aplicar esta función en futuras nubes para predecir la disminución que provocarán en la radiación solar directa normal.

3 FUNDAMENTOS.

3.1 El recurso solar.

El Sol es la principal fuente de energía para todos los procesos que tienen lugar en nuestro planeta. Localizado a una distancia media de 150 millones de kilómetros, tiene un radio de 109 veces el de la Tierra y está formado por gases a muy alta temperatura. En su núcleo se producen continuamente reacciones atómicas de fusión nuclear que convierten el hidrógeno en helio. Este proceso libera gran cantidad de energía que sale hasta la superficie visible del Sol (fotosfera), y escapa en forma de rayos solares al espacio exterior. Solo una pequeña parte de la energía resultante de las reacciones que tienen lugar en el interior del Sol llega a la superficie terrestre, aun así, es la fuente de energía más abundante de que disponen los seres vivos. [3] El aporte de energía solar que llega a la tierra en un solo año es muy superior a toda la energía existente en la tierra en forma de recursos fósiles. Si se aprende a aprovechar completamente la energía que llega del Sol se pueden llegar a satisfacer todas las necesidades energéticas de los seres vivos [2]. Se estima que a lo largo del presente año el Sol habrá arrojado sobre la Tierra aproximadamente cuatro mil veces más energía de la que se va a consumir. Sería poco racional por lo tanto no intentar aprovechar esta fuente de energía limpia e “inagotable” (Varias estimaciones concretan que en los próximos 6.000 millones de años, el Sol tan solo consumirá el diez por ciento del hidrógeno que contiene en su interior, por lo que podemos suponerlo “inagotable”), que puede librar al ser humano definitivamente de la dependencia del petróleo o de otras alternativas poco seguras, contaminantes o simplemente limitadas [3]. Es de vital importancia por lo tanto proseguir con el desarrollo y perfeccionamiento de las tecnologías de captación, acumulación y distribución de la energía solar para conseguir las condiciones que la hagan definitivamente competitiva a escala mundial.




Figura 1- Energía solar recibida en un año y reservas de energía presentes en la Tierra. [4]

Por otro lado, existen varios inconvenientes que dificultan el aprovechamiento de este tipo de energía, destacan especialmente la dispersión y discontinuidad de la radiación solar. Este es el principal motivo por el cual a pesar de ser una fuente de energía limpia y de calidad no se ha desarrollado en plenitud.

Centrándonos en la energía procedente del sol, como consecuencia del movimiento de la Tierra alrededor del Sol según una órbita elíptica la distancia a este último varía ligeramente, lo que influye en las características de la radiación recibida. Los datos de referencia de la radiación solar, que son la constante solar y la distribución espectral, se establecen para las condiciones de distancia media Sol-Tierra. Se denomina constante solar a la energía que incide por unidad de área y en la unidad de tiempo sobre una superficie orientada normalmente a la dirección de la propagación de la radiación solar y situada en el exterior de la atmósfera terrestre. Este valor varía ligeramente y equivale en valor promedio a 1367 W/m^2 . La radiación emitida por el Sol se distribuye en un amplio espectro de longitudes de onda correspondiendo la mayor parte de la energía radiada a la porción comprendida entre 0.2 y $3.0 \mu\text{m}$, con una distribución espectral muy similar a la producida por un cuerpo negro a 5777 K . Alrededor de la mitad de dicha energía se encuadra dentro de la banda visible, 0.39 a $0.77 \mu\text{m}$. El resto corresponde casi por completo a radiación infrarroja, con un pequeño porcentaje de radiación ultravioleta [2].

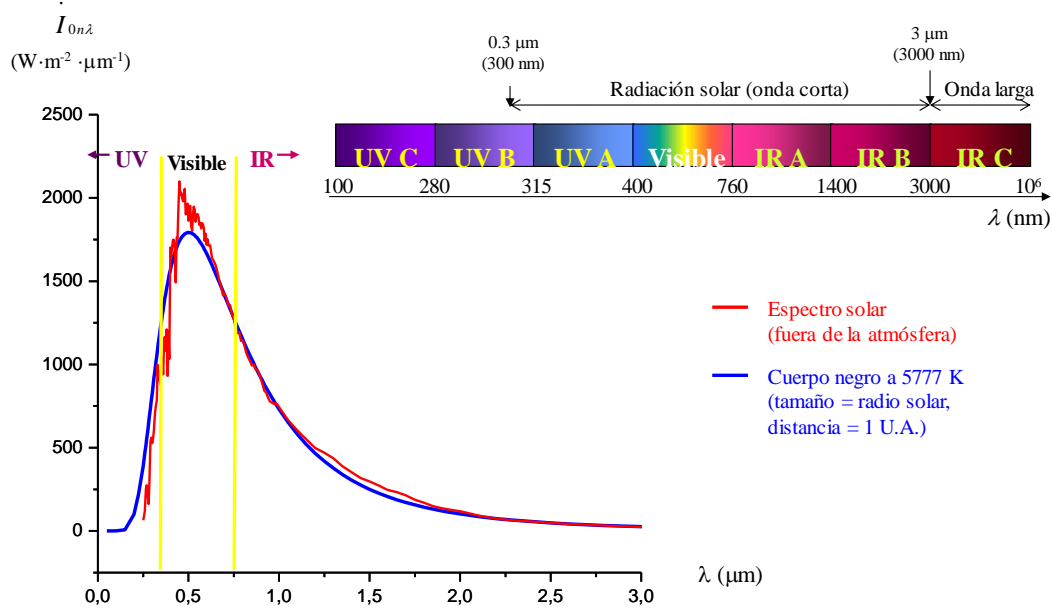


Figura 2 – Caracterización de la radiación solar mostrando la irradiancia espectral para las diferentes longitudes de onda del espectro solar. [2]

3.2 Radiación solar y sus componentes.

La radiación global, la medición más común de la radiación solar, es el total de la radiación que llega a una determinada superficie, es la suma de las radiaciones directa y difusa sobre una superficie. A continuación se describen estas dos componentes [2]:

Radiación directa: Se conoce como radiación directa a la radiación recibida del Sol que no ha sido absorbida ni dispersada, es decir, aquella que proviene directamente del disco solar. La radiación solar que se mide fuera de la atmósfera es en su totalidad radiación directa, ya que no hay presencia de cuerpos o fenómenos que modifiquen su trayectoria. Sin embargo, cuando los rayos del Sol cruzan la atmósfera, una parte de ellos son absorbidos o dispersados y el resto logra tocar la superficie terrestre en forma directa. Ha de medirse utilizando sistemas de seguimiento del movimiento del Sol.

Radiación difusa: Es la radiación solar recibida en la superficie terrestre después de que su dirección haya sido modificada, ya sea como consecuencia de su paso por la atmósfera o por incidir en otra superficie y posteriormente reflejarse, será entonces la procedente de toda la bóveda celeste excepto el disco solar. La radiación difusa que llega a la superficie de captación tras ser reflejada por el suelo se llama radiación de albedo.

En la siguiente figura se muestran gráficamente las componentes de la radiación:




Figura 3 – Diferentes componentes de la radiación solar. [5]

Para medir la radiación directa normal se requiere de un sistema de seguimiento solar que esté continuamente siguiendo la trayectoria del sol y de un dispositivo que capte los rayos en una superficie normal a su dirección (pirheliómetro). La componente difusa se mide generalmente con un sensor en posición horizontal (piranómetro) y un dispositivo acoplado que lo mantiene constantemente sombreado. La radiación global que generalmente se mide a nivel horizontal, se mide con el mismo sensor que la radiación difusa (piranómetro) pero sin sistema de sombreado acoplado. Para hacer un correcto balance energético a partir de las componentes de la radiación, es necesario proyectar la componente directa sobre el mismo plano en el que se determinan la radiación global y la componente difusa, proyección que se realiza mediante una simple relación trigonométrica.

La siguiente figura muestra el valor de la irradiancia para las diferentes componentes de la radiación en un día claro.

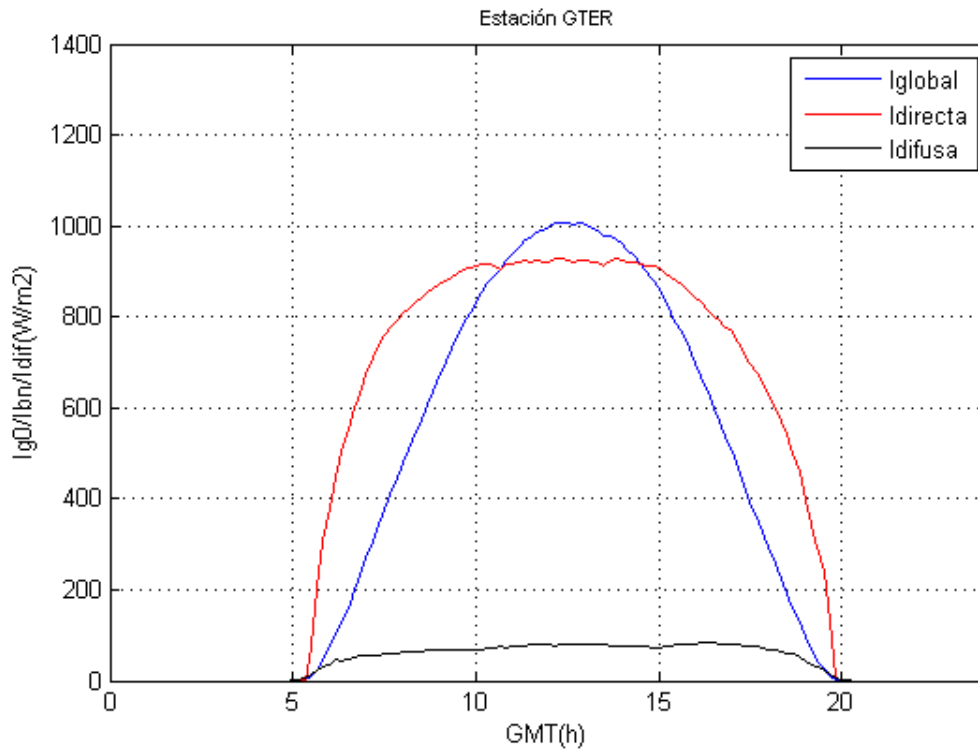


Figura 4 – Representación de las diferentes componentes de la radiación solar para un día claro. [2]

3.3 Interacción de la radiación solar con la atmosfera terrestre.

Antes de alcanzar cualquier punto de la superficie de la Tierra la radiación solar ha de atravesar la atmósfera terrestre. En este proceso la radiación se ve sometida a una atenuación que varía en función del camino recorrido, es decir, de la longitud del camino y de la composición de la atmósfera en el mismo. El primer parámetro se puede determinar fácilmente a partir de la altura y la posición del Sol empleando las ecuaciones básicas de radiación solar. En cuanto a la composición de la atmósfera, ésta varía de forma importante tanto en el tiempo como en el espacio. Los componentes atmosféricos más influyentes son las moléculas de ozono, de dióxido de carbono, vapor de agua y aerosoles. Como consecuencia de la interacción con estos componentes la radiación solar sufre diversos procesos de reflexión, absorción y difusión. La reflexión se debe principalmente a la interacción con nubes y partículas en suspensión. La absorción es responsable de la disminución de aproximadamente un 20% de la energía solar incidente en valores promedio. Los principales componentes que la producen son el ozono, el vapor de agua y el dióxido de carbono. En cuanto a la difusión o scattering, esta da lugar a la atenuación de la radiación solar que llega al límite superior de la atmosfera haciendo que esta se distribuya en todas las direcciones [2]. Los componentes atmosféricos que producen este efecto son el vapor de agua, los aerosoles y los componentes moleculares. Se pueden distinguir tres tipos de difusión [3]:

- **Difusión de Rayleigh:** Se origina cuando la longitud de onda de la irradiancia solar es mayor que la dimensión de las partículas responsables. Este proceso es producido por moléculas de gases constituyentes de la atmósfera, principalmente de oxígeno y nitrógeno. Afecta a longitudes de onda cortas y es responsable del color azul del cielo. Este fenómeno se da principalmente en las capas altas de la atmósfera.
- **Difusión de Mie:** Se produce cuando la longitud de onda de la irradiancia solar tiene el mismo orden de magnitud que las moléculas causantes del efecto. Su causa fundamental se debe al vapor de agua, polvo y aerosoles. Tiene efecto sobre todas las longitudes de onda del canal visible y se da en las capas bajas de la atmósfera.
- **Difusión no selectiva:** se produce cuando la longitud de onda es menor que la dimensión de las partículas. Este efecto es causado principalmente por las gotas de agua que forman las nubes o niebla. En la siguiente figura se muestra el efecto en tanto por ciento, de los distintos componentes de la atmósfera sobre la radiación solar.

Desde muchos puntos de vista es importante predecir la cantidad de radiación solar que alcanza un lugar de la superficie terrestre. Este cálculo, que sería fácil de realizar si no existiese atmósfera, resulta prácticamente imposible debido en gran parte a la variabilidad en la composición de la atmósfera terrestre y de la nubosidad. [3]

3.4 La nube y sus tipologías.

Una nube se puede entender como la materialización física y visual del vapor de agua atmosférico que al cambiar de fase y agruparse, forma estructuras que cubren total o parcialmente el cielo. El Instituto Nacional de Meteorología (INM) define el término nube como una porción de aire enturbada por el vapor de agua condensado en forma de cristales de hielos, esferas congeladas o gotas líquidas, pequeñas y numerosas [2]. La radiación directa normal se ve fuertemente afectada por este tipo de atenuación ya que gran parte de esta radiación es desviada o absorbida por el vapor de agua que forma las nubes. Por eso es muy importante conocer cómo se comporta la nubosidad y su evolución.

Sin embargo no todas las nubes tienen el mismo efecto en la irradiancia. Hay diferentes tipos de nubes caracterizadas por sus dimensiones, opacidad y multitud diversa de parámetros, teniendo cada tipo de nube diferentes efectos sobre la irradiancia solar. Además, una nube individual bien definida no tiene el mismo efecto sobre la irradiancia solar que un conjunto de nubes pequeñas o que un cielo totalmente nublado. Tenemos entonces que la bajada de la irradiancia dependerá de cómo la nube tape al sol y de qué tipo o tipos de nubes lo hagan [6]. Por tanto, analizaremos los diferentes tipos de nubes basándonos en la clasificación del WMO (World Meteorological Organization).

Uno de los primeros sistemas de clasificación de nubes basándose en el género y en la especie, fue originalmente desarrollado por Howard (1803). El esquema de clasificación moderno utilizado hoy en día está basado en el sistema de Howard, y está detallado en el Atlas internacional de las nubes [7]

Las nubes son generalmente definidas de acuerdo a la fase del agua que presentan y a la temperatura de su parte superior [8]

Y son clasificadas en base a:

1. El género, que representa la característica principal de la forma de la nube.
2. La especie, la cual depende de las peculiaridades en la forma y las diferencias en la estructura interna de la nube.
3. Las variedades, que definen las características especiales de organización y transparencia de una nube.
4. La aparición de nubes complementarias, para las nubes en las que se forman nubes menores asociadas a la nube principal.
5. La nube madre, que es la nube a partir de la cual ha sido formada la nube que se somete a estudio. [10]

Además del sistema estándar de clasificación género-especie, la WMO también clasifica nubes por su altura y divide la troposfera verticalmente en tres niveles: bajo, medio y alto [11]. Cada nivel está definido por un rango vertical de alturas en el cual aparece típicamente cada tipo de nube, aunque este rango de alturas depende de la región polar donde sean observadas las nubes como se muestra en la tabla 1.

Nivel	Región polar	Región templada	Región tropical
Nubes altas	3-8 km	5- 13 km	6-18 km
Nubes medias	2-4 km	2-7 km	2-8 km
Nubes bajas	Superficie terrestre hasta 2km	Superficie terrestre hasta 2km	Superficie terrestre hasta 2km

Tabla 1 - Clasificación de las nubes basándose en su altitud para las diferentes regiones polares. [11].

Las nubes se clasifican en 10 tipos y cada uno suele aparecer en los niveles que se indican [10] [12] [13]:

- Nubes de nivel alto: Cirros (Ci), Cirrocúmulo (Cc) y Cirrostratos (Cs). Tienen normalmente una apariencia fina y muy blanca, pero pueden aparecer con una amplia gama de colores cuando el sol está bajo en el horizonte.
- Nivel medio: Altocúmulos (Ac), Altoestratos (As), y Nimbostratos (Ns). Están compuestas principalmente por gotas de agua. A veces, también pueden estar compuestas de cristales de hielo cuando las temperaturas son lo suficientemente bajas.
- Nubes de nivel bajo: Cúmulos (Cu), Estratocúmulos (Sc), Estratos (St), y Cumulonimbos (Cb). Están compuestas siempre por gotas de agua.




Figura 5 - Clasificación de los diferentes tipos de nubes. [14]

Además de la división por tipo, las nubes también pueden ser clasificadas en especies y divididas también en variedades, las cuales definen las características especiales de las nubes, como pueden ser la transparencia y la organización de los elementos macroscópicos de la nube. La Tabla 2 [7] presenta las especies y variedades para cada tipo de nube.

Genero	Especies	Variedades
Cirros (Ci)	Uncinus , fibratus , spissatus, castellanus	Insortus, radiatus, vertebratus
Cirrostratos (Cs)	Nubulosus, fibratus	-
Cirrocúmulos (Cc)	Castellanus, floccus, lenticularis	Undulatus
Altocúmulos (Ac)	Castellanus, floccus, lenticularis	Translucidus, opacus, undulatus, perlucidus
Altoestratos (As)	-	Translucidus, opacus
Nimbostratos (Ns)	-	-
Estratocúmulos (Sc)	Castellanus, lenticularis	Perlucidus, translucidus, opacus
Estratos (St)	Fractus, nebulosus	-
Cumulonimbos (Cb)	Calvus, capillatus	-
Cúmulos (Cu)	Fractus, humilis, mediocris, congestus	-

Tabla 2 - Variedades y especies de los diez tipos de nubes más comunes. [7]

Por último para terminar con la clasificación total de las nubes, aparte de estos diez tipos de nubes también se pueden considerar la niebla y las estelas. Aunque estas tienen unas características similares a la de las nubes, la niebla y las estelas tienen un origen diferente. La niebla aparece frecuentemente alrededor de cuerpos de agua cerca de la superficie terrestre y otros lugares donde el

aire frío se mezcla con aire cálido y viceversa. Está formada por gotas de agua suspendidas en la atmosfera y reduce la visibilidad en la superficie terrestre [10] [12]. Las estelas o rastros de vapor son nubes artificiales que son generadas de manera artificial por la condensación del vapor de agua del escape de los motores de los aviones. Los gases de escape están muy calientes y cuando entran en contacto con el aire frío del alrededor se pueden condensar, si el aire es suficientemente frío, generando así una nube de gotas de agua microscópicas. Cuando el aire es demasiado frío la estela puede llegarse a componer por diminutos trocitos de cristal. La formación de estelas depende del nivel de humedad en la atmosfera y la altitud a la que vuela el avión. Las estelas pueden ser consideradas como las hermanas artificiales de las nubes de tipo cirrus, ya que se producen a una altura parecida y tienen la misma forma. [6]

3.5 Predicción de la radiación solar a muy corto plazo.

Uno de los desafíos más importantes para la consolidación de las tecnologías solares es el problema de la intermitencia en el recurso solar. La variabilidad en la irradiancia hace que tanto la regulación como el mantenimiento de una producción energética constante sea difícil y costosa. Esta variabilidad introduce cierta incertidumbre en la generación solar lo que hace que este tipo de energías tengan una desventaja a la hora de competir con las energías fósiles más convencionales ya que la intención de hacer la tecnología solar más gestionable y con una producción constante hace que sean necesarias grandes capacidades de regulación y una reserva energética con la que se pueda satisfacer la demanda en los momentos de intermitencia [15]. Además, el uso cada vez más generalizado de las plantas de producción de energía eléctrica basadas en la tecnología CSP (Concentrated Solar Power) ha generado una búsqueda constante para mejorar y optimizar la producción final de esta tecnología. Saber cuándo la radiación solar sufre estas intermitencias al ser atenuada por las nubes puede proporcionar información muy útil para los operadores de las plantas CSP permitiéndoles adaptar la producción de electricidad a la presencia de nubes, logrando así una optimización de la producción eléctrica [16]. Por eso es de interés para la industria de la energía solar el estudio de estos cambios repentinos y generalizados que se producen en la radiación. Estos cambios repentinos son a veces denominados “cambios en rampa”, y suelen estar causados por la aparición de grandes nubes que tapan el disco solar o por cambios repentinos en el tipo de nubosidad como pueden ser la transformación de una nube opaca y gruesa en otra nube más tenue y fina, o la división de una nube grande en numerosas nubes de pequeño tamaño [17]. Por lo tanto, estos “cambios en rampa” hacen que sean necesarios servicios auxiliares capaces de predecir rampas de subida o bajada en la irradiancia para conocer a priori la producción energética y así mantener la

calidad de la energía generada. La reducción de la incertidumbre en la generación solar logrando una mayor precisión en la predicción del recurso puede ayudar notablemente a la reducción del coste de la tecnología facilitando así la integración de estas tecnologías.

Hasta ahora la predicción de la radiación solar se ha centrado principalmente en dos enfoques: el uso de modelos físicos basados en métodos numéricos para la predicción del clima (NWP - physics-based Numerical Weather Prediction), y otra forma de predicción más directa es el uso de imágenes de satélite tomadas a tiempo real para la predicción de las condiciones de nubosidad [15]. Centrándonos en el estado actual de estos dos enfoques encontramos que la predicción a través de NWP generalmente tiene mejores resultados que la predicción a través de satélites para horizontes de predicción mayores que unas horas [18]. Sin embargo, la limitada resolución y la incertidumbre de las condiciones iniciales hace que los modelos NWP no sean válidos para predecir de forma exacta la posición de las nubes y su efecto en la radiación solar de una localización específica. Consecuentemente, es necesario el desarrollo de una tecnología capaz de lograr mejores resultados en la predicción a corto plazo que se base en medidas predictivas con una alta resolución espacial y temporal [15].

Actualmente está aumentando el interés por la investigación sobre el uso de cámaras de cielo para lograr una predicción a muy corto plazo que permita a los operadores de las plantas CPS optimizar la producción eléctrica adaptándola a presencia de los diferentes tipos de nubes. Estos sistemas se basan en el uso de redes de sensores y cámaras de cielo las cuales están tomando constantemente capturas del estado del cielo. Estas imágenes son analizadas en conjunto para determinar cómo pueden afectar las nubes detectadas en la producción eléctrica de la planta. Para ello se obtienen las propiedades de la imagen de las nubes y se realiza una clasificación de los diferentes tipos de nubes y de cómo cada uno de estos tipos puede afectar a la radiación solar. Además el sistema de cámaras no solo se encarga de analizar la atenuación que pueden provocar las nubes o un conjunto de estas sino que también, a través del análisis de una secuencia de imágenes, son capaces de predecir la trayectoria que seguirán las nubes de forma que definen que nubes tienen una alta probabilidad de tapar el disco solar de forma total o parcial. El área total para la predicción que cubren estos sistemas depende de la configuración con la que es instalado el conjunto de cámaras y el tipo de cámaras que sea utilizado, teniendo un orden de magnitud de varios kilómetros. El uso de estos sistemas se está usando recientemente para la predicción del recurso solar a un tiempo de 15 minutos para irradiancia normal directa [19], o con un tiempo de 10 minutos para la irradiancia global horizontal [20].

Como se ha mencionado, cada vez más está emergiendo el uso de cámaras de cielo hemisféricas con el objeto de predecir la radiación solar disponible. Autores como Gueymard [20] han utilizado

dichas cámaras para estudiar el impacto de los aerosoles en la radiación solar. Olmo et al. [21] también ha utilizado cámaras de cielo para determinar la profundidad óptica de los aerosoles. Como se concluye en estos estudios, las cámaras de cielo tienen un gran potencial en la monitorización de las características atmosféricas como la detección y clasificación de nubes, el estudio de los efectos de los aerosoles, etc. La atenuación que provocan las nubes también ha sido estudiada por Kassianov et al [22], quien estableció un modelo que representa la atenuación provocada por la nube usando un TSI (total sky imager). En la investigación expuesta por Cazorla et al [23], el autor hace uso del ratio rojo/azul en las imágenes de la cámara de cielo junto con un algoritmo de clasificación KNN (K Nearest Neighbor) para la estimación de la atenuación de la nube. También aplicando el algoritmo de clasificación KNN Heinle et al [24] hace una clasificación de cielos, dividiendo los tipos de cielo en siete grupos. Para validar el correcto funcionamiento del algoritmo obtenido, este se aplica a un conjunto de 275 imágenes diferentes a las utilizadas para entrenar el algoritmo KNN, lográndose que el 75% de estas imágenes sean catalogadas correctamente. Otro estudio utilizando una técnica similar, es el estudio de Martínez-Chico et al. [25] el cual también combinó las medidas de DNI e imágenes de cámaras de cielo para realizar un clasificador de nubes agrupándolas en cuatro tipos diferentes de nubes, con el objetivo de relacionar la atenuación provocada en la radiación con el tipo de nube. Además Thuillier et al [26] utilizó una cámara de cielo para asociar la presencia de nubes finas al efecto producido en la irradiación solar. Sin embargo varios de estos autores han detectado que las cámaras de cielo tienen un problema relacionado con el procesado de la imagen. El problema que se presenta es que en las imágenes del cielo la zona cercana al disco solar aparece saturada. Para resolver este problema Alonso et al [27] desarrolló una metodología para identificar la saturación del pixel en el área perteneciente al disco solar utilizando datos radiométricos. Gracias a esto el problema fue solventado y las nubes cercanas al disco solar fueron identificadas correctamente consiguiendo así una identificación de la imagen completa y solventando el problema de la saturación cerca del disco solar.

En cuanto a instalaciones de investigación que utilizan este tipo de sistema podemos citar la instalación que se encuentra en el Centro de Investigación del recurso solar de la Universidad de Almería (CIESOL) en la cual se usan conjuntamente la predicción con imágenes de cámaras de cielo y el sistema de predicción a través de imágenes por satélite, logrando así una predicción a más largo plazo, en este caso hasta de tres horas. [16]

Otra instalación a citar es la que se encuentra en la Universidad de San Diego en California la cual combina una red de sensores (principalmente piranómetros) y un sistema de cámaras de cielo que toman capturas cada 30 segundos. El conjunto está comunicado entre sí para lograr una predicción de la radiación global. Esta instalación se ha utilizado en varios estudios haciendo uso de horizontes temporales de 5, 10 y 15 minutos. [15]

3.6 Análisis de imágenes en Matlab.

Matlab (abreviatura de MATriz LABoratory, ‘laboratorio de matrices’), uno de los paquetes software matemático más utilizados actualmente en el mundo de la docencia y de la investigación, dispone de entre sus muchas herramientas una específica para el procesado digital de imágenes. Esta toolbox de procesado digital de imágenes está formada por un conjunto de funciones adicionales que amplían la capacidad del entorno numérico de Matlab y permiten realizar un gran número de operaciones de procesado digital de imágenes directamente a través del programa principal. MATLAB es un software matemático que ofrece un entorno de desarrollo integrado (IDE) con un lenguaje de programación propio (lenguaje M). Entre sus prestaciones básicas se encuentra la manipulación de matrices y la representación de datos y funciones, la implementación de algoritmos, y la creación de interfaces de usuario (GUI) y la comunicación con programas en otros lenguajes con otros dispositivos hardware. Además, se pueden ampliar las capacidades de MATLAB con las cajas de herramientas (toolboxes) que cubren actualmente la mayoría de áreas principales del mundo de la ingeniería y la simulación, como por ejemplo la toolbox de procesado digital de imágenes la cual será usada en este proyecto. MATLAB proporciona un entorno de trabajo interactivo cuyo elemento básico de trabajo son las matrices. Al trabajar con matrices se pueden describir infinidad de variables de una forma altamente flexible y matemáticamente eficiente. Por ejemplo, una imagen se puede escribir como una matriz de píxeles. [28]

El procesado digital de imágenes (PDI) es el procesado, entendiendo este como el almacenamiento, transmisión y representación de información, de imágenes digitales por medio de una computadora digital. El interés en el procesado digital de imágenes se basa esencialmente en dos aspectos: la mejora de la información contenida en una imagen para la interpretación humana y el tratamiento de los datos de una escena para favorecer la percepción autónoma por parte de una máquina. [28]

Podemos definir una imagen como una función bidimensional de intensidad de luz $f(x,y)$, donde x e y denotan las coordenadas espaciales y el valor de f en cualquier punto (x,y) es proporcional a la intensidad de la imagen en ese punto.

De esta forma podremos definir diferentes tipos de imágenes, como ejemplo en una imagen en escala de grises en vez de intensidad de luz se hablará de nivel de gris o brillantez. En el caso de una imagen a color, en el espacio de trabajo típico RGB (Red, Green, Blue), la imagen será resultado de la combinación de tres imágenes individuales, donde cada una representa una componente de color, la primera será la intensidad de luz en rojo, la segunda la intensidad de luz en verde y la tercera la intensidad de luz en azul. Otro espacio de trabajo para la representación de imágenes a color que será utilizado en este proyecto será el modelo HSV (Hue, Saturation, Value) o HSB ((Hue, Saturation,

Brightness), donde la imagen a color será también resultado de la combinación de tres imágenes, que son:

- La primera, matiz, se representa como un grado de ángulo cuyos valores posibles van de 0 a 360° (En el caso de MATLAB se normalizan del 0 al 1) y cada valor corresponde a un color (Ejemplo: 0 es rojo, 1/6 es amarillo y 1/3 es verde). [28]
- La segunda, saturación, se representa como la distancia al eje de brillo negro-blanco. Los valores posibles van del 0 al 1. Cuanto menor sea la saturación de un color, mayor tonalidad grisácea habrá y más decolorado estará. [28]
- Y la tercera, valor, representa la altura en el eje blanco-negro. Los valores posibles van del 0 al 1. En el valor 0 siempre será negro y dependiendo de la saturación, 1 podría ser blanco o un color más o menos saturado. [28]




Figura 6 – Representación de la gama de colores mediante el modelo HSV [36]

Otro procedimiento para el análisis de las imágenes se basa no solo en utilizar la información de color de la imagen sino también utilizar la información de la textura. El análisis de textura intenta cuantificar las cualidades intuitivas descritas por términos como la aspereza, suavidad, rugosidad, etc. Intentando caracterizar estas propiedades como una función de la variación espacial en la intensidad de luz en escala de grises de los píxeles de una imagen. La textura de una imagen nos da la variabilidad local de los valores de intensidad de sus píxeles, si una superficie presenta muchas variabilidad en los valores de intensidad de los píxeles que la componen podemos decir que esta superficie tiene una textura visual rugosa, mientras que si la variabilidad de los valores de intensidad es poca podemos decir que la superficie tiene un textura visual lisa o suave. Podemos concluir

entonces que a diferencia del color, la textura de un píxel individualmente no está definida, hay que estudiar la vecindad de un grupo de píxeles y las variaciones en estos. El análisis de texturas se suele usar en una gran variedad de aplicaciones, como pueden ser la teledetección, la inspección automatizada, el procesado de imágenes para uso médico, etc. En concreto, el análisis de textura resulta ser muy útil cuando los objetos de una imagen se caracterizan más por su textura que por la intensidad de luz en modelos de imágenes a color y cuando las técnicas tradicionales de umbralización no se pueden usar de forma efectiva.

Para obtener información acerca de la textura de una imagen se utilizarán medidas estadísticas de valores de intensidad de sus píxeles. Para ello se pasarán las imágenes a escala de grises y se estudiarán mediante variables estadísticas las variaciones en los valores de intensidad de los conjuntos de píxeles. Se utilizarán dos procedimientos diferentes para obtener mayor cantidad de propiedades de textura. El primer grupo estará compuesto por las medidas estadísticas de la entropía, desviación estándar y rango de la imagen, conceptos que se definen a continuación [30]:

Entropía

La entropía es una medida estadística de la aleatoriedad que se puede utilizar para definir la textura de una imagen. Se define como:

$$S = \sum_i p_i * \log_2(p_i) \quad (1)$$

Donde p contiene la cuenta del histograma. En nuestro caso el sistema donde se va aplicar la entropía es en cada imagen, obteniéndose una matriz en donde cada píxel de salida contiene el valor de la entropía de los alrededores de 9x9 alrededor del píxel correspondiente en la entrada de la imagen que está siendo procesada.

Desviación estándar

Es una medida de dispersión para variables de razón y de intervalo, de gran utilidad en la estadística descriptiva. El cálculo de la desviación estándar de los píxeles puede indicar el grado de variabilidad de los valores de los píxeles en esa región. Se obtendrá una matriz en donde cada píxel contiene el valor de la desviación estándar para el conjunto de píxeles vecinos de la imagen.

Rango de la imagen

El rango de la imagen puede ser considerado como la resta entre el máximo valor y el mínimo valor alrededor del píxel central. Por ejemplo, en áreas con textura suave, el rango de valores en la zona de alrededor de un píxel será un valor pequeño, en áreas de textura rugosa, la gama será más grande.




Figura 7 – Explicación de la propiedad rango de la imagen. [30]

Estos estadísticos pueden caracterizar la textura de una imagen porque aportan información de la variabilidad local en los valores de intensidad de luz de los píxeles de una imagen. Por ejemplo, en superficies de textura suave, los valores del rango de los píxeles vecinos que componen dicho objeto tendrá un valor bajo. En superficies con rugosidad, el rango será mayor. Similarmente, el valor de la desviación estándar de un conjunto de píxeles vecinos nos indicará el grado de variabilidad de los valores de los píxeles en de esa región.

Otro método estadístico para examinar texturas que está basado en las relaciones espaciales de los píxeles es el uso de la matriz de co-ocurrencia de niveles de grises (GLCM - gray-level co-occurrence matrix), también conocida como la matriz de dependencia de niveles de grises. La matriz GLCM caracteriza la textura de una imagen calculando cuantas veces un conjunto de dos píxeles con unos valores específicos aparecen con una relación espacial especificada en un área de la imagen, creándose como resultado la matriz GLCM, de la que luego se pueden extraer medidas estadísticas [30].

Para crear la GLCM, se utiliza la función *graycomatrix*. La función *graycomatrix* crea una matriz de co-ocurrencia de niveles de grises, calculando cuantas veces un píxel con un valor intensidad “i” (en escala de gris) aparece con una relación espacial específica a un píxel con un valor de intensidad “j”. Por defecto, la relación espacial está definida como el píxel de interés y el píxel que esta inmediatamente a su derecha, pero se puede especificar otras relaciones espaciales entre dos píxeles. Cada elemento (i, j) en la matriz resultante glcm es simplemente la suma del número de veces que el píxel con valor “i” aparece en la relación espacial determinada con el píxel de valor “j” en la imagen de entrada.

Para ilustrar, la siguiente figura muestra cómo se realiza la composición de la GLCM para una matriz en escala de grises dada y cómo se calculan los dos primeros valores en la GLCM. En este ejemplo, la relación espacial está definida como el píxel horizontalmente adyacente inmediato a la derecha. En la matriz GLCM, el elemento que se encuentra en la posición (1,1) contiene el valor 1 porque solo hay una instancia en la imagen de entrada donde dos píxeles adyacentes horizontalmente

tengan valores iguales a 1. En GLCM (1,2) contiene el valor 2 porque hay dos instancias donde dos pixeles adyacentes horizontalmente tienen los valores 1 y 2 respectivamente. De esta forma la función *graycomatrix* recorre la imagen de entrada hasta obtener todas las relaciones especificadas entre dos pixeles. [30]




Figura 8 – Proceso seguido para crear la matriz GLCM [30].

El número de niveles de gris que hay en la imagen determinará el tamaño de la matriz GLCM. Por defecto, la función *graycomatrix* realiza un escalado para reducir el número de valores de intensidad de una imagen hasta 8, pero se pueden utilizar los parámetros *NumLevels* y *GrayLimits* para controlar esta escala de niveles de grises.

La matriz GLCM puede revelar ciertas propiedades de la distribución espacial en los niveles de grises en la textura de una imagen. Por ejemplo, si la mayoría de elementos en la GLCM están concentrados a lo largo de la diagonal, la textura es rugosa respecto a la relación espacial especificada, ya que habrá próximos espacialmente valores muy dispares [30].

Después de crear la matriz GLCM, se puede obtener de ella varios estadísticos utilizando la función *graycoprops*. Estos estadísticos aportan información sobre la textura de una imagen. Los estadísticos que se pueden obtener a través de este método son [30]:

Estadístico	Descripción
Contraste	Medida de la variación local de la GLCM
Correlación	Mide la probabilidad de que se encuentren juntos dos píxeles con unos valores de intensidad específicos.

Energía

Nos da el sumatorio de los elementos al cuadrado de la matriz GLCM. También se conoce a veces como uniformidad o segundo momento angular.

Homogeneidad

Mide la cercanía en la distribución de cada elemento de la GLCM a la diagonal de esta matriz.

3.7 Fundamento de las redes neuronales

Las Redes Neuronales artificiales (NN: Neural Networks) fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, constituidos por un conjunto de unidades llamadas neuronas o nodos conectados unos con otros. El primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts en términos de un modelo computacional de actividad nerviosa. Este modelo era un modelo binario, donde cada neurona tenía un escalón o umbral prefijado, y sirvió de base para los modelos posteriores. [31]

Las NN aplicadas están, en general, inspiradas en las redes neuronales biológicas. Las características principales de las NN son las siguientes:

1. Auto-Organización y Adaptabilidad: utilizan algoritmos de aprendizaje adaptativo y auto-organización, por lo que se evita que realice esta tarea el usuario y se consiga un procesado robusto y adaptativo.
2. Procesado no-Lineal: aumenta la capacidad de la red para aproximar funciones, clasificar patrones y aumenta su inmunidad frente al ruido.
3. Procesado paralelo: normalmente se usa un gran número de nodos de procesado, con alto nivel de interconectividad, lo que permite que se obtengan respuestas en tiempo real.

El elemento básico de computación para redes neuronales es conocido habitualmente como nodo, unidad o neurona. Este recibe una entrada desde otras unidades o de una fuente externa de datos. La neurona, le asocia a cada entrada un determinado peso “w”, el cual se irá modificando en el llamado proceso de aprendizaje logrando así darle una mayor importancia a las entradas que más influyen en la salida [31]. A continuación, cada unidad aplica una función “f” a la suma de las entradas ponderadas mediante los pesos:

$$y_i = \sum_j w_{ij} y_j \quad (2)$$

El resultado de aplicar dicha función será la salida, la cual podrá ser una de las salidas del sistema completo o la entrada a otra neurona.




Figura 9 – Representación del funcionamiento básico de una neurona [31].

Hay dos fases en la modelización de redes neuronales [32]:

Fase de entrenamiento: se usa un conjunto de datos o patrones de entrenamiento para determinar los parámetros que definen el modelo de red neuronal. Se calculan de manera iterativa, de acuerdo con los valores de los valores de entrenamiento, con el objeto de minimizar el error cometido entre la salida obtenida por la red neuronal y la salida deseada.

Fase de validación: en la fase anterior, el modelo puede que se ajuste demasiado a las particularidades presentes en los patrones de entrenamiento, perdiendo su habilidad de generalizar su aprendizaje a casos nuevos. Para evitar este problema, se utiliza una segunda etapa con un segundo grupo de datos diferentes a los de entrenamiento, el grupo de validación, que permita controlar el proceso de aprendizaje logrando así que el modelo pueda aportar resultados correctos en mayor variedad de casos.

Para este proyecto se ha hecho uso de la toolbox de Matlab *Neural Net Pattern Recognition*, la cual nos permite clasificar las diferentes entradas en los grupos que se deseen. Para ello esta herramienta tomará una matriz definida como Input donde cada columna pertenecerá a un caso y cada fila de esa columna representará una característica de dicho caso. También tomará una matriz definida como Target en la cual se recogerá a que grupo pertenece cada uno de los diferentes casos presentados en la matriz Input. A continuación, de todo el conjunto de casos se seleccionara el porcentaje del conjunto completo que irá a formar parte de cada una de las fases que aplica la red neuronal, en el caso de esta herramienta se definen tres fases:

La fase de entrenamiento: Ya descrita anteriormente y que intenta definir la función de forma que se

minimice el error cometido.

La fase de validación: también descrita anteriormente, cuyo objetivo es lograr la generalización de la red neuronal.

La fase de prueba o de testeo: la cual no tiene ningún efecto sobre la función resultado obtenida finalmente y la cual Matlab utiliza para poder dar datos sobre la calidad de la actuación que proporciona la red neuronal entrenada, como pueden ser los errores que esta comete y la matriz de confusión del conjunto de resultados.

Más adelante Matlab nos da la opción de seleccionar el número total de neuronas que compondrá nuestra red. Para este caso se ha seleccionado el utilizado por defecto ya que no se ha visto ningún cambio sustancial al utilizar redes más amplias o de menor tamaño.

Finalmente, la herramienta nos da la opción de ampliar el número de casos si los resultados de la simulación no han sido buenos o de obtener la función resultado de varias formas como pueden ser en un script o un modelo de *Simulink*, además de dar los resultados obtenidos en la fase de testeo.

4 INSTRUMENTACIÓN

Para llevar a cabo el proyecto se ha hecho uso de dos elementos fundamentales, el pirheliómetro encargado de medir la radiación directa y la cámara captadora de imágenes de cielo. El pirheliómetro es el modelo CHP1 del fabricante Kipp & Zonen. El pirheliómetro y sus especificaciones se muestran en la siguiente figura:

Especificaciones

Rango espectral	200 a 4000 nm
Sensibilidad	7 a 14 $\mu\text{V}/\text{W}/\text{m}^2$
Tiempo de respuesta	< 5 s
Offset cero B	< 1 W/m^2
Dépendance en température de la sensibilité (-20 °C à +50 °C)	< 0.5 %
Campo de visión	5 \pm 0.2 °
Tiempo de respuesta	-40 a +80 s
No-linealidad	< 0.2 %
Irradiancia solar máxima	4000 W/m^2
Normes internacionales (ISO)	Primera Clase ISO



Figura 10 – Especificaciones técnicas y fotografía del pirheliómetro CHP1 de Kipp & Zonen Citar fabricante y manual [33]

Las medidas realizadas por el pirheliómetro son registradas cada 5 segundos. Los datos que se recogen del pirheliómetro quedan registrados y guardados en un ordenador. La forma en la que se guardan estos datos es a través de un archivo de extensión .txt que guardará los datos para el día completo. El archivo será nombrado con el día del año al que se representa. En este archivo además también se registran los datos tomados por los diferentes sensores de la estación meteorológica de la Escuela Técnica Superior de Ingeniería de Sevilla, pero en este proyecto no se hará uso de ellos. En el archivo citado se presenta en la primera columna la hora, minuto y segundo en GMT en la que se ha registrado cada medida, y en la decimocuarta columna los datos recogidos por el pirheliómetro.

En cuanto al sistema de cámaras de cielo, se disponen de tres cámaras de las cuales solo será necesario hacer uso de una de ellas. La cámara de la cual se hará uso será el modelo Q-25M del fabricante Mobotix. Las características técnicas se muestran en la siguiente figura:

Technical Data Q25M	
Model variants	MX-Q25M-Basic, MX-Q25M-SEC, MX-Q25M-SEC-Night
Lens options	12 to 25 mm, 35 mm format, hor. angle of view 180° to 82° (5MP)
Sensitivity	Color sensor: 0.25 lux at 1/60 s, 0.013 lux at 1 s Black and white sensor: 0.05 lux at 1/60 s, 0.0025 lux at 1/1 s MxLEO – MOBOTIX Lowlight Exposure Optimization
Image sensor	1/2.5" CMOS , 5 megapixels, progressive scan
Max. image size	Color/Black and white: 2592x1944 (5MP)
Image formats	2592x1944 (5MP), 2048x1536 (QXGA), 1920x1080 (full HD), 1280x960 (MEGA), 1280x720 (HD), 1024x768, 800x600, 768x576 (D1-PAL), 704x576 (TV-PAL), 640x480, 384x288, 320x240, 160x120, custom formats
Max. frame rate M-JPEG (live/recording)	VGA: 30 fps, MEGA: 15 fps, QXGA: 8 fps, 5MP: 5 fps
Max. frame rate MxPEG (live and recording including sound)	VGA: 30 fps, MEGA: 30 fps, QXGA: 20 fps, 5MP: 10 fps
Image compression	MxPEG, M-JPEG, JPEG, H.264
Internal DVR	MicroSD card pre-installed (SDXC)
External video ring buffer	Directly on NAS and computer/server without additional recording software
Software (included)	MxEasy video management software, MxControlCenter control center software, MOBOTIX App for iOS devices with iOS 5.0 and higher
Image processing	Backlight compensation, automatic white balance, image distortion correction, panorama correction, Video Motion detection, MxActivitySensor, MxAnalytics
Virtual PTZ	Digital pan/tilt/zoom, continuous 8X zoom
Alarm/events	Video Motion detection, MxActivitySensor, external signal, temperature sensor, PIR, microphone, shock detector, notification over e-mail, FTP, IP telephony (VoIP, SIP), visual/acoustic alarms, pre- and post-alarm images
Microphone and speaker	Microphone and speaker integrated
Audio features	Lip-synchronous audio, two-way communication, audio recording
Interfaces	10/100 Ethernet, IPv4/IPv6, MiniUSB, MxBus; inputs/ outputs and RS232 via accessories


Figura 11 – Especificaciones técnicas de la cámara Q-25M de Mobotix [34]



Figura 12 – Imagen de la cámara Q-25M de Mobotix [34]

Esta cámara de cielo tomará capturas desde la salida a la puesta de sol con un intervalo de tiempo de 5 minutos. En cada uno de estos instantes la cámara realizara dos fotografías una con un tiempo de exposición bajo logrando así una imagen la cual tenga poca iluminación y en la que se pueda observar mejor la zona cercana al disco solar, y otra con un tiempo de exposición mayor en la que se pueden observar mejor las zonas lejanas al disco solar. Ambas imágenes serán guardadas en un ordenador, en primer lugar se crea una carpeta para el día completo, en la cual encontramos una carpeta para cada instante en el que se realizan las fotografías y dentro de cada una de estas carpetas las dos fotografías con diferente tiempo de exposición. El archivo de la imagen se guardará en extensión .jpg y el nombre contendrá el instante en el que se ha realizado la fotografía.

En cuanto a la disposición estos dos dispositivos, se muestra en la siguiente figura que representa un plano de la Escuela Superior de Ingeniería y sus laboratorios.





-  Localización del pirheliómetro CHP1 de Kipp & Zonen
-  Localización de la cámara de cielo Q-25M de Mobotix

Figura 13 – Plano de la Escuela Superior de Ingenieros y la localización de los instrumentos usados en este proyecto [35]

5 METODOLOGÍA.

5.1 Red neuronal clasificadora de píxeles.

En este apartado se describirá el proceso seguido para entrenar una red neuronal la cual tenga como objetivo la clasificación de píxeles de forma individual, agrupando estos en cuatro grupos diferentes: pixel perteneciente a cielo despejado, nube densa y opaca, nube tenue o pixel perteneciente al disco solar. Para ello se implementara con anterioridad un algoritmo capaz de obtener la posición del sol en la imagen haciendo uso de las coordenadas celestes horizontales. A continuación se le aplicará a la imagen un código HDR mejorando la visibilidad de la imagen en las zonas más cercanas al sol y en las más alejadas. Por último se extraerá información de cada pixel sobre sus propiedades de intensidad de luz para los modelos RGB y HSV, para finalmente realizar una red neuronal que tenga como entrada las características de la Tabla 3 y como resultado la clasificación del pixel en una de los cuatro tipos ya citados.

Configuración del Input

Intensidad de luz de rojo

Intensidad de luz de verde

Intensidad de luz de azul

Intensidad de matiz

Intensidad de saturación

Intensidad de brillancia

Distancia del pixel a estudiar al pixel colocado en el centro del disco solar

Tabla 3 – Parámetros de entrada a la red neuronal clasificadora de píxeles.

5.1.1 Cálculo de la posición del Sol en la imagen y cálculo de la distancia de cualquier píxel al centro solar.

Para obtener la posición del sol en la imagen obtenida por la cámara de cielo primero obtendremos la posición solar en la bóveda celeste obteniendo las coordenadas celestes horizontales, es decir, el ángulo cenital y el ángulo azimutal.

Para ello, será necesaria la información sobre el momento en el que ha sido tomada la fotografía. Por tanto cada vez que la cámara de cielo tome una fotografía registrará la hora a la que ha sido tomada y el nombre de la imagen seguirá el siguiente formato:

Año-Mes-Día_Hora_Min_seg.extension

Ejemplo: 2016-4-22_18_55_14.jpg

Quedando el año desde el primer guion hacia atrás el mes entre el segundo guion y el tercero, el día entre el segundo guion y el primer guion bajo, la hora entre el primer y segundo guion bajo y el último que es de nuestro interés, el minuto, entre el segundo y tercer guion bajo. De esta forma creando un código capaz de leer esta información del título tendremos el momento en el que ha sido tomada la fotografía.

Una vez tengamos el momento en el que ha sido tomada la fotografía, a partir de día y mes obtendremos el día juliano y de la hora y el minuto obtendremos el tiempo oficial (TO) como:

$$TO = h + \left(\frac{\text{min}}{60}\right) \quad (3)$$

Obtendremos el ángulo diario (Γ) relativo a la posición de la Tierra en el plano de la eclíptica como:

$$\Gamma = \frac{360}{365} * (n - 1) \quad (4)$$

A continuación utilizaremos la ecuación del tiempo que se define como la diferencia existente entre el día solar medio y el día solar verdadero (tiempo entre dos pasos consecutivos del sol por el meridiano del lugar). Esa diferencia es variable debido a la excentricidad de la órbita terrestre y a la constancia de la velocidad areolar. También influyen otros movimiento del planeta Tierra (precesión y nutación principalmente). Utilizaremos la aproximación de Spencer (1971) para obtener la ecuación del tiempo:

$$E_t = \frac{229,2}{60} * [0,000075 + 0,001868 * \cos(\Gamma) - 0,032077 * \text{sen}(\Gamma) - 0,014615 * \cos(2 * \Gamma) - 0,04089 * \text{sen}(2 * \Gamma)] \quad (5)$$

Una vez tengamos este valor calculado obtendremos el tiempo solar verdadero que es el tiempo basado en el movimiento aparente del Sol en la bóveda celeste. A las 0:00 hora solar verdadera, el Sol atraviesa el meridiano del observador y alcanza la máxima altura sobre el horizonte. Así pues, el tiempo solar verdadero comienza a contarse a partir del mediodía solar, este tipo de hora es la usada

en todas las relaciones que describen los ángulos de posición del Sol respecto al observador. Para nuestro caso (Horario español peninsular) utilizaremos las siguientes ecuaciones, en función del momento del año en el que estemos:

Para 2016 si nos encontramos entre las 2:00AM del 27 de Marzo y las 3:00 AM del 25 de Octubre (Horario de Verano), utilizaremos:

$$TSV = TO + Et - 12 + \left(\frac{\lambda - \lambda_s}{15}\right) - 2 \quad (6)$$

Si nos encontramos fuera de este rango (Horario de invierno) utilizaremos:

$$TSV = TO + Et - 12 + \left(\frac{\lambda - \lambda_s}{15}\right) - 1 \quad (7)$$

Donde λ es la longitud geográfica y λ_s la longitud de referencia, para el caso de España podemos suponerla 0 ya que nos encontramos en el meridiano de referencia (Meridiano de Greenwich).

A continuación obtendremos el ángulo horario definido como el desplazamiento angular del sol en el plano del ecuador celeste. La equivalencia de este ángulo con el Tiempo solar es inmediata, resultando 15° por hora (360° en 24 horas). Antes del mediodía solar ω es negativo y después positivo. Queda entonces que:

$$\omega = TSV * 15 \quad (8)$$

También necesitaremos el cálculo de la declinación definida como el ángulo que forma la línea que une el centro de la Tierra y el centro del Sol con el plano del ecuador celeste. Obtendremos este valor a partir de una expresión matemática sencilla propuesta por Cooper (1969), la cual ofrece un error máximo de 1.5° y es:

$$\delta = 23.45 * \text{sen} \left(\left(\frac{360}{365} \right) * (n + 284) \right) \quad (9)$$

Una vez que tengamos todos estos valores procederemos a calcular las coordenadas celestes horizontales.

En primer lugar obtendremos el ángulo cenital que es aquel que forma la vertical del observador con la línea observador-Sol. Lo obtendremos utilizando la siguiente expresión:

$$\cos(O_z) = \cos(\phi) * \cos(\delta) * \cos(\omega) + \text{sen}(\phi) * \text{sen}(\delta) \quad (10)$$

En segundo lugar obtendremos el ángulo acimutal el cual es el ángulo que forma el meridiano del lugar (incluye la vertical del lugar y pasa por el sur geográfico) con el que pasa por el sol, el acimut hacia el Este es negativo, y hacia el Oeste positivo. Para obtener este valor:

$$\cos(Az) = \frac{(\sin(\phi) * \cos(O_z) - \sin(\delta))}{\cos(O_z) * \cos(\phi)} \quad (11)$$

Todas las ecuaciones empleadas para el cálculo de las coordenadas horizontales celestes del sol han sido extraídas de [4].

Una vez tenemos ya las coordenadas celeste horizontales del sol en la bóveda celeste deberemos pasar estas coordenadas a las coordenadas en píxeles que tenemos en la imagen. Definiendo la imagen como una matriz de píxeles, las coordenadas de los píxeles para una imagen se definen como se muestra en la siguiente figura:




Figura 14 – Coordenadas con las que se definen un píxel en una imagen.

Para ello en primer lugar pasaremos las coordenadas celestes horizontales a coordenadas polares en píxeles. Para la coordenada radial (r) utilizaremos una regla de tres (Para el ángulo cenital máximo (90°), deberemos tener $r = R_{imagen}$). Para la coordenada angular tendremos que realizar un giro para que el sur corresponda con el eje x positivo. Podemos concluir entonces que las ecuaciones para transformar las coordenadas celestes a coordenadas polares quedarían:

$$r = \frac{R_{imagen}}{90^\circ} * O_z \quad (12)$$

$$\theta = Az - \alpha \quad (13)$$

Donde α sería el ángulo que forma el eje x positivo con la recta que une el centro con el sur en la imagen. Estas coordenadas tendrán como origen el centro de la imagen.

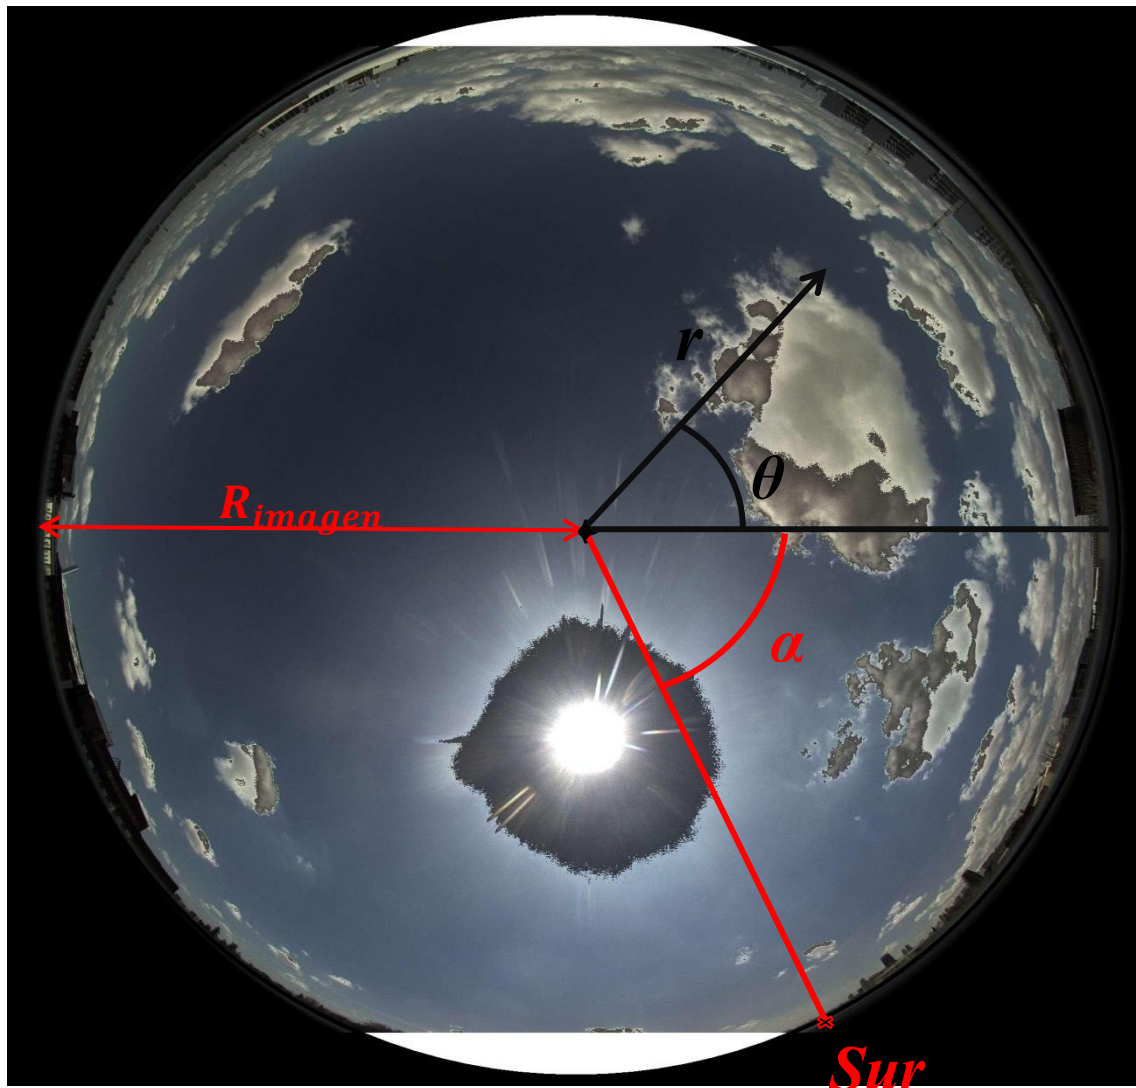


Figura 15 – Representación de las coordenadas polares en la imagen y de los valores α y R . Una vez que tengamos las coordenadas polares definidas realizaremos el cambio de variables para obtener las coordenadas cartesianas:

$$x_1 = r * \cos(\theta) \quad (14)$$

$$y_1 = r * \sen(\theta) \quad (15)$$

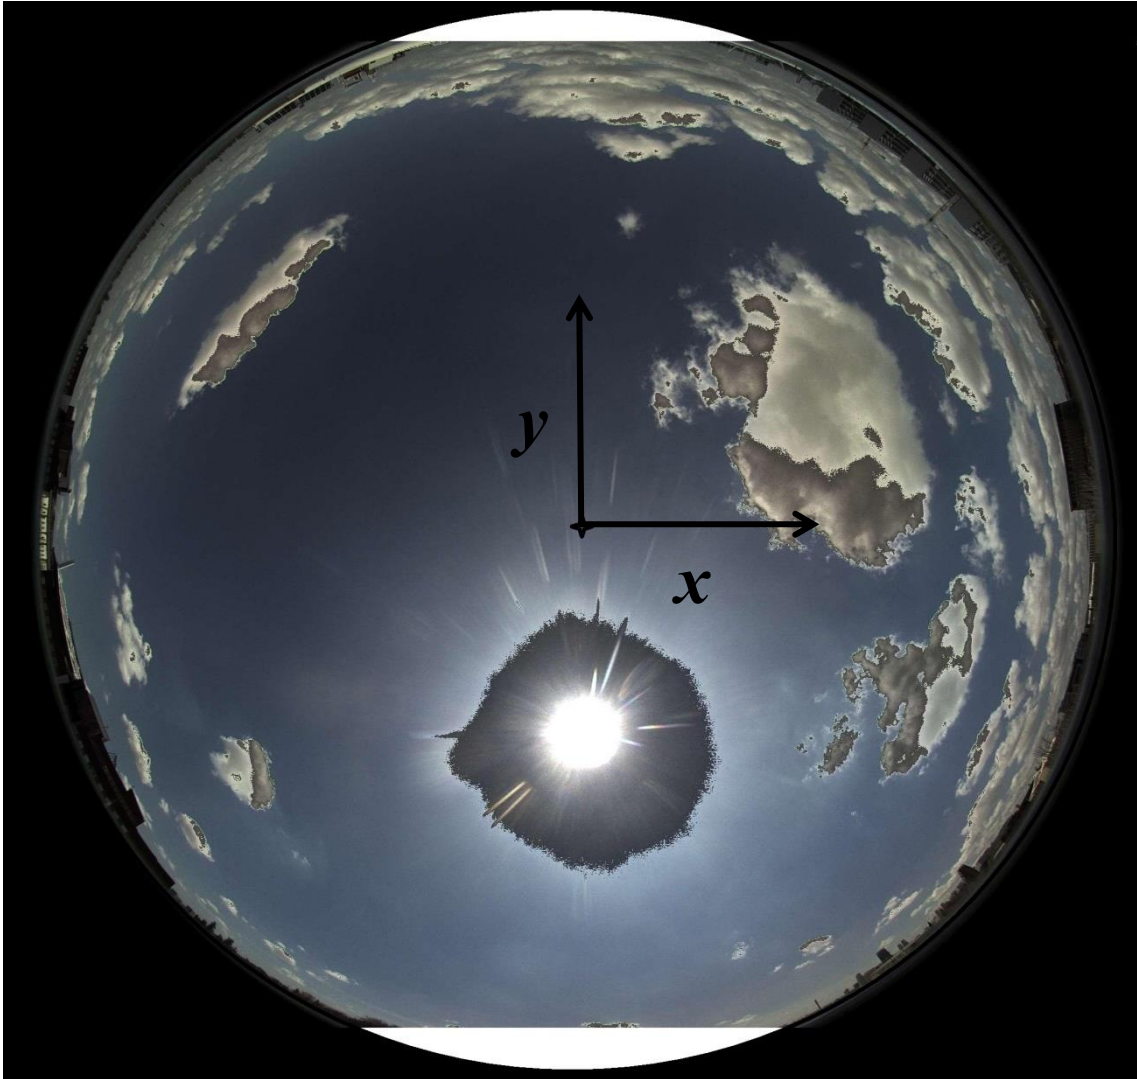


Figura 16 – Muestra de las coordenadas cartesianas en la imagen centras en el centro de la cámara.

Estas coordenadas tendrán como origen el centro de la imagen, deberemos desplazar el origen y cambiar el sentido del eje y para que los ejes queden definidos como el estándar en las imágenes. Para trasladar el origen y cambiar el sentido de los ejes aplicaremos las siguientes ecuaciones:

$$x = x_1 + x_c \quad (16)$$

$$y = y_c - y_1 \quad (17)$$

De esta forma tendremos definidas las coordenadas de la misma forma que se definen las coordenadas de los píxeles en las imágenes, permitiendo así identificar en que píxeles se encuentra el Sol.

Una vez sabemos en qué píxel está situado el centro del Sol y las coordenadas de este en la imagen, el cálculo de la distancia de un píxel a este es inmediato aplicando la ecuación de distancia entre dos puntos:

$$d = \sqrt{(x_{sol} - x_{pixel})^2 + (y_{sol} - y_{pixel})^2} \quad (18)$$

5.1.2 Aplicación del código HDR

Para las imágenes utilizadas en el proceso de entrenamiento de la red neuronal se les aplicará previamente un código HDR el cual mezcle dos imágenes del cielo en dos instantes consecutivos. Una de estas imágenes será capturada con un tiempo de exposición bajo de forma que la luz que entra en la cámara sea menor y la imagen quede más oscura, justo un instante después se realizará otra captura esta vez la cámara utilizará un tiempo de exposición mayor para captar más luz y lograr una imagen más clara. Ambas imágenes presentan deficiencias si son utilizadas individualmente, en la imagen más clara la zona aparente de Sol será mayor y tendremos mayor saturación lo que impedirá ver con claridad la que hay cercano al sol. Mientras que en la imagen oscura, cuando el día es nublado y disponemos de menos luz, las zonas alejadas del sol salen excesivamente oscuras impidiendo distinguir con claridad la zona y complicado el reconocimiento de esta por la red neuronal. Por ello se aplica el código HDR que generará una imagen resultado mezcla de las dos anteriores. Quedándose con la imagen con poca luz de las zonas cercanas al sol y con la imagen más clara en las zonas alejadas del sol, logrando así una imagen en la cual tengamos la mejor información tanto en las zonas cercanas al sol como en las zonas más alejadas.

Para lograr este efecto obtendremos el modelo HSV de la imagen más clara y observaremos el valor de saturación en cada píxel. Si el valor de saturación es mayor que 0.7 la imagen resultado tomará como valor para ese píxel el valor de la imagen más oscura, en el caso de que sea menor que 0.7 el píxel de la imagen resultado será igual al de la imagen más clara.




Figura 17 – Combinación de dos imágenes a través del uso del código HDR para lograr una imagen con mejor visibilidad.

5.1.3 Aplicación de la red neuronal clasificadora.

Para el entrenamiento de la red neuronal se han escogido un conjunto de aproximadamente 12.000.000 píxeles que han sido clasificados de forma visual. Para ello se han observado imágenes de un total de dos meses en las que se ha realizado un recorte y se ha extraído la información en zonas pertenecientes a cada uno de los diferentes grupos definidos, estos recortes extraídos de las imágenes se han intentado realizar con la mayor variedad posible de situaciones para lograr que la red neuronal sea capaz de actuar correctamente en la mayoría de situaciones que se puedan dar y de esta forma generalizarla. Para la caracterización de los píxeles y definir el tipo al que pertenecen se utilizará una red neuronal que utilice las siguientes 7 entradas:

- Las tres propiedades de color del píxel que se estudia, es decir su intensidad de luz para rojo, verde y azul.
- Las tres propiedades de brillo del píxel que se estudia, es decir su intensidad de luz para matiz (Hue), saturación (Saturation) y brillantez (Brightness).
- Distancia en píxeles desde píxel que se analiza hasta el píxel que representa al centro del sol.

Como salida de esta red neuronal tendremos una matriz de cuatro columnas en la cual una de las columnas será igual a 1 mientras que el resto será igual a 0, esto nos definirá a que tipo pertenecerá el píxel estudiado, se definirán los siguientes cuatro tipos:

- Si el resultado es un 1 en la primera columna de la matriz, el píxel pertenece a un cielo despejado.
- Si el resultado es un 1 en la segunda columna de la matriz, el píxel pertenece al Sol.
- Si el resultado es un 1 en la tercera columna de la matriz, el píxel es identificado como ligera nubosidad.
- Por último, si el resultado es un 1 en la cuarta columna de la matriz, el píxel será identificado como una nubosidad más densa.

Una vez sabidos los valores de entrada y los resultados que dan se procederá a entrenar la red neuronal que buscará las relaciones entre el tipo de píxel y los valores de entrada. Terminado el entrenamiento se obtendrá la función resultado, la cual dada los 7 datos de entrada que tiene el píxel en cuestión, dará como salida el tipo al que pertenece ese píxel.

5.2 Red neuronal asociadora de un factor de atenuación a cada nube.

En este apartado a partir de un modelo de cielo despejado y de los datos reales de radiación directa normal medidos por el pirheliómetro se calculará el factor de atenuación. A partir de este factor de atenuación se observarán un conjunto de días y se verán los factores de atenuación que provocarán diferentes conjuntos de nubes. También con el objeto de definir la nube de la manera más completa posible se citarán las propiedades que se aplicarán para definir la nube haciendo uso de propiedades como el color, la textura o distancia a la que se encuentra la nube.

5.2.1 Modelo de cielo despejado y cálculo del factor de atenuación.

Para la obtención de la curva de cielo despejado se hará uso de un modelo de cielo despejado, en concreto del modelo AB. El modelo AB es propuesto y validado por Manuel Silva en su tesis doctoral *Estimación del recurso solar para sistemas termosolares de concentración*, (2002). Se basa en la fórmula de Kastrov, con la modificación de la introducción de un segundo parámetro. Mürk, entre otros, hace notar que se requieren de al menos dos parámetros para modelar la evolución temporal de la irradiancia solar directa [3].

La expresión de la irradiancia normal directa tiene la siguiente forma:

$$E_{bn} = I_{cs} * E_t * \left(\frac{A}{1 + B \cdot m_R} \right) \quad (19)$$

- I_{cs} es la constante solar definida como la irradiancia solar que incide sobre una superficie plana normal al vector posición del Sol ubicada en el límite superior de la atmósfera

terrestre. Adopta un valor de 1367 W/m².

- E_t se obtiene utilizando la ecuación (5).
- m_R es la masa óptica relativa del aire que cuantifica la longitud del camino óptico que recorre la radiación solar. Generalmente la masa óptica se define en relación al camino óptico vertical en dirección cenital (cuando el sol está en el cenit) y en un lugar situado a nivel del mar. Será determinada según la expresión de Kasten y Young (1989) [3]:

$$m_R = \frac{p/p_0}{\operatorname{sen}\alpha_v + 0.50572 \cdot (57.29578 \cdot \alpha_v + 6.07995)^{-1.6364}} \quad (20)$$

Los parámetros A y B pretenden modelar el estado de transparencia o turbidez de la atmósfera. El parámetro A da cuenta principalmente de los procesos de absorción en determinadas bandas del espectro, en particular en aquellas en las que la absorción es más fuerte, mientras que B da cuenta principalmente de los fenómenos de dispersión, aunque también de fenómenos de absorción más débiles [3].

Una vez obtenida la irradiancia directa normal de cielo despejado, procederemos a calcular el factor de atenuación. Para ello utilizaremos los datos de irradiancia directa normal medida a través del pirheliómetro. Una vez obtenidos estos valores, se calculará el factor de atenuación como:

$$k = \frac{DNI_{real\ medida}}{DNI_{cielo\ despejado}} \quad (21)$$

5.2.2 Cálculo de las propiedades de la nube y asociación a un factor de atenuación.

Una vez tenemos definida la atenuación debemos elegir los parámetros que puedan ser más característicos de la imagen de la nube para después asociarle a cada nube el factor de atenuación que ha provocado.

Para definir la nube a partir de su imagen se obtendrán del conjunto de píxeles que componen la nube las siguientes propiedades:

Característica	Herramienta	Parámetros obtenidos
Color y brillo	Modelos de representación RGB y HSV.	Media, desviación típica y oblicuidad (skewness) para las intensidades de luz de rojo, verde, azul, matiz, saturación y brillantez.
Textura	Obtención de los valores de entropía, rango de la imagen y desviación estándar.	Media, desviación típica y oblicuidad para las propiedades de entropía, rango de la imagen y desviación estándar.
Textura	Uso de la matriz de co-ocurrencia de niveles de grises (GLCM)	Se obtiene las propiedades de contraste, correlación, energía y homogeneidad.

Tabla 4 – Propiedades de la imagen utilizadas para caracterizar la nube.

Las características de color y brillo permiten distinguir entre nubes más oscuras cargadas de agua, las cuales si tapan el sol producirán que la radiación directa sea nula, de nubes más finas las cuales suelen tener un tono blanco ligeramente azulado y que producen una bajada en la radiación directa pero sin lograr hacerla nula. En cuanto a las propiedades de textura, estas propiedades nos dan la variabilidad en los niveles de intensidad de grises que muestra la nube. Esto permite distinguir entre un conjunto de nubes pequeñas abultadas como puede ser un Cirrocúmulos los cuales presentan una textura rugosa y que en función de cómo tapen el sol provocarán caídas bruscas de la radiación de forma intermitente, de otras tipologías de nubes como pueden ser los Altoestratos que presentan una capa fina y lisa que provocarán una bajada relativamente pequeña en la radiación directa pero de manera constante.

Por otro lado se aplicará la función resultado obtenida en la primera red neuronal para obtener del conjunto de píxeles que componen la nube cuantos han sido identificados como nube densa y cuantos han sido identificados como nube poco densa.

Por último se obtendrán dos distancias en píxeles de la imagen, la distancia media que hay entre la nube y el sol, y la distancia media que hay entre la nube y el centro de la imagen. Con la primera se

pretende que la red neuronal tenga presente de cierta forma cómo puede afectar la distancia al sol en el brillo y color que se percibe de la nube, además de la distancia que total que debe recorrer la nube la cual si es muy grande durante este recorrido en la nube se producirán demasiados cambios como subdivisiones en otras nubes más pequeñas o simplemente la desaparición de esta, teniendo en cuenta así como de fiables pueden ser los datos extraídos de la nube. Por otro lado la segunda distancia se utilizará para que la red neuronal tenga presente de cierta forma el tamaño total de la nube. Es decir, como ya dispone del número de píxeles que componen la nube en su totalidad (sería igual al número de píxeles clasificados como nube densa más el número de píxeles clasificados como nube poco densa), la distancia al centro de la imagen permitirá aproximar la escala del tamaño de la nube ya que una nube compuesta por pocos píxeles pero que este lejana al centro de la cámara podría ser mayor que una nube pequeña la cual está justo encima de la cámara de cielo.

Una vez que obtenemos estas características de la imagen de la nube, procedemos a asociarla con un factor de atenuación. Para ello en primer lugar se representarán gráficamente los valores de radiación directa reales que han sido medidos y los valores de radiación directa calculados con el modelo de cielo despejado, y se localizarán puntos de interés en los cuales se obtenga el valor de atenuación. Estos puntos de interés suelen darse en días despejados con nublados momentáneos en los que se pueda posteriormente localizar la nube que ha producido esa atenuación. Sin embargo los días nublados en los que aparecen claros momentáneos es muy difícil definir qué conjunto de nubes provocaban esa atenuación ya que al disponer solo de fotografías realizadas con un intervalo de tiempo de 5 minutos, el conjunto de nubes puede sufrir muchos cambios y resulta muy dificultoso localizar que nube entre todas las presentes había sido la que provocaba esa atenuación.

Una vez localizado ese momento de interés, calculamos la atenuación y vemos en que instante se ha producido esa disminución de la radiación directa. Una vez determinada la hora y el minuto en el que se ha producido, se procede a observar las imágenes para localizar en la imagen a la nube que ha provocado esa disminución de la radiación directa. Para ello se observa si hay alguna imagen en ese intervalo en la que se detecte la nube tapando el sol. En el caso de que no se dé este hecho se observarán varias imágenes en secuencia intentando detectar la trayectoria que siguen las nubes, y solo en el caso de que se observe de forma clara cuál es la única nube que ha pasado por el sol se le asociará a esa nube la atenuación provocada. En el caso en el que no se pueda observar de forma clara y se tenga una pequeña incertidumbre sobre la nube que ha provocado esa disminución de radiación, ese instante de interés no será caracterizado y se procederá a la búsqueda de otros instantes en los que se detecte la imagen de forma clara.




Figura 18 – Representación del método de localización para detectar puntos de interés



Figura 19 – Localización de la nube que provoca la disminución de la radiación solar.

5.2.3 Utilización de una red neuronal para el cálculo del factor de atenuación.

Aplicando este procedimiento a la base de datos disponible, que está compuesta por imágenes captadas aproximadamente durante dos meses, se han logrado asociar 55 nubes diferentes con su factor de atenuación, extrayéndose de cada nube un total de 36 propiedades que la definan mostradas en la Tabla 5. Por lo tanto la red neuronal tendrá como entrada una matriz Input compuesta por 55 columnas y 36 filas. En cuanto a la salida, se realizarán dos redes neuronales diferentes y se compararán los resultados obtenidos para cada una de ellas. La primera, tendrá como salida una matriz de 55 columnas y una sola fila en la que se muestran los valores de atenuación asociados a cada caso. En el caso de la segunda también se tendrá las 55 columnas correspondientes a cada uno de los casos recogidos, pero se agruparán los factores de atenuación en tres grupos diferentes, por lo que se tendrán tres filas quedando finalmente la salida como una matriz de 55 columnas y 3 filas en las que cada caso podrá ser:

- Si el resultado es un 1 en la primera fila y el resto de filas 0, el factor de atenuación será menor o igual de 0.25.
- Si el resultado es un 1 en la segunda fila y el resto de filas 0, el valor del factor de atenuación estará comprendido entre 0.25 y 0.7.
- Por último, si el resultado es un 1 en la tercera fila de la columna y un 0 en el resto, el valor del factor de atenuación será mayor o igual que 0.7.

Configuración de Input
Media de rojo
Desviación típica de rojo
Oblicuidad de rojo
Media de verde
Desviación típica de verde
Oblicuidad de verde
Media de azul
Desviación típica de azul
Oblicuidad de azul

Media de matiz
Desviación típica matiz
Oblicuidad matiz
Media de saturación
Desviación típica de saturación
Oblicuidad de saturación
Media de brillantez
Desviación típica de brillantez
Oblicuidad de brillantez
Media de entropía
Desviación típica de entropía
Oblicuidad de entropía
Media de rango de la imagen
Desviación típica de rango de la imagen
Oblicuidad de rango de la imagen
Media de desviación estándar
Desviación típica de desviación estándar
Oblicuidad de desviación estándar
Contraste
Correlación
Energía
Homogeneidad

Distancia en píxeles de la nube al sol en la imagen
Distancia en píxeles de la nube al centro de la imagen
Número de píxeles clasificados como cielo despejado
Número de píxeles clasificados como nube tenue
Número de píxeles clasificados como nube densa

Tabla 5 – Matriz de entrada de la red neuronal clasificadora de nubes.

6 RESULTADOS.

6.1 Resultados obtenidos en la red neuronal clasificadora de píxeles.

En la primera red neuronal que tiene como objetivo la clasificación de los píxeles y su definición en uno de los cuatro grupos que se han definido, se ha utilizado una matriz de confusión con el objeto de facilitar una visión de la calidad de los datos que se obtienen de esta función. Se han realizado cuatro matrices de confusión una por cada etapa de entrenamiento de la red neuronal y la cuarta que engloba todo el conjunto de resultados. Estas matrices de confusión obtenidas se muestran en la siguiente figura:



Figura 20 – Matrices de confusión obtenidas como resultado de la actuación de la red neuronal clasificadora de píxeles.

El tipo 1 es el perteneciente al cielo despejado, la primera fila sería el conjunto de píxeles que pertenecen al cielo despejado, el cuadrado verde representa el número de píxeles que han sido definidos correctamente mientras que los cuadrados rojos muestran los píxeles que se han clasificado de manera errónea. En cuanto a los cuadrados grises se muestra el porcentaje total de acierto y error que se ha tenido en toda la fila o columna. Por ejemplo, la primera fila muestra como han sido clasificados el conjunto de píxeles pertenecientes al tipo de cielo despejado, como podemos observar en la matriz de confusión total, el 98.9% de los píxeles de cielo despejado que se han utilizado para la red neuronal han sido catalogados correctamente, mientras que el mayor número de píxeles pertenecientes a cielo despejado clasificados erróneamente fueron catalogados como nubosidad tenue, de esta forma podemos deducir que nuestra red neuronal tiene una pequeña tendencia a confundir ciertos cielos despejados con nubosidades tenues. En cuanto al segundo grupo podemos observar que la mayor parte de píxeles mal catalogados son los confundidos con nubes densas, esto se debe a que la red neuronal lo confunde con nubes densas cercanas al sol las cuales al ser observadas en la imagen casi totalmente deslumbradas y muestran una alta saturación, quedando con valores similares a los píxeles de la imagen que pertenecen al disco solar. Continuando con el análisis podemos observar que el tercer grupo perteneciente a los píxeles de nubosidad tenue tiende a confundirse con píxeles de nubosidades más opacas o con cielos despejados mientras que nunca se ha dado una confusión con el grupo tres es decir el de píxeles pertenecientes al sol y por tanto se puede concluir que ambos grupos están perfectamente diferenciados. En cuanto al grupo cuatro que representa los píxeles catalogados como nube densa podemos observar que el número de píxeles de este grupo que son catalogados como cielo despejado y como nube tenue son muy parecidos. La confusión de píxeles pertenecientes al grupo cuatro con píxeles de cielo despejado se debe a que cuando tenemos cielo despejado en las regiones cercanas al sol se alcanzan colores muy claros y casi blanquecinos lo que provoca que algunos píxeles de nubes densas sean confundidos con este tipo de píxeles. En cuanto a la confusión con nubes tenues, ambos grupos suelen presentar colores parecidos lo que provoca que la catalogación en uno de estos dos grupos sea complicada.

A pesar de estos errores, si observamos los recuadros de los resultados totales para cada grupo (recuadros grises) se puede ver que los porcentajes de éxito en cada grupo son muy altos, lográndose que para los grupos uno, dos y cuatro se alcancen porcentajes de éxito mayores del 98%. Para el tercer grupo el cual obtiene los peores resultados podemos ver que el 90.9% de los píxeles pertenecientes a imágenes de nubes tenue han sido correctamente catalogados y que de todos los píxeles que han sido catalogados como nube tenue el 80% ha sido catalogado correctamente.

Aun así los resultados mostrados en estas matrices de confusión son datos que han servido como entrada a la propia red neuronal por ello para comprobar como de buena ha sido la generalización de esta red neuronal se aplica la función extraída de su entrenamiento para ver como caracteriza una imagen completa. Para ello se leerá una imagen completa obtenida por la cámara y se obtendrán para

cada píxel los 7 valores definidos como entrada. Luego se aplicara la función y se catalogarán todos los píxeles de la imagen y finalmente se mostrará una imagen donde cada píxel muestre un color diferente en función del grupo en el que ha sido catalogado. A continuación se muestra una imagen real de la cámara y la imagen en función de la catalogación realizada.



Figura 21 – Imagen obtenida por la cámara de cielo a la cual se le aplicará la red neuronal clasificadora de píxeles.




Figura 22 – Imagen resultado obtenida tras aplicar la red neuronal clasificadora de píxeles.

Como podemos observar el resultado es bastante bueno pero si aprecian dos defectos importantes. El primero es que en la zona cercana al sol se confunden los reflejos producidos en la bóveda de la cámara con zonas de nubes densas, cuando en realidad deberían pertenecer a píxeles de cielo despejado. En segundo lugar podemos observar que las zonas que están muy alejadas del centro de la imagen en las que hay bastante nubosidad, son confundidas en su totalidad como nubes densas y no aparece ningún tipo de zona de cielo despejado que separe unas nubes de otras. A pesar de estos dos defectos en nuestro caso las nubes se estudian con imágenes de cinco minutos anteriores a que se produjera el tapamiento del sol lo que suele colocar a la mayoría de nubes en zonas que no están demasiado cerca del sol ni demasiado alejadas del centro de la imagen lo que permite que esta herramienta sea utilizada en el siguiente procedimiento. Además para asegurar la correcta catalogación de nubes que se lleva a cabo en la siguiente etapa, se mostrarán el resultado que de esta función con la nube a estudiar para así asegurar que la asociación de un factor de atenuación se hace de forma correcta.

6.2 Resultados obtenidos en la red neuronal encargada de estimar el factor de atenuación que provoca una nube.

En este punto se comentarán los resultados obtenidos en las dos redes neuronales realizadas para asociar un factor de atenuación a cada nube. En ambos casos se tiene la misma entrada pero en el primer caso la salida será directamente el factor de atenuación mientras que en el segundo la salida será una columna de tres filas la cual nos mostrara en que rango de valores se mueve el factor de atenuación.

Para analizar los datos del primer caso se hará uso del coeficiente de regresión “R” el cual nos muestra si las salidas ofrecidas por la red neuronal se aproximan a los objetivos que nosotros le hemos impuesto. Un valor de R próximo a 1 nos muestra que la relación salida entrada está cerrada, mientras que un coeficiente de regresión igual a 0 nos dirá que la función nos dará un valor de salida totalmente aleatorio ya que no encuentra ninguna relación. Los resultados obtenidos se muestran en la siguiente figura:

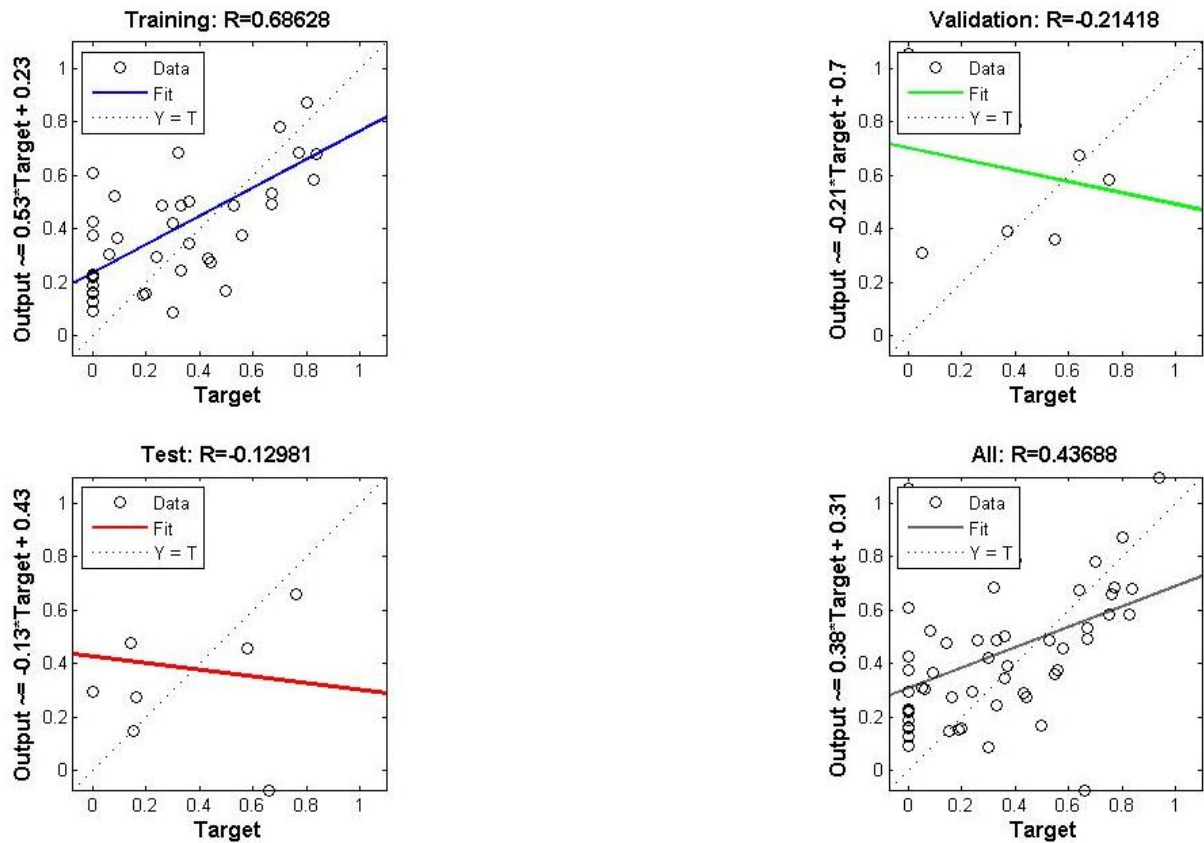


Figura 23 – Valores de la regresión obtenida en las diferentes etapas de la red neuronal clasificadora de nubes.

Como podemos observar en el proceso de entrenamiento conseguimos un ajuste más o menos aceptable, pero si continuamos observando vemos que tanto en la parte de validación como en la fase de prueba no se consigue ajuste alguno. Podemos concluir por tanto que a pesar de que el entrenamiento es correcto y puede existir una relación entre los parámetros seleccionados de entrada y la salida, la red neuronal no consigue una función generalizada que logre ampliarse al resto de casos existentes, por lo que habría que aumentar el número de casos que son utilizados en el proceso de validación para lograr una mejor generalización. Se ha intentado repartir el número de casos total de forma que el proceso de validación disponga de más datos, pero para ello se han tenido que disminuir los casos usados en el entrenamiento y los resultados finales obtenidos han sido bastante peores que en este caso.

También para poder tener datos sobre la calidad de esta red neuronal se ha realizado un histograma de errores en el cual se muestran el número de casos que tiene un determinado valor de error, tomando el error como la diferencia entre la salida dada por la red neuronal y el valor objetivo a alcanzar que se le ha dado. Además en este histograma también se muestra la parte del proceso a la que pertenece el caso en cuestión. Los resultados reflejados en el histograma se muestran en la siguiente figura:




Figura 24 – Histograma de errores obtenidos en los resultados de la red neuronal clasificadora de nubes.

Como podemos observar los casos usados en el entrenamiento han sido los que menor error cometen y la mayoría de ellos cometen errores menores que 0.25. Sin embargo podemos observar que hay algunos casos en los que los errores son totalmente inadmisibles, especialmente en los casos empleados en la validación y en la fase de prueba, por lo que se recalca otra vez los fallos de red neuronal debido a que no se ha logra conseguir una generalización de la función.

En cuanto a la segunda red neuronal, al volver a clasificar cada nube y agruparla en uno de los tres grupos en los que se ha acotado el factor de atenuación se hará uso otra vez de la matriz de confusión para observar la calidad de la actuación de la red neuronal. Las matrices de confusión obtenidas se muestran en la siguiente figura:



Figura 25 – Matrices de confusión obtenidas como resultado de la actuación de la red neuronal clasificadora de nubes.

Como podemos observar en las matrices de confusión los resultados no son demasiado buenos pero se acierta un 60% de los casos analizados, los casos mejor catalogados son los pertenecientes al grupo 2, con un porcentaje de acierto del 71.4%. A continuación le sigue el grupo 1 con un porcentaje total de acierto del 63.3%. Para el grupo 3 solo se consigue un 36.4% de aciertos. Tanto en la matriz de entrenamiento como en la pruebas se puede observar que la peor catalogación se da en el grupo 3, es decir el de las nubes más tenues por lo que se puede concluir que la red neuronal tiene especial problema para esta clase de nubosidades. Si observamos la matriz de confusión del proceso de pruebas y validación vemos que los aciertos conseguidos son solo del 50% por lo que podemos concluir que la generalización de la función obtenida por la red neuronal no ha logrado generalizarse de forma correcta.

7 CONCLUSIONES.

En primer lugar una de las conclusiones que se han podido extraer de este proyecto es la gran utilidad que pueden tener las herramientas basadas en las redes neuronales para la realización de estudios basados en comportamiento climáticos. Al ser una herramienta que realiza un estudio estadístico de sucesos y relaciona estos con los efectos que pueden generar, es una herramienta muy potente para clasificar las diferentes tipologías de nubes agrupándolas en función del efecto que provocan en la radiación solar directa.

Por otro lado también podemos obtener también como conclusión que el uso de imágenes de cámaras de cielo puede llegar a definir la nube con muy buena aproximación. De la imagen de una nube se pueden obtener parámetros que reflejen su textura y su color, los cuales como se ha mostrado en este proyecto tienen una relación directa con la disminución en la radiación solar directa provocada por dichas nubes. Por eso podemos concluir que el uso de cámaras de cielo para conseguir una predicción de la climatología a muy corto plazo tienen un alto potencial, lo que puede ayudar al operador de plantas que usan la tecnología CSP a anticiparse permitiéndole adaptar la producción de electricidad a la presencia de nubes y logrando así una optimización de la producción eléctrica, lo que puede suponer un impulso para este tipo de tecnologías.

Finalmente observando los resultados que se han obtenido en este proyecto, se pueden extraer dos últimas conclusiones. En primer lugar, al basarse las redes neuronales en análisis estadísticos, cabe destacar la importancia que tienen en estas herramientas el uso de una base de datos de calidad y amplia, para poder llegar a funciones generalizables que sean aplicables en todos los casos que se puedan dar en la realidad. En segundo lugar, mencionar que puede ser de interés la realización de un pretratamiento y procesado de la imagen más intenso el cual ensalce las características de la nube para así lograr como resultado una imagen en la que se pueda facilitar la diferenciación de los diferentes tipos de nubosidades.

8 REFERENCIAS.

- [1] Web: “<http://www.energiaysociedad.es/ficha/1-6-insostenibilidad-del-sistema-energetico-y-vias-de-solucion>”
- [2] Miguel Larrañeta Gómez-Caminero “Generación sintética de series de irradiación directa normal de alta resolución espacial” Trabajo Fin de Master 2014.
- [3] Marina Fabre Morales “Estimación de la irradiancia directa normal a partir de las medidas registradas por un pirheliómetro y un modelo para cielo despejado” Proyecto Fin de Carrera 2013.
- [4] Manuel A. Silva Pérez, *Diapositivas de Centrales Solares*, 2016
- [5] Imagen extraída de la web: “<http://calculationsolar.com/>”
- [6] R. Tapakis and A. G. Charalambides, “Equipment and methodologies for cloud detection and classification: A review,” *Sol. Energy*, vol. 95, pp. 392–430, 2013.
- [7] World Meteorological Organization, 1956. International Cloud Atlas, vol. 1, Geneva.
- [8] American Meteorological Society, 2016. <<http://www.ametsoc.org/>>.
- [9] World Meteorological Organization, 2011. <<http://www.wmo.int/>>.
- [10] Ahrens, C.D., 2009. *Meteorology Today – An Introduction to Weather, Climate and Environment*, ninth ed. Pacific Grove, California, Brooks/Cole.
- [11] National Oceanic and Atmospheric Administration’s – National Weather Service, 2011. <<http://www.nws.noaa.gov/>>.
- [12] Cotton, W.R., Bryan, G.H., Van de Heever, S.C., 2011. Storm and cloud dynamics, second ed.. In: *International Geophysics Series*, vol. 99 Elsevier, UK.
- [13] Rogers, R.P., Yau, M.K., 1989. *A Short Course in Cloud Physics*, third ed. Pergamon Press, Elmsford, NY.
- [14] Cloud Appreciation Society, 2011. <www.cloudappreciationsociety.org>.
- [15] H. Yang, B. Kurtz, D. Nguyen, B. Urquhart, C. W. Chow, M. Ghonima, and J. Kleissl, “ScienceDirect Solar irradiance forecasting using a ground-based sky imager developed at UC San Diego,” *Sol. Energy*, vol. 103, pp. 502–524, 2014.
- [16] J. Alonso and F. J. Batlles, “Short and medium-term cloudiness forecasting using remote sensing techniques and sky camera imagery,” *Energy*, vol. 73, pp. 890–897, 2014.
- [17] Pfister, G., McKenzie, R.L., Liley, J.B., Thomas, A., Forgan, B.W., Long, C.N., 2003. Cloud coverage based on all-sky imaging and its impact on surface solar irradiance. *J. Appl. Meteorol. Climatol.* 42 (10), 1421–1434.
- [18] Paoli, C., Voyant, C., Muselli, M., Nivet, M.-L., 2010. Forecasting of preprocessed daily solar radiation time series using neural networks.

Solar Energy 84 (12), 2146–2160.

[19] Marquez, R., Coimbra, C.F.M., 2013a. Intra-hour DNI forecasting based on cloud tracking image analysis. Solar Energy 91, 327–336.

Chow, C.W., Urquhart, B., Lave, M., Dominguez, A., Kleissl, J., Shields, J., Washom, B., 2011. Intra-hour forecasting with a total sky imager at the UC San Diego solar energy testbed. Solar Energy 85, 2881–2893.

[20] Gueymard CA. Importance of atmospheric turbidity and associated uncertainties in solar radiation and luminous efficacy modelling. Energy 2005

[21] Olmo FJ, Cazorla A, Alados-Arboledas L, López-Álvarez MA, Hernández-Andrés J, Romero J. Retrieval of the optical depth using an all-sky CCD camera. Appl Opt 2008

[22] Kassianov EI, Long CN, Ovtchinnikov M. Cloud sky cover versus cloud fraction: whole-sky simulations and observations. J Appl Meteorol 2005

[23] Cazorla A, Olmo FJ, Alados-Arboledas L. Estimación de la cubierta nubosa en imágenes de cielo mediante el algoritmo de clasificación KNN. Puerto la Cruz

[24] Heinle A, Macke A, Srivastav A. Automatic cloud classification of whole sky images. Atmos Meas Tech 2010

[25] Martínez-Chico M, Batlles FJ, Bosch JL. Cloud classification in a mediterranean location using radiation data and sky images. Energy 2011

[26] Thuillier G, Perrin J, Keckhut P, Huppert F. Local enhanced solar irradiance on the ground generated by cirrus: measurements and interpretation. J Appl Remote Sens 2013;7. Art. no. 13057.

[27] Alonso J, Batlles FJ, Villarroel C, Ayala R, Burgaleta JI. Determination of the sun area in sky camera images using radiometric data. Energy Convers Manag 2014

[28] E. Laorden Fiter, “Descripción, comparación y ejemplos de uso de las funciones de la toolbox de procesamiento digital de imágenes de MATLAB ®,” no. Plan 2000, 2012

[29] Wikipedia modelo HSV. Web: “https://es.wikipedia.org/wiki/Modelo_de_color_HSV”

[30] Web de ayuda de Matlab “<http://es.mathworks.com/help/images>”

[31] J. M. Marín Diazaraque, “Introducción a las redes neuronales aplicadas,” pp. 1–31, 2007.

[32] Sandra Patricia Daza P. Universidad Militar Nueva Granada Facultad de Ingeniería Mecatrónica Bogotá,

Web: “<http://www.monografias.com/trabajos12/redneur/redneur2.shtml#ixzz4BCQczZhz>”

[33] Manual del pirheliómetro modelo CHP1 de Kipp & Zonen.

[34] Manual de la cámara Q-25M de Mobotix.

[35] Web de Google maps: “<https://www.google.es/maps/@>”

[36] Imagen extraída de la web: “<http://matlab.izmiran.ru/help/toolbox/images/color10.html>”