

**UNIVERSIDAD POLITÉCNICA DE MADRID**

Escuela Técnica Superior de Ingeniería Agronómica,  
Alimentaria y de Biosistemas



**Metodologías de generación de secuencias  
meteorológicas características para la  
valoración de la producción vegetal**

**TESIS DOCTORAL**

Presentada para optar al título de Doctor por:

**Ousmane Wane**

Máster en Física Aplicada

Madrid, 2025



UNIVERSIDAD POLITÉCNICA DE MADRID  
Escuela Técnica Superior de Ingeniería  
Agronómica, Alimentaria y de Biosistemas

**Doctorado en Tecnología Agroambiental Para Una Agricultura  
Sostenible**

**Metodologías de generación de secuencias  
meteorológicas características para la  
valoración de la producción vegetal**

**TESIS DOCTORAL**

Presentada para optar al título de Doctor por:

**Ousmane Wane**

Máster en Física Aplicada

Bajo la dirección de:

Dr. Luis Fernando Zarzalejo Tirado

Dra. Rita Ximena Valenzuela Balderrama

Madrid, 2025

Título: Metodologías de generación de secuencias meteorológicas características para valoración de la producción vegetal

Autor: Ousmane Wane

Programa de Doctorado: Tecnología Agroambiental Para Una Agricultura Sostenible

Dirección de tesis:

Dr. Luis Fernando Zarzalejo Tirado, Investigador Titular, CIEMAT

Dra. Rita Ximena Valenzuela Balderrama, Investigadora Titular, CIEMAT

Revisores externos:

Tribunal de tesis:

Fecha de defensa:

Esta tesis ha sido financiada por los proyectos:

ALGATEC - CM (S2018/BAA-4532)., Comunidad Autónoma de Madrid, España y el FEDER «A way of making Europe».

TEDDY (TED2021-130366B-I00), Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033) y el programa «Next Generation EU» /PRTR de la Unión Europea.

Programa Aurum Supporting International Research Team Building (subvención DEC-6/1/2022/IDUB/II.1a/Au), Universidad Tecnológica de Gdansk.



*A la memoria de mi Padre*  
*A mi madre*



# Agradecimientos

A lo largo de este proceso de investigación científico, he tenido la suerte de recibir el apoyo de muchas personas. A ellas debo la culminación de esta tesis doctoral. Contribuyeron de formas diferentes, pero sus aportaciones fueron beneficiosas para llegar hasta aquí.

Por cierto, mi más sincero reconocimiento y agradecimiento van a mis directores de tesis, Dr. Luis F. Zarzalejo y Dra. Rita X. Valenzuela, por su paciencia y orientación para canalizar este trabajo durante estos años. Su gran interés, experiencia, dedicación y “collejas ☺” han sido clave para el desarrollo y enriquecimiento de esta investigación.

No puedo pasar por alto a Ana A. Navarro y Francisco Ferrera, por su compañerismo. Les agradezco mucho por sus contribuciones, colaboración, disponibilidad y por hacer de este camino un proceso más llevadero. Sus ideas y apoyo moral fueron un pilar en los momentos más desafiantes.

I would like also to sincerely thank Dr. Beata Bochentyn from the Faculty of Applied Physics and Mathematics at the University of Gdansk for hosting me. I had a wonderful experience, learned a great deal, and working with you has truly broadened my perspective. It was an inspiring and enriching time.

A mi familia, especialmente a mi mujer Mame Sokhna Seck y a mi madre Saly Diagne, gracias por su amor incondicional, por su apoyo, por creer en mí incluso cuando yo dudaba, y por ser mi motivación cada día. Este logro es también vuestro.

Llega la pausa y siempre habrá “Café con McGiver y el Equipo A”. Gracias colegas por los instantes “Café-té”, de conversación, distracción y risas ¡que hay vida más allá de la investigación!

Una vez más, ¡mil gracias a todos!



# Abstract

Numerical simulation as a tool for predicting the growth of plants and other photosynthetic organisms plays an important role in making decision about the effect of meteorological parameters on crop production under limiting environmental conditions or even to guide investments towards other more relevant circular economy goals. In general, the proliferation of these organisms requires specific ranges of temperature and photosynthetically active radiation, as a result of which crop productivity is strongly influenced by climate variability. Knowledge of the meteorological conditions in the study region and the ability to effectively use this data in numerical simulations to assess the feasibility of a project in advance are technically important when it comes to agricultural projects targeting the same area.

The main objective of this doctoral thesis is to generate separate typical meteorological sequences, each consisting of consecutive days that represent the climatic variability of each particular season of the year, or crop season, in a specific geographical location, to be used, *a posteriori*, in the numerical simulation of the production of photosynthetic organisms.

For this purpose, regional models of photosynthetically active radiation were established. Likewise, volume reductions of multi-year time series grouped by seasons of the year were carried out, using as a reference the generation of the typical meteorological year (TMY) method previously developed. In our study, the methodology based on Finkelstein-Schafer statistics was used, adapting the criterion for the final selection of the most representative sequence to the availability of data and research objectives. This task was carried out to generate all the Typical Meteorological Sequences (TMS) for the seasons of the year. Finally, they were used to simulate, in our case study, the production of algal biomass combined with the treatment of domestic wastewater obtained after primary treatment.

The results of this study focus on the perception of the representativeness and adaptability of TMS to the specific type of crop and the weather season. In perspective, some reformulations of the TMS generation methodology are proposed, using extensive and complete long-term hourly or sub-hourly time series for high temporal resolution of the TMS and robustness of the method.

# Resumen

La simulación numérica como herramienta de predicción del crecimiento de cultivos juega un papel importante en la toma de decisiones con respecto al efecto de los parámetros meteorológicos en la producción vegetal bajo condiciones ambientales limitantes, o incluso para orientar las inversiones hacia otros objetivos económicos circulares más relevantes. Por lo general, la proliferación de estos organismos requiere rangos específicos de temperatura y radiación fotosintéticamente activa, lo cual explica por qué la productividad de los cultivos está notablemente influida por la variabilidad meteorológica. Es técnicamente significativo, en el marco de un proyecto agrario, contar con una visión global de las condiciones meteorológicas de la región de estudios y poder emplear estos datos de manera eficiente en simulaciones computacionales para establecer de forma anticipada la factibilidad del proyecto.

Esta tesis tiene como objetivo generar secuencias meteorológicas tipo (Typical Meteorological Sequences, TMS, por sus siglas en inglés), cada una de ellas compuesta por una serie de días consecutivos, que representen la variabilidad meteorológica de cada estación del año, o temporada de cultivo en particular, en una localización geográfica específica; para su uso, a posteriori, en la simulación numérica de la producción vegetal que ayude a la toma de decisiones, la selección óptima de cultivos y el uso racional del agua, del terreno y de la energía para una agricultura sostenible.

Con esta finalidad, se desarrollaron modelos regionales de radiación fotosintéticamente activa. Asimismo, se llevaron a cabo reducciones de volumen de series temporales plurianuales agrupadas por estación del año, tomando como referencia distintas metodologías de generación del año meteorológico tipo (Typical Meteorological Year, TMY) previamente desarrolladas. En nuestro estudio, la metodología basada en el estadístico de Finkelstein-Schafer adaptando los criterios de selección final de la secuencia más representativa a la disponibilidad de datos y objetivos de investigación. Esa tarea se llevó a cabo con el fin de generar las TMS de las estaciones del año. Finalmente, se utilizaron para simular, en nuestro caso de estudio, la producción de biomasa algal combinada con el tratamiento de las aguas residuales domésticas.

Las conclusiones obtenidas están en relación con las percepciones de la adaptabilidad respecto al tipo de cultivo y de la representatividad de las TMS para una temporada

meteorológica o periodo de cultivo correspondiente. En perspectiva, se proponen algunas reformulaciones de la metodología de generación de las TMS mediante el uso de series temporales horarias o sub-horarias a largo plazo, más extensas y completas, que permitan conseguir una mayor resolución temporal y una mejora de la robusteza del método.



## Tabla de Contenido

|                                                                                                                                             |             |
|---------------------------------------------------------------------------------------------------------------------------------------------|-------------|
| <b>Agradecimientos</b>                                                                                                                      | <b>v</b>    |
| <b>Abstract</b>                                                                                                                             | <b>vii</b>  |
| <b>Resumen</b>                                                                                                                              | <b>viii</b> |
| <b>Lista de Figuras</b>                                                                                                                     | <b>xiii</b> |
| <b>Lista de Tablas</b>                                                                                                                      | <b>xv</b>   |
| <b>Abreviaturas, Acrónimos, Símbolos</b>                                                                                                    | <b>xvi</b>  |
| <b>1. Introducción</b>                                                                                                                      | <b>1</b>    |
| <b>2. Metodología</b>                                                                                                                       | <b>9</b>    |
| 2.1. Dispositivos experimentales .....                                                                                                      | 10          |
| 2.1.1. Estaciones radiométricas .....                                                                                                       | 11          |
| 2.1.2. Ensayos de crecimiento de microalgas.....                                                                                            | 16          |
| 2.2. Datos experimentales .....                                                                                                             | 19          |
| 2.2.1. Datos radiométricos medidos in situ .....                                                                                            | 19          |
| 2.2.2. Estimaciones de satélites y de reanálisis .....                                                                                      | 20          |
| 2.2.3. Datos de los ensayos en laboratorio .....                                                                                            | 22          |
| 2.3. Enfoque metodológico .....                                                                                                             | 23          |
| 2.3.1. Tratamiento de los datos .....                                                                                                       | 24          |
| 2.3.2. Modelización de la PAR .....                                                                                                         | 28          |
| 2.3.3. Generación de las secuencias de crecimiento.....                                                                                     | 32          |
| 2.3.4. Simulación del crecimiento de organismo fotosintético.....                                                                           | 36          |
| <b>3. Análisis comparativo de modelos de Radiación Fotosintéticamente Activos basados en atributos radiométricos en la España península</b> | <b>39</b>   |
| 3.1. Introducción .....                                                                                                                     | 40          |
| 3.2. Materiales y métodos.....                                                                                                              | 42          |
| 3.3. Resultados y Discusión .....                                                                                                           | 46          |
| 3.3.1. Análisis gráfico de la PAR y de otras variables radiométricas.....                                                                   | 46          |
| 3.3.2. Desarrollo y Validación de los Modelos Completos .....                                                                               | 51          |
| 3.3.3. Comparación entre Modelos completos y Modelos de la bibliografía .....                                                               | 57          |
| 3.3.4. Comparación entre Modelos Completos y Modelos por Intervalos .....                                                                   | 58          |
| 3.4. Conclusiones .....                                                                                                                     | 60          |
| 3.5. Apéndice A.....                                                                                                                        | 62          |
| <b>4. Generación de secuencias meteorológicas típicas para simular el crecimiento y la producción de sistemas biológicos</b>                | <b>71</b>   |
| 4.1. Introducción .....                                                                                                                     | 72          |
| 4.2. Metodología .....                                                                                                                      | 74          |
| 4.2.1. Metodología de los Laboratorios Nacionales Sandia .....                                                                              | 75          |
| 4.2.2. Caso de estudio .....                                                                                                                | 76          |

|                                                                                                                                                                                                                                 |            |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 4.2.3. Aplicación de la metodología TMS.....                                                                                                                                                                                    | 78         |
| 4.3. Resultados y discusión .....                                                                                                                                                                                               | 83         |
| 4.4. Conclusiones .....                                                                                                                                                                                                         | 88         |
| 4.5. Apéndice B.....                                                                                                                                                                                                            | 91         |
| <b>5. Un nuevo enfoque metodológico para simular el crecimiento de organismos fotosintéticos mediante secuencias meteorológicas representativas a largo plazo: un caso de estudio de microalgas (<i>Chlorella vulgaris</i>)</b> | <b>95</b>  |
| 5.1. Introducción .....                                                                                                                                                                                                         | 96         |
| 5.2. Materiales y métodos.....                                                                                                                                                                                                  | 98         |
| 5.2.1. Caso de estudio .....                                                                                                                                                                                                    | 99         |
| 5.2.2. Modelo de crecimiento de microalgas.....                                                                                                                                                                                 | 101        |
| 5.2.3. Proceso de simulación.....                                                                                                                                                                                               | 105        |
| 5.2.4. Conjunto de datos para análisis estadístico .....                                                                                                                                                                        | 107        |
| 5.3. Resultados y discusión .....                                                                                                                                                                                               | 108        |
| 5.3.1. Producción estacional de biomasa.....                                                                                                                                                                                    | 108        |
| 5.3.2. Análisis comparativo de la producción de algas .....                                                                                                                                                                     | 110        |
| 5.4. Conclusiones .....                                                                                                                                                                                                         | 113        |
| 5.5. Apéndice C.....                                                                                                                                                                                                            | 115        |
| <b>6. Discusión General</b>                                                                                                                                                                                                     | <b>119</b> |
| 6.1. Descripción de la solución.....                                                                                                                                                                                            | 120        |
| 6.2. Análisis de los resultados .....                                                                                                                                                                                           | 121        |
| 6.2.1. Modelización de la PAR .....                                                                                                                                                                                             | 121        |
| 6.2.2. Secuencias meteorológicas de crecimiento .....                                                                                                                                                                           | 127        |
| 6.2.3. Simulación del crecimiento de organismo fotosintético.....                                                                                                                                                               | 134        |
| 6.3. Conclusiones, aportaciones y futuras líneas de investigación .....                                                                                                                                                         | 135        |
| 6.3.1. Conclusiones .....                                                                                                                                                                                                       | 135        |
| 6.3.2. Aportaciones de la tesis.....                                                                                                                                                                                            | 137        |
| 6.3.3. Futuras líneas de investigación.....                                                                                                                                                                                     | 138        |
| 6.3.4. Conclusions.....                                                                                                                                                                                                         | 139        |
| 6.3.5. Contributions of the thesis.....                                                                                                                                                                                         | 141        |
| 6.3.6. Future lines of research .....                                                                                                                                                                                           | 142        |
| <b>Referencias</b>                                                                                                                                                                                                              | <b>145</b> |

---

## Lista de Figuras

|                                                                                                                                                                                                                                                                    |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 2-1: Cronología de las publicaciones científicas, resumiendo los objetivos específicos de la tesis.....                                                                                                                                                     | 10 |
| Figura 2-2 : Estaciones radiométricas instaladas en Aranjuez, Riosequillo, Soria (CEDER-CIEMAT) y Almería (PSA-CIEMAT). ....                                                                                                                                       | 15 |
| Figura 2-3 : Imagen del dispositivo experimental de cultivo de microalga a partir de agua residual doméstica del tratamiento secundario de una EDAR ubicada en Madrid. ....                                                                                        | 19 |
| Figura 2-4: Esquema del procedimiento de pretratamiento de los datos meteorológicos utilizados en el marco de esta tesis.....                                                                                                                                      | 28 |
| Figura 2-5: Diagrama de la cadena de modelización y validación de la radiación fotosintéticamente activa (PAR). ....                                                                                                                                               | 32 |
| Figura 2-6 : Reorganización de los datos por estaciones meteorológicas (bloques) y el remuestreo para aumentar el número de secuencia de un bloque. ....                                                                                                           | 33 |
| Figura 2-7: Diagrama de flujo relativo a la metodología de generación de las secuencias tipo. ....                                                                                                                                                                 | 35 |
| Figura 2-8: Diagrama de flujo relativo a la simulación del crecimiento de microalgas.....                                                                                                                                                                          | 38 |
| Figura 3-1 : Localización de las estaciones de CEDER-CIEMAT and PSA-CIEMAT.....                                                                                                                                                                                    | 43 |
| Figura 3-2 : Diagrama de dispersión entre la PAR y el ángulo de elevación solar. La barra de color representa el $k_t$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT. ....                                                                                  | 47 |
| Figura 3-3 : Diagrama de dispersión entre la PAR y la GHI. La barra de color representa el índice $k_t$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT. ....                                                                                                 | 47 |
| Figura 3-4 : Diagrama de dispersión entre la PAR y la DHI. La barra de color representa el índice $k_d$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT.....                                                                                                  | 47 |
| Figura 3-5 : Diagrama de dispersión entre la PAR y la DNI. La barra de color representa el índice $k_b$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT.....                                                                                                  | 48 |
| Figura 3-6 : Diagrama de dispersión entre la PAR, el ángulo de elevación solar, y el ángulo acimutal para la estación CEDER-CIEMAT (donde valores positivos del ángulo acimutal indican las horas de la mañana). La barra de color representa el $k_t$ . ....      | 48 |
| Figura 3-7 : Diagrama de dispersión entre la PAR, el ángulo de elevación solar, y el ángulo acimutal para la estación PSA-CIEMAT (donde valores positivos del ángulo acimutal indican las horas de la mañana). La barra de color representa el índice $k_t$ . .... | 48 |

|                                                                                                                                                                                                                                                                                                                                                                                          |     |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 3-8 : Resultados obtenidos en la validación de los modelos completos mencionados anteriormente, cada gráfico utilizando los datos medidos en las estaciones CEDER-CIEMAT (a, c, e) y PSA-CIEMAT (b, d, f). .....                                                                                                                                                                  | 52  |
| Figura 3-9 : Distribución del error absoluto de los modelos completos (a, b) y de los modelos por intervalos (c, d) propuestos en la Tabla 3-1 en las estaciones CEDER-CIEMAT (a, c) y PSA-CIEMAT (b, d). .....                                                                                                                                                                          | 56  |
| Figura 3-10 : Resultados de la validación de modelos en los intervalos mencionados anteriormente en cada gráfica utilizando datos medidos en las estaciones CEDER-CIEMAT (a, c, e) y PSA-CIEMAT (b, d, f). .....                                                                                                                                                                         | 59  |
| Figura 4-1 : Localización de la WWTPs consideradas en la Comunidad de Madrid.....                                                                                                                                                                                                                                                                                                        | 77  |
| Figura 4-2 : Variaciones diarias de los valores medios diarios de temperatura (media, máxima y mínima) y PAR para las TMW seleccionadas en cada estación del año en Colmenarejo Este (1991 a 2005). .....                                                                                                                                                                                | 88  |
| Figura 5-1 : Puesta en marcha experimental del cultivo de microalgas en aguas residuales domésticas.....                                                                                                                                                                                                                                                                                 | 104 |
| Figura 5-2 : Modelo de diagrama de bloques del crecimiento de microalgas en cultivo por lotes. ....                                                                                                                                                                                                                                                                                      | 106 |
| Figura 5-3 : Datos de secuencias meteorológicas típicas (TMS) de una localidad del norte de la región de Madrid, Riosequillo, para producir las curvas de concentración de biomasa que se muestran en la Figura 5-4. $T_{min}$ y $T_{max}$ representan la temperatura mínima y máxima diaria promedio. ....                                                                              | 109 |
| Figura 5-4 : Variación estacional de la concentración de biomasa algal en función de parámetros meteorológicos (secuencia meteorológica típica, TMS) en la región norte de Madrid (Riosequillo). Estas curvas se obtuvieron aplicando al modelo, como datos de entrada, la temperatura media diaria $T_{me}$ y los valores de PAR de las TMS seleccionadas, Figura 5-3.....              | 110 |
| Figura 5-5 : Función de distribución de probabilidad (PDF) de la secuencia de concentraciones de biomasa día a día utilizando datos de PAR y temperatura de cada input GMS para el modelo de la temporada de verano en Riosequillo (Madrid). (a–f) Representan la PDF de la concentración de biomasa de cada conjunto de datos de los días D2, D3, D4, D5, D6 y D7, respectivamente..... | 112 |
| Figura 5-6 : Los diagramas de caja muestran estadísticas de la serie de producciones diarias promedio de biomasa obtenidas para cada estación. ....                                                                                                                                                                                                                                      | 113 |
| Figura 6-1 : Representaciones graficas de las TMS (por estación del año y por localidad) que muestran las variaciones en promedio diarios de las temperaturas (media, máxima y mínima) y de la irradiancia PAR de catorce de las dieciocho localidades estudiadas de la Comunidad de Madrid.....                                                                                         | 133 |

---

## Lista de Tablas

|                                                                                                                                                                                                                                                           |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabla 2-1: Coordenadas geográficas de las principales estaciones radiométricas y los parámetros meteorológicos registrados in situ.....                                                                                                                   | 14  |
| Tabla 2-2: Concentración inicial de nitrógeno y fosforo del medio de cultivo (agua residual) y coeficientes de eliminación de los nutrientes considerados constantes en la simulación del crecimiento de microalgas para cada estación meteorológica..... | 23  |
| Tabla 2-3 : Modelos de PAR entrenados en el marco de esta tesis.....                                                                                                                                                                                      | 30  |
| Tabla 3-1 : Resultados obtenidos a partir de los ajustes de seis modelos completos de los grupos G1 y G2 y sus estadísticos de validación .....                                                                                                           | 54  |
| Tabla 3-2 : Índices estadísticos entre modelos completos y modelos de la bibliografía.....                                                                                                                                                                | 57  |
| Tabla 4-1: Opciones de factores de ponderación (wf) para obtener la suma ponderada.....                                                                                                                                                                   | 82  |
| Tabla 4-2 : Estadísticas diarias de largo plazo en Colmenarejo Este .....                                                                                                                                                                                 | 84  |
| Tabla 4-3 : Semanas candidatas en primavera para Colmenarejo Este para diferentes conjuntos de factores de ponderación y tamaño del lag .....                                                                                                             | 85  |
| Tabla 4-4 : Semanas candidatas en la localidad de Colmenarejo Este durante la primavera.....                                                                                                                                                              | 86  |
| Tabla 5-1 : Valores de los parámetros para realizar la simulación.....                                                                                                                                                                                    | 107 |
| Tabla 6-1 : Coeficientes de regresión de los modelos por intervalo y los modelos completos.....                                                                                                                                                           | 125 |
| Tabla 6-2 : Métricas cuantitativas (o estadísticos) de la validación de todos los modelos de PAR desarrollados en esta tesis .....                                                                                                                        | 126 |
| Tabla 6-3 : Coordenadas geográficas de las sitios estudiados y fecha del día inicial de las TMS por estación del año y por localidad.....                                                                                                                 | 129 |

# Abreviaturas, Acrónimos, Símbolos

|            |                                                                                                                                           |
|------------|-------------------------------------------------------------------------------------------------------------------------------------------|
| AEI        | Agencia Estatal de Investigación                                                                                                          |
| ALGATEC-CM | Proyecto de desarrollo de tecnologías avanzadas de microalgas para una economía circular                                                  |
| BSRN       | Baseline Surface Radiation Network                                                                                                        |
| CAPEX      | Capital Expenditure (Gastos de capital)                                                                                                   |
| CDF        | Cumulative Distribution Function                                                                                                          |
| CEDER      | Centro de Desarrollo de Energías Renovables                                                                                               |
| CIEMAT     | Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas                                                                    |
| CMSAF      | Satellite Application Facility on Climate Monitoring                                                                                      |
| DHI        | Direct Horizontal Irradiance                                                                                                              |
| DNI        | Direct Normal Irradiance                                                                                                                  |
| DQO        | Demanda Química de Oxígeno                                                                                                                |
| ECMWF      | European Center for Medium-Range Weather Forecasts                                                                                        |
| EDAR       | Estaciones de Depuración de Aguas Residuales                                                                                              |
| EUMETSAT   | European Organisation for the Exploitation of Meteorological Satellites                                                                   |
| ERA5       | Quinta generación del reanálisis atmosférico ECMWF del clima mundial que abarca el período comprendido entre enero de 1940 y el presente. |
| FAO        | Organización de las Naciones Unidas (ONU) para la Alimentación y la Agricultura                                                           |
| FEDER      | Fondo Europeo de Desarrollo Regional                                                                                                      |
| FS         | Estadístico de Finkelstein-Schafer                                                                                                        |
| GEOPAR     | Red de estaciones de medida de Radiación Fotosintéticamente Activa                                                                        |
| GHI        | Global Horizontal Irradiance                                                                                                              |
| GMS        | Growth Meteorological Sequence                                                                                                            |
| GSM        | Global System for Mobile communications                                                                                                   |
| HRAP       | High Rate Algae Pond                                                                                                                      |
| IMIDRA     | Instituto Madrileño de Investigación y Desarrollo Rural, Agrario y Alimentario                                                            |

---

|       |                                                 |
|-------|-------------------------------------------------|
| IR    | Radiación infrarroja solar                      |
| ISO   | International Organization for Standardization  |
| MAE   | Mean Absolute Error (Error absoluto medio)      |
| MBE   | Mean Bias Error (Sesgo)                         |
| MPE   | Mean Percentage Error (Error porcentual medio)  |
| NREL  | National Renewable Energy Laboratory            |
| ODS   | Objetivos de Desarrollo Sostenible              |
| OMM   | Organización Meteorología Mundial               |
| ONU   | Organización de las Naciones Unidas             |
| PAR   | Photosynthetic Active Radiation                 |
| PDF   | Función de distribución de probabilidad         |
| PPFD  | Photosynthetic Photon Flux Density              |
| PSA   | Plataforma Solar de Almería                     |
| PVGIS | PhotoVoltaic Geographical Information System    |
| RMSE  | Root Mean Square Error (Error cuadrático medio) |
| SAM   | System Advisor Model                            |
| SIM   | Subscriber Identity Module                      |
| SRI   | Solar Surface Irradiance                        |
| SRY   | Short Reference Year                            |
| TMM   | Typical Meteorological Month                    |
| TMS   | Typical Meteorological Sequence                 |
| TMY   | Typical Meteorological Year                     |
| TMW   | Typical Meteorological Week                     |
| TRY   | Test Reference Year                             |
| DRY   | Design Reference Year                           |
| UE    | Unión Europea                                   |
| UV    | Radiación ultravioleta solar                    |
| WWT   | Waste Water Treatment                           |
| WWTP  | Wastewater Treatment Plants                     |

| Símbolo          | Magnitud                                     | Rango y unidad                     |
|------------------|----------------------------------------------|------------------------------------|
| $I_0$            | Irradiancia solar extraterrestre             | $\text{W m}^{-2}$                  |
| $k_a$            | Coeficiente de extinción                     | $\text{m}^2 \text{g}^{-1}$         |
| $k_b$            | Fracción directa normal                      | $0 \sim 1$                         |
| $k_d$            | Fracción difusa horizontal                   | $0 \sim 1$                         |
| $K_i$            | Constante de inhibición de PAR               | $\mu\text{E m}^{-2} \text{s}^{-1}$ |
| $K_I$            | Constante de saturación de PAR               | $\mu\text{E m}^{-2} \text{s}^{-1}$ |
| $K_S$            | Constante de saturación del sustrato (P o N) | $\text{mg l}^{-1}$                 |
| $k_t$            | Índice de transparencia atmosférica          | $0 \sim 1$                         |
| N                | Concentración de nitrógeno total             | $\text{mg l}^{-1}$                 |
| $N_{\text{sol}}$ | Duración del día solar                       | h (hora)                           |
| P                | Concentración de fósforo                     | $\text{mg l}^{-1}$                 |
| $R^2$            | Coeficiente de determinación                 | $0 \sim 1$                         |
| $T_{\text{me}}$  | Temperatura media diaria                     | $^{\circ}\text{C}$                 |
| $T_{\text{min}}$ | Temperatura mínima diaria                    | $^{\circ}\text{C}$                 |
| $T_{\text{max}}$ | Temperatura máxima diaria                    | $^{\circ}\text{C}$                 |
| $T_{\text{opt}}$ | Temperatura óptima                           | $^{\circ}\text{C}$                 |
| $T_{\text{rgo}}$ | Rango diario de temperatura                  | $^{\circ}\text{C}$                 |
| X                | Concentración de microalga                   | $\text{mg l}^{-1}$                 |
| wf               | Factor de ponderación                        | $0 \sim 100 \%$                    |
| WS               | suma ponderada                               |                                    |
| $Y_N$            | Coeficientes de eliminación de nitrógeno     |                                    |
| $Y_P$            | Coeficientes de eliminación de fósforo       |                                    |
| $\alpha$         | Ángulo de elevación solar                    | $0 \sim \pi/2$ radianes            |
| $\mu$            | Tasa de crecimiento específico               | $\text{d}^{-1}$ (1/día)            |
| $\mu_D$          | Tasa de mortalidad específica                | $\text{d}^{-1}$ (1/día)            |

# 1. Introducción

El aumento y el cambio en el patrón de consumo de la población están generando serios problemas energéticos que afectan, entre otros aspectos, a la producción de alimentos y en el uso racional del agua, incluyendo la gestión adecuada de las aguas residuales. Por ejemplo, la prevalencia mundial de la inseguridad alimentaria, que es un indicador para medir el hambre mundial (Objetivos de Desarrollo Sostenible - ODS), reveló en 2023 que el 28,9 % de la población mundial, es decir 2 330 millones de personas, sufría de inseguridad alimentaria. Esto se traduce por una falta de avances significativos en el cumplimiento de los objetivos de Hambre Cero fijados para el 2030 (FAO et al. 2024). Además, la financiación para la seguridad alimentaria y la nutrición a través del gasto público en agricultura de los países, cuantificado por habitante de zonas rurales, es, en general, poco significativo en los últimos años. A pesar de eso, la agricultura es el sector dónde menos se incrementa la eficiencia en el uso del agua con un 0,6 USD/m<sup>3</sup>; mientras que la industria se sitúa en 32,3 USD/m<sup>3</sup> (FAO and ONU-Agua 2022; FAO et al. 2024).

A esto se añaden el aumento de las sequías y la desertificación debido al cambio climático global. Cada vez más países están experimentando estrés hídrico que afecta gravemente el crecimiento y la producción agrícola y forestal. De acuerdo con (Wu et al. 2022), el estrés hídrico es un factor limitante del desarrollo de las plantas afectando la morfología, actividad fotosintética, sistema enzimático antioxidante y niveles hormonales de estas últimas. Por otro lado, el crecimiento de la población y la intensificación de la producción agrícola entrenaron el uso excesivo de productos químicos tradicionalmente empleados en agricultura que son potenciales contaminantes de suelos y aguas subterráneas. Además, la mecanización de la agricultura ha aumentado el uso de energía con un elevado consumo de combustibles fósiles.

Otro asunto a considerar también es el aumento de la temperatura, lo que provoca el estrés térmico y la aceleración del proceso de evapotranspiración de la superficie del suelo entre las plantas. El aumento de la temperatura representa una amenaza para las explotaciones agrícolas debido al elevado consumo de agua y a la necesidad de disponer de agua para el riego. Estos dos factores limitan la posibilidad de riego en numerosas regiones del mundo, lo que repercute negativamente en la productividad agrícola y en el desarrollo

socioeconómico de las zonas afectadas. Por lo tanto, el uso eficiente del agua y de la energía en la agricultura es cada vez más importante debido a la escasez de recursos hídricos y al aumento de los costes energéticos.

Por otro lado, la creciente demanda de productos agrícolas y la escasez de los recursos en agua y suelo fértil, entre otros, ocasionaron el incremento del consumo energético en el sector de la agricultura. Eso se debe al uso creciente de maquinaria de regadíos o drenajes y de laboreo, transformación o recolección de parcelas agrícolas que suponen las mayores consumidoras energéticas en el sector agroalimentario. La escasez hídrica obliga a extraer agua de pozos profundos o trasvasarla, aumentando el gasto en electricidad o combustible. Además, el uso de sistemas de riego presurizados (goteo, pivotes) consumen más energía que los métodos tradicionales por gravedad. El laboreo intensivo, la utilización de tractores, cosechadoras y otras máquinas agrícolas incrementan el consumo energético y la degradación de los suelos. La reducción del consumo energético en la agricultura no solo mitigaría el cambio climático, sino que también mejoraría la resiliencia económica del sector agrícola.

En un mundo en el que el estrés hídrico afecta al 40% de la población y la agricultura contribuye con el 24% del consumo energético global (FAO et al. 2024), surgen interrogantes críticas: ¿Es factible seguir extrayendo agua de acuíferos sobreexplotados para cultivos de alto consumo hídrico? ¿De que manera se puede romper el círculo vicioso entre dependencia de combustibles fósiles y degradación ambiental en el sector agrícola? La transición hacia una agricultura de bajo consumo de agua y energía con una producción óptima de alimentos requiere enfoques innovadores que combinen tecnología, prácticas agroecológicas y gestión inteligente. Entre los planteamientos innovadores para una agricultura climáticamente inteligente figuran:

- la instalación de energías renovables como paneles solares en los cultivos que permitiría generar energía mientras protegen las plantas del estrés térmico y reducen el proceso de evapotranspiración.
- la reutilización de aguas residuales tratadas y la producción de biogás a partir de la biomasa agrícola para la autogeneración de energía en sistemas de riego que reducirían las emisiones de CO<sub>2</sub> en la agricultura a mediana escala.

Esta tesis propone la integración de las condiciones meteorológicas en estrategias agrícolas para la mejora de la productividad por gota de agua – cantidad de producto obtenido por unidad de agua – y la reducción del consumo energético y del impacto ambiental ocasionado por el sector, buscando demostrar que otra agricultura es posible. Así, el objetivo principal de esta tesis es la generación de secuencias meteorológicas que caracterizan la variabilidad estacional de la temperatura y de la irradiancia solar en una localización geográfica específica; para su uso como datos de entrada en programas de simulación numérica de producción vegetal.

La simulación numérica desempeña un papel fundamental en las etapas iniciales de la implantación de sistemas que ayuden a gestionar los desafíos del desarrollo sostenible. Su utilización permite realizar estimaciones a largo plazo sobre la viabilidad técnica y económica, lo que contribuye a definir la configuración más adecuada para su aplicación en situaciones reales. La simulación numérica aplicada a los sistemas energéticos es una herramienta clave, ya que permite conocer el comportamiento de dichos sistemas y adoptar estrategias adecuadas para optimizar su gestión. En el caso de los sistemas de cultivo de organismos fotosintéticos, esta herramienta permite prever el impacto de los parámetros meteorológicos en la productividad bajo condiciones ambientales limitantes, facilitando así la toma de decisiones y la reorientación de inversiones hacia otros objetivos más viables. Para entrenar estos sistemas, es fundamental utilizar datos meteorológicos representativos de los factores ambientales del emplazamiento del cultivo, incluyendo parámetros específicos relacionados con el desarrollo de los mismos. Estos parámetros de cultivo que representan las condiciones meteorológicas del entorno, son la temperatura, la humedad, la radiación solar y la evapotranspiración superficial y régimen pluviométrico. Por otro lado, constituyen unos factores fundamentales para la gestión del balance energético e hídrico del sistema de cultivo. Además, estos datos de interés en agricultura pueden formar parte de las bases de datos y otros sistemas de apoyo a los servicios agro-meteorológicos donde se podrán consultar y descargar para planificar un proyecto agrícola. El conocimiento previo y a largo plazo de las variaciones meteorológicas puede proporcionar información relevante para la gestión del riego y la definición de un plan de uso eficiente del agua y de la energía en la agricultura. Asimismo, la utilización de los parámetros meteorológicos como datos de entrada a programas de simulación numérica puede ser beneficioso para tener una visión previa del comportamiento de un sistema en función de los factores ambientales.

El desarrollo de esta tesis toma como punto de partida las metodologías de creación de secuencias meteorológicas propuestas y estudiadas previamente por (Hall et al. 1978; Lund 1991; Festa and Ratto 1993; Marion and Urban 1995). Entre estas metodologías, destacan las metodologías propuestas por Sandia National Laboratories, el Año Meteorológico Tipo (Typical Meteorological Year, TMY). Un TMY, es una secuencia, habitualmente horaria, de datos meteorológicos estadísticamente representativos de un año completo para una ubicación geográfica específica, seleccionados de un periodo más largo de tiempo para reflejar las condiciones climáticas promedio. Dicho método de creación de los TMY ha sido modificado a lo largo de los años para adaptarlo al tipo de sistema propuesto (Habte et al. 2014). En general, los TMY son comúnmente utilizados para simular el consumo energético de los edificios (fundamentalmente la climatización), simular el comportamiento de los sistemas de generación fotovoltaica, sistema de captación solar de baja temperatura y tecnologías de concentración, etc.

Los datos TMY se obtienen a partir de series temporales plurianuales (largo plazo) de determinados parámetros meteorológicos, seleccionados y ponderados según criterios específicos. Al emplear un único año representativo en lugar de utilizar un gran volumen de datos históricos, se logra reducir considerablemente el tiempo de ejecución de las simulaciones, manteniendo que los resultados continúen siendo satisfactorios. Un ejemplo de este enfoque se utiliza en programas de simulación de sistemas energéticos que integran datos TMY, tales como el System Advisor Model (SAM) del National Renewable Energy Laboratory – NREL – (Gilman et al. 2012) y el PhotoVoltaic Geographical Information System (PVGIS) de la Comisión Europea (Huld et al. 2012).

Es evidente que la productividad de los cultivos está fuertemente condicionada por la variabilidad meteorológica del sitio donde se instala el sistema agrícola. Por ello, los modelos de producción agrícola requieren una caracterización meteorológica a largo plazo en el sitio de estudio, con el fin de obtener estimaciones precisas del rendimiento de los cultivos. En este contexto, y como fue mencionado previamente, se emplearon conjuntos de datos TMY en modelos orientados a la optimización y mejora de la producción energética. El uso de los conjuntos de datos TMY en la simulación numérica continúan desempeñando un papel importante en la toma de decisiones previas para el diseño eficiente de sistemas energéticos. Pero, su aplicación en ámbitos como la simulación de la productividad agrícola ha sido escasamente explorada. Según (Domínguez et al. 2013), el uso del TMY en

agricultura se ha limitado principalmente al diseño de prototipos de invernaderos, poniendo una adaptación del método de generación del TMY con el objetivo de prever un calendario de riego y mejorar la productividad hídrica de los cultivos de ajo en la zona central de España. En este estudio, se generó el TMY seleccionando la pluviometría, la evapotranspiración y las temperaturas del aire como parámetros meteorológicos específicos del cultivo.

Teniendo en cuenta que un TMY representa una serie meteorológica anual estadísticamente representativa de un lugar específico y que la mayoría de los cultivos tienen periodos de crecimiento, desarrollo y producción menos de un año estrechamente relacionados a las condiciones ambientales estacionales, resulta de gran interés investigar y proponer una metodología para la generación de una Secuencia Meteorológica Típica (Typical Meteorological Sequence, TMS) que se ajuste al periodo y tipo de cultivo a estudiar, incluyendo parámetros como la temperatura y la radiación fotosintéticamente activa (PAR, por sus siglas en inglés).

La PAR que es la fracción del espectro solar utilizada por las plantas y otros organismos vivos para llevar a cabo el proceso de fotosíntesis, corresponde al rango de longitudes de onda comprendido entre 400 y 700 nm del espectro solar. Este parámetro meteorológico, puede expresarse en términos de densidad de flujo de fotones fotosintéticos (Photosynthetic Photon Flux Density – PPFD – en  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) o en términos de densidad de flujo radiante ( $\text{W m}^{-2}$ ), y tiene múltiples aplicaciones relevantes en muchos campos, como la industria agroalimentaria o el cultivo de plantas. La PAR constituye la principal fuente de energía para los organismos fotosintéticos y afecta el metabolismo de las plantas y de la calidad de la producción vegetal de los cultivos (Tang et al. 2022). Además, desempeña un papel clave en los mecanismos de secuestro de  $\text{CO}_2$  por microalgas (Prasad et al. 2021), la estimación de la producción primaria bruta o neta (Pinker et al. 2010), la eficiencia en la conversión de la energía absorbida en biomasa (Leblon et al. 1991) y el intercambio de carbono entre el ecosistema y la atmósfera (Roderick et al. 2001). En el diseño de invernaderos, las propiedades ópticas de los materiales dentro del rango PAR (400 - 700 nm) deben tenerse en cuenta (Lee et al. 2019), ya que la disponibilidad de PAR en el interior del invernadero puede verse muy afectada por los factores como la orientación, especialmente en el plano vertical (Wang et al. 2021).

Al igual que la PAR, la temperatura es uno de los parámetros más relevantes que inciden en el crecimiento, desarrollo y reproducción de los organismos fotosintéticos (Ras et al. 2013). Actúa de forma diferente sobre ellos según la especie en cuestión modificando las condiciones de crecimiento y, por tanto, afectando a la eficacia de la producción. Esta secuela es aún más notable cuando el cultivo se desarrolla a cielo abierto donde los parámetros meteorológicos escapan a nuestro control. De acuerdo con (Hatfield and Prueger 2015), el efecto más significativo de las temperaturas elevadas en las etapas de crecimiento de una planta se produjo en la fase reproductiva y que el desarrollo vegetativo suele tenerse una temperatura óptima superior a la del desarrollo reproductivo. Cada especie dispone un intervalo de temperaturas mínima y máxima fuera de las cuales el ritmo de crecimiento se ralentiza, lo que representa un riesgo importante que hay que gestionar para mantener una producción rentable (Barlow et al. 2015). En el caso de las microalgas, la temperatura óptima del medio de cultivo se sitúa, en general, entre 10 y 30 °C. Fuera de este intervalo de temperaturas, existe el riesgo de que las células de microalgas se dañen o mueran (Singh and Singh 2015; Serra-Maia et al. 2016). El estudio experimental del crecimiento de estos organismos fotosintéticos en aguas residuales domésticas en fotobiorreactores expuestos a la intemperie permitió evaluar el efecto de las variaciones diaria e inter-estacional en la producción de biomasa algal (Díez-Montero et al. 2020).

El presente trabajo de investigación presenta una metodología para la generación de TMS orientada a la simulación del crecimiento de organismos fotosintéticos. Es decir, se pretende crear una secuencia meteorológica característica de una temporada (por ejemplo, una estación del año) para su aplicación como datos de entrada a un programa de simulación numérica de producción vegetal. La metodología propuesta para generar las TMS trata de emplear el estadístico de Finkelstein-Schafer ampliamente utilizado para crear un TMY destinado para la simulación numérica de sistemas energéticos, riego o diseño de invernaderos. Por ello, la hipótesis de partida se establece en que una TMS deberá estar adaptable a cada tipo de cultivo y ser estadísticamente representativa de una estación meteorológica o temporada de cultivo. Esto permitiría conseguir una mayor precisión en la simulación de la producción agrícola.

Por lo tanto, se emplearon series extensivas de datos meteorológicos para la creación de las TMS con los siguientes seis parámetros: la PAR, la duración del día solar, el máximo, el mínimo, la media y el rango de temperaturas. Se tratan de los estudios realizados por etapas y materializados por las publicaciones de tres artículos como primer autor. El orden de publicación de los artículos que corresponden a los estudios asociados a los objetivos específicos, constituye el proceso de investigación seguido para abordar la temática propuesta en esta tesis doctoral. A continuación, se presentan el esquema de esta presente memoria por capítulos y un breve resumen de cada uno de los artículos asociados a este proceso de investigación.

Tras la introducción (capítulo 1), el capítulo 2 de esta memoria recoge, de manera general, el enfoque metodológico que sustenta todas las tareas desarrolladas en el marco de esta tesis. Asimismo, en esta sección, se describe el dispositivo experimental utilizado para el seguimiento del crecimiento de los organismos fotosintéticos utilizados. Se incluyen las cuatro estaciones radiométricas de la red equipadas con sensores de radiación fotosintéticamente activa (PAR). Con el objetivo de capacitar al doctorando en la gestión de las estaciones radiométricas, se efectuaron varias visitas de campo centradas en aspectos como la programación, el monitoreo y el mantenimiento de los equipos.

Los capítulos 3, 4 y 5 están compuestos por el compendio de los tres artículos publicados en revistas de divulgación científica con sello de calidad. En el capítulo 3 se expone el trabajo elaborado en el primer artículo titulado “Comparative Analysis of Photosynthetically Active Radiation Models Based on Radiometric Attributes in Mainland Spain” (Wane et al. 2022). En la actualidad, en España hay un número relevante de estaciones meteorológicas que registran variables de radiación solar integrada, temperatura ambiente, humedad,... bien repartidas geográficamente en el territorio. Sin embargo, las estaciones meteorológicas con registros de PAR son bastante escasas. Por ello, y como alternativa a esta carencia, se desarrollaron modelos regionales de estimación de PAR, utilizando combinaciones de variables radiométricas disponibles in-situ. A este artículo, se le añade otro estudio previo, como parte del programa de investigación del Departamento de Energía del CIEMAT, en el que se aportó una contribución personal para obtener una combinación de modelos empíricos para la generación de los primeros mapas PAR de España (Ferrera-Cobos et al. 2021).

En el segundo artículo, “Generation of Typical Meteorological Sequences to Simulate Growth and Production of Biological Systems” (Wane et al. 2023), que corresponde al capítulo 4, se presenta el desarrollo del modelo estadístico que permitió generar conjuntos de datos TMS representativos de las variabilidades meteorológicas de las distintas estaciones del año en 18 localidades de la región de Madrid. La metodología empleada para generar las TMS se inspira en las metodologías clásicas utilizadas para obtener los TMY con las adaptaciones necesarias respecto al tercer objetivo específico planteado. Las TMS generadas para su uso como datos de entrada en modelo cinético de crecimiento de microalgas en aguas residuales representaron los datos meteorológicos representativos de las estaciones meteorológica de un lugar específico. Cada una de ellas, se constituyó de una secuencia de siete días consecutivos que corresponderían al periodo de cultivo de las microalgas.

Las algas, al igual que las plantas, obtienen su energía mediante el aprovechamiento de la PAR y la temperatura. Ambas variables tienen un efecto considerable en la composición química de las algas (Béchet et al. 2013; Singh and Singh 2015; Metsoviti et al. 2020). Para estudiar el efecto de estos parámetros meteorológicos en el crecimiento de organismos capaces de realizar fotosíntesis, se definió un caso de estudio instrumental de producción biomasa algal en aguas residuales domésticas, que hace parte de la etapa final de esta tesis. El capítulo 5, tercer y último artículo publicado en el marco de esta tesis, lleva el título “A Novel Methodological Approach to Simulating the Growth of Photosynthetic Organisms Using Long-Term Meteorological Sequences: A Case Study of Microalgae (*Chlorella vulgaris*)” (Wane et al. 2024). En este artículo se recoge el uso de las TMS para simular el crecimiento de un género de algas verdes unicelulares, *Chlorella Vulgaris*, demostrando la utilidad práctica de la metodología de generación de TMS propuesta.

Finalmente, en el capítulo 6, se ofrece una descripción integral de las soluciones aportadas a lo largos de esta tesis y un análisis global de los resultados obtenidos. Esta sección concluye con las principales conclusiones, las aportaciones adicionales de la tesis y las futuras perspectivas encaminadas a consolidar la metodología y ampliar su campo de aplicación.

## 2. Metodología

La PAR es parámetro meteorológico no rutinariamente medido y fundamentalmente utilizado a lo largo de la tesis. Se encuentra en muy baja cobertura geográfica no solo en España sino a nivel global (Alados et al. 1996; Akitsu et al. 2015; Tang et al. 2022). En este contexto, nuestra participación en un proyecto de investigación desarrollado en el Departamento de Energía del CIEMAT, dio lugar a la publicación del artículo sobre la elaboración del primer mapa de PAR en la España peninsular (Ferrera-Cobos et al. 2021). Este trabajo preliminar sentó las bases para la primera etapa metodológica en el desarrollo de la investigación. A partir de este punto, inicié el trabajo que daría origen a mi tesis.

En esta sección se describe el proceso metodológico adoptado en la tesis. Además de la capacitación en gestión y mantenimiento de una estación radiométrica, se definieron tres objetivos principales que fueron alcanzados tras los estudios realizados por etapas y divulgados en forma de artículos. La serie de artículos publicados en el marco de esta tesis describen de forma coherente la línea de investigación desarrollada. Este recorrido abarca desde la instalación, el mantenimiento y monitoreo de estaciones de medida, hasta la generación de secuencias meteorológicas tipo para el crecimiento de organismos fotosintéticos, incluyendo también la modelización y la simulación numérica como medios fundamentales del proceso, para finalmente aplicar la metodología propuesta en un caso de estudio.

En la Figura 2-1 se presenta un resumen cronológico de los artículos publicados en revistas científicas indexadas en los cuartiles Q1 o Q2. En cada cuadrado de la Figura 2-1, se incluye el objetivo principal que corresponde a la fase de estudio del proceso de investigación. Las tres fases de estudio incluían la modelización de la PAR, la generación de las TMS y la simulación de la producción de biomasa algal. Además, se indica para cada etapa el origen del conjunto de datos empleados como entrada para realizar el trabajo correspondiente. El trabajo de la fase de modelización, fase de generación de la TMS y fase de simulación se culminó con la publicación de artículos que han sido referenciados en la Figura 2-1.




Figura 2-1: Cronología de las publicaciones científicas, resumiendo los objetivos específicos de la tesis

## 2.1. Dispositivos experimentales

El denominado “dispositivo experimental” incluyó tanto el monitoreo de estaciones meteorológicas previamente instaladas y la ejecución de ensayos de cultivo de microalgas en el laboratorio. En ambos casos, el montaje conlleva la instalación de varios dispositivos como sensores, sistemas de adquisición de datos y la configuración específica del software para el seguimiento de parámetros a medir. Asimismo, el objetivo común fue recoger datos precisos y continuos en un entorno específico con una opción de monitorización a largo plazo en el caso de las estaciones radiométricas.

### 2.1.1. Estaciones radiométricas

La conceptualización e implementación de la red de medidas de PAR en la España peninsular se llevó a cabo previamente en el marco del proyecto GEOPAR, Red de estaciones de medida de Radiación Fotosintéticamente Activa, con el número de registro CGL2016-79284-P AEI/FEDER/UE financiado por el Fondo Europeo de Desarrollo Regional (FEDER). En las estaciones instaladas, se incluyen también el registro de otros parámetros meteorológicos que se detallarán más adelante en esta sección.

La red de medidas de PAR contaba con siete estaciones radiométricas, además de las previamente instaladas en la Plataforma Solar de Almería (PSA-CIEMAT) y en el Centro de Desarrollo de Energías Renovables (CEDER-CIEMAT). No obstante, sigue siendo fundamental ampliar el número de estaciones de medida para garantizar una cobertura geográfica más completa, que permita caracterizar con mayor precisión las variabilidades espaciales de la irradiancia PAR en todo el territorio español.

En este contexto, y en línea con los objetivos de esta tesis, se procedió a la instalación de dos nuevas estaciones radiométricas en la Comunidad de Madrid. Estas estaciones se encuentran ubicadas en las instalaciones del Instituto Madrileño de Investigación y Desarrollo Rural, Agrario y Alimentario (IMIDRA) de Aranjuez y de Riosequillo, situados en la región sur y norte de Madrid, respectivamente. También, estas dos instalaciones forman parte de otro proyecto titulado “Desarrollo de tecnologías avanzadas de microalgas para una economía circular”, ALGATEC-CM (S2018/BAA-4532), cofinanciado por la Comunidad Autónoma de Madrid, y por los fondos FEDER.

Sin embargo, para el desarrollo de esta tesis, se han considerado solo cuatro estaciones de las once estaciones radiométricas gestionadas por el Grupo de Radiación Solar del Departamento de Energía del CIEMAT. Esta consideración viene motivada por los datos registrados que se utilizaron para los estudios de modelización de la PAR y las visitas de campo efectuadas que entran la capacitación en materia de seguimiento y mantenimiento (preventivo y correctivo) de una estación meteorológica. Por un lado, las estaciones instaladas en la Comunidad de Madrid responden a la línea de investigación definida en el marco de la tesis y alineada con los objetivos del proyecto ALGATEC del que formaba parte. Por otro lado, las estaciones de CEDER-CIEMAT y PSA-CIEMAT han sido las únicas que proporcionaban un conjunto extenso de datos radiométricos medidos in situ, permitiendo así el desarrollo de los modelos regionales de PAR desarrollados en esta tesis.

Para un mejor conocimiento de los dispositivos instalados en las estaciones relacionadas con esta tesis, se describe en detalle los sensores meteorológicos utilizados en cada una de ellas, así como sus características y capacidad de datos.

#### ARANJUEZ y RIOSEQUILLO:

- Los datos son recopilados por un *datalogger* de monitorización remota del modelo RX3004 de la marca HOBO, actualmente parte de la compañía LI-COR Environmental. Este modelo de *datalogger* proporciona acceso instantáneo a datos registrados a través de Internet vía una comunicación GSM (sistema global para las comunicaciones móviles).
- La temperatura ambiental y la humedad relativa se miden con el sensor S-THB-M002 de la marca HOBO. Es un sensor inteligente que comunica automáticamente la información de configuración al *datalogger* (HOBO) sin necesidad previa de programación, calibración o configuración exhaustiva por parte del usuario. El sensor viene con todos sus parámetros de comunicación con el *datalogger* almacenados en su interior.
- La PAR se mide con el sensor SQ-110-SS de APOGEE. Es un sensor cuántico analógico y autoalimentado con una salida de 0 a 800 mV. Mide la PPFD y tiene aplicación para la medición de dicho parámetro sobre cubiertas vegetales en entornos exteriores, invernaderos y cámaras de crecimiento. También, se puede usar para medir la PPFD en medios acuáticos, incluidos los acuarios de agua salada donde se cultivan corales. En nuestro caso se utilizó para medir la PAR no solo en las estaciones radiométricas; sino también el valor de la PAR dentro y fuera del medio de cultivo (medio acuático) de microalgas durante los experimentos en laboratorio.
- La irradiancia horizontal global (GHI) se registró con el sensor de modelo SP-110-SS de la misma marca APOGEE. También, ha sido instalado en el dispositivo experimental de cultivo de microalgas para medir la GHI de la fuente de luz.

#### CEDER-CIEMAT y PSA-CIEMAT:

- Los equipos de adquisición de datos corresponden a los modelos CR1000X (CEDER-CIEMAT) y CR3000 (PSA-CIEMAT) de Campbell Scientific.
- La PAR en ambas estaciones es medida con el sensor ML-020P de EKO Instruments.
- La GHI y la irradiancia horizontal difusa (DHI) se miden con un piranómetro CM21, mientras que la irradiancia directa normal (DNI) se registra con un pirheliómetro CH1, ambos fabricados por Kipp & Zonen.
- La temperatura y la humedad relativa se registran con una sonda HMP60 de Vaisala en CEDER-CIEMAT. Por su parte, en la PSA, se miden las temperaturas de bulbo húmedo y de bulbo seco por dos psicrómetros Thies modelo 1.1130.10.000.
- La presión atmosférica a temperatura ambiente en ambas estaciones se obtiene con un barómetro digital PTB110 de la marca Vaisala.
- En las dos estaciones, la pluviometría se registra mediante el sensor YOUNG 52203 que dispone de un área de captación de 200 cm<sup>2</sup> y una resolución de medición de 0.1 mm.
- La radiación infrarroja (IR) solar y la radiación ultravioleta (UV) solar se registran únicamente en la estación de la PSA. La IR mide con pirgeómetro de modelo PIR (Precision Infrared Radiometer) de la misma compañía. La UV se obtienen con el radiómetro de modelo Eppley TUVB (Total UltraViolet Radiometer) de la compañía Eppley Laboratory (EPLAB).

A continuación, se muestran, en la Tabla 2-1, las coordenadas geográficas y los parámetros físicos registrados en cada una de las estaciones radiométricas consideradas en el desarrollo de esta tesis doctoral. En las cuatro estaciones se miden los siguientes parámetros meteorológicos: GHI, PAR y T. Para las estaciones CEDER-CIEMAT y PSA-CIEMAT también se incluyen las medidas de DHI, DNI y otros parámetros meteorológicos que se indican en la Tabla 2-1.

Tabla 2-1: Coordenadas geográficas de las principales estaciones radiométricas y los parámetros meteorológicos registrados in situ.

| <b>Estación</b> | <b>Latitud / Longitud<br/>(°N / °O)</b> | <b>Altitud<br/>(m.a.s.n.)</b> | <b>Parámetro<br/>registrado</b>                           |
|-----------------|-----------------------------------------|-------------------------------|-----------------------------------------------------------|
| Aranjuez        | 40.07 / -3.52                           | 544                           | GHI, PAR<br>T, HR.                                        |
| Riosequillo     | 40.99 / -3.65                           | 998                           | GHI, PAR<br>T, HR.                                        |
| CEDER-CIEMAT    | 41.60 / -2.51                           | 1099                          | GHI, DNI,<br>DHI, PAR,<br>T, HR,<br>precipitación.        |
| PSA-CIEMAT      | 37.09 / -2.37                           | 496                           | GHI, DNI<br>DHI, PAR,<br>T, HR, UV, IR,<br>Precipitación. |

De las estaciones meteorológicas presentadas en la Tabla 2-1, sólo las de Aranjuez y Riosequillo cuentan con una fuente de energía autónoma mediante un sistema de panel solar con batería. Las demás están conectadas a la red eléctrica del CIEMAT dónde se encuentran ubicadas.

Todas las estaciones son automáticas y disponen de un *datalogger* como dispositivo de adquisición de datos. Este dispositivo registra los datos de los sensores, almacena/transmite y permite su posterior descarga, procesamiento y visualización. Además, cuenta con un software que gestiona la sincronización entre sensores y permite la monitorización remota. Para la puesta en marcha, los *dataloggers* de Aranjuez y Riosequillo no requirieron programación y configuración específica previa. Pero en el caso de los instalados en CEDER-CIEMAT y PSA-CIEMAT sí fue necesario especificar los sensores conectados y parámetros a medir en el código de ejecución del *datalogger* de Campbell Scientific.

Las estaciones de Aranjuez y Riosequillo transmiten los datos al ordenador central a través de una tarjeta de comunicación SIM integrada en el *datalogger*. Por otra parte, el acceso a los datos de CEDER-CIEMAT y PSA-CIEMAT se realiza vía internet, también, mediante la conexión ethernet del *datalogger*. En la Figura 2-2 se muestran imágenes de las cuatro estaciones meteorológicas que formaron parte de los dispositivos experimentales.



Figura 2-2 : Estaciones radiométricas instaladas en Aranjuez, Riosequillo, Soria (CEDER-CIEMAT) y Almería (PSA-CIEMAT).

Por cuestiones obvias, las estaciones meteorológicas y los instrumentos montados en ellas están expuestos a la intemperie. En consecuencia, debido a las condiciones meteorológicas, interacción con el entorno natural a cielo abierto (características del entorno incluyendo la presencia de fauna local) las series temporales registradas en las estaciones de medida pueden presentar interrupciones ocasionales debidas, por ejemplo, campañas de calibración, ajustes en los instrumentos o fallos en los equipos. En nuestro caso, los periodos de medida entre las estaciones no siempre coinciden.

Con el objetivo de garantizar la calidad de las medidas y la capacitación del doctorando en el mantenimiento preventivo y correctivo de las estaciones meteorológicas, se llevaron a cabo controles regulares mediante el monitoreo en tiempo real de los sensores instalados en dichas estaciones. Además, se realizaron visitas de campo en las estaciones para sustituir instrumentos, verificar y mejorar su nivelado; así como para la limpieza de polvo y otros depósitos acumulados en los sensores. Estas campañas de comprobación sobre el terreno posibilitaron garantizar una mejora en la calidad de los datos registrados para su uso en futuros estudios. Excepto las estaciones instaladas en Aranjuez y Riosequillo, operadores de mantenimiento de las instalaciones del CIEMAT, se encargan de la limpieza periódica de los sensores meteorológicos de CEDER-CIEMAT y PSA-CIEMAT, eliminando polvo, nieve u otras partículas que pueden depositarse sobre ellos.

### **2.1.2. Ensayos de crecimiento de microalgas**

En el marco de esta tesis, también se llevaron a cabo experimentos de crecimiento de microalgas a nivel laboratorio empleado agua residual como medio de cultivo. El objetivo de los experimentos es la determinación del coeficiente de extinción,  $k_a$  ( $m^2/g$ ), de la biomasa algal a partir de la ley de Lambert-Beer que relaciona la absorbancia con la transmitancia de la luz (PAR). Para ello, se colocaron dos sensores PAR dentro y fuera del medio de cultivo. Además, se midieron otros parámetros la GHI de la fuente de iluminación, la temperatura ambiental y la del medio cultivo.

Por otro lado, una parte esencial de estos ensayos corresponde al ámbito de la bioquímica, debido el carácter biológico del proceso de crecimiento de microalgas. De hecho, en colaboración con la Unidad de Biocarburantes del Departamento de Energía del CIEMAT, se realizaron los análisis de laboratorio para determinar diariamente la concentración de biomasa algal.

El dispositivo experimental estuvo compuesto por los siguientes instrumentos y sensores:

- una fuente de iluminación: una lámpara LED de crecimiento vegetal de la serie OVNIGROW-N, con una potencia nominal 250 W y ajustable entre 0 y 100%, diseñada para simular el espectro de radiación solar,
- un sistema de control desarrollado en LabView, encargado de regular la duración del fotoperiodo y la intensidad de la radiación emitida por la lámpara LED,
- un sistema de aireación: bomba de aire,
- cinco sensores de:
  - PAR del modelo SQ-110-SS de APOGEE, utilizado para medir la radiación PAR dentro y fuera del cultivo.
  - GHI de APOGEE también. El modelo correspondiente es SP-110-SS. Fue empleado para medir la irradiancia GHI emitida por la lámpara OVNIGROW-N. Este sensor fue colocado fuera del cultivo.
  - T, medida mediante un termopar tipo K, tanto en el interior como en el exterior del cultivo.
- un sistema de adquisición de datos: modelo CR1000X de Campbell Scientific, encargado de registrar y almacenar los datos obtenidos por los sensores.
- un recipiente para contener el medio de cultivo (agua residual domestico),
- inóculo, microalga del género *Chlorella sp.*
- agua residual doméstica.

La configuración del dispositivo experimental (Figura 2-3) permitió un control preciso de las condiciones de iluminación y temperatura, asegurando un entorno óptimo para el estudio del crecimiento de la microalga según la estación del año.

La especie de microalga seleccionada para investigar el crecimiento de organismos fotosintéticos y su comportamiento en una planta piloto pertenece al género *Chlorella sp.* y ha sido cultivada y preservada en los laboratorios de IMDEA Energía. Se trata de una microalga unicelular verde, de una forma esférica, con un diámetro que oscila entre 2 y 10  $\mu\text{m}$ , y que forma parte del filo *Chlorophyta*.

Además, las microalgas *Chlorella* son fáciles de cultivar y crecen con éxito en aguas residuales (Li et al. 2021). De acuerdo con (Alazaiza et al. 2023) que realizó el estudio de tratamiento de aguas residuales con microalgas *Chlorella vulgaris*, se llegó a eliminar 84% de las formas de materia orgánica (DQO) al quinto día de cultivo en agua residual, el 95% del nitrógeno amoniacal y el 97% del fósforo. Otros autores eligieron únicamente dicho género de microalga o en consorcio con otra especie de microalga o cianobacteria y obtuvieron resultados satisfactorios en estudios de tratamientos de agua residual de origen industrial (Hernández et al. 2013; Liu et al. 2017) o doméstico (Silambarasan et al. 2021).

En nuestro caso, se utilizaron muestras de aguas residuales domésticas como medio de cultivo. Las muestras de agua residual municipal (doméstica) fueron obtenidas gracias a un convenio firmado entre el CIEMAT y el Canal de Isabel II, que permitió el uso de las aguas de depuración. En concreto, las muestras se tomaron tras la eliminación de sólidos (tratamiento primario) y de la fase de tratamiento biológico (tratamiento secundario) en una de las Estaciones de Depuración de Aguas Residuales (EDAR) ubicadas en la Comunidad de Madrid.

El medio de cultivo se dispuso en un vaso con los bordes cubiertos, permitiendo la entrada de luz únicamente por la parte superior del medio de cultivo (Figura 2-3). También, los bordes del dispositivo experimental han sido tapados y el todo metido en una caseta. La intensidad de luz (PAR) incidente y el fotoperiodo son contralados mediante un dispositivo electrónico programado para una cantidad de luz y de duración de la iluminación adecuada.

En general, se realizaron cultivos por lote cerrado. En otras palabras, un cultivo comienza con una cantidad inicial de nutrientes y, con el paso del tiempo, las microalgas consumen estos recursos (nutrientes) para su crecimiento y producción; todo esto sin adicionar más nutrientes al medio de cultivo. El experimento se daba por finalizado cuando una vez constatado, por análisis de la composición química de una muestra, que la concentración de biomasa no superaba un umbral de aumento en dos días consecutivos. A continuación, en el apartado 2.2.3, se describirán los datos experimentales considerados en nuestro caso de estudio.



Figura 2-3 : Imagen del dispositivo experimental de cultivo de microalga a partir de agua residual doméstica del tratamiento secundario de una EDAR ubicada en Madrid.

## 2.2. Datos experimentales

A continuación, se describen los datos empleados para llevar a cabo, primero, los estudios de modelización de la PAR, luego, la generación de las TMS y finalmente, de simulación de la producción de biomasa algal. Por lo general, estos datos clasificaban en dos categorías: datos medidos y datos estimados. Los primeros permitieron realizar la modelización de PAR y provenían de las estaciones radiométricas de Soria (CEDER-CIEMAT) y de Almería (PSA-CIEMAT). Los últimos que eran estimaciones de satélites y de reanálisis, se usaron para completar los estudios relativos el segundo objetivo específico, la creación de las TMS.

### 2.2.1. Datos radiométricos medidos in situ

Los conjuntos de datos recolectados de las estaciones radiométricas se registraron con una resolución temporal de un minuto. En el contexto de trabajo de modelización de la PAR, se han utilizado medidas de GHI, DHI, DNI y PAR.

Estos datos minútales provienen de las estaciones radiométricas CEDER-CIEMAT, situada en Soria, meseta norte, y PSA-CIEMAT, ubicada al sureste de la Península Ibérica. Los períodos de medida abarcan desde el 30 de enero de 2018 hasta el 13 de julio de 2021 en

CEDER-CIEMAT, y desde el 24 febrero de 2016 hasta el 13 de julio de 2021 en PSA-CIEMAT. En ambas estaciones, los datos de GHI, DHI, DNI y PAR son registrados mediante los sensores descritos en la sección 2.1.1 y satisfacen los requisitos establecidos por la Organización Mundial de la Meteorología (OMM-Nº8) en materia de garantía de la calidad y gestión de los sistemas de observación (World Meteorological Organization - WMO 2023). Para garantizar la trazabilidad y la conformidad con los estándares establecido en las normas ISO 9059, ISO 9846 e ISO 9847, se llevan a cabo campañas de calibración periódicas, siguiendo los procedimientos y criterios específicos en dichas normas.

### **2.2.2. Estimaciones de satélites y de reanálisis**

Los datos estimados juegan un papel crucial en la producción agrícola y también aportan datos relevantes en países con una red de estaciones meteorológicas muy escasas. Este valor añadido es aún más beneficioso cuando se trata de un parámetro meteorológico como la PAR que no se registra habitualmente en las estaciones de medidas. Los satélites quizás no midan, la PAR directamente; pero pueden proporcionar datos regulares, especialmente en áreas sin sensores.

Debido a la escasez de estaciones radiométricas en el territorio español que incluyan la medida de PAR, fue necesario recurrir a estimaciones satelitales para alcanzar los objetivos propuestos. Estos datos fueron obtenidos a través de los portales web del Satellite Application Facility on Climate Monitoring (CMSAF), perteneciente a la Organización Europea para la Explotación de Satélites Meteorológicos - EUMESAT - (Huld et al. 2012; Ferrera-Cobos et al. 2020b). El CMSAF forma parte de las tres plataformas de aplicaciones por Satélite (SAF) encargadas de generar y proporcionar una amplia gama de datos del balance de radiación en la superficie y en la parte superior de la atmósfera relacionados con el ciclo de la energía y del agua, así como de facilitar el análisis y el seguimiento del sistema climático en Europa (Schulz et al. 2009; Müller and Pfeifroth 2022).

En el momento de la recopilación la base de datos CMSAF no proporcionaba información específica de datos de PAR; sino que facilitaba datos sobre el producto “Solar Surface Irradiance (SRI)” que ofrece la irradiancia correspondiente a cada una de las bandas de Kato. Por lo tanto, para estimar la PAR se aplicó a los datos de GHI de CMSAF el método propuesto por (Wandji Nyamsi et al. 2015), que permite estimar la PAR en el rango de 400 a 700 nm a nivel del suelo bajo condiciones de cielo despejado. Este método se basa en el

uso de doce de las bandas espectrales, las cuales dividen el espectro solar en treinta y dos intervalos de longitud de onda, según la definición propuesta por (Kato et al. 1999).

Los datos se descargaron en formato ráster, cubriendo la superficie comprendida entre 35.3°N y 44.0°N de latitud y de 9.5°W y 3.5°E de longitud. La base de datos de CMSAF tiene una resolución espacial de  $0.125^\circ \times 0.125^\circ$ , permitiendo localizar cada pixel del ráster a partir de sus coordenadas geográficas. Esta superficie cubre la región geográfica de Madrid dónde se focalizó nuestro estudio. A través CMSAF, se obtuvieron datos diarios promedio de temperatura ambiente y de GHI para el período comprendido entre 1991 to 2005, abarcando un total de 15 años.

Adicionalmente, se descargaron datos de temperatura media horaria a partir de la base de datos del European Center for Medium-Range Weather Forecasts (ECMWF). Se trata de la temperatura del aire a 2 m por encima de la superficie terrestre obtenida por reanálisis ERA5 que combinan datos de modelos con observaciones. ERA5 se enmarca dentro de la trayectoria del ECMWF, iniciada en 1979 con el proyecto FGGE (Molinari et al. 1986) y representa la quinta generación de reanálisis atmosféricos (Hersbach et al. 2020). Este parámetro se descargó en unidades de kelvin (K) y posteriormente fue convertido a grados Celsius (°C). Al igual que los datos de CMSAF, los datos del ECMWF fueron descargados en formato ráster, con una resolución horizontal de 31 km cubriendo la misma área que los datos CMSAF. La frecuencia de salida de los datos del ECMWF es horaria y cubre un periodo desde 1950 hasta hoy. El período considerado en el presente trabajo para el análisis datos ECMWF coincide con el utilizado en los datos de CMSAF. Del mismo modo que la bases de datos de CMSAF, la del ECMWF también dispone de una gran cantidad de parámetros de radiación; pero la entrada de su modelo es más apropiada para la evolución del contenido de los gases que afectan al efecto invernadero, los aerosoles y otras (Hersbach et al. 2020).

El uso de la base de datos ECMWF ha sido motivado también por el hecho de que proporcionaba series temporales de temperatura con un promedio horario para poder extraer valores estadísticos de temperatura (rango, mínimo y máximo).

### **2.2.3. Datos de los ensayos en laboratorio**

Los ensayos en laboratorio se diseñaron en función del caso de estudio que correspondía con la producción de biomasa microalgal combinada con el tratamiento de agua residual (medio de cultivo). El objetivo principal de los ensayos ha sido medir los parámetros externos del cultivo, como la temperatura y la PAR, con el fin determinar por cálculo el coeficiente de extinción de la biomasa. Una parte esencial de estos ensayos estaba vinculada al ámbito de la bioquímica debido el carácter biológico del proceso de crecimiento de microalgas y de la composición química del medio de cultivo.

Así, ante la necesidad de analizar la composición química de las muestras de aguas residuales y determinar la concentración de biomasa algal al inicio los experimentos (inóculo) y de nutrientes (nitrógeno y fósforo) diariamente durante el periodo experimental (crecimiento de microalgas), se contaba con la colaboración de la Unidad de Biocarburantes del Departamento de Energía del CIEMAT. Con esa colaboración, se obtuvieron las características iniciales de las muestras de agua residual y las concentraciones de microalgas y nutrientes presentes en el medio de cultivo (agua residual). Entre los parámetros analizados, se tomaron las concentraciones de nitrógeno total y fósforo total como características del medio de cultivo. Se determinaron la concentración diaria de otros parámetros químicos del agua residual como la demanda química de oxígeno (DQO) para constatar el nivel de depuración del agua. En cualquier caso, el modelo logístico de crecimiento de una población de microorganismos desarrollado en el marco de esta tesis sólo tiene en cuenta las variaciones de la concentración de nitrógeno total y fósforo total; suponiendo que los demás parámetros del medio de cultivo permanecían en condiciones óptimas para favorecer el crecimiento de las microalgas (Wane et al. 2024).

Debido a la variabilidad natural en la composición bacteriana del agua residual, se observaron diferencias en la concentración de nutrientes, incluso en muestras recolectadas el mismo día en la depuradora. De hecho, el primer análisis de la composición química de las muestras de agua residual ha sido considerado como valor inicial de las concentraciones de nutrientes que componían el medio de cultivo. Estos valores fueron utilizados para la inicialización del programa de simulación de crecimiento de microalgas bajo distintas condiciones estacionales. En la Tabla 2-2, se muestran los valores iniciales de microalga (inóculo), nitrógeno y fosforo presentes en el agua residual, y los coeficientes de eliminación de dichos nutrientes (Wane et al. 2024) para la simulación de la producción de biomasa algal.

Son los parámetros utilizados para la inicialización del programa de simulación del crecimiento de microalgas. El coeficiente de extinción no se incluye en la Tabla 2-2, ya que es un parámetro estimado a partir de las mediciones de concentración de biomasa y de irradiancia PAR dentro y fuera del cultivo.

Tabla 2-2: Concentración inicial de nitrógeno y fosforo del medio de cultivo (agua residual) y coeficientes de eliminación de los nutrientes considerados constantes en la simulación del crecimiento de microalgas para cada estación meteorológica.

| Parámetro                  | Nutriente           | Valor                   |
|----------------------------|---------------------|-------------------------|
| Concentración inicial      | nitrógeno total (N) | 224 mg l <sup>-1</sup>  |
|                            | fósforo total (P)   | 16.1 mg l <sup>-1</sup> |
|                            | microalgas (X)      | 100 mg l <sup>-1</sup>  |
| Coeficiente de eliminación | nitrógeno           | 0.71                    |
|                            | fósforo             | 0.035                   |

## 2.3. Enfoque metodológico

En este apartado, se presenta una descripción general de las metodologías aplicadas que dieron lugar a los resultados publicados en los tres artículos que conforman esta tesis. Con el objetivo de facilitar la lectura del documento, el pretratamiento de datos realizado para abordar los dos primeros objetivos específicos de la tesis, la modelización de la PAR y la creación de las TMS, se presentan de manera conjunta. En cambio, se detallan, por separado, los enfoques específicos a cada uno de estos dos objetivos. Por último, se describe la metodología aplicada para simular el crecimiento de microalgas. Cada una de estas secciones se acompaña de un diagrama de flujo que resume los diferentes pasos seguidos para lograr los objetivos enumerados.

El procesamiento de las series de datos y las simulaciones realizadas se llevaron a cabo utilizando Matlab R2021a, a través su plataforma de programación y paquete adicional de simulación gráfica multidominio, MATLAB<sup>®</sup> y Simulink<sup>®</sup>.

### **2.3.1. Tratamiento de los datos**

Los pasos iniciales de las dos primeras etapas de esta tesis se centraron en el análisis y el control de calidad de los datos registrados, por un lado, y de los datos procedentes de estimaciones, por otro.

Debido a las posibles interrupciones del registro en las estaciones de medida por campañas de mantenimiento, calibración y otros, es muy complicado recopilar una serie temporal extensa, continúa y sin valores erróneos (Sengupta et al. 2024). De la misma manera, los datos meteorológicos registrados in situ en las estaciones meteorológicas CEDER-CIEMAT y PSA-CIEMAT también incluyen errores, valores atípicos y omitidos. Para poder trabajar con series de datos completos fue necesario detectar y sustituir las mediciones sospechosas o erróneas en los datos obtenidos de las mencionadas fuentes.

El análisis gráfico permitió tener una visión global y una primera apreciación sobre la calidad de los datos. Esta técnica exploratoria que es una herramienta sencilla, contribuye con la caracterización de los datos. La interpretación de los resultados de análisis orientó el proceso a adoptar para conseguir la mejora de las series temporales. Los dos conjuntos de datos (CEDER-CIEMAT y PSA-CIEMAT) contenían valores erróneos y registros incompletos (huecos). En el caso de la falta de datos en algunas filas, se aplicaron algoritmos estadísticos para ir sustituyendo los mismos y así obtener conjuntos de series temporales mucho más completos. La sustitución se efectuó definiendo unos criterios para rellenar los huecos mediante interpolación, extrapolación o correspondencia con el promedio de los días de misma fecha (día-mes) de la serie temporal.

Excepto los huecos identificados, los datos de estimaciones (reanálisis y satélites) no comportaban valores extremadamente diferentes entre ellos y estuvieron bastante aceptables para las latitudes de la región de Madrid. Por lo tanto, el pretratamiento se focalizó sobre todo en la sustitución de los valores que faltaban. Además, por trabajar con datos diarios, se aplicó de forma arbitraria una interpolación cuando el número de datos que faltaban era inferior a tres. En el caso de que hubiera tres o cuatro días sin datos, se realizó una extrapolación. Más allá de estos supuestos, el hueco se sustituye por el valor promedio de todos los días de cada año de la serie temporal que corresponden con la fecha del día sin datos (hueco).

Los datos de satélite y de reanálisis eran bastante completos, con registros sin valores (Not A Number) ocasionales en intervalos muy cortos (de 2 a 4 días). Una vez corregidas, se ha contabilizado un conjunto de 5479 días (100%), de datos en promedio diario.

El mismo procedimiento de sustitución de los huecos se aplicó con los datos registrados in situ en CEDER-CIEMAT y PSA-CIEMAT. Pero, como se disponían de datos minútales, se eligió una interpolación si el número de huecos es inferior o igual a media hora de datos. Mientras que una extrapolación correspondía cuando los huecos superaron una hora de datos e inferior a tres horas. Fuera de estos intervalos, se aplicaba la misma regla de correspondencia establecida anteriormente para un día sin datos.

Para los datos de irradiancia (GHI, DHI y DNI) medidos en el terreno, se aplicaron los procedimientos de control de calidad definidos por la Baseline Surface Radiation Network - BSRN (Long and Dutton 2002; Long and Shi 2008) que se ha convertido en el estándar en materia de proceso de control de calidad de los datos radiométricos medidos (Hegnar et al. 1998). Las pruebas de control de calidad recomendadas por la red global BSRN consisten en la definición de límites (intervalos) físicamente posibles, límites extremadamente raros y efectuar comparaciones de cada parámetro en función de un valor referencial del ángulo cenital solar. A continuación, se presenta la metodología de las pruebas de calidad de la irradiancia propuesta por BSRN:

- Límites físicamente posibles:

$$-4 \text{ Wm}^{-2} \leq \text{GHI} \leq (1367 \varepsilon \cdot 1.5 \mu_0^{1.2} + 100) \text{ Wm}^{-2}$$

$$-4 \text{ Wm}^{-2} \leq \text{DHI} \leq (1367 \varepsilon \cdot 0.95 \mu_0^{1.2} + 50) \text{ Wm}^{-2}$$

$$-4 \text{ Wm}^{-2} \leq \text{DNI} \leq (1367 \varepsilon) \text{ Wm}^{-2}$$

- Límites extremadamente raros:

$$-2 \text{ Wm}^{-2} \leq \text{GHI} \leq (1367 \varepsilon \cdot 1.2 \mu_0^{1.2} + 50) \text{ Wm}^{-2}$$

$$-2 \text{ Wm}^{-2} \leq \text{DHI} \leq (1367 \varepsilon \cdot 0.75 \mu_0^{1.2} + 30) \text{ Wm}^{-2}$$

$$-2 \text{ Wm}^{-2} \leq \text{DNI} \leq (1367 \varepsilon \cdot 0.95 \mu_0^{0.2} + 10) \text{ Wm}^{-2}$$

- Comparaciones:

$$\frac{\text{GHI}}{[\text{DHI} + \text{DNI} \cdot \mu_0]} < 1.08 \quad \text{para } \text{SZA} < 75^\circ, [\text{DHI} + \text{DNI} \cdot \mu_0] > 50 \text{ Wm}^{-2}$$

$$\frac{GHI}{[DHI + DNI \cdot \mu_0]} < 1.15 \quad \text{para } 75^\circ < SZA < 93^\circ, [DHI + DNI \cdot \mu_0] > 50 \text{Wm}^{-2}$$

$$\frac{DHI}{GHI} < 1.05 \quad \text{para } SZA < 75^\circ, GHI > 50 \text{Wm}^{-2}$$

$$\frac{DHI}{GHI} < 1.10 \quad \text{para } 75^\circ < SZA < 93^\circ, GHI > 50 \text{Wm}^{-2}$$

Donde  $SZA$ ,  $\varepsilon$  y  $\mu_0$  son el ángulo cenital solar, el factor de corrección de la excentricidad de la órbita terrestre y el coseno de  $SZA$ , respectivamente.

En el caso de la PAR, no existe un procedimiento estándar para el control de calidad de datos PAR. Para filtrar los valores atípicos se establecieron límites físicamente posibles definiendo valores umbrales superior e inferior a modo de filtro pasa banda (Hu et al. 2007; Wane et al. 2022).

Este proceso fue implementado mediante un algoritmo automatizado, utilizando funciones preexistentes en las librerías de MATLAB®, lo que permitió automatizar el control de calidad y el procesamiento de estos grandes conjuntos de datos. Tras aplicar los procedimientos de filtrado, se disponían:

- para la estación CEDER-CIEMAT, de 505.267 minutos de datos de un total inicial de 1.815.841 minutos, es decir, alrededor del 27,83%.
- para PSA-CIEMAT, de 691.678 minutos de datos de un total inicial de 2.832.481 minutos, sea aproximativamente al 24.42%.

Para ambas series temporales, se descartó casi el 70% de los datos borrando una línea entera cuando el valor de un parámetro GHI, DHI, DNI o PAR no satisfacía la condición de filtrado. Este porcentaje traduce el hecho de que la mitad de la serie temporal corresponde a los datos registrados entre la puesta y la salida del sol (“datos nocturnos”). A estos se añaden las incertidumbres en las mediciones por falta de precisión de los sensores o instrumentos de adquisición de datos. Por otro lado, no se han realizado pruebas de coherencia interna o comparaciones cruzadas que confrontarían los datos utilizados aquí con los de otros sensores instalados alrededores de los incluidos en este estudio.

La Figura 2-4 muestra de manera general los pasos de los procesos de pretratamiento de los datos medidos in situ y estimados por satélites y reanálisis usados para la modelización de la PAR (objetivo específico 1) y la generación de las TMS (objetivo específico 2). Así, la base de datos constituida está compuesta de datos medidos y estimados destinados para tratar de llegar a los objetivos 1 y 2, respectivamente. Dado que las series temporales proceden de distintas fuentes, el tratamiento se ha realizado por separado en función de los objetivos y de las necesidades de los estudios:

- Por un lado, los datos medidos a nivel del suelo (GHI, DHI, DNI y PAR) procedentes del CEDER-CIEMAT ubicado en los Altos de Lubia en Soria y del PSA-CIEMAT situado el desierto de Tabernas en Almería, se destinaron para la elaboración de los modelos horarios de PAR documentado en el artículo referenciado por (Wane et al. 2022). Para el desarrollo de estos modelos, se utilizó, además de los datos medidos en el terreno (GHI, DHI, DNI y PAR), el seno del ángulo de elevación solar obtenido por cálculo en función de las latitudes de CEDER-CIEMAT Y PSA-CIEMAT.
- Por otro lado, los datos por satélite y reanálisis fueron usados para la generación de secuencias meteorológicas de crecimiento de organismos fotosintéticos (Wane et al. 2022). Por no disponer de datos medidos en el sitio de estudio, se necesitaban datos estimados para alcanzar dicho objetivo. Por lo tanto, se descargaron los datos de PAR en promedio diario expresado en  $W \cdot m^{-2}$  y la temperatura media horaria. Además de estos dos parámetros, la metodología de generación de las TMS incluye la duración del día solar obtenida por cálculo a partir de la declinación solar y de la latitud de los sitios elegidos para llevar a cabo el estudio. Para la generación de las TMS, se necesitaba datos en promedio diario. Así, se procesaron los datos de temperatura media horaria para extraer los valores medio, mínimo y máximo de la serie temporal. La temperatura media diaria ( $T_{me}$ ) fue calculada a partir de esta media horaria. Al no disponer de registros de temperaturas mínima y máxima en la base de datos, se consideraron los valores mínimo y máximo para un día como la temperatura mínima media ( $T_{min}$ ) y la temperatura máxima media ( $T_{max}$ ) diarias. Finalmente, se determinaron el rango diario de temperatura ( $T_{rgo}$ ) a partir de  $T_{min}$  y  $T_{max}$ . Este último completó el conjunto de datos destinado al estudio para las TMS.




Figura 2-4: Esquema del procedimiento de pretratamiento de los datos meteorológicos utilizados en el marco de esta tesis.

### 2.3.2. Modelización de la PAR

El desarrollo de los modelos horarios de PAR se realizó con los conjuntos de datos filtrados procedentes de CEDER-CIEMAT y de PSA-CIEMAT. Antes de abordar la modelización, se efectuaron análisis gráficos entre la PAR y cada uno de los demás parámetros radiométricos para evaluar el grado de correlación entre ambas. Por un lado, se llevó a cabo el análisis usando datos de CEDER-CIEMAT y, de forma independiente, con datos de PSA-CIEMAT.

La metodología empleada se basó principalmente en el análisis de regresión multivariante utilizando variables radiométricas medidas in situ. La PAR ha sido definida como la variable dependiente y los índices que se determinaron previamente a partir de GHI, DHI y DNI, y junto con el seno del ángulo de elevación solar ( $\alpha$ ) obtenido por cálculo, representaron las variables independientes del modelo de regresión multivariante. Estos índices son: el índice de transparencia atmosférica ( $k_t$ ), la fracción difusa horizontal ( $k_d$ ) y la fracción directa normal ( $k_b$ ). Las expresiones algebraicas para calcular estos índices y el seno del ángulo de elevación solar son:

$$\sin(\alpha) = \sin(\phi) \cdot \sin(\delta) + \cos(\phi) \cdot \cos(\delta) \cdot \cos(\omega) \quad (1)$$

$$k_t = \frac{\text{GHI}}{I_{sc} \cdot \varepsilon \cdot \sin(\alpha)} \quad (2)$$

$$k_d = \frac{\text{DHI}}{\text{GHI}} \quad (3)$$

$$k_b = \frac{\text{DNI}}{I_{sc} \cdot \varepsilon} \quad (4)$$

También, los datos PAR han sido normalizados con la irradiancia extraterrestre  $I_0$  para tener todos los atributos a una escala de 0 a 1 y que los modelos (ecuaciones) tengan sentido físico (homogeneidad adimensional). En total, se generaron quince combinaciones lineales posibles a partir de las cuatro variables independientes que son  $\alpha$ ,  $k_t$ ,  $k_d$  y  $k_b$ . Como se puede ver en la siguiente Tabla 2-3 donde a, b, c, d y e son los coeficientes de ajuste. La determinación de estos coeficientes se hizo con el entrenamiento de los modelos de regresión.

Tabla 2-3 : Modelos de PAR entrenados en el marco de esta tesis.

| Combinación de los atributos radiométricos | Modelo                                                                                 | Indeficador del modelo |
|--------------------------------------------|----------------------------------------------------------------------------------------|------------------------|
| Mono-atributo                              | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha)$                                           | M01                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_t$                                                    | M02                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_d$                                                    | M03                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_b$                                                    | M04                    |
| Bi-atributo                                | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t$                             | M05                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_d$                             | M06                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_b$                             | M07                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_t + c \cdot k_d$                                      | M08                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_t + c \cdot k_b$                                      | M09                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_d + c \cdot k_b$                                      | M10                    |
| Tri-atributo                               | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_d$               | M11                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_b$               | M12                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_d + d \cdot k_b$               | M13                    |
|                                            | $\frac{PAR}{I_0} = a + b \cdot k_t + c \cdot k_d + d \cdot k_b$                        | M14                    |
| Tetra-atributo                             | $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_d + e \cdot k_b$ | M15                    |

Los modelos han sido entrenados utilizando la concatenación del 80% de los datos filtrados provenientes de las estaciones de CEDER-CIEMAT y de PSA-CIEMAT, constituyendo así el conjunto de datos de entrenamiento. El proceso de entrenamiento de los quince modelos desarrollos (Tabla 2-3) siguió dos enfoques diferenciados en función del uso de dichos datos.

En primer lugar, se utilizó la totalidad del conjunto de datos de entrenamiento para desarrollar los quince modelos que a continuación se denominaron como “modelos completos”. En segundo lugar, el conjunto de datos de entrenamiento fue separado en función de los intervalos del índice  $k_t$ , lo que permitió la generación de los denominados “modelos por intervalo”. Para esta separación, se definieron arbitrariamente tres categorías de cielo, siguiendo la metodología descrita por (Wane et al. 2022), correspondientes con los siguientes intervalos:

- Cielos nublados:  $0 \leq k_t \leq 0.3$ ; la condición del cielo se define como totalmente cubierto de nubes. Se supone que la DNI es prácticamente igual a 0 en la superficie terrestre.
- Cielos parcialmente nublados:  $0.3 < k_t \leq 0.7$ ; En este intervalo, el fracción difusa horizontal es mayor que la fracción directa normal o que ocurre el caso contrario. No se definió un límite entre estas dos situaciones.
- Cielos despejados:  $0.7 < k_t \leq 1$ ; Es decir que la componente difusa de la radiación solar (DHI) es muy pequeña con respecto a la directa (DNI).

Los modelos han sido validados en cada una de las localizaciones con el 20% de los datos restantes. Con respecto a los modelos por intervalos, los datos de validación se agruparon de la misma forma descrita anteriormente. Finalmente, los resultados obtenidos se han publicado con el título: “Comparative Analysis of Photosynthetically Active Radiation Models Based on Radiometric Attributes in Mainland Spain” (Wane et al. 2022).

Para determinar de la bondad de ajuste de los datos a los modelos de PAR, se obtuvieron los parámetros estadísticos como el coeficiente de determinación ( $R^2$ ), el error medio de sesgo (Mean Bias Error, MBE), el error absoluto medio (Mean Absolute Error, MAE), el error cuadrático medio (RMSE), el error porcentual medio (Mean Percentage Error, MPE) y el error absoluto. Además, en función de los resultados obtenidos y para facilitar su interpretación, los modelos fueron agrupados en dos grupos. Uno de ellos es el grupo que incluye al mismo tiempo el índice  $k_t$  y el seno del ángulo de elevación. A continuación, se muestra en la Figura 2-5 el diagrama de flujo del procedimiento adoptado para llevar a cabo el desarrollo de la modelización de la PAR.




Figura 2-5: Diagrama de la cadena de modelización y validación de la radiación fotosintéticamente activa (PAR).

### 2.3.3. Generación de las secuencias de crecimiento

La segunda etapa se enfocó en el desarrollo de un método de generación de secuencias meteorológicas para el crecimiento de plantas, protistas o bacterias. Conforme al caso de estudio propuesto aquí, cada secuencia representa una estación del año. Los estudios culminaron con la publicación del artículo con el título “Generation of Typical Meteorological Sequences to Simulate Growth and Production of Biological Systems” (Wane et al. 2023).

El planteamiento inicial en esta fase de la tesis era obtener datos radiométricos medidos in situ o en las proximidades de los emplazamientos de las dieciocho EDAR, situadas en la

Comunidad de Madrid, seleccionadas en marco de esta tesis por sus ubicaciones en entornos rurales donde hay aproximadamente 1500 habitantes. Además, se requerían datos medidos simultáneamente de temperatura para las mismas ubicaciones. Pero, por escasez de datos radiométricos medidos y sobre todo a largo plazo, se rechazó la hipótesis de partida que correspondía en usar los modelos PAR desarrollados en la primera fase del proceso de investigación. Así, al no disponer de datos de PAR ni de GHI, DHI y DNI medidos in situ y poder obtener la PAR a través de uno de los modelos generados durante la primera etapa de esta tesis, se emplearon quince años (1991-2005) de datos estimados de PAR y temperatura en formato ráster que cubría la superficie de la Comunidad de Madrid. Cada píxel del grid es localizable por sus coordenadas geográficas. Así, la latitud y la longitud permitieron extraer los datos específicos a cada una de las dieciocho localizaciones estudiados.

Tras someter los datos al pretratamiento explicado en el apartado 2.3.1 e ilustrado en la Figura 2-4, fueron agrupados por estaciones meteorológicas. Así se obtuvieron cuatro bloques o subconjuntos de datos correspondientes a las estaciones meteorológicas de: primavera, verano, otoño e invierno. Un bloque reúne, en un orden ascendente, todos los meses de la serie temporal que están relacionado con la estación meteorológica representada. A su vez, cada bloque se dividió en sub-bloques, que más tarde denominamos secuencias meteorológicas. Entre dos secuencias consecutivas hay una diferencia de solo un día. Este remuestreo de la serie temporal ha se hizo para cada bloque, permitiendo aumentar considerablemente el número de secuencias meteorológicas y agrupar los datos en intervalos de tiempo de acuerdo con el objetivo de nuestro caso de estudio (Figura 2-6)




Figura 2-6 : Reorganización de los datos por estaciones meteorológicas (bloques) y el remuestreo para aumentar el número de secuencia de un bloque.

Para el objetivo de la etapa final de esta tesis (Figura 2-7), las secuencias meteorológicas se adaptaron para un sistema de cultivo de microalgas por lotes y por estación del año. Las

microalgas tienen un periodo de crecimiento y desarrollo muy corto, comparándolas con las plantas. Además, las microalgas son organismos fundamentales en la gestión de nutrientes como el fósforo (P) y el nitrógeno (N) presentes en el medio de cultivo, gracias a su capacidad para absorber y metabolizar estos elementos de manera eficiente. Por eso, si se encuentran cultivadas por lote en aguas residuales, la producción de biomasa algal va emparejado con la depuración de las aguas residuales. En el caso de usar este tipo de medio de cultivo, el periodo de crecimiento y desarrollo se corresponde con el tiempo de retención del agua residual para su reciclaje. Este periodo de crecimiento oscila entre 3 y 10 días según (García-Malea et al. 2006; Choi and Lee 2013), entre 3 y 7 días (Acién et al. 2016) o entre 12 y 14 días de acuerdo con (Alazaiza et al. 2023). En general, el intervalo de cultivo depende de las condiciones ambientales del entorno, del género de la microalga y de la composición biológica y química del medio de cultivo.

Asimismo, en nuestro caso de estudio, una secuencia meteorológica se definió como una serie temporal de siete días consecutivos correspondiendo al tiempo de retención del agua residual considerado como medio de cultivo. Sin embargo, este número de días que constituye una secuencia meteorológica puede adaptarse en función de las necesidades del cultivo estudiado.

Por último, se aplicaron métodos de alineación estadística y la similitud de las funciones de distribución acumulativa (CDF), mediante el uso del estadístico de Finkelstein-Schafer y criterios de selección establecidos, con el objetivo de determinar la secuencia más representativa de cada estación meteorológica del año de referencia. La secuencia seleccionada se denominó TMS correspondiente a estación del año a la que corresponde. De este modo, se generaron las TMS asociadas a cada estación meteorológica a lo largo del año.

El resultado de esta etapa ha sido la obtención de una base de datos compuesta de cuatro TMS que serían los datos de irradiancia PAR y de temperatura en promedio diario para la simulación del crecimiento de organismos fotosintéticos.




Figura 2-7: Diagrama de flujo relativo a la metodología de generación de las secuencias tipo.

### 2.3.4. Simulación del crecimiento de organismo fotosintético

La aplicación de las TMS para simular el crecimiento de organismos fotosintéticos posibilitó abordar el tercer objetivo específico planteado en esta tesis que constituyó la fase final de estudio de este proceso de investigación. Además del uso de los datos TMS, esta etapa involucró el desarrollo de un modelo cinético para el crecimiento poblacional, así como la realización previa de experimentos de cultivo microalgas en laboratorio.

Nuestro caso de estudio corresponde al cultivo de la *Chlorella sp* que es un microorganismo con elevada eficiencia fotosintética gracias a su estructura celulares simple y rápida división. Como ya se ha indicado, se adoptó un tipo de cultivo de crecimiento por lote con el objetivo de obtener experimentalmente la absorbancia de la luz por parte de la *Chlorella sp*. A partir de ella y de la concentración de biomasa algal, se determinó el coeficiente de extinción del cultivo.

Los experimentos se iniciaron con los datos mostrados en la Tabla 2-2 y se llevaron a cabo como se indicó anteriormente en el apartado 2.1.2. Los sensores de PAR instalados dentro y fuera del medio de cultivo permitieron registrar por minutos dicho parámetro para la determinación de la absorbancia de la luz por parte de la *Chlorella sp*. Además, se determinaba la concentración diaria de biomasa por análisis en laboratorio. Con los valores diarios de estos parámetros, se calcularon los valores promedios de los coeficientes de extinción en los cultivos utilizando la ley de Beer-Lambert.

Por otro lado, se desarrolló un modelo de crecimiento no segregado, no estructurado, determinista y empírico (Alcón-Martín 1999); ampliamente utilizado en la modelización del crecimiento de una población que puede estar formada por animales, bacterias u otros microorganismos tales como las algas verdes unicelulares (*Chlorella sp*). Se supone que todas las células de *Chlorella sp* tienen la misma masa y que la reproducción es común a todos los miembros sin ninguna distinción. Así, la biomasa algal se considera como un único componente y el modelo se describe mediante una ecuación diferencial de primer orden con la concentración de biomasa algal como variable dependiente y el tiempo como variable independiente. Por lo tanto, según la cinética de crecimiento de las microalgas, la variación de la concentración de biomasa en nuestro caso, es proporcional a la tasa de crecimiento específica (Beltrami 1987; Schirmer and Posten 2016; Eze et al. 2018; Shoener et al. 2019). Esta tasa específica puede ser positiva (crecimiento) o negativa (mortalidad) y depende exclusivamente de la concentración de sustrato disponible en el medio de cultivo. Este es

el modelo propuesto por Monod (Monod 1949; Darvehei et al. 2018; Shoener et al. 2019). Las ecuaciones matemáticas que rigen el modelo propuesto se describen detalladamente en (Wane et al. 2024)

El modelo se implementó a través del entorno de programación basado en diagramas de bloques de MATLAB® y Simulink®. Las simulaciones estacionales del crecimiento de organismos fotosintéticos, en nuestro caso de microalgas de la especie *Chlorella vulgaris*, se realizaron utilizando las TMS (PAR y temperatura) correspondientes a las estaciones del año en una localización situada en la parte norte de la Comunidad de Madrid (Riosequillo), generadas previamente en la segunda etapa de este proceso de investigación (Wane et al. 2023). En este estudio, una TMS corresponde a una serie temporal de siete días consecutivos de datos PAR y Temperatura en promedio diario. Las condiciones meteorológicas (PAR y temperatura) del entorno de cultivo para cada estación del año está representada por una TMS utilizada como parámetro de entrada al modelo de simulación. Además, se emplearon los coeficientes de extinción de la biomasa algal determinados experimentalmente para la parametrización del modelo. Para hallar el valor de este coeficiente de extinción por estación, los experimentos cultivos se llevaron en laboratorio en las condiciones descritas en el apartado 2.1.2 con el dispositivo de control de la intensidad de la lámpara OVNIGROW-N programado para que el perfil de iluminación durante el periodo de cultivo sea igual el de la PAR de la TMS considerados.

También, se ejecutó para cada estación del año, la misma simulación numérica con todas las secuencias meteorológicas candidatas a la TMS. Para cada estación, se efectuó un análisis comparativo de la producción de biomasa algal obtenida a partir de la TMS y las que se determinaron en función a las demás secuencias meteorológicas candidatas. Las concentraciones diarias de biomasa algal obtenidas a partir de todas las secuencias meteorológicas, incluida la TMS, han sido agrupadas por día. Es decir que se juntaron todas las concentraciones del día 2 entre ellas, lo mismo para las del día 3, día 4 hasta el día 7. El día 1 no se consideró ya que corresponde a la concentración inicial de biomasa algal. Con estos seis conjuntos, se calculó la función de distribución de probabilidad (PDF) de las concentraciones de biomasa por día. La finalidad era comparar si las estimaciones de concentración de biomasa por TMS coincidan con los valores PDF más probables obtenidos con el método propuesto.

Resumiendo, el enfoque metodológico consistió en la determinación de la concentración de masa celular de las microalgas en un medio de cultivo por lote sometido a las condiciones de iluminación y de temperatura ambiental definida en las secuencias meteorológicas. Además, de estos dos parámetros externos (PAR y T), la simulación tuvo en cuenta la variación de la productividad de biomasa algal en función de las concentraciones de nitrógeno y fosforo del medio de cultivo (Figura 2-8).




Figura 2-8: Diagrama de flujo relativo a la simulación del crecimiento de microalgas.

### 3. Análisis comparativo de modelos de Radiación Fotosintéticamente Activos basados en atributos radiométricos en la España península

Ousmane Wane<sup>1,2,3\*</sup>, Julián A. Ramírez-Ceballos<sup>1\*</sup>, Francisco Ferrera-Cobos<sup>1</sup>, Ana A. Navarro<sup>1</sup>, Rita X. Valenzuela<sup>1</sup> y Luis F. Zarzalejo<sup>1</sup>

<sup>1</sup> CIEMAT Energy Department, Renewable Energy Division, Avda. Complutense 40, 28040 Madrid, Spain

<sup>2</sup> E.T.S.I. Agronómica, Alimentaria y de Biosistemas, Universidad Politécnica de Madrid, Avda. Puerta de Hierro 2-4, 28040 Madrid, Spain

<sup>3</sup> Microbial and Plant Biotechnology Department, Centro de Investigaciones Biológicas Margarita Salas-CSIC, Ramiro de Maeztu 9, 28040 Madrid, Spain

\* Correspondencia: [jaramirezce@gmail.com](mailto:jaramirezce@gmail.com); Tel.: +34-91-346-6668

Land 2022, 11, (10), 1868; <https://doi.org/10.3390/land11101868>

#### Resumen

El objetivo de este estudio es analizar la calidad de los datos de radiación solar y desarrollar varios modelos horarios de radiación fotosintéticamente activa (PAR) utilizando combinaciones de variables radiométricas, como la irradiancia global horizontal (GHI), la irradiancia difusa horizontal (DHI) y la irradiancia normal directa (DNI), a partir de sus índices adimensionales: el índice de transparencia atmosférica ( $k_t$ ), la fracción difusa horizontal ( $k_d$ ) y la fracción directa normal ( $k_b$ ), junto con el ángulo de elevación solar ( $\alpha$ ).

Los datos de GHI, DHI y DNI con una frecuencia minatural, recopilados entre 2016 y 2021 en CEDER-CIEMAT (en la meseta norte) y PSA-CIEMAT (en el sureste de la Península Ibérica), se utilizaron para comparar dos ubicaciones con climas muy diferentes según la clasificación de Köppen-Geiger. Se ajustaron y validaron un total de 15 modelos multivariantes (con datos de entrenamiento y validación independientes), primero usando el conjunto de datos completo y luego por intervalos de  $k_t$ . En la mayoría de los casos, los modelos que incluían el índice  $k_t$  mostraron mejor rendimiento, y entre ellos, aquellos que también incorporaban el ángulo  $\alpha$  obtuvieron resultados destacables. Además, de acuerdo con la validación estadística, estos modelos presentaron buenos resultados en comparación con otros modelos de la bibliografía. Finalmente, las estadísticas de validación indican un mejor desempeño de los modelos por intervalos en comparación con los modelos completos.

### 3.1. Introducción

Las plantas y otros organismos, como las algas, realizan la fotosíntesis para convertir la energía solar en energía química, que utilizan en sus procesos metabólicos. La porción del espectro solar utilizada en la fotosíntesis se denomina radiación PAR que se encuentra entre 400 y 700 nm de longitud de onda.

La PAR es un parámetro agro-meteorológico con múltiples aplicaciones en diversos campos, como la industria agroalimentaria y los cultivos. Estas medidas del espectro visible constituyen un factor fundamental en el metabolismo, crecimiento y producción de biomasa de plantas y cultivos (Raymond Hunt 1994; Kim et al. 2013; Hindersin et al. 2014; Vadiveloo et al. 2015; Schmidt et al. 2016; Ramírez-Pérez et al. 2017; Trofimchuk et al. 2019), así como en la evaluación de la captura de CO<sub>2</sub> por microalgas (Farrelly et al. 2013; Ali and Park 2017; Prasad et al. 2021). También es un componente clave en cálculos de producción primaria neta y bruta (Wu et al. 2009; Pinker et al. 2010), eficiencia de conversión de energía absorbida en biomasa (Leblon et al. 1991) o el intercambio de carbono entre los ecosistemas y la atmósfera (Roderick et al. 2001; Gu et al. 2002). Por ejemplo, las propiedades ópticas que abarcan entre 400 y 700 nm del invernadero deben tenerse en cuenta en su diseño (Cemek et al. 2006; Lee et al. 2019), así como la disponibilidad de PAR dentro del invernadero, la cual parece estar altamente afectada en el plano vertical por su orientación (Wang et al. 2021).

Debido a la complejidad de las interacciones con la atmósfera terrestre, la variabilidad espacial y estacional de la irradiancia solar en el espectro PAR ha sido abordada en estudios previos (Wang et al. 2014a; Wang et al. 2014b; Ferrera-Cobos et al. 2020a). Además, la relación entre la PAR y la irradiancia global muestra cambios estacionales y variabilidad espacial en todo el mundo (Akitsu et al. 2022). La cantidad de irradiancia solar que llega a la superficie terrestre está influenciada por la nubosidad y los aerosoles presentes en la atmósfera (Xia et al. 2007). La extinción de la irradiancia causada por los aerosoles es mayor en longitudes de onda más cortas; en consecuencia, la presencia de aerosoles afecta más intensamente a las bandas ultravioleta o visible que a las bandas infrarrojas (Kidder and Vonder Haar 1995). Por otro lado, las nubes afectan a la irradiancia solar tanto por absorción como por dispersión, mientras que la absorción del vapor de agua es mayor en longitudes de onda más largas y la dispersión es no selectiva. Por lo tanto, la PAR, que se encuentra en el rango visible, depende en gran medida de las condiciones climáticas y atmosféricas de cada

ubicación (Vindel et al. 2018; Ferrera-Cobos et al. 2020a) y es fuertemente afectada por la presencia de nubes, registrándose valores más altos en condiciones de cielo despejado (Lozano et al. 2022).

Las estaciones radiométricas o meteorológicas que incluyen sensores de PAR son escasas, sin embargo, se miden con mayor frecuencia GHI, DHI y DNI. Dado que los datos de PAR no siempre están disponibles para una ubicación o período específico, es necesario recurrir a datos de teledetección (sensores satelitales) o modelos de estimación de PAR.

En este contexto, se han desarrollado numerosos modelos para estimar la PAR en distintas ubicaciones. Muchos de estos modelos se basan en correlaciones empíricas entre parámetros radiométricos y meteorológicos. Algunos estudios previos incluyen:

- Escobedo et al. (2009), desarrollaron varios modelos que correlacionan la GHI y la PAR, considerando cuatro condiciones de cielo en función de los valores diarios del índice  $k_t$  (Escobedo et al. 2009).
- Alados et al. (1996), describieron la variación de la relación entre la PAR y la radiación solar de banda ancha a partir de modelos multivariantes con otros parámetros como el índice  $k_t$ , el ángulo  $\alpha$  y la temperatura de punto de rocío (Alados et al. 1996).
- Mizoguchi et al. (2014), propusieron un modelo de regresión lineal múltiple con variables independientes como el índice  $k_t$ , la masa óptica del aire y la presión de vapor de agua (Mizoguchi et al. 2014).
- Yu et al. (2015), predijeron la PAR diaria a partir de relaciones empíricas con GHI, los índices  $k_t$  y  $k_d$  junto con la brillancia del cielo, la temperatura del punto de rocío y el coseno del ángulo cenital (Yu et al. 2015).
- Pashiardis et al. (2017) investigaron las características estacionales de la PAR y la fracción de PAR en función de la GHI, el índice  $k_t$ , la masa óptica del aire, el ángulo cenital, la presión de saturación del vapor de agua y la presión de vapor de agua (Pashiardis et al. 2017).
- Vindel et al. (2018) y Ferrera-Cobos et al. (2020b) utilizaron la GHI para modelar la radiación PAR (Vindel et al. 2018; Ferrera-Cobos et al. 2020b). Ferrera-Cobos et al. (2021) modelaron regiones climáticas empleando variables como GHI, índice  $k_t$ , la temperatura, la humedad relativa y el coseno del ángulo cenital (Ferrera-Cobos et al. 2021).

- García-Rodríguez et al. (2021) usaron diez parámetros meteorológicos, incluyendo los índices  $k_t$  y  $k_d$ , la fracción directa horizontal, GHI, seno de  $\alpha$ , la temperatura ambiente, la presión atmosférica y otros parámetros (García-Rodríguez et al. 2021).

Estos modelos de PAR generalmente utilizan los índices  $k_t$  y  $k_d$ , la fracción directa horizontal y/u otros parámetros meteorológicos, pero no incluyen el índice  $k_b$

(National Renewable Energy Laboratory 1993; Sengupta et al. 2015) como variable de entrada en los modelos. Liu y Jordan (1960) definieron este índice y establecieron una relación empírica entre las intensidades de radiación directa y difusa en días despejados (Liu and Jordan 1960).

En este trabajo, se desarrollaron varios modelos de PAR utilizando combinaciones de GHI, DHI y DNI con sus índices adimensionales  $k_t$ ,  $k_d$  y  $k_b$  y el ángulo  $\alpha$ . Los modelos se validaron en dos estaciones situadas en el interior de la meseta norte, en el Centro de Desarrollo de Energías Renovables (CEDER-CIEMAT) y en el sureste de la Península Ibérica, en la Plataforma Solar de Almería (PSA-CIEMAT). Finalmente, los modelos más destacados se compararon con modelos previos de la bibliografía.

### 3.2. Materiales y métodos

Se utilizaron datos de dos estaciones radiométricas ubicadas en España:

- CEDER-CIEMAT (41.60°N, 2.51°W, 1099 m s.n.m.), con un clima mediterráneo continental según la clasificación de Köppen-Geiger (Köppen and Geiger 1936; Agencia Estatal de Meteorología (AEMET) and Instituto de Meteorologia de Portugal (IM) 2011).
- PSA-CIEMAT (37.09°N, 2.37°W, 496 m s.n.m.), con un clima árido según la clasificación de Köppen-Geiger (Köppen and Geiger 1936; Agencia Estatal de Meteorología (AEMET) and Instituto de Meteorologia de Portugal (IM) 2011).

Los datos de GHI, DHI y DNI se recopilaron con una frecuencia minutal desde el 30 de enero de 2018 hasta el 13 de julio de 2021 en CEDER-CIEMAT y desde el 24 de febrero de 2016 hasta el 13 de julio de 2021 en PSA-CIEMAT.




Figura 3-1 : Localización de las estaciones de CEDER-CIEMAT and PSA-CIEMAT.

Para la medida de datos experimentales, se utilizaron piranómetros, estándar secundario, Kipp & Zonen CM-11 o CM-21 para medir la GHI y la DHI, mientras que, para medir la DNI, se empleó un pirheliómetro CH1 de primera clase. En todos los casos, estos instrumentos cumplen con los requisitos establecidos por la Organización Meteorológica Mundial (OMM, 2008) para sensores de alta calidad. Los sensores se acoplaron a un seguidor solar de dos ejes Kipp & Zonen 2AP, que tiene una precisión superior a  $0.1^\circ$  y sigue la trayectoria del Sol. Además, los instrumentos se calibran periódicamente según las normas ISO 9059, ISO 9846 e ISO 9847 en las instalaciones de la PSA. Estos instrumentos tienen una precisión inferior al 2%.

Finalmente, los datos de PAR se registraron utilizando un sensor ML-020P (EKO Instruments). No existe un método estándar específico para realizar la calibración; generalmente se realiza utilizando fuentes de luz estándar trazables al NIST, por lo que la calibración se realiza con el fabricante cada dos años. La precisión es de  $\pm 5\%$ .

Para garantizar la calidad de los datos, se aplicó el método de control de calidad de la Red de Superficie de Radiación de Base – BSRN – (Zo et al. 2017). Hasta la fecha, no se ha definido un modelo estándar de control de calidad para la PAR. Esto ha llevado al desarrollo de varios enfoques para la validación de los datos de PAR. Sin embargo, en este trabajo, los datos de PAR se han validado utilizando los siguientes criterios (Hu et al. 2007; Pashiardis et al. 2017): los valores medidos de PAR deben ser inferiores al PAR extraterrestre, y la relación diaria PAR/GHI debe estar en el rango de 1.6 a 2.5  $\mu\text{mol}/\text{Ws}$ . El segundo criterio es arbitrario y se basa en un número mínimo de posibles valores atípicos. En otras palabras, al limitar la relación PAR/GHI entre 1.6 y 2.5, el número de valores atípicos eliminados por el último filtro es menor que en otros intervalos. Se eliminaron también los datos nocturnos.

Antes de generar el conjunto de datos de entrenamiento, se eliminaron también los datos con un ángulo de elevación solar inferior a  $7^\circ$  para minimizar los errores de medida debido a la gran masa de aire que atraviesa la radiación cuando el Sol está cerca del horizonte (geometría solar). Además, se eliminaron los posibles valores atípicos presentes en cada uno de los subconjuntos para descartar datos no representativos (Polo et al. 2006).

Después del filtrado, se utilizó el 80% de los datos seleccionados aleatoriamente de cada base de datos para el ajuste del modelo, y el 20% restante se usó para validarlo por separado en cada ubicación. Para evitar un sesgo de ponderación en el ajuste, se seleccionó el mismo número de observaciones en ambas bases de datos para llevar a cabo el entrenamiento de los modelos. Dado que el conjunto de datos de PSA-CIEMAT es mayor que el de CEDER-CIEMAT, los datos de validación para PSA-CIEMAT se componen del 20% inicial del período total de medición, más los datos pertenecientes al 80% inicial que no se utilizaron para el ajuste del modelo. Por lo tanto, los datos de entrenamiento de los modelos son la unión de los obtenidos de CEDER-CIEMAT y PSA-CIEMAT.

Las variables explicativas del modelo se calcularon utilizando las expresiones (1) a (4) (Iqbal 1983; Sengupta et al. 2021), donde  $I_{sc}$  es la constante solar, igual a  $1367 \text{ Wm}^{-2}$ . Las variables  $\delta$ ,  $\phi$ ,  $\omega$  y  $\varepsilon$  representan, respectivamente, la declinación, la latitud geográfica de la estación, el ángulo horario solar y el factor de corrección por la excentricidad de la órbita terrestre (Iqbal 1983; National Renewable Energy Laboratory 1993; Sengupta et al. 2015).

$$\sin(\alpha) = \sin(\phi) \cdot \sin(\delta) + \cos(\phi) \cdot \cos(\delta) \cdot \cos(\omega) \quad (1)$$

$$k_t = \frac{GHI}{I_{sc} \cdot \varepsilon \cdot \sin(\alpha)} \quad (2)$$

$$k_d = \frac{DHI}{GHI} \quad (3)$$

$$k_b = \frac{DNI}{I_{sc} \cdot \varepsilon} \quad (4)$$

Los modelos fueron desarrollados mediante regresiones multivariantes utilizando diferentes combinaciones de las variables  $k_t$ ,  $k_d$ ,  $k_b$ , y  $\alpha$ . El número de combinaciones posibles fue de 15, es decir,  $2^n - 1$  modelos, donde “n” es el número de variables independientes mencionadas anteriormente. Estas variables independientes de los modelos son todas adimensionales. Teniendo en cuenta que el rango de magnitud de las variables independientes y la PAR es muy diferente, se eligió la relación  $PAR/I_0$  como la variable de salida para los modelos evaluados, donde  $I_0$  es la irradiancia extraterrestre para 1 hora centrada en la mitad de cada ángulo horario  $\omega$  (Iqbal 1983):

$$I_0 = I_{sc} \cdot \varepsilon \cdot \sin(\alpha) \quad (5)$$

Los modelos completos fueron entrenados con todo el conjunto de datos, mientras que los modelos por intervalos fueron ajustados a partir de los datos de entrenamiento separados por los correspondientes intervalos. Los datos de entrenamiento y validación utilizados para el modelo completo son los mismos que los empleados para el modelo de intervalo correspondiente. En este último caso, los datos de entrenamiento y validación se dividieron en tres intervalos para representar diferentes condiciones del cielo: el primer intervalo ( $0 \leq k_t \leq 0.3$ ) corresponde a cielos cubiertos, el segundo ( $0.3 < k_t \leq 0.7$ ) a cielos parcialmente nublados, mientras que el tercero ( $0.7 < k_t \leq 1$ ) se refiere a condiciones de cielo despejado (Salazar and Raichijk 2014; Yu et al. 2015). Para evaluar la calidad de los modelos, la PAR estimada a partir de los tres intervalos se unificó antes de la validación. Los modelos fueron validados comparando las estimaciones de PAR con el 20% de los datos medidos (datos de

validación). Lo mismo se realizó para los modelos completos. Se utilizaron estadísticos como el coeficiente de determinación ( $R^2$ ), el error medio de sesgo (MBE), el error absoluto medio (MAE), el error cuadrático medio (RMSE), el error porcentual medio (MPE) y el error absoluto para evaluar la calidad de todos los modelos.

$$MBE = \frac{1}{n} \sum_{i=1}^n (PAR_{Modeled} - PAR_{Measured}) \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |PAR_{Modeled} - PAR_{Measured}| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (PAR_{Modeled} - PAR_{Measured})^2} \quad (8)$$

$$MPE = \frac{100\%}{n} \sum_{i=1}^n \frac{PAR_{Measured} - PAR_{Modeled}}{PAR_{Measured}} \quad (9)$$

$$R^2 = \frac{\sigma_{PARmodeled PARmeasured}^2}{\sigma_{PARmodeled}^2 \sigma_{PARmeasured}^2} \quad (10)$$

$$Absolute\_error = measured\_value - estimated\_value \quad (11)$$

### 3.3. Resultados y Discusión

#### 3.3.1. Análisis gráfico de la PAR y de otras variables radiométricas

Desde la Figura 3-2 hasta la Figura 3-7 se muestra el comportamiento de la PAR con respecto a las demás variables radiométricas utilizando los datos previamente filtrados proporcionados por ambas estaciones.




Figura 3-2 : Diagrama de dispersión entre la PAR y el ángulo de elevación solar. La barra de color representa el  $k_t$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT.




Figura 3-3 : Diagrama de dispersión entre la PAR y la GHI. La barra de color representa el índice  $k_t$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT.




Figura 3-4 : Diagrama de dispersión entre la PAR y la DHI. La barra de color representa el índice  $k_d$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT.




Figura 3-5 : Diagrama de dispersión entre la PAR y la DNI. La barra de color representa el índice  $k_b$ . (a) Estación CEDER-CIEMAT; (b) Estación PSA-CIEMAT.




Figura 3-6 : Diagrama de dispersión entre la PAR, el ángulo de elevación solar, y el ángulo acimutal para la estación CEDER-CIEMAT (donde valores positivos del ángulo acimutal indican las horas de la mañana). La barra de color representa el  $k_t$ .




Figura 3-7 : Diagrama de dispersión entre la PAR, el ángulo de elevación solar, y el ángulo acimutal para la estación PSA-CIEMAT (donde valores positivos del ángulo acimutal indican las horas de la mañana). La barra de color representa el índice  $k_t$ .

La Figura 3-2, muestra el diagrama de dispersión entre la PAR y  $\alpha$ . Como era de esperarse, se alcanzaron valores más altos de PAR para ángulos  $\alpha$  mayores y con altos índices  $k_t$ . De hecho, la diferencia entre los días despejados ( $k_t$  superior a 0.7) y los días cubiertos ( $k_t$  inferior a 0.3) es muy evidente en ambas estaciones. Sin embargo, existen particularidades para cada estación. Por ejemplo, dado que PSA-CIEMAT se encuentra en una ubicación más meridional, se registraron valores de  $\alpha$  más elevados que en CEDER-CIEMAT. Por otro lado, en CEDER-CIEMAT se observaron valores del índice  $k_t$  menores para ángulos  $\alpha$  inferiores a  $30^\circ$ ; este comportamiento, que también se puede apreciar en la Figura 6, se comentará más adelante.

En la Figura 3-3, se observa un número considerable de valores elevados de  $k_t$  en un amplio rango de GHI en la estación PSA-CIEMAT en comparación con la estación CEDER-CIEMAT (Figura 3a, b). Esto puede explicarse por el clima árido presente en esta zona del sur de España, que generalmente implica condiciones de cielo despejado y precipitaciones escasas. Además, la Figura 3-3 muestra que hay una pequeña dispersión entre la GHI y la PAR, lo que permite apreciar la dependencia lineal entre estas dos variables. No obstante, los gráficos de ambas estaciones presentan cierta dispersión que puede estar relacionada con las diferentes sensibilidades y el envejecimiento de los sensores.

En la Figura 3-4, el diagrama de dispersión entre la PAR y la DHI muestra tendencias similares en ambas estaciones. En los días despejados (índice  $k_d$  inferior a 0.3), se observaron valores bajos de DHI asociados a valores altos de PAR, mientras que en los días nublados (índice  $k_d$  superior a 0.7) ocurrió lo contrario. En CEDER-CIEMAT, se registraron valores más altos de DHI (Figura 4a). Este resultado es una consecuencia del clima mediterráneo continental presente en esta estación, donde hay más días nublados o tormentosos en comparación con el clima árido de PSA-CIEMAT (Figura 4b).

De igual forma, la Figura 3-5 muestra tendencias similares en ambas estaciones en los diagramas de dispersión entre PAR y DNI. La principal diferencia entre ambas estaciones es que, en días nublados ( $k_b$  inferior a 0.3 y DNI cercana a cero), se alcanzaron valores más altos de PAR en CEDER-CIEMAT.

Algunas características de la cobertura nubosa y las condiciones generales de cada estación pueden apreciarse en la Figura 3-6 y la Figura 3-7; en ambas figuras, para CEDER-CIEMAT, las situaciones de mayor nubosidad suceden principalmente por la mañana (azimut solar positivo). También es notable, en ciertos períodos del año, la ausencia de condiciones despejadas durante la tarde (azimut solar negativo) en CEDER-CIEMAT. Sin embargo, en PSA-CIEMAT, las condiciones de mayor nubosidad se presentaron principalmente a última hora de la tarde. En esas dos figuras, se puede apreciar la ausencia de datos para ángulos de elevación solar muy bajos (amanecer y atardecer). Estos datos fueron eliminados al aplicar los diferentes filtros en el pre-tratamiento de datos; considerados como valores atípicos, su eliminación se justifica por la progresiva desaparición del disco solar en el horizonte respecto al instrumento de medida.

Los gráficos presentados en las Figura 3-2 a la Figura 3-7, muestran que la relación matemática entre la PAR y las demás variables varía a medida que cambian los índices  $k_t$ ,  $k_d$ ,  $k_b$  o el ángulo  $\alpha$ . Esta variación indica que, para el modelado de la PAR, es necesario utilizar una combinación de todas estas variables. Los modelos seleccionados para este estudio se muestran en la Tabla 3-1.

Las principales tendencias en la relación entre la PAR y las demás variables fueron comunes en ambas estaciones. Aunque están ubicadas en regiones con climas diferentes – Mediterráneo continental en CEDER-CIEMAT y árido en PSA-CIEMAT – (Köppen and Geiger 1936; Agencia Estatal de Meteorología (AEMET) and Instituto de Meteorologia de Portugal (IM) 2011), las características principales de estos climas no son lo suficientemente distintas como para provocar una diferencia significativa en el comportamiento de la PAR. Sin embargo, se observaron algunas particularidades en cada estación, por ejemplo, en PSA-CIEMAT se alcanzaron ángulos  $\alpha$  más altos, así como los valores mayores del índice  $k_t$ . En CEDER-CIEMAT, en cambio, se registraron valores mayores de DHI y PAR en días nublados.

Las condiciones de mayor nubosidad ocurrieron a primeras horas de la tarde en PSA-CIEMAT, mientras que en CEDER-CIEMAT, estas condiciones se presentaron al final de la mañana. Estas particularidades influyen en la dependencia de la PAR con otros parámetros radiométricos.

En los distintos diagramas de dispersión realizados con todos los datos mostrados anteriormente, también se puede apreciar la interdependencia entre PAR y GHI. Sin embargo, se observa que esta relación no es perfectamente lineal. Además, en condiciones de cielo parcialmente nublado ( $0.3 < k_t \leq 0.7$ ), se presenta una dispersión (Figura 3-3) que podría deberse al efecto de las nubes o estar relacionada con las diferentes sensibilidades y el envejecimiento de los sensores.

Fuera de este intervalo de cielo parcialmente nublado, los dos parámetros muestran una correlación más evidente. La causa de esta aparente correlación podría ser que ambos parámetros están relacionados con un tercer parámetro, lo que nos llevó a estudiar y analizar diversas combinaciones para identificar los modelos más adecuados.

### **3.3.2. Desarrollo y Validación de los Modelos Completos**

La Tabla 3-1 muestra los parámetros de ajuste para cada uno de los modelos completos presentados. La selección de estos modelos se realizó excluyendo combinaciones que no incluyeran al ángulo  $\alpha$  como variable explicativa, aquellas que solo incluyen el término  $\sin(\alpha)$  y aquellas que incluyen todas las variables.

Los gráficos que se presentan en las siguientes secciones, muestran que los modelos que incluyen las variables  $k_t$  o el par  $k_t$  y  $\sin(\alpha)$  ofrecen resultados de correlación más relevantes con los datos de validación. En contraste, en el resto de los modelos, la dispersión es más notable (Figura 3-8).

En esta Tabla 3-1 también se muestran los resultados de la aplicación de los estadísticos de validación para los diferentes modelos.




Figura 3-8 : Resultados obtenidos en la validación de los modelos completos mencionados anteriormente, cada gráfico utilizando los datos medidos en las estaciones CEDER-CIEMAT (a, c, e) y PSA-CIEMAT (b, d, f).

Desde un punto de vista cualitativo, los seis modelos presentados en Tabla 3-1 pueden dividirse en dos grupos: aquellos que consideran solo dos variables independientes (m\_1, m\_2 y m\_3) y aquellos que utilizan tres (m\_4, m\_5 y m\_6). Esta clasificación no es significativa en cuanto a los resultados obtenidos sin embargo, se observan diferencias notables en una clasificación basada en las variables explicativas consideradas:

- G1: modelos que incluyen  $\sin(\alpha)$  y  $k_t$  (m\_1, m\_4 y m\_5),

$$m\_1: \frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t$$

$$m\_4: \frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_d$$

$$m\_5: \frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_b$$

- G2: modelos que no incluyen simultáneamente  $\sin(\alpha)$  y  $k_t$  (m\_2, m\_3 y m\_6),

$$m\_2: \frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_d$$

$$m\_3: \frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_b$$

$$m\_6: \frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_d + d \cdot k_b$$

La comparación de los valores de RMSE permite apreciar la diferencia en el orden de magnitud entre los modelos del grupo G1 y los del grupo G2. Los RMSE del grupo G1 varían entre 33.177 y 37.433  $\mu\text{mol m}^{-2} \text{s}^{-1}$ , mientras que los del grupo G2 oscilan entre 115.844 y 145.848  $\mu\text{mol m}^{-2} \text{s}^{-1}$  (Tabla 3-1).

En cuanto al grupo de modelos G1, se observa que la validación con los datos de CEDER-CIEMAT proporciona un valor de RMSE más bajo que el obtenido con los datos de PSA-CIEMAT. Por otro lado, para el grupo de modelos G2, el RMSE es mayor cuando se utilizan los datos de CEDER-CIEMAT.

El análisis de regresión entre la PAR medida y estimada mostró que el MAE es significativamente menor para el grupo G1. El análisis de los errores de sesgo (MBE) indica que los modelos tienden a sobreestimar en el caso de la estación CEDER-CIEMAT, mientras que subestiman los valores para los datos de PSA-CIEMAT. Los valores más bajos de MBE se encuentran en los modelos del grupo G1 cuando se validan con los datos de CEDER-CIEMAT (Tabla 3-1).

Tabla 3-1 : Resultados obtenidos a partir de los ajustes de seis modelos completos de los grupos G1 y G2 y sus estadísticos de validación

| Modelos |     | a     | b      | c      | d      | Estación | MAE <sup>1</sup> | MBE <sup>1</sup> | RMSE <sup>1</sup> | MPE (%) | R <sup>2</sup> |
|---------|-----|-------|--------|--------|--------|----------|------------------|------------------|-------------------|---------|----------------|
| G1      | m_1 | 0.018 | −0.030 | 0.385  | -      | CEDER    | 25.683           | 3.242            | 33.425            | −1.795  | 0.995          |
|         |     |       |        |        |        | PSA      | 28.445           | −6.253           | 36.641            | 1.246   | 0.994          |
|         | m_4 | 0.028 | −0.029 | 0.373  | −0.008 | CEDER    | 25.313           | 2.542            | 33.177            | −1.816  | 0.996          |
|         |     |       |        |        |        | PSA      | 28.913           | −6.040           | 37.433            | 1.186   | 0.994          |
|         | m_5 | 0.019 | −0.030 | 0.380  | 0.004  | CEDER    | 25.595           | 2.990            | 33.360            | −1.851  | 0.995          |
|         |     |       |        |        |        | PSA      | 28.673           | −6.152           | 36.979            | 1.226   | 0.994          |
| G2      | m_2 | 0.295 | 0.035  | −0.198 | -      | CEDER    | 108.033          | 6.330            | 145.848           | −16.338 | 0.913          |
|         |     |       |        |        |        | PSA      | 92.002           | −18.124          | 127.034           | −1.284  | 0.922          |
|         | m_3 | 0.126 | 0.006  | 0.255  | -      | CEDER    | 101.927          | 7.143            | 136.499           | −19.155 | 0.923          |
|         |     |       |        |        |        | PSA      | 86.357           | −12.325          | 116.862           | −1.599  | 0.935          |
|         | m_6 | 0.094 | 0.001  | 0.038  | 0.301  | CEDER    | 101.762          | 8.770            | 136.903           | −20.294 | 0.923          |
|         |     |       |        |        |        | PSA      | 85.478           | −11.117          | 115.844           | −1.799  | 0.936          |

<sup>1</sup>  $\mu\text{mol m}^{-1} \text{s}^{-1}$

El sesgo entre ambas estaciones podría deberse a diferencias sistemáticas, como las variaciones en los equipos utilizados durante la campaña de medición.

En cuanto al error porcentual medio (MPE), los valores obtenidos son bajos y cercanos al 0%. Además, los MPE obtenidos con los datos de CEDER-CIEMAT y PSA-CIEMAT son aún menores para los modelos del grupo G1 en comparación con los del grupo G2.

En cuanto al coeficiente de correlación ( $R^2$ ) de los diferentes modelos, se observa que es muy alto en todos los casos, con valores muy cercanos entre sí. Sin embargo, los modelos del grupo G1 presentan los valores más elevados, destacando que, para CEDER-CIEMAT, los resultados son mejores hasta el nivel de la milésima. En lo que respecta al grupo G2, los resultados obtenidos (según el valor  $R^2$ ) en la estación PSA-CIEMAT son mejores que los proporcionados por la estación CEDER-CIEMAT.

Las expresiones matemáticas obtenidas y los resultados estadísticos de cada uno de los modelos desarrollados pueden consultarse en el Apéndice A. Para abordar el análisis desde un punto de vista gráfico, los modelos m\_1, m\_3 y m\_6 se presentan en los siguientes gráficos (los resultados estadísticos de todos los modelos también pueden consultarse en el Apéndice A).

La Figura 3-8 muestra los diagramas de dispersión entre la PAR estimada a partir de los modelos completos y la PAR medida para los modelos m\_1, m\_3 y m\_6 en ambas estaciones. Por un lado, se observa claramente que los modelos que incluyen el índice  $k_t$  como variable explicativa presentan un mejor ajuste para valores bajos de PAR en ambas ubicaciones. Por otro lado, los modelos del grupo G2 muestran una dispersión notable, no solo en los valores bajos de PAR, sino también en los valores medios y altos. Esta tendencia se generaliza cuando se analizan las curvas de dispersión de todos los modelos estudiados.

En la Figura 3-9, diagramas de Box&Whiskers de la distribución de errores absolutos según la Ecuación (11) para cada modelo y ubicación, proporciona una representación visual de la calidad de los seis modelos presentados. Esta figura muestra la mediana, los cuartiles inferior y superior así como los valores atípicos (estadísticamente no representativos).




Figura 3-9 : Distribución del error absoluto de los modelos completos (a, b) y de los modelos por intervalos (c, d) propuestos en la Tabla 3-1 en las estaciones CEDER-CIEMAT (a, c) y PSA-CIEMAT (b, d).

Por un lado, se observa claramente que los modelos del grupo G1 presentan un rango intercuartílico muy estrecho alrededor del valor de error absoluto “0” (mediana) y que los valores atípicos no están muy dispersos en ambas ubicaciones. Por otro lado, al comparar las distribuciones del error absoluto entre los dos tipos de modelos, se observa que el modelado por intervalos proporciona mejores resultados en la estimación de la PAR que los modelos de rango completo. Esto se evidencia por un rango intercuartílico aún más estrecho y con un menor número de valores atípicos.

### 3.3.3. Comparación entre Modelos completos y Modelos de la bibliografía

Al comparar los estadísticos de validación obtenidos en ambas estaciones (Tabla 3-2), se observa que todos los valores de  $R^2$  fueron altos, con valores ligeramente mayores en CEDER-CIEMAT. Por el contrario, los valores de MPE estuvieron más cercanos a cero en PSA-CIEMAT.

En cuanto al RMSE, los modelos arrojan mejores resultados en CEDER-CIEMAT, excepto en el caso del modelo de (Alados et al. 1996). El MBE mostró diferencias notables entre ambas estaciones, por ejemplo, el RMSE del modelo de Alados et al. (1996) en PSA-CIEMAT fue dos órdenes de magnitud menor que en CEDER-CIEMAT. Finalmente, todos los modelos, excepto el de (Wang et al. 2015), presentaron un MAE menor en CEDER-CIEMAT.

Tabla 3-2 : Índices estadísticos entre modelos completos y modelos de la bibliografía.

| Modelos       | CEDER-CIEMAT     |                  |                   |         |       | PSA-CIEMAT       |                  |                   |         |       |
|---------------|------------------|------------------|-------------------|---------|-------|------------------|------------------|-------------------|---------|-------|
|               | MAE <sup>1</sup> | MBE <sup>1</sup> | RMSE <sup>1</sup> | MPE(%)  | R2    | MAE <sup>1</sup> | MBE <sup>1</sup> | RMSE <sup>1</sup> | MPE(%)  | R2    |
| m_1           | 25.6828          | 3.242            | 33.425            | 1.795   | 0.995 | 28.445           | -6.253           | 36.641            | 1.246   | 0.994 |
| m_4           | 25.3128          | 2.542            | 33.177            | -1.816  | 0.996 | 28.913           | -6.040           | 37.433            | 1.186   | 0.994 |
| m_5           | 25.5951          | 2.990            | 33.360            | -1.851  | 0.995 | 28.673           | -6.152           | 36.979            | 1.226   | 0.994 |
| Alados        | 110.944          | 110.581          | 136.863           | -15.840 | 0.994 | 116.581          | 5.819            | 53.018            | 1.125   | 0.992 |
| Foyo-Moreno   | 110.0813         | 109.323          | 150.393           | -12.479 | 0.994 | 124.593          | 123.633          | 166.398           | -10.524 | 0.991 |
| Wang          | 43.4608          | 36.287           | 53.859            | -8.035  | 0.994 | 40.835           | 27.326           | 56.229            | -2.993  | 0.991 |
| Ferrera-Cobos | 136.1521         | 135.026          | 174.649           | -16.660 | 0.994 | 151.318          | 148.399          | 193.599           | -12.384 | 0.991 |

<sup>1</sup>  $\mu\text{mol m}^{-1} \text{s}^{-1}$

Teniendo en cuenta todas las estadísticas, los modelos m\_1, m\_4 y m\_5 presentaron un rendimiento similar y estadísticos de validación más bajos. Entre los modelos de la bibliografía, destaca el modelo de Alados et al. (1996), que presentó los menores valores de MPE y MBE frente al resto de modelos (incluidos m\_1, m\_4 y m\_5) en la estación PSA-CIEMAT. En esta estación, Alados et al. (1996) obtuvo los mejores estadísticos de

validación, excepto en el caso del MAE, donde el modelo de Wang et al. (2015) presentó un valor menor.

En el caso de CEDER-CIEMAT, el modelo de Wang et al. (2015) fue el que obtuvo los mejores estadísticos de validación entre los modelos de la bibliografía implementados (Alados et al. 1996; Wang et al. 2015; Foyo-Moreno et al. 2017; Ferrera-Cobos et al. 2021).

En general, estos resultados no son sorprendentes ya que los modelos desarrollados en este estudio fueron entrenados con datos recopilados en estas dos estaciones. Dada la importancia de las condiciones climáticas y atmosféricas en el comportamiento de la PAR, los datos utilizados para desarrollar los modelos de PAR condicionan su rendimiento cuando se aplican a datos de otras ubicaciones con climas muy diferentes. En este sentido, los buenos resultados del modelo de Alados et al. (2016) en PSA-CIEMAT pueden explicarse por el hecho de que este modelo fue ajustado utilizando datos de la Universidad de Almería, donde el clima árido influenciado por la proximidad del mar, es muy similar al clima de PSA-CIEMAT (ambas ubicaciones se encuentran aproximadamente a 40 km de distancia).

### **3.3.4. Comparación entre Modelos Completos y Modelos por Intervalos**

Para mejorar los resultados obtenidos con el modelo completo, el estudio se amplió ajustando modelos por intervalos. Para un modelo dado, la PAR estimada es el conjunto de estimaciones en condiciones de cielo cubierto, parcialmente cubierto y despejado. La Figura 3-10 muestra los gráficos de correlación entre la PAR total estimada a partir de los modelos y la PAR medida en cada estación radiométrica. Las estadísticas de validación muestran una mejora en los datos PAR estimados por intervalos en comparación con los obtenidos con los modelos completos. Es evidente que los modelos que incluyen como variable explicativa el índice  $k_t$  se ajustan mejor a valores bajos de PAR en ambas ubicaciones. Sin embargo, la dispersión se desvía ligeramente hacia abajo de la línea de correlación perfecta para valores altos de PAR.




Figura 3-10 : Resultados de la validación de modelos en los intervalos mencionados anteriormente en cada gráfica utilizando datos medidos en las estaciones CEDER-CIEMAT (a, c, e) y PSA-CIEMAT (b, d, f).

### 3.4. Conclusiones

Los modelos del grupo G1 ( $m_1$ ,  $m_4$  y  $m_5$ ), es decir, aquellos que incluyen simultáneamente el índice de claridad atmosférica y el seno del ángulo de elevación solar como variables independientes, presentan los mejores resultados, siendo difícil discernir cuál de ellos es el más preciso. Además, los errores de sesgo calculados para ambas estaciones indican que los modelos sobreestiman en la estación CEDER-CIEMAT, mientras que subestiman los valores en PSA-CIEMAT. El análisis realizado nos permite concluir que los estadísticos de validación indican un mejor ajuste de los modelos por intervalos en comparación con los modelos completos.

No obstante, los modelos completos también mostraron buenos resultados en relación con los modelos considerados en la bibliografía. Por otro lado, el desarrollo de un modelo mejorado de PAR podría basarse en la minimización de errores sistemáticos relacionados con los datos registrados, lo que permitiría explorar posibles aplicaciones en otros campos, como el cálculo del balance energético en ecosistemas o la productividad de biomasa.

**Contribuciones de cada autor:** Conceptualización, R.X.V. y L.F.Z.; metodología, R.X.V., L.F.Z., J.A.R.C. y O.W.; software, J.A.R.C. y O.W.; validación, J.A.R.C. y O.W.; análisis formal, L.F.Z., J.A.R.C. y O.W.; investigación, R.X.V., J.A.R.C. y O.W.; recursos, R.X.V. y L.F.Z.; curación de datos, O.W., J.A.R.C., R.X.V., A.A.N., L.F.Z. y F.F.-C.; Redacción: preparación del borrador original, O.W., J.A.R.C., R.X.V., A.A.N., L.F.Z. y F.F.-C.; redacción: revisión y edición, O.W., J.A.R.C., R.X.V., A.A.N., L.F.Z. y F.F.-C.; visualización, O.W., A.A.N., F.F.-C., R.X.V. y L.F.Z.; supervisión, R.X.V. y L.F.Z.; administración del proyecto, R.X.V. y L.F.Z.; obtención de financiación, R.X.V. Todos los autores han leído y aceptado la versión publicada del manuscrito.

**Financiación:** Esta investigación fue financiada por la Comunidad Autónoma de Madrid, España, y cofinanciada por FEDER «A way of making Europe» ALGATEC - CM (S2018/BAA-4532).

**Agradecimientos:** Los autores agradecen la financiación de la Comunidad Autónoma de Madrid, España, y la cofinanciación de FEDER « A way of making Europe » ALGATEC - CM (S2018/BAA-4532). Los autores también agradecen al Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo (CYTED) (RED RENUWAL P320RT0005 CYTED).

**Declaración de disponibilidad de datos:** Los datos medidos del Grupo de Radiación Solar (CIEMAT) están disponibles para investigadores de buena fe, sujeto a un acuerdo. Para más detalles sobre los datos y cómo solicitar acceso, contacte con el autor correspondiente.

**Conflictos de intereses:** Los autores declaran no tener ningún conflicto de intereses.

### 3.5. Apéndice A

Tabla A1. Ecuaciones matemáticas de los modelos, coeficientes de ajustes y estadísticos de validación de los Modelos Completos.

| Modelos                                                                                | a     | b      | c      | d      | e      | Estación | MPE (%) | MBE <sup>1</sup> | RMSE <sup>1</sup> | R <sup>2</sup> |
|----------------------------------------------------------------------------------------|-------|--------|--------|--------|--------|----------|---------|------------------|-------------------|----------------|
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha)$                                           | 0.189 | 0.109  | -      | -      | -      | CEDER    | -69.046 | 151.513          | 356.347           | 0.557          |
|                                                                                        |       |        |        |        |        | PSA      | -12.277 | 6.877            | 232.068           | 0.740          |
| $\frac{PAR}{I_0} = a + b \cdot k_t$                                                    | 0.007 | 0.372  | -      | -      | -      | CEDER    | -2.114  | 10.983           | 35.786            | 0.996          |
|                                                                                        |       |        |        |        |        | PSA      | 1.437   | -1.049           | 44.151            | 0.994          |
| $\frac{PAR}{I_0} = a + b \cdot k_d$                                                    | 0.318 | -0.204 | -      | -      | -      | CEDER    | -17.194 | -1.998           | 147.847           | 0.911          |
|                                                                                        |       |        |        |        |        | PSA      | -1.731  | -25.528          | 128.259           | 0.921          |
| $\frac{PAR}{I_0} = a + b \cdot k_b$                                                    | 0.128 | 0.256  | -      | -      | -      | CEDER    | -19.24  | 5.498            | 136.714           | 0.924          |
|                                                                                        |       |        |        |        |        | PSA      | -1.652  | -13.661          | 116.63            | 0.935          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t$                             | 0.018 | -0.030 | 0.385  | -      | -      | CEDER    | -1.795  | 3.242            | 33.425            | 0.995          |
|                                                                                        |       |        |        |        |        | PSA      | 1.246   | -6.253           | 36.641            | 0.994          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_d$                             | 0.295 | 0.035  | -0.198 | -      | -      | CEDER    | -16.338 | 6.33             | 145.848           | 0.913          |
|                                                                                        |       |        |        |        |        | PSA      | -1.284  | -18.124          | 127.034           | 0.922          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_b$                             | 0.125 | 0.006  | 0.254  | -      | -      | CEDER    | -19.155 | 7.143            | 136.499           | 0.923          |
|                                                                                        |       |        |        |        |        | PSA      | -1.599  | -12.325          | 116.862           | 0.935          |
| $\frac{PAR}{I_0} = a + b \cdot k_t + c \cdot k_d$                                      | 0.025 | 0.353  | -0.014 | -      | -      | CEDER    | -2.15   | 9.442            | 34.877            | 0.996          |
|                                                                                        |       |        |        |        |        | PSA      | 1.296   | -0.789           | 44.92             | 0.993          |
| $\frac{PAR}{I_0} = a + b \cdot k_t + c \cdot k_b$                                      | 0.009 | 0.365  | 0.006  | -      | -      | CEDER    | -2.206  | 10.633           | 35.49             | 0.996          |
|                                                                                        |       |        |        |        |        | PSA      | 1.394   | -0.802           | 44.623            | 0.993          |
| $\frac{PAR}{I_0} = a + b \cdot k_d + c \cdot k_b$                                      | 0.093 | 0.039  | 0.303  | -      | -      | CEDER    | -20.343 | 8.661            | 136.944           | 0.923          |
|                                                                                        |       |        |        |        |        | PSA      | -1.812  | -11.213          | 115.783           | 0.936          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_d$               | 0.028 | -0.029 | 0.373  | -0.008 | -      | CEDER    | -1.816  | 2.542            | 33.177            | 0.996          |
|                                                                                        |       |        |        |        |        | PSA      | 1.186   | -6.04            | 37.433            | 0.994          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_b$               | 0.019 | -0.030 | 0.380  | 0.004  | -      | CEDER    | -1.851  | 2.99             | 33.36             | 0.995          |
|                                                                                        |       |        |        |        |        | PSA      | 1.226   | -6.152           | 36.979            | 0.994          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_d + d \cdot k_b$               | 0.094 | 0.001  | 0.038  | 0.301  | -      | CEDER    | -20.294 | 8.77             | 136.903           | 0.923          |
|                                                                                        |       |        |        |        |        | PSA      | -1.799  | -11.117          | 115.844           | 0.936          |
| $\frac{PAR}{I_0} = a + b \cdot k_t + c \cdot k_d + d \cdot k_b$                        | 0.073 | 0.373  | -0.072 | -0.087 | -      | CEDER    | -1.070  | 8.825            | 35.513            | 0.996          |
|                                                                                        |       |        |        |        |        | PSA      | 1.310   | -3.016           | 41                | 0.993          |
| $\frac{PAR}{I_0} = a + b \cdot \sin(\alpha) + c \cdot k_t + d \cdot k_d + e \cdot k_b$ | 0.056 | -0.025 | 0.383  | -0.044 | -0.053 | CEDER    | -1.165  | 3.082            | 33.085            | 0.996          |
|                                                                                        |       |        |        |        |        | PSA      | 1.200   | -6.521           | 36.047            | 0.994          |

<sup>1</sup>  $\mu\text{mol m}^{-1} \text{s}^{-1}$

La Tabla A2, relativa a las ecuaciones matemáticas de los modelos, coeficientes de ajustes y estadísticos de validación de los modelos por intervalos, ha sido incluido en el capítulo 6 de la presente memoria.

Figura A1. Resultados obtenidos de la validación de los 15 modelos completos (primera columna) y modelos por intervalos (segunda columna) mencionados anteriormente, utilizando datos proporcionados por la estación CEDER-CIEMAT.




Figura A1: continúa




Figura A1: continúa




Figura A1: continúa




Figura A1: termina

Figura A2. Resultados obtenidos de la validación de los 15 modelos completos (primera columna) y modelos por intervalos (segunda columna) mencionados anteriormente, utilizando datos proporcionados por la estación PSA-CIEMAT.




Figura A2: continúa




Figura A2: continúa




Figura A2: continúa




Figura A2: termina

## 4. Generación de secuencias meteorológicas típicas para simular el crecimiento y la producción de sistemas biológicos

**Ousmane Wane<sup>1,2,3</sup>, Luis F. Zarzalejo<sup>1,\*</sup>, Francisco Ferrera-Cobos<sup>1</sup>, Ana A. Navarro<sup>1</sup>, Alberto Rodríguez-López<sup>1</sup> and Rita X. Valenzuela<sup>1</sup>**

<sup>1</sup> CIEMAT Energy Department, Renewable Energy Division, Avda. Complutense 40, 28040 Madrid, Spain;

ousmane.wane@externos.ciemat.es (O.W.); francisco.ferrera@ciemat.es (F.F.-C.);

a.navarro@ciemat.es (A.A.N.); alberto.rodriguez@ciemat.es (A.R.-L.);

r.valenzuela@ciemat.es (R.X.V.);

<sup>2</sup> E.T.S.I. Agronómica, Alimentaria y Biosistemas, Universidad Politécnica de Madrid, Avda. Puerta Hierro 2-4, 28040 Madrid, Spain;

<sup>3</sup> Department of Microbial and Plant Biotechnology, Center for Biological Research Margarita Salas - CSIC, Ramiro de Maeztu 9, 28040 Madrid, Spain;

\*Correspondencia: lf.zarzalejo@ciemat.es (L.F.Z.)

Appl. Sci. 2023, 13, 4826. <https://doi.org/10.3390/app13084826>

### Resumen

La simulación numérica aplicada a la agricultura o al tratamiento de aguas residuales (WasteWater Treatment, WWT) es actualmente una herramienta complementaria para conocer, a priori, el impacto de los parámetros meteorológicos en la productividad bajo condiciones ambientales limitantes o incluso para orientar las inversiones hacia otros objetivos económicos circulares más relevantes. Este trabajo propone una nueva metodología para calcular Secuencias Meteorológicas Típicas (TMS) que podrían usarse como datos de entrada para la simulación del crecimiento y la productividad de organismos fotosintéticos en diferentes sistemas biológicos, como un estanque de algas de alto rendimiento (High Rate Algae Pond, HRAP), sistemas WWT u otros cultivos agrícolas. La TMS se genera aplicando el estadístico de Finkelstein-Schafer (FS) y representa la secuencia meteorológica más probable a largo plazo para cada estación meteorológica. En nuestro caso de estudio, se consideran 18 ubicaciones en la Comunidad de Madrid (España) en función de las condiciones climáticas representadas por la irradiancia solar y la temperatura. Los parámetros seleccionados para generar TMS fueron la radiación fotosintéticamente activa (PAR), la duración del día solar, el máximo, el mínimo, la media y el rango de temperatura. La selección de secuencias potenciales según el período de crecimiento del organismo se realiza mediante el remuestreo de los datos meteorológicos disponibles, lo que, en este caso de estudio, aumenta el número de secuencias candidatas en un 700%.

## 4.1. Introducción

El incremento y el cambio en los patrones de consumo de la población están generando graves problemas energéticos que afectan, entre otros, a la producción de alimentos y al tratamiento de aguas residuales (WWT). Las simulaciones desempeñan un papel importante en la implementación previa de sistemas que contribuyen al control de estos problemas, ya que representan una aproximación a largo plazo de la viabilidad técnica y económica, contribuyendo a decidir la configuración más adecuada para su implementación real. Además, la eficiencia en el uso del agua y la energía en la agricultura es un problema cada vez más importante debido a la creciente escasez de la primera y al aumento de los costos de la segunda (Domínguez et al. 2013). Ambos factores limitan el riego de cultivos en muchas zonas del mundo, lo que condiciona la productividad. Por otro lado, la necesidad de WWT constituye un desafío en cualquier población y actividad económica, especialmente en zonas rurales y países en desarrollo, donde el uso de sistemas de tratamiento de lodos activados puede generar altos costos de capital y operación. Por esa razón, se han propuesto “tecnologías basadas en la naturaleza” en pequeñas poblaciones (Garfí et al. 2017). Una de estas tecnologías son los “estanques de algas de alto rendimiento” (HRAP), que consisten en el uso de poblaciones microbianas presentes en aguas residuales y microalgas inoculadas en el medio para obtener un acoplamiento metabólico que produce WWT (López-Sánchez et al. 2022). Los procesos basados en microalgas son mucho más simples, imponen bajo gasto de capital (CAPEX) y reducen, frente a los sistemas convencionales, los costos de mantenimiento debido a la menor maquinaria requerida y al menor consumo de energía (Acién et al. 2016). Además, el rendimiento del HRAP se puede describir con precisión utilizando solo dos variables: pH y oxígeno disuelto (Robles et al. 2020). Sin embargo, las microalgas son muy sensibles a las variaciones en los parámetros climáticos, como la temperatura y la irradiancia solar (Arcila and Buitrón 2017; Iasimone et al. 2018), particularmente la radiación fotosintéticamente activa (PAR).

Por lo tanto, para gestionar estos sistemas biológicos, es importante utilizar datos climáticos y sus estimaciones a largo plazo para adoptar estrategias de riego adecuadas en zonas con escasez de agua y optimizar la productividad de los cultivos o para la depuración de aguas residuales con sistemas HRAP. En este caso, es posible estimar, utilizando programas de simulación adecuados, no solo la productividad de las microalgas en el proceso y la

generación de energía mediante biogás y su uso como fuente de energía en la propia planta, sino también la eficiencia del sistema de depuración de aguas residuales.

Por otro lado, el denominado “Año Meteorológico Típico” -Typical Meteorological Year, TMY- (Hall et al. 1978), desarrollado por Sandia National Laboratories, es una secuencia temporal ampliamente utilizada para describir las condiciones meteorológicas más probables (incluyendo radiación solar, temperatura, humedad, entre otras) en una ubicación arbitraria. El TMY está formado por 12 meses seleccionados estadísticamente y concatenados a partir de una serie de años para generar un año completo (Leite et al. 2015), que ofrece una descripción climatológica representativa de una ubicación a largo plazo (Marion and Urban 1995). La variabilidad de las series meteorológicas generadas mediante esta metodología es mayor que la de una serie de variables compuestas por promedios climáticos. Sin embargo, un TMY no es necesariamente un buen indicador de las condiciones climáticas de un año específico en el futuro ni de eventos meteorológicos extremos. Los TMY se han utilizado en la simulación y estimación de la energía producida para diferentes tecnologías de energía renovable y eficiencias energéticas, como SAM (<https://sam.nrel.gov/>) (consultado el 6 de septiembre de 2022), PVSyst (<https://www.pvsyst.com/>) (consultado el 6 de septiembre de 2022), ESP-r

(<https://www.strath.ac.uk/research/energysystemsresearchunit/applications/esp-r/>)

(consultado el 6 de septiembre de 2022), DOE-2 (<https://www.doe2.com/>) (consultado el 6 de septiembre de 2022), TRNSYS (<http://www.trnsys.com/>) (consultado el 6 de septiembre de 2022), EnergyPlus (<https://energyplus.net/>) (consultado el 6 de septiembre de 2022) entre otros.

Como previamente se ha mencionado, la variabilidad debida a los cambios climatológicos tiene un gran impacto en la productividad de los cultivos. Por ese motivo, los modelos de producción agrícola requerirían una descripción climatológica a largo plazo del emplazamiento en cuestión para obtener estimaciones del rendimiento del cultivo. En este contexto, el TMY se ha utilizado en estudios sobre diseño de invernaderos (Heinemann and Walker. 1987; Marbis 2001; Fernández et al. 2015), así como para el desarrollo de un sistema de riego óptimo para diferentes cultivos en condiciones externas (Domínguez et al. 2013; Leite et al. 2015; Martínez-Romero et al. 2019). Además, podría emplearse en la simulación hipotética de sistemas energéticos híbridos basados en el uso de energía fotovoltaica en invernaderos semitransparentes para la producción de microalgas (Shen et al. 2015) o para

estudiar los materiales más adecuado para un invernadero y así reducir al máximo su consumo energético (Baneshi et al. 2020).

Hasta donde se ha podido revisar, el concepto de Secuencia Meteorológica Típica (TMS) no se ha aplicado para estudiar el comportamiento de una planta de tratamiento de aguas residuales en un HRAP, considerando una serie meteorológica típica representativa aquella correspondiente al tiempo de retención hidráulica necesario para la planta de tratamiento de aguas residuales. Un TMS compuesto por siete días consecutivos, denominado “semana meteorológica típica” (Typical Meteorological Weeek, TMW), podría analizarse como un período comparable al tiempo de retención de agua a tratar en el HRAP (nuestro caso de estudio), aunque el período típico puede variar según su aplicación. Razón por la cual, a largo plazo, puede ser útil saber en qué estaciones del año el sistema puede estar en funcionamiento y cuándo puede detenerse, dependiendo de las condiciones climáticas del emplazamiento. También puede ser útil para identificar los sitios óptimos para la implementación de este sistema, ya que se espera que el proceso no se detenga por exceso o defecto de radiación solar o temperatura.

El objetivo principal de este trabajo es desarrollar una metodología para generar una secuencia meteorológica típica, una semana para nuestro caso de estudio, representativa de cada estación meteorológica. Para ello, el trabajo se divide en las siguientes secciones: (1) descripción de la metodología Sandia; (2) caso de estudio, con indicación de las ubicaciones donde se generan las TMW en la Comunidad de Madrid; (3) aplicación de la metodología TMW para cada estación del año; y, finalmente, (4) resultados y discusión.

## **4.2. Metodología**

Desde la década de 1980, se han presentado numerosos estudios para la generación de TMY utilizando ecuaciones del estadístico de Finkelstein-Schafer (FS) según la metodología propuesta por Sandia National Laboratories. Estos estudios se basan principalmente en la utilización de diferentes parámetros climáticos, coeficientes de ponderación y criterios de persistencia en la fase final de selección de las secuencias apropiadas. En este trabajo, para determinar la importancia de los parámetros meteorológicos en el período de crecimiento de microalgas en HRAP para WWT o plantas en agricultura para cultivos, se utilizó la metodología Sandia considerando diferentes escenarios de coeficientes de ponderación y dividiendo el conjunto de datos en intervalos para definir el estadístico FS.

#### **4.2.1. Metodología de los Laboratorios Nacionales Sandia**

La metodología Sandia está ampliamente presente en la bibliografía y resulta ser uno de los métodos más comunes para generar un TMY (Hall et al. 1978; D. Pissimanis et al. 1988; Kalogirou 2003; Skeiker 2004; Huld et al. 2018). El TMY se obtiene a partir de series históricas plurianuales, por ejemplo, 30 años (ciclo climático), de diferentes parámetros meteorológicos: entre otros, temperatura (media, máxima, mínima y rango) e irradiancia solar (irradiancia horizontal global). Inicialmente, estos parámetros se registraron in-situ (26 estaciones SOLMET) durante 23 años, desde 1953 hasta 1975 (Hall et al. 1978). De las series temporales diarias disponibles, la metodología Sandia seleccionó 12 “meses meteorológicos típicos” (Typical Meteorological Month, TMM) para obtener información sobre la variabilidad anual de los parámetros estudiados. Utilizando el estadístico FS, se elige un TMM para cada uno de los 12 meses del calendario de todos los años disponibles en la serie temporal. Esto se realizó asignando un “factor de ponderación” (weighting factor, wf) a los parámetros meteorológicos considerados, lo que resultó en una reducción en la cantidad de datos, con la menor pérdida de información posible (Cebecauer and Suri 2015; Sun et al. 2017). El wf puede variar según la importancia de la variable (Georgiou et al. 2013). El conjunto de datos obtenido representa un año típico de datos fiables para la simulación de tecnologías energéticas renovables (Huld et al. 2018).

Además de utilizar el estadístico FS para generar un TMY, algunos estudios introdujeron otros enfoques, como el análisis de componentes principales o algoritmos genéticos (Chan et al. 2006; Yang et al. 2011). Existen otras metodologías, distintas a las mencionadas anteriormente, basadas en la disponibilidad de datos meteorológicos y la aplicación de la secuencia generada. Entre ellas se encuentran los denominados “año de referencia para ensayo” – Test Reference Year, TRY – (Lund 1985; De Miguel and Bilbao 2005), el “año de referencia para diseño” – Design Reference Year, DRY – (Lund 1991) y el “año de referencia corto” – Short Reference Year, SRY – (Liem and Van Paassen 1984). Hasta la fecha, estas metodologías han tenido resultados notables en comparación con los datos meteorológicos promedio a largo plazo de las estaciones meteorológicas (Skeiker 2004; Zang et al. 2012; Cebecauer and Suri 2015; Rodríguez et al. 2019).

#### **4.2.2. Caso de estudio**

La simulación de cultivos es importante para conocer las características morfológicas del cultivo en función de los parámetros meteorológicos y para ayudar en la toma de decisiones sobre agricultura, seguridad alimentaria, cambio climático, ahorro energético, etc. (Holzworth et al. 2014; Kephe et al. 2021). Para abordar la importancia de la influencia meteorológica, en este trabajo se propone una metodología modificada para generar una secuencia meteorológica típica; en este caso, se aplica una TMW para su uso en la simulación del crecimiento de microalgas en un HRAP en la Comunidad de Madrid. Por otro lado, se han realizado estudios sobre la productividad de las microalgas como materia prima para la generación de productos de alto valor añadido o como fuente de energía. Por ello, algunos autores han utilizado estimaciones de variables climáticas (Cligen) para incorporarlas en modelos de crecimiento microbiano y estimar la producción de microalgas (Wigmosta et al. 2011; Huesemann et al. 2016).

Las microalgas son microorganismos fotótrofos que crecen rápidamente y se reproducen en cuestión de horas, en consecuencia, las microalgas generan una gran cantidad de biomasa en un tiempo relativamente corto en comparación con otras especies vivas.

La producción de biomasa y la gestión de aguas residuales están afectadas por parámetros meteorológicos incontrolables que varían a lo largo del período de cultivo. Entre estos parámetros, la temperatura y la irradiancia solar entre 400 y 700 nm (Darvehei et al. 2018) son indispensables para el crecimiento de las microalgas (Breuer et al. 2013; Cabello et al. 2015; Viruela et al. 2016; Baxevanou et al. 2020; García-Rodríguez et al. 2022). El trabajo realizado en (Baxevanou et al. 2020) muestra que la reducción observada en la radiación PAR diaria media que entra en el invernadero afecta al metabolismo vegetal. El mismo efecto se observa cuando se aplica estrés térmico al cultivo (Jabri et al. 2021).

Por lo tanto, debido al corto tiempo de retención hidráulica para el desarrollo de las microalgas, se estudia una TMS por temporada meteorológica utilizando los datos meteorológicos de la Comunidad de Madrid. Las cuatro TMW que se generarán, uno para cada estación meteorológica, se basan en la PAR y la temperatura de 18 “estaciones depuradoras de aguas residuales” (WasteWater Treatment Plants, WWTP) en la Comunidad de Madrid, tal como muestra la Figura 4-1.




Figura 4-1 : Localización de la WWTPs consideradas en la Comunidad de Madrid.

Debido a la disponibilidad de datos simultáneos de PAR y temperatura en estas ubicaciones, se utilizó un conjunto de 15 años de PAR y valores diarios de temperatura ambiente media, máxima y mínima. La PAR se obtuvo a partir de las bandas de Kato, proporcionadas por “Spectral Resolved Irradiance” (SRI) del “Centro de aplicaciones satelitales para la vigilancia del Clima” (Satellite Application Facility on Climate Monitoring, CM-SAF), perteneciente a la “Organización europea para la explotación de satélites meteorológicos” – European Organization for the Exploitation of Meteorological Satellites, EUMETSAT – (Müller et al. 2015). La temperatura media diaria se obtuvo del “Centro europeo de previsiones meteorológicas a medio plazo” – European Center for Medium-Range Weather Forecasts, ECMWF – (Hersbach et al. 2020). El período utilizado en el presente estudio fue de 1991 a 2005, con una resolución espacial de  $0,125^\circ \times 0,125^\circ$ .

Estos cuatro parámetros se agrupan en una matriz a la que se añadieron dos columnas adicionales: el rango de temperatura y la duración del día solar. Esta última se utiliza para tener en cuenta el fotoperiodo, es decir, el número de horas solares durante las cuales las microalgas están expuestas a la PAR y la duración máxima posible del día solar (Zhang et al. 2017).

La Comunidad de Madrid se encuentra prácticamente en el centro de la Península Ibérica (entre 41,15 °N y 39,88 °N de latitud y entre 3,05 °W y 4,57 °W de longitud) en la Meseta Central, con una altitud que oscila entre los 476 y los 2428 m, con una media de 678 m sobre el nivel del mar y una superficie aproximada de 8000 km<sup>2</sup>. La orografía de la Comunidad de Madrid se caracteriza por la presencia de la Cordillera Central en el norte y el oeste del territorio, mientras que el resto del territorio se compone de llanuras y el valle del Tajo. El clima de la región está fuertemente influenciado por su orografía. En consecuencia, en la sierra y sus alrededores, se observa un clima de montaña – Dsc según la clasificación de Köppen-Geiger – (Köppen and Geiger 1936; Peel et al. 2007; Beck et al. 2018) y un clima oceánico-mediterráneo (Csb). Por otro lado, se observa un clima mediterráneo típico (Csa) en las llanuras y un clima semiárido (BSk) en las zonas meridionales y en torno al valle del río Tajo. Esta variación climática podría estimarse mediante la generación de TMS que reflejen esta variabilidad en el crecimiento de las microalgas.

#### **4.2.3. Aplicación de la metodología TMS**

El crecimiento y la productividad de las microalgas se ven afectados por múltiples parámetros de cultivo, como el pH, los nutrientes, la luz, la temperatura, la agitación, el medio de cultivo, etc. En nuestro caso, este enfoque científico solo considera los parámetros físicos irradiancia solar (PAR y duración del día solar) y temperatura ambiente para estudiar los efectos de ambos en la actividad de las microalgas.

Por tanto, la existencia de valores de estos parámetros que permitan determinar si el cultivo se encuentra en su nivel óptimo nos lleva a considerar diferentes conjuntos de factores de ponderación para temperatura e irradiancia. Para ello, se utiliza un enfoque basado en las metodologías TMY para determinar la importancia de los parámetros meteorológicos en el período de crecimiento de las microalgas. Además, dado que estos dos parámetros de cultivo varían significativamente entre dos estaciones meteorológicas, se adopta un enfoque estacional: cada estación se examina por separado siguiendo un proceso de varias etapas. En primer lugar, el conjunto completo de datos disponibles (15 años en nuestro caso de estudio) se ha distribuido en las cuatro estaciones ( $E_w = 1, 2, 3, 4$ ): 1 = primavera (marzo-mayo), 2 = verano (junio-agosto), 3 = otoño (septiembre-noviembre) y 4 = invierno (diciembre-febrero), en ese orden. Estas estaciones se basan en el ciclo anual de temperatura y no en las estaciones astronómicas, por lo que existe una clara transición entre ellas. Para cada ubicación, existe una serie temporal correspondiente a 14 estaciones ( $A_y = 1, 2, \dots, 14$ ) para cada una de estas

cuatro estaciones meteorológicas. A continuación, se identifica un período como sigue:  $E_w A_y$ . Por ejemplo,  $E_1 A_4$  representa la temporada de primavera ( $E_1$ ) de 1994 ( $A_4$ ), que es la primera primavera de las 14 temporadas de primavera que tenemos entre marzo de 1991 y mayo de 2004;  $E_4 A_{14}$  representa la temporada de invierno que comienza en diciembre de 2004 y termina en febrero de 2005, etc.

Dado que se pretende caracterizar una semana ( $S_p$ ) a lo largo de una estación, y una semana es un conjunto de siete días consecutivos (no necesariamente que comiencen en lunes y terminen en domingo), la propuesta se basa en un remuestreo de los datos disponibles, de modo que se incremente el número de semanas candidatas durante el período de estudio. Por otro lado, para una estación dada, las semanas se construyen de tal manera que existe una discontinuidad al pasar de un año a otro; en otras palabras, en una secuencia (semana en nuestro caso), no podemos tener días que provengan de dos años diferentes. Este procedimiento generará  $p$  semanas a partir de los  $q$  días disponibles por estación meteorológica ( $d_q$ ) de la siguiente manera:

$$E_w A_y = \{d_1, d_2, \dots, d_q\}$$

$$S_1 = \{d_1, d_2, \dots, d_7\}, \quad S_2 = \{d_2, d_3, \dots, d_8\}, \quad \dots \quad S_p = \{d_{q-6}, d_{q-5}, \dots, d_q\}$$

donde  $p = q - 6$ . Esto representa un aumento de casi el 700 % en el número de semanas candidatas para una estación en cada año (estación) de la serie temporal. Los datos obtenidos (todos los paquetes de 7 días) representan, por ejemplo, todas las semanas candidatas para todas las estaciones de primavera entre marzo de 1991 y mayo de 2004. Se ha hecho lo mismo para las demás estaciones meteorológicas. Como resultado, este procedimiento generó un considerable número ( $q$ ) de semanas candidatas para cada una de estas cuatro estaciones meteorológicas: 1204 para la primavera, 1204 para el verano, 1190 para el otoño y, finalmente, 1184 para el invierno.

A continuación, para todo el conjunto de datos correspondiente a cada estación y para cada semana (de cada estación), se determina una “función de distribución acumulada” (Cumulative Distribution Function, CDF), Ecuación (5), para cada uno de los seis parámetros meteorológicos seleccionados: PAR, duración del día solar, media, máxima, mínima y rango de temperatura.

La CDF de cada parámetro meteorológico ( $x$ ) se calculó clasificando el conjunto de datos en intervalos de igual tamaño, a menudo denominados “lags”, ya que el tamaño de los datos a largo plazo difiere del de los datos a corto plazo. Por ello, resulta interesante utilizar lags para calcular la Ecuación (6). Posteriormente, el número “ $n$ ” de observaciones es igual al número de lags ( $n$ ). Finalmente, las observaciones se ordenan de manera ascendente  $x_1, x_2, \dots, x_n$ . La CDF de cada observación viene dada por una función escalonada monótonamente creciente definida según:

$$CDF(x) = \begin{cases} 0 & \text{for } x < x_1 \\ \frac{(k-0.5)}{n} & \text{for } x_k \leq x \leq x_{k+1} \\ 1 & \text{for } x > x_n \end{cases} \quad (5)$$

donde “ $k$ ” representa el número de orden desde 1 hasta  $(n-1)$ .

Por otro lado, el estadístico FS de cada secuencia (en nuestro caso, una semana) para cada parámetro dado ( $x$ ) se obtienen según la ecuación (6). En otras palabras, las estadísticas de FS para la semana candidata se obtienen calculando las diferencias entre la CDF, definida en la Ecuación (5), para esta semana (a corto plazo) y la CDF de todas las semanas de la temporada meteorológica correspondiente (a largo plazo) para cada parámetro y ubicación.

$$FS = \frac{1}{n} \sum_{i=1}^n \delta_i \quad (6)$$
$$\delta_i = |CDF_{lt}(x_i) - CDF_{st}(x_i)|$$

donde  $CDF_{lt}$  y  $CDF_{st}$  representan respectivamente la CDF a largo y corto plazo del parámetro  $x$ .

La suma ponderada (WS) de los estadísticos FS correspondientes a cada parámetro (FS<sub>j</sub>) de cada semana se calcula aplicando un factor de ponderación (wf<sub>j</sub>), donde “m” es el número de parámetros meteorológicos:

$$WS = \sum_{j=1}^m wf_j \cdot FS_j \quad (7)$$

El factor de ponderación elegido dependerá de la importancia que tenga cada parámetro en el crecimiento de las microalgas y deberá cumplir con:

$$\sum_{j=1}^m wf_j = 1 \quad (8)$$

A continuación, se seleccionan las mejores semanas candidatas (aplicando diferentes opciones de wfs) según la proporción que determina su impacto en el crecimiento de las microalgas. Por lo que se propone analizar la influencia de estos wfs en la clasificación de las semanas candidatas para una TMW.

De hecho, la generación de TMYs se realizó utilizando diferentes parámetros climáticos y distintos factores de ponderación (Marion and Urban 1995; Zarzalejo et al. 1995; Kalogirou 2003; Chan et al. 2006; Skeiker 2007; Zhang et al. 2017). Todas estas propuestas son esencialmente similares, siendo las principales diferencias los distintos parámetros climáticos considerados (tipo y número) y sus correspondientes factores de ponderación.

Los parámetros estudiados: temperatura (media, máxima, mínima y rango), PAR, y duración del día solar desempeñan un papel importante en el desarrollo de una TMS. Sin embargo, en nuestro caso de estudio, no tienen el mismo impacto en la productividad de las microalgas. En suma, algunos parámetros meteorológicos pueden ser más importantes que otros. Los parámetros más influyentes reciben el factor de ponderación (wf<sub>j</sub>) más alto por la representatividad de su impacto en el crecimiento de las microalgas.

En la Tabla 4-1, se proponen nueve escenarios con diferentes wfs para evaluar distintas opciones de wf<sub>s</sub>. Esto permitirá comprobar la robustez de la metodología. La idea es otorgar la misma importancia a los parámetros de temperatura: máxima (Tmx), mínima (Tmn), media (Tme), rango (Trg), irradiancia solar, PAR y duración del día solar (Nsol).

Tabla 4-1: Opciones de factores de ponderación (wf) para obtener la suma ponderada.

| Parameters  | wf_1 | wf_2 | wf_3 | wf_4 | wf_5 | wf_6 | wf_7 | wf_8 | wf_9 |
|-------------|------|------|------|------|------|------|------|------|------|
| <b>Tmx</b>  | 0.10 | 0.05 | 0.05 | 0.10 | 0.05 | 0.05 | 0.05 | 0.05 | 0.10 |
| <b>Tmn</b>  | 0.10 | 0.05 | 0.05 | 0.10 | 0.05 | 0.05 | 0.05 | 0.05 | 0.10 |
| <b>Tme</b>  | 0.30 | 0.40 | 0.30 | 0.25 | 0.25 | 0.45 | 0.40 | 0.40 | 0.20 |
| <b>Trg</b>  | -    | -    | -    | 0.05 | 0.05 | 0.05 | 0.05 | 0.05 | 0.10 |
| <b>PAR</b>  | 0.30 | 0.20 | 0.30 | 0.25 | 0.30 | 0.20 | 0.30 | 0.15 | 0.20 |
| <b>Nsol</b> | 0.20 | 0.30 | 0.30 | 0.25 | 0.30 | 0.20 | 0.15 | 0.30 | 0.30 |

Finalmente, la secuencia más representativa (en nuestro caso, la semana) entre las cinco semanas candidatas más prometedoras se obtiene determinando la frecuencia de repetición de las semanas candidatas, considerando su persistencia según los diferentes lags y wfs. Además, la decisión final sobre la elección de la TMW también se ve afectada por su posición en el período estacional específico. Esta posición se valida calculando la diferencia en Nsol entre el día en la mitad de la estación meteorológica y el cuarto día de la semana candidata, Ecuación (9). Esto se realizó para evitar valores extremos para una estación que pudieran comprometer los resultados esperados. La diferencia en Nsol se define según:

$$\Delta Nsol_q^w = \left| Nsol_{q/2}^w - Nsol_4^w \right| \quad (9)$$

donde  $Nsol_{q/2}^w$  representa el Nsol del cuarto día de la semana en medio de la estación meteorológica considerada ( $w = 1, 2, 3$  y  $4$  para primavera, verano, otoño e invierno) y  $Nsol_4^w$  corresponde a Nsol del cuarto día de la semana candidata.

### 4.3. Resultados y discusión

Aunque el crecimiento de las microalgas se ve afectado por diversos parámetros fisicoquímicos, como la temperatura, la luz, el pH, la salinidad y los nutrientes, entre otros, los resultados y la discusión presentados en este artículo se limitan al aporte de energía solar y temperatura.

Se seleccionaron las cinco semanas con los valores más bajos de WS para cada WWTP. La TMW seleccionada presenta una persistencia notable y una baja diferencia en  $\Delta N_{sol}^w$ . La persistencia de una semana corresponde al número de veces que aparece en la selección para diferentes factores de ponderación y diferentes lags. Al ampliar los criterios de selección final con más factores de ponderación y lags, surge una secuencia de nuevas semanas candidatas que podrían ser diferentes a sus predecesoras. En algunos casos, las mismas semanas se repiten, pero en un orden distinto. Finalmente, se espera que la TMW seleccionada presente las propiedades características a largo plazo de los datos meteorológicos. Se adopta el mismo proceso para cada una de las cuatro estaciones meteorológicas de cada una de las 18 WWTP. Para facilitar la lectura de los resultados, se presentan los detalles de las estadísticas semanales y a largo plazo en las siguientes Tabla 4-2, Tabla 4-3 y Tabla 4-4. El resto de los resultados se incluyen en el Apéndice B.

La Tabla 4-2 muestra las estadísticas trimestrales estacionales para la localidad de “Colmenarejo Este” durante el período 1991 a 2005. Incluye la media y la mediana de cada uno de los seis parámetros para las diferentes estaciones, así como la desviación típica, que proporciona información sobre la dispersión media de cada uno de ellos. Se observa una desviación típica entre 2.48 y 6.10 para los parámetros de temperatura; la PAR tiene una desviación típica alta con valores distribuidos en un rango entre 16.35 y 28.99, mientras que la desviación típica de Nsol está en torno a 1 en primavera y otoño y menor que 1 durante el verano y el invierno. La variabilidad diaria o estacional de estos parámetros de crecimiento afecta significativamente a la producción de microalgas. Teniendo en cuenta las variaciones estacionales, se puede demostrar que el invierno tiene condiciones meteorológicas desfavorables con menos luz, temperaturas muy bajas y un fotoperiodo inadecuado para el crecimiento de las microalgas. El verano ofrece los rangos de valores adecuados para maximizar la productividad, mientras que la primavera y el otoño son desfavorables para el

metabolismo de las microalgas. Se pueden observar variaciones extremas en estos parámetros a lo largo del año, lo que puede tener efectos inhibidores sobre las microalgas.

Debido al gran número de semanas para evaluar las nueve opciones de WF (Tabla 4-1), en este artículo no se presentan en forma de tabla las estadísticas de WS de los diferentes parámetros.

La Tabla 4-3 muestra los resultados obtenidos para la temporada de primavera en la localidad de Colmenarejo Este: cada celda muestra el ordinal de la semana candidata correspondiente a un conjunto de factores de ponderación (columna) y un número de lags (filas). Para cada par de factores de ponderación y tamaño del lags, se presentan las cinco mejores candidatas ordenadas de arriba a abajo según el valor mínimo de WS. En el caso de Colmenarejo Este, el número total de semanas analizadas es de 1204, de modo que, por ejemplo, la semana 235 representa la secuencia de siete días que comienza el 2 de mayo de 1993.

Tabla 4-2 : Estadísticas diarias de largo plazo en Colmenarejo Este

| <b>Spring</b>       |                         |            |            |            |                                           |             |
|---------------------|-------------------------|------------|------------|------------|-------------------------------------------|-------------|
|                     | <b>Temperature (°C)</b> |            |            |            | <b>Solar irradiance (W/m<sup>2</sup>)</b> |             |
|                     | <b>Tmx</b>              | <b>Tmn</b> | <b>Tme</b> | <b>Trg</b> | <b>PAR</b>                                | <b>Nsol</b> |
| <b>Mean</b>         | 16.25                   | 5.40       | 10.84      | 10.85      | 91.26                                     | 13.05       |
| <b>Median</b>       | 16.05                   | 5.11       | 10.45      | 10.98      | 92.99                                     | 13.13       |
| <b>Av. Std. Des</b> | 4.81                    | 3.41       | 3.97       | 3.43       | 28.99                                     | 1.04        |
| <b>Summer</b>       |                         |            |            |            |                                           |             |
|                     | <b>Temperature (°C)</b> |            |            |            | <b>Solar irradiance (W/m<sup>2</sup>)</b> |             |
|                     | <b>Tmx</b>              | <b>Tmn</b> | <b>Tme</b> | <b>Trg</b> | <b>PAR</b>                                | <b>Nsol</b> |
| <b>Mean</b>         | 28.46                   | 15.54      | 22.29      | 12.91      | 126.57                                    | 14.35       |
| <b>Median</b>       | 29.21                   | 16.00      | 22.88      | 13.30      | 130.40                                    | 14.58       |
| <b>Av. Std. Des</b> | 4.41                    | 3.26       | 3.80       | 2.48       | 20.52                                     | 0.57        |
| <b>Autumn</b>       |                         |            |            |            |                                           |             |
|                     | <b>Temperature (°C)</b> |            |            |            | <b>Solar irradiance (W/m<sup>2</sup>)</b> |             |
|                     | <b>Tmx</b>              | <b>Tmn</b> | <b>Tme</b> | <b>Trg</b> | <b>PAR</b>                                | <b>Nsol</b> |
| <b>Mean</b>         | 17.27                   | 8.00       | 12.39      | 9.27       | 61.25                                     | 10.91       |
| <b>Median</b>       | 16.71                   | 8.06       | 12.06      | 9.42       | 58.03                                     | 10.85       |
| <b>Av. Std. Des</b> | 6.10                    | 4.54       | 5.18       | 3.35       | 26.51                                     | 1.02        |
| <b>Winter</b>       |                         |            |            |            |                                           |             |
|                     | <b>Temperature (°C)</b> |            |            |            | <b>Solar irradiance (W/m<sup>2</sup>)</b> |             |
|                     | <b>Tmx</b>              | <b>Tmn</b> | <b>Tme</b> | <b>Trg</b> | <b>PAR</b>                                | <b>Nsol</b> |
| <b>Mean</b>         | 8.61                    | 0.50       | 4.10       | 8.11       | 39.68                                     | 9.63        |
| <b>Median</b>       | 8.54                    | 0.12       | 4.12       | 8.00       | 41.24                                     | 9.39        |
| <b>Av. Std. Des</b> | 2.91                    | 2.98       | 2.65       | 3.07       | 16.35                                     | 0.55        |

Tabla 4-3 : Semanas candidatas en primavera para Colmenarejo Este para diferentes conjuntos de factores de ponderación y tamaño del lag

| wf<br>lags       | wf_1 | wf_2 | wf_3 | wf_4 | wf_5 | wf_6 | wf_7 | wf_8 | wf_9 |
|------------------|------|------|------|------|------|------|------|------|------|
| <b>lags = 10</b> | 1082 | 1082 | 642  | 641  | 642  | 235  | 642  | 235  | 235  |
|                  | 641  | 235  | 235  | 235  | 235  | 641  | 235  | 641  | 641  |
|                  | 642  | 641  | 641  | 642  | 641  | 642  | 641  | 642  | 642  |
|                  | 235  | 642  | 1082 | 1082 | 1081 | 1081 | 1081 | 1082 | 378  |
|                  | 507  | 1081 | 1081 | 378  | 507  | 1082 | 1082 | 1081 | 1082 |
| <b>lags = 20</b> | 642  | 642  | 642  | 642  | 642  | 642  | 642  | 642  | 642  |
|                  | 1082 | 1081 | 1081 | 641  | 641  | 235  | 641  | 235  | 235  |
|                  | 641  | 1082 | 641  | 235  | 235  | 1081 | 235  | 641  | 641  |
|                  | 496  | 641  | 235  | 1082 | 1081 | 641  | 1081 | 1081 | 1082 |
|                  | 235  | 235  | 507  | 496  | 507  | 1082 | 1082 | 1082 | 864  |
| <b>lags = 30</b> | 642  | 642  | 642  | 642  | 642  | 642  | 642  | 642  | 642  |
|                  | 1082 | 1082 | 507  | 235  | 235  | 1081 | 235  | 235  | 235  |
|                  | 496  | 1081 | 1081 | 641  | 641  | 235  | 1081 | 1081 | 641  |
|                  | 641  | 641  | 641  | 1082 | 507  | 641  | 641  | 939  | 378  |
|                  | 507  | 496  | 1082 | 496  | 1081 | 1082 | 507  | 641  | 1082 |

La TMW para cada estación y cada una de las 18 localidades se presenta en la Tabla B2. En esta Tabla B2, solo se proporciona el primer día de la semana seleccionada. Si bien los años de las semanas seleccionadas no son idénticos, se observa una ligera diferencia en los períodos (meses y días) del año para los emplazamientos estudiados. Esta diferencia podría deberse a las variaciones de las temperaturas promedio que disminuyen con la latitud. Sin embargo, las variaciones de la PAR entre localidades son muy pequeñas y se deben a las pequeñas diferencias de latitud entre un punto y otro. Esto último puede tener poca influencia en los resultados esperados, especialmente porque la diferencia de PAR es muy pequeña entre localidades. Otros factores que también juegan un papel muy importante en la generación de semanas tipo son las wfs asignadas a las variables y el número de lags (Tabla 4-3). Si nos centramos en una columna (valor wf) de la Tabla 4-3, podemos ver que casi las mismas semanas reaparecen en diferentes posiciones al cambiar el número de lags. Por otro lado, al considerar un número de lags, la tendencia de los resultados también varía cada vez que se modifica la distribución de las semanas de primavera en el mismo sentido que se mencionó anteriormente. De ahí el interés en elegir varias opciones de semanas de primavera que compensen la falta de información sobre el parámetro meteorológico con mayor impacto en el crecimiento de las microalgas.

La Tabla 4-4 muestra la información correspondiente a todas las semanas candidatas generadas para la primavera en Colmenarejo Este, representadas en la Tabla 4-3. En la Tabla 4-4, también se muestra el número de repeticiones de estas semanas candidatas generadas, representadas por su ordinal en la secuencia de 1204 semanas de primavera. Una vez seleccionada una semana candidata su número de secuencia identifica el inicio de la semana indicando el año, mes y día correspondiente.

Tabla 4-4 : Semanas candidatas en la localidad de Colmenarejo Este durante la primavera

| Number of Week | Frequency | Year | Month | Day | $Nsol_4^w$ | $\Delta Nsol_q^w$ |
|----------------|-----------|------|-------|-----|------------|-------------------|
| 235            | 24        | 1993 | 5     | 2   | 13.91      | 0.78              |
| 378            | 3         | 1995 | 4     | 3   | 12.64      | 0.49              |
| 496            | 5         | 1996 | 5     | 5   | 14.05      | 0.92              |
| 507            | 8         | 1996 | 5     | 16  | 14.41      | 1.28              |
| 641            | 27        | 1998 | 4     | 8   | 12.91      | 0.22              |
| 642            | 27        | 1998 | 4     | 9   | 12.96      | 0.18              |
| 864            | 1         | 2001 | 3     | 4   | 11.31      | 1.82              |
| 939            | 1         | 2001 | 5     | 18  | 14.44      | 1.31              |
| 1081           | 18        | 2003 | 4     | 18  | 13.35      | 0.21              |
| 1082           | 21        | 2003 | 4     | 19  | 13.39      | 0.26              |

En esta Tabla 4-4 también se muestra  $(Nsol_4^w)$  del cuarto día de cada una de las semanas candidatas, así como el valor absoluto de la diferencia  $(\Delta Nsol_q^w)$  entre el Nsol del cuarto día de la semana a mitad de la estación  $(Nsol_{q/2}^w)$  y el Nsol de la semana candidata  $(Nsol_4^w)$ . Esta diferencia permite apreciar la posición de la semana en relación con los extremos de esa estación concreta. Como se mencionó anteriormente, esto evita tener una semana típica con condiciones meteorológicas más cercanas a la temporada anterior o posterior, de forma que, la TMW seleccionada tiene la mayor frecuencia de ocurrencia. En caso de que esta frecuencia de ocurrencia sea igual, la semana meteorológica típica sería aquella con el valor más bajo de  $(\Delta Nsol_q^w)$ . Por ejemplo, el Nsol del cuarto día de la semana a mitad de la

temporada de primavera en la localidad de Colmenarejo Este es de 12.96 h. Según las diferentes semanas presentadas en la Tabla 4-4, la frecuencia de ocurrencia en la semana 641 es la misma que en la semana 642. Esta coincidencia en el número de ocurrencias se explica por la diferencia de un día entre estas dos semanas: una comienza el 8 de abril de 1998 y la otra el 9 de abril de 1998. Por lo tanto, la semana representativa de las condiciones meteorológicas primaverales en Colmenarejo Este se elige como la semana con el valor más bajo de  $(\Delta N_{sol_q}^w)$ . En el caso de Colmenarejo Este, la semana 642 es la semana típica que representa las condiciones meteorológicas primaverales del período 1991-2005.

La Comunidad de Madrid no es muy extensa y por lo que se observa una pequeña diferencia del orden de magnitud tanto para la PAR como para la temperatura en una estación dada entre una localidad a otra (Figura 4-2 y B1–B3). Esto también se puede observar en las Tabla 4-2 y B1 (Apéndice B), donde se presentan las estadísticas de datos meteorológicos a largo plazo para cuatro localidades.

A partir de los valores medios diarios de los parámetros de TMW obtenidos para cada estación se representó gráficamente la variabilidad de algunos de ellos como se ilustra en la Figura 4-2, que muestra la variación diaria de los valores medios de PAR y los parámetros de temperatura para las diferentes estaciones. Las Figura 4-2 y B1–B3 indican que, para ambos parámetros meteorológicos, existe variabilidad interestacional. Los valores más altos de PAR y temperatura se observan durante el verano y los más bajos durante el invierno. Por un lado, la oscilación térmica es mayor entre verano e invierno. Dado que Madrid se encuentra en la zona centro peninsular, una posible explicación podría ser la influencia del efecto moderador del mar, que disminuye según nos alejamos de la costa. Además, las Figura 4-2 y B1–B3 muestran que la amplitud térmica es menor en invierno. Las estaciones de primavera y otoño presentan temperaturas medias diarias aproximadamente similares. Sin embargo, la PAR media diaria es menor en otoño que en primavera, y su variabilidad es a veces similar a la del invierno en ciertas localidades. Esto se explica por el predominio de cielos cubiertos y probablemente lluviosos en esta época del año. De hecho, la nubosidad reduce la insolación al obstruir la radiación solar.




Figura 4-2 : Variaciones diarias de los valores medios diarios de temperatura (media, máxima y mínima) y PAR para las TMW seleccionadas en cada estación del año en Colmenarejo Este (1991 a 2005).

## 4.4. Conclusiones

En este trabajo, se propone una metodología para la generación de TMS para la simulación del crecimiento y la productividad de organismos fotosintéticos, gestión de aguas residuales (WWT) o agricultura. La selección de secuencias potenciales según el período de crecimiento del organismo se realiza mediante el remuestreo de los datos meteorológicos disponibles lo que, en nuestro caso de estudio, aumenta el número de secuencias candidatas en un 700 %.

El conocimiento previo del impacto de los factores meteorológicos permitiría optimizar la productividad de los cultivos, el uso racional del agua y evaluar el período del año adecuado para la gestión de aguas residuales en sistemas de HRAP con microalgas. Es importante considerar la variabilidad a largo plazo de los parámetros físicos entre estaciones para desarrollar sistemas sostenibles. La ventaja de los datos contenidos en la TMS es que permiten superar las limitaciones de potencia computacional cuando se requieren múltiples simulaciones para obtener una visión general del comportamiento del sistema biológico en función de las condiciones climáticas locales.

El enfoque TMS ha permitido generar una secuencia típica denominada TMW, generada para simular el crecimiento de la biomasa de microalgas para la producción de biocombustibles o el tratamiento sostenible de aguas residuales en un HRAP. Para la generación de la TMW en nuestro caso de estudio, una vez identificados los parámetros meteorológicos más relevantes, se realizó un examen detallado de los diferentes factores de peso para cada una de las variables consideradas con el objetivo de asegurar la robustez de la metodología.

**Contribuciones de cada autor:** Conceptualización, R.X.V. y L.F.Z.; metodología, L.F.Z., O.W. y A.A.N.; software, O.W.; validación, O.W. y L.F.Z.; análisis formal, L.F.Z., O.W. y F.F.-C.; investigación, O.W., A.R.-L., R.X.V., A.A.N., L.F.Z. y F.F.-C.; recursos, R.X.V. y L.F.Z.; tratamiento de datos, O.W., R.X.V., A.A.N., L.F.Z. y F.F.-C.; redacción: preparación del borrador original, O.W., A.R.-L., R.X.V., A.A.N., L.F.Z. y F.F.-C.; redacción: revisión y edición, O.W., R.X.V., A.A.N., A.R.-L., L.F.Z. y F.F.-C.; visualización, O.W., A.A.N. y A.R.-L.; supervisión, R.X.V. y L.F.Z.; administración del proyecto, R.X.V. y L.F.Z.; y búsqueda de financiación, R.X.V. Todos los autores han leído y aceptado la versión publicada del manuscrito.

**Financiación:** Esta investigación fue financiada por la Comunidad Autónoma de Madrid (España) y por el programa FEDER «A way of making Europe» ALGATEC-CM (S2018/BAA-4532), el Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033) y el programa «Next Generation EU»/PRTR de la Unión Europea, TEDDY (TED2021-130366B-I00).

**Declaración del Comité de Ética de la Investigación:** No aplica.

**Declaración de consentimiento informado:** No aplica.

**Declaración de disponibilidad de datos:** Los datos proporcionados por el ECMWF utilizados en este estudio están disponibles en <https://www.ecmwf.int/en/forecasts/access-forecasts/access-archive-datasets>, número de referencia (Hersbach et al. 2020b) – consultado el 17 de abril de 2021 –. Los datos de CMSAF utilizados en este estudio están

disponibles en <https://wui.cmsaf.eu/safira/action/viewProduktList?dId=2&d-1342877-p=6>, números de referencia (Müller et al. 2015) – consultado el 14 de abril de 2021 –.

**Agradecimientos:** Los autores agradecen la contribución de CYTED-Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo (RED RENUWAL P320RT0005 CYTED).

**Conflictos de intereses:** Los autores declaran no tener ningún conflicto de intereses.

## 4.5. Apéndice B




Figura B1. Variaciones diarias de los valores medios diarios de temperatura (media, máxima y mínima) y PAR para las TMW seleccionadas para cada estación del año en Fresno-Ribatejada (1991 a 2005).




Figura B2. Variaciones diarias de los valores medios diarios de temperatura (media, máxima y mínima) y PAR para las TMW seleccionadas para cada estación en Ríosequillo (1991 a 2005).




Figura B3. Variaciones diarias de los valores medios diarios de temperatura (media, máxima y mínima) y PAR para las TMW seleccionadas para cada estación en Valdelaguna (1991 a 2005).

Tabla B1. Estadísticos a largo plazo para los cuatro emplazamientos.

| <b>FRESNO-RIBATEJADA</b> |               |        |           |               |        |           |               |        |           |               |        |           |
|--------------------------|---------------|--------|-----------|---------------|--------|-----------|---------------|--------|-----------|---------------|--------|-----------|
|                          | <b>Spring</b> |        |           | <b>Summer</b> |        |           | <b>Autumn</b> |        |           | <b>Winter</b> |        |           |
|                          | Mean          | Median | Std. Dev. | Mean          | Median | Std. Dev. | Mean          | Median | Std. Dev. | Mean          | Median | Std. Dev. |
| Tmx                      | 16.36         | 16.20  | 4.83      | 28.55         | 29.41  | 4.38      | 17.34         | 16.75  | 6.09      | 8.73          | 8.62   | 2.91      |
| Tmn                      | 5.55          | 5.25   | 3.43      | 15.67         | 16.13  | 3.29      | 8.11          | 8.22   | 4.54      | 0.68          | 0.27   | 2.97      |
| Tme                      | 10.95         | 10.52  | 4.00      | 22.41         | 23.01  | 3.78      | 12.46         | 12.17  | 5.16      | 4.25          | 4.29   | 2.63      |
| Trg                      | 10.81         | 10.94  | 3.45      | 12.88         | 13.30  | 2.46      | 9.24          | 9.45   | 3.37      | 8.05          | 7.96   | 3.10      |
| PAR                      | 93.53         | 94.58  | 28.07     | 126.61        | 130.02 | 19.44     | 62.46         | 59.39  | 26.16     | 40.31         | 41.47  | 16.22     |
| NSol                     | 13.05         | 13.13  | 1.04      | 14.35         | 14.59  | 0.58      | 10.91         | 10.85  | 1.02      | 9.62          | 9.39   | 0.55      |

| <b>RIOSEQUILLO</b> |               |        |           |               |        |           |               |        |           |               |        |           |
|--------------------|---------------|--------|-----------|---------------|--------|-----------|---------------|--------|-----------|---------------|--------|-----------|
|                    | <b>Spring</b> |        |           | <b>Summer</b> |        |           | <b>Autumn</b> |        |           | <b>Winter</b> |        |           |
|                    | mean          | median | Std. Dev. | mean          | median | Std. Dev. | mean          | median | Std. Dev. | mean          | median | Std. Dev. |
| Tmx                | 15.21         | 14.99  | 4.76      | 27.06         | 27.75  | 4.44      | 16.23         | 15.69  | 6.02      | 7.80          | 7.73   | 2.95      |
| Tmn                | 4.22          | 4.05   | 3.39      | 13.84         | 14.18  | 3.22      | 6.83          | 6.99   | 4.40      | -0.24         | -0.57  | 2.99      |
| Tme                | 9.69          | 9.37   | 3.92      | 20.72         | 21.27  | 3.76      | 11.24         | 10.95  | 5.00      | 3.31          | 3.31   | 2.65      |
| Trg                | 10.99         | 11.00  | 3.59      | 13.22         | 13.61  | 2.71      | 9.39          | 9.44   | 3.56      | 8.03          | 7.93   | 3.12      |
| PAR                | 85.56         | 87.74  | 30.37     | 121.60        | 127.06 | 23.67     | 56.75         | 53.00  | 26.28     | 36.83         | 38.15  | 16.25     |
| NSol               | 13.07         | 13.15  | 1.05      | 14.38         | 14.62  | 0.58      | 10.89         | 10.83  | 1.04      | 9.59          | 9.36   | 0.56      |

| <b>VALDELAGUNA</b> |               |        |           |               |        |           |               |        |           |               |        |           |
|--------------------|---------------|--------|-----------|---------------|--------|-----------|---------------|--------|-----------|---------------|--------|-----------|
|                    | <b>Spring</b> |        |           | <b>Summer</b> |        |           | <b>Autumn</b> |        |           | <b>Winter</b> |        |           |
|                    | mean          | median | Std. Dev. | mean          | median | Std. Dev. | mean          | median | Std. Dev. | mean          | median | Std. Dev. |
| Tmx                | 17.36         | 17.14  | 4.93      | 29.82         | 30.67  | 4.35      | 18.24         | 17.70  | 6.16      | 9.49          | 9.36   | 2.90      |
| Tmn                | 6.49          | 6.14   | 3.51      | 17.10         | 17.63  | 3.35      | 9.00          | 9.01   | 4.73      | 1.25          | 0.92   | 3.06      |
| Tme                | 11.92         | 11.43  | 4.09      | 23.76         | 24.35  | 3.80      | 13.37         | 12.99  | 5.32      | 4.92          | 5.00   | 2.66      |
| Trg                | 10.87         | 11.18  | 3.44      | 12.71         | 13.07  | 2.31      | 9.24          | 9.51   | 3.28      | 8.24          | 8.27   | 3.18      |
| PAR                | 94.36         | 95.49  | 27.66     | 127.23        | 130.60 | 18.73     | 63.75         | 60.96  | 25.94     | 41.55         | 42.45  | 15.88     |
| NSol               | 13.04         | 13.12  | 1.02      | 14.32         | 14.55  | 0.57      | 10.92         | 10.86  | 1.01      | 9.66          | 9.43   | 0.55      |

Generación de secuencias meteorológicas típicas para simular el crecimiento y la  
producción de sistemas biológicos

Tabla B2. Primer día de la Semana Meteorológica Típica de cada temporada para cada una de las  
plantas WWTP.

| Site                    | Season | Year | Month | Day | Site                      | Season | Year | Month | Day |
|-------------------------|--------|------|-------|-----|---------------------------|--------|------|-------|-----|
| ARANJUEZ                | Spring | 1994 | 03    | 20  | ORUSCO DE<br>TAJUÑA       | Spring | 2003 | 04    | 20  |
|                         | Summer | 1997 | 06    | 20  |                           | Summer | 1995 | 06    | 19  |
|                         | Autumn | 1993 | 11    | 06  |                           | Autumn | 1996 | 11    | 20  |
|                         | Winter | 1996 | 12    | 18  |                           | Winter | 1992 | 12    | 18  |
| BATRES                  | Spring | 1993 | 05    | 02  | PEZUELA DE LAS<br>TORRES  | Spring | 1993 | 05    | 02  |
|                         | Summer | 1991 | 06    | 19  |                           | Summer | 1997 | 06    | 15  |
|                         | Autumn | 1996 | 10    | 19  |                           | Autumn | 1996 | 09    | 08  |
|                         | Winter | 1996 | 12    | 14  |                           | Winter | 1994 | 12    | 16  |
| COLMENAREJO<br>ESTE     | Spring | 1998 | 04    | 09  | RIOSEQUILLO               | Spring | 2002 | 04    | 09  |
|                         | Summer | 1994 | 06    | 16  |                           | Summer | 1994 | 06    | 17  |
|                         | Autumn | 1996 | 09    | 20  |                           | Autumn | 1994 | 10    | 13  |
|                         | Winter | 1996 | 12    | 18  |                           | Winter | 2000 | 12    | 18  |
| CONJUNTA DE<br>GASCONES | Spring | 2003 | 04    | 19  | ROBLEDO                   | Spring | 1995 | 04    | 03  |
|                         | Summer | 1991 | 06    | 19  |                           | Summer | 1991 | 06    | 19  |
|                         | Autumn | 1996 | 11    | 21  |                           | Autumn | 1996 | 09    | 20  |
|                         | Winter | 1995 | 12    | 14  |                           | Winter | 1996 | 12    | 15  |
| ESTREMERÁ               | Spring | 1993 | 03    | 17  | ROZAS DE<br>PUERTO REAL   | Spring | 1996 | 03    | 27  |
|                         | Summer | 1994 | 06    | 19  |                           | Summer | 1998 | 06    | 19  |
|                         | Autumn | 1996 | 11    | 20  |                           | Autumn | 2001 | 09    | 27  |
|                         | Winter | 1996 | 12    | 16  |                           | Winter | 1996 | 12    | 15  |
| FRESNO-<br>RIBATEJADA   | Spring | 2002 | 04    | 11  | SAN MARTIN<br>NORESTE     | Spring | 2001 | 05    | 18  |
|                         | Summer | 1991 | 06    | 19  |                           | Summer | 2000 | 06    | 15  |
|                         | Autumn | 1996 | 09    | 08  |                           | Autumn | 1999 | 10    | 11  |
|                         | Winter | 1995 | 12    | 14  |                           | Winter | 1996 | 12    | 15  |
| FUENTIDUEÑA             | Spring | 2003 | 04    | 20  | SANTA Mª DE LA<br>ALAMEDA | Spring | 1998 | 05    | 20  |
|                         | Summer | 1995 | 06    | 19  |                           | Summer | 1994 | 06    | 16  |
|                         | Autumn | 1998 | 09    | 21  |                           | Autumn | 1996 | 09    | 20  |
|                         | Winter | 1996 | 12    | 16  |                           | Winter | 1996 | 12    | 15  |
| LOZOYUELA               | Spring | 2002 | 04    | 09  | TALAMANCA DEL<br>JARAMA   | Spring | 2003 | 04    | 19  |
|                         | Summer | 1997 | 06    | 20  |                           | Summer | 1997 | 06    | 20  |
|                         | Autumn | 1996 | 09    | 20  |                           | Autumn | 1996 | 09    | 20  |
|                         | Winter | 2000 | 12    | 18  |                           | Winter | 1994 | 12    | 16  |
| NAVALAFUENTE            | Spring | 2003 | 04    | 19  | VALDELAGUNA               | Spring | 1993 | 05    | 02  |
|                         | Summer | 1997 | 06    | 20  |                           | Summer | 1997 | 06    | 20  |
|                         | Autumn | 1994 | 10    | 13  |                           | Autumn | 1998 | 09    | 21  |
|                         | Winter | 1996 | 12    | 16  |                           | Winter | 1992 | 12    | 18  |



## 5. Un nuevo enfoque metodológico para simular el crecimiento de organismos fotosintéticos mediante secuencias meteorológicas representativas a largo plazo: un caso de estudio de microalgas (*Chlorella vulgaris*)

Ousmane Wane<sup>1,2,\*</sup>, Luis F. Zarzalejo<sup>2,\*</sup>, Francisco Ferrera-Cobos<sup>2</sup>, Ana A. Navarro<sup>2</sup> y Rita X. Valenzuela<sup>2</sup>

<sup>1</sup> E.T.S.I. Agronómica, Alimentaria y Biosistemas, Universidad Politécnica de Madrid, Avda. Puerta Hierro 2-4, 28040 Madrid, Spain

<sup>2</sup> CIEMAT Departamento de Energía, División de Energías Renovables, Avda. Complutense 40, 28040 Madrid, España;

francisco.ferrera@ciemat.es (F.F.-C.); a.navarro@ciemat.es (A.A.N.); r.valenzuela@ciemat.es (R.X.V.)

\*Correspondencia: ousmane.wane@alumnos.upm.es o ousmane.wane@ciemat.es (O.W.); lf.zarzalejo@ciemat.es (L.F.Z.)

Appl. Sci. 2024, 14(22), 10580; <https://doi.org/10.3390/app142210580>

### Resumen

El crecimiento de organismos fotosintéticos requiere rangos específicos de temperatura y radiación fotosintéticamente activa. Monitorizar y mantener estas condiciones es técnicamente difícil, especialmente en cultivos al aire libre. En estos casos, una secuencia meteorológica típica puede ser una herramienta útil para estimar el crecimiento de organismos fotosintéticos. Este estudio propone una nueva metodología basada en secuencias meteorológicas a largo plazo para simular el crecimiento de organismos fotosintéticos. Este caso de estudio aborda la simulación del crecimiento de microalgas (*Chlorella vulgaris*) en Riosequillo, al norte de la Comunidad de Madrid (España), durante las cuatro estaciones del año. Posteriormente, estas estimaciones se comparan con los resultados observados en un cultivo experimental de microalgas en aguas residuales domésticas. Los resultados también muestran una fuerte concordancia con la función de distribución de probabilidad de la concentración diaria de biomasa, obteniendo los mejores resultados para las secuencias meteorológicas típicas de verano y primavera. La metodología parece confirmar la representatividad de las secuencias meteorológicas típicas, permite identificar los escenarios de producción más probables para los análisis de viabilidad de proyectos y puede aplicarse a la toma de decisiones.

## 5.1. Introducción

El uso de algas para la eliminación, biotransformación o mineralización de diversos nutrientes y metales pesados de las aguas residuales es un proceso respetuoso con el medio ambiente, ya que no se produce contaminación secundaria si la biomasa producida se utiliza como materia prima y las aguas residuales tratadas se reutilizan. Según (Oswald and Gotaas 1957; García et al. 2006), la investigación en este campo no es nueva y ha demostrado la capacidad de las microalgas para utilizar eficientemente el nitrógeno, el fósforo y otras impurezas de las aguas residuales para promover su crecimiento (Wang et al. 2010; Sacristán de Alva et al. 2013; AlMomani and Örmeci 2016). Además de estos nutrientes que aportan las aguas residuales, las microalgas también dependen de otros parámetros externos, como la luz, que se absorbe y utiliza en el proceso de fotosíntesis (Janssen 2016), y la temperatura, que influye en la fotosíntesis y la división celular (Ras et al. 2013). Además, al ser microorganismos autótrofos, las microalgas contribuyen a reducir la concentración de gases de efecto invernadero fijando CO<sub>2</sub> durante su crecimiento (Gerotto et al. 2020). Estos esfuerzos a lo largo de los años permitieron alcanzar un nivel avanzado de dominio de esta tecnología, lo que ha llevado a su implementación en una comunidad rural de 300 personas (Buchanan et al. 2018).

Un número considerable de organizaciones de investigación (Singh and Singh 2015; Darvehei et al. 2018) han estudiado los efectos de la temperatura y la irradiación solar en el crecimiento de muchas cepas diferentes de microalgas cultivadas en sistemas abiertos o cerrados. Un estudio del impacto de la temperatura en las microalgas mostró una disminución de células viables a altas temperaturas y un aumento de 20 °C a 28 °C, el rango de temperatura óptimo (Serra-Maia et al. 2016). Este rango de temperatura óptimo varía dependiendo de la cepa de microalgas (Singh and Singh 2015). Con respecto a la luz incidente, se investigaron tres niveles diferentes de irradiación solar (6213, 2741 y 3799 Wh m<sup>-2</sup> d<sup>-1</sup>) para comprender la influencia de la irradiación solar en un consorcio de microalgas y bacterias cultivado en 80 L de aguas residuales domésticas en un “estanque de algas de alto rendimiento” (HRAP) al aire libre (Arcila and Buitrón 2017). De manera similar, el efecto de ambos parámetros en el crecimiento de las microalgas se estudió en (Bernard and Rémond 2012) mediante el modelado y la validación de la variación en la tasa de crecimiento como una función de la temperatura a diferentes niveles de intensidad de luz. Además de la importancia de la intensidad de la luz, su calidad y fotoperiodicidad también desempeñan un

papel fundamental en el metabolismo de las microalgas. Por ejemplo, el trabajo presentado en (Metsoviti et al. 2020) mostró una tasa de crecimiento más rápida y un mayor contenido lipídico en la biomasa de algas cuando el medio recibió luz blanca en lugar de luz roja.

Los cultivos de microalgas al aire libre a gran escala, bajo irradiación solar natural diaria o estacional y temperatura, produjeron resultados satisfactorios para comprender el impacto de ambos parámetros de cultivo (Huesemann et al. 2016; Díez-Montero et al. 2020; Hoyo et al. 2022). Sin embargo, es importante conocer la variabilidad temporal a largo plazo de estos parámetros al planificar la instalación de un sistema HRAP en un sitio determinado. Para considerar la variabilidad climática en cultivos masivos al aire libre, se han desarrollado secuencias meteorológicas típicas (TMS) como paso preliminar para evaluar los efectos de la temperatura y la irradiación solar en el crecimiento de microalgas en HRAP, como en (Wane et al. 2023). Esto permite considerar las condiciones extremas de estas variables al evaluar la viabilidad a largo plazo de un proyecto propuesto.

Sin embargo, la viabilidad económica de un sistema de cultivo en estanques abiertos en una ubicación determinada está estrechamente relacionada con la variabilidad climática. Cuando se cultivan microalgas en un estanque abierto, los parámetros meteorológicos, entre otros, escapan a nuestro control. Las fluctuaciones diarias y estacionales de los parámetros climáticos de cultivo afectan significativamente el metabolismo de las microalgas (Díez-Montero et al. 2020). En algunos casos, esto podría tener efectos negativos en la productividad de estos microorganismos y, por lo tanto, en la calidad del reciclaje de agua, energía y nutrientes fertilizantes. En un sistema de cultivo en estanques abiertos para microalgas, la temperatura y la radiación fotosintéticamente activa (PAR) son los parámetros meteorológicos más relevantes. En el caso de la radiación solar, asumiendo la representatividad del período cubierto por la base de datos meteorológicos disponible, la función de distribución de probabilidad empírica correspondiente (Gilman et al. 2012) permite caracterizar su variabilidad temporal a largo plazo. Trabajos previos en el campo de la generación de energía solar térmica (Fernández-Peruchena et al. 2016; Fernández-Peruchena et al. 2018) han presentado, desde el punto de vista de la viabilidad económica, análisis probabilísticos de diferentes escenarios de producción.

Este trabajo presenta las productividades diarias promedio (en términos de concentración de microalgas) correspondientes a  $n$  secuencias meteorológicas de crecimiento (1204 en nuestro

caso de estudio) simuladas a partir de mediciones horarias de PAR y temperatura registradas *in situ* mediante un modelo de producción simplificado. Esta serie de "productividades de biomasa" para una estación determinada se comparó con la productividad correspondiente al TMS representativo para el mismo período del año (Wane et al. 2023). Este manuscrito se estructura de la siguiente manera: la Sección 5.2 presenta el caso de estudio y describe el conjunto de datos medidos, el modelo de crecimiento propuesto en este trabajo y el modelo de simulación empleado. La Sección 5.3 presenta los principales resultados y su discusión. Finalmente, la Sección 5.4 presenta las conclusiones y el trabajo futuro.

## 5.2. Materiales y métodos

El crecimiento de organismos fotosintéticos (plantas, protistas y bacterias) requiere condiciones difíciles de lograr, especialmente cuando este bioproceso se lleva a cabo en un dispositivo expuesto a la intemperie. En este caso, el rendimiento del cultivo se vería significativamente afectado por los impactos ambientales que cambian a lo largo del año. Sin embargo, el desarrollo óptimo del cultivo depende de muchos factores, algunos de los cuales influyen directamente en las características de crecimiento. Este es el caso de la temperatura y la luz o la radiación fotosintéticamente activa (PAR) en cultivos masivos al aire libre. En esta situación, una representación de la variabilidad a largo plazo de estos dos parámetros en un sitio determinado puede ser ventajosa al utilizar herramientas de simulación de crecimiento en organismos fotosintéticos o al realizar estudios a escala de laboratorio para su aplicación en dicho sitio.

Una secuencia meteorológica de crecimiento (GMS) corresponde a una secuencia de días consecutivos en un sitio y una estación determinados; el número de días consecutivos de cada GMS puede adaptarse teniendo en cuenta el período de crecimiento de la especie fotosintética en estudio. Esta herramienta adaptativa se ha diseñado para obtener datos de entrada para simular diferentes tipos de cultivos con un período de crecimiento de unos pocos días a unas pocas semanas. Por lo tanto, el cultivo de microalgas u otras especies vegetales podría ser un caso de estudio.

Por otro lado, proporciona una representación general de la variabilidad a largo plazo de la irradiancia solar y la temperatura durante un período correspondiente al tiempo que tarda la especie de cultivo en alcanzar la cosecha. La simulación de la productividad de microalgas a partir de conjuntos de datos meteorológicos a largo plazo ofrece la oportunidad de explorar la rentabilidad del cultivo en diferentes escenarios antes de su aplicación *in situ*. En este

contexto, el cultivo de microalgas, tomates o cualquier otro cultivo podría ser un ejemplo de un caso práctico de simulación numérica que incluye la PAR y la temperatura como datos de entrada.

### 5.2.1. Caso de estudio

El foco del caso de estudio es un modelo de tratamiento de aguas residuales basado en microalgas. Modelar un sistema de este tipo puede ser beneficioso para anticipar posibles obstáculos y tomar decisiones sobre su implementación.

Según (Su et al. 2011), más del 80% del nitrógeno total y el 70% del fósforo total en aguas residuales se eliminan en 5 días, con una productividad de biomasa igual a  $0,64 \text{ g L}^{-1} \text{ d}^{-1}$  para el cultivo por lotes. Además, Zou et al. (2020) obtuvieron un resultado significativo de  $1,72 \text{ g L}^{-1} \text{ d}^{-1}$  de biomasa de microalgas producida durante el tratamiento por lotes y propusieron que un tiempo de retención hidráulica de 7 a 9 días podría ser eficiente para la eliminación de nutrientes y la producción de biomasa de microalgas durante el tratamiento continuo (Zou et al. 2020). En nuestro caso de estudio, se tuvo en cuenta la variabilidad climática a largo plazo de la temperatura del aire y la PAR mediante la generación de un conjunto de  $n$  GMS que consta de siete días consecutivos generados de acuerdo con la metodología propuesta en (Wane et al. 2023). La metodología ofrece un número significativo de secuencias de siete días para cada estación del año, con 1204 para primavera, 1204 para verano, 1190 para otoño y 1184 para invierno, adoptando el siguiente enfoque.

$$E_w A_y = \{d_1, d_2, \dots, d_q\}$$

$$S_1 = \{d_1, d_2, \dots, d_7\}, \quad S_2 = \{d_2, d_3, \dots, d_8\}, \quad \dots \quad S_p = \{d_{q-6}, d_{q-5}, \dots, d_q\}$$

Donde EA corresponde a todos los días disponibles ( $n$ ) para una estación determinada y  $S_m$  es un conjunto de una secuencia de 7 días consecutivos (con  $m = n - 6$ ).

Se aplicó el estadístico de Filkenstein-Schafer (FS) y un criterio de persistencia para determinar la secuencia más típica de la serie:

$$FS = \frac{1}{n} \sum_{i=1}^n \delta_i \quad (6)$$

Donde N es el número de días de la semana ( $N = 7$ ).  $\delta_i = |CDF_{lt}(x_i) - CDF_{st}(x_i)|$ , con  $CDF_{lt}$  y  $CDF_{st}$  como las CDF a largo y corto plazo para cada parámetro meteorológico x. Para cada secuencia, se calculó la ecuación (2) para todas las estaciones y todos los parámetros meteorológicos estudiados. Según las estadísticas de FS, la CDF de cada parámetro x con n observaciones, ordenadas en orden ascendente  $x_1, x_2, \dots, x_{k-1}, x_k$ , viene dada por una función  $CDF(x)$ , definida por:

$$CDF(x) = \begin{cases} 0 & \text{for } x < x_1 \\ \frac{(k-0.5)}{n} & \text{for } x_k \leq x \leq x_{k+1} \\ 1 & \text{for } x > x_n \end{cases} \quad (5)$$

La suma ponderada (WS) de las estadísticas FS correspondientes a cada parámetro  $FS_i$  se calculó aplicando un factor de ponderación  $wf_i$ .

$$WS = \sum_{j=1}^m wf_j \cdot FS_j \quad (7)$$

La persistencia se evalúa determinando el número de ocurrencias de una secuencia dada. En este caso de estudio, cada una de estas secuencias se utilizó para obtener la producción de biomasa algal y evaluar la variabilidad de la productividad. Este enfoque se describe con más detalle en las Secciones 5.2.3 y 5.2.4.

Además, se obtuvo un conjunto de datos de PAR y variación de temperatura de siete días a partir de datos de teledetección de 15 años, con una resolución espacial de  $0,125^\circ \times 0,125^\circ$ . Los datos de PAR se obtuvieron de las bandas de Kato, proporcionados por la irradiancia con resolución espectral (SRI) del *Satellite Application Facility on Climate Monitoring*

(CMSAF), perteneciente a la *European Organisation for the Exploitation of Meteorological Satellites* (EUMETSAT). Los valores de temperatura se obtuvieron del *Copernicus Climate Change Service* (2023): *ERA5 hourly data*.

### 5.2.2. Modelo de crecimiento de microalgas

En este estudio, un modelo de estanque de algas de alta tasa (reactor) fue simplificado para enfocarse en el crecimiento de microalgas como una función de la temperatura del aire (T), radiación fotosintéticamente activa (PAR) y un número reducido de impurezas presentes en el medio de cultivo. El fósforo (P) y el nitrógeno (N) son dos de las impurezas en aguas residuales (medio de cultivo) que las microalgas pueden remover para su crecimiento. Las aguas residuales contienen una serie de compuestos de nitrógeno, tales como amonio, nitrógeno orgánico, nitratos y nitritos. En este estudio, el nitrógeno total es considerado igual a la suma total del nitrógeno de Kjeldahl, nitrito y nitrato. De manera similar, las aguas residuales son relativamente ricas en compuestos de fósforo, incluyendo iones de fosfato, formas inorgánicas (orto y polifosfatos) y formas orgánicas (fosfatos unidos orgánicamente). Por lo tanto, el fósforo total es dado aquí como una combinación de estos diferentes compuestos de fósforo. Estos parámetros fueron tomados como sustratos limitantes para el crecimiento de estos microorganismos fotosintéticos.

Además, las concentraciones iniciales de nitrógeno y fósforo en el medio de cultivo favorecen el crecimiento de microorganismos. Estos sustratos son consumidos exclusivamente por las microalgas. Solo la PAR y la temperatura escapan a nuestro control y pueden actuar como inhibidores en algunas ocasiones. Esta simplificación ha permitido reducir la complejidad del modelo y estudiar la productividad de la biomasa, incluyendo la variabilidad climática.

Los microcontaminantes restantes, metales pesados, otros nutrientes y contaminantes orgánicos se consideran nutrientes no limitantes. El modelo no incluye la población

bacteriana ni el mantenimiento de las microalgas. El balance energético (Behera et al. 2018) y el intercambio de gases (Ali and Park 2017; Gerotto et al. 2020) entre el sistema y su entorno también se desestimaron. Finalmente, la profundidad del estanque fue el único parámetro geométrico del sistema incluido en el modelo, que fue 10 cm. La profundidad se utilizó para calcular el valor medio de PAR en el medio de cultivo.

La concentración de masa celular de las microalgas en el medio de cultivo se determinó mediante el método de balance de materiales. En un modelo de cultivo por lotes, el influente y el efluente de los materiales en el medio son nulos; es decir, no aportan nutrientes al medio de cultivo y el volumen se considera constante. Además, asumiendo que todas las células tienen la misma masa, la cinética de crecimiento de las microalgas es proporcional a su tasa de crecimiento específico ( $\mu$ ), que depende de la disponibilidad de un sustrato limitante. Se añadió a la formulación del modelo la proporción de microalgas que mueren durante el cultivo, representada por la tasa de mortalidad específica ( $\mu_D$ ).

$$\frac{dX}{dt} = \mu(P, N, PAR, T) \cdot X - \mu_D \cdot X \quad (10)$$

$$\mu(PAR, T, P, N) = \mu_{max} \cdot \mu(P) \cdot \mu(N) \cdot \mu(PAR) \cdot \mu(T)$$

donde  $X$  (mg/L) es la concentración de microalgas,  $\mu_{max}$ , en  $\text{dia}^{-1}$ , es la tasa máxima de crecimiento específico de las microalgas. Para calcular la tasa de crecimiento específico, estos factores  $\mu(P)$  y  $\mu(N)$  se estimaron a partir del modelo Monod (Monod 1949; Eze et al. 2018),  $\mu(PAR)$  del modelo Monod modificado (Aiba 1982; Schirmer and Posten 2016) y  $\mu(T)$  del llamado modelo de temperatura cardinal (Rosso et al. 1993; Bernard and Rémond 2012). El modelo empírico Monod, que es fácil de calibrar y vincula el crecimiento con un parámetro de cultivo, se usa ampliamente para simular el tratamiento de aguas residuales utilizando microorganismos (Shoener et al. 2019). Para PAR, el modelo modificado de Monod implicó agregar un término al denominador para tener en cuenta la inhibición cuando el sustrato (PAR) está muy por encima del límite óptimo. La misma consideración se incluyó en el modelo de temperatura cardinal.

La ecuación (11) expresa los factores  $\mu(P)$  y  $\mu(N)$ , donde  $S$  representa la concentración de fósforo (P) o nitrógeno (N).  $K_S$  es una constante, expresada en mg/L, que representa la concentración de semisaturación de los nutrientes limitantes (P y N).

$$\mu(S) = \frac{S}{K_S + S} \quad (11)$$

Para las ecuaciones (12) y (13), se realizó un cálculo intermedio para determinar los valores medios de la PAR disponible y la temperatura del medio de cultivo, respectivamente. Respecto a la tasa de fotosíntesis – Ecuación (12) –, se aplicó la ley de Lambert-Beer para obtener el valor medio de la PAR ( $\mu E \cdot m^{-2} \cdot s^{-1}$ ). Este valor representa la intensidad de la luz a la que están expuestas las células en el medio de cultivo y se estimó según lo propuesto en (García-Malea et al. 2006; Pawłowski et al. 2018).

$$\mu(PAR) = \frac{PAR}{K_I + PAR + \frac{PAR^2}{K_i}} \quad (12)$$

$K_i$  y  $K_I$  (en  $\mu E \cdot m^{-2} \cdot s^{-1}$ ) son la constante de inhibición y la intensidad de saturación de PAR en la que la tasa de crecimiento específica es la mitad del máximo, respectivamente.

La Figura 5-1 muestra la experiencia de cultivo de *Chlorella vulgaris* en laboratorio a partir de un recipiente abierto representativo de un estanque. El tipo de agua residual seleccionada para este estudio procedía de una planta de tratamiento de aguas residuales secundarias de un municipio de la Comunidad de Madrid y, por lo tanto, era de uso doméstico. Se inyectó aire en el fondo del recipiente para asegurar el movimiento del agua y evitar su posible eutrofización.

Las condiciones experimentales se establecieron para garantizar que la luz recibida por el cultivo provenga principalmente de una lámpara ajustable. Esta lámpara calibrada se conectó a un dispositivo electrónico programado para gestionar los valores de fotoperiodo y PAR correspondientes al TMS de cada estación. No se controló la temperatura del medio de

cultivo. Sin embargo, los experimentos se realizaron en épocas del año con rangos no muy alejados a los valores obtenidos con los TMY.



Figura 5-1 : Puesta en marcha experimental del cultivo de microalgas en aguas residuales domésticas

Para la adquisición de datos, se utilizaron sensores PAR de espectro completo de *Apogee Instruments* y sensores de temperatura adecuados, respectivamente, para medir la intensidad luminosa y la temperatura dentro y fuera del medio. A partir de estas mediciones, se estimó el promedio del coeficiente de extinción de la ecuación de Lambert-Beer relacionando la absorbancia con la transmitancia de la luz. Este coeficiente de extinción se estimó experimentalmente para cada estación. Se programó una lámpara calibrada con los valores PAR correspondientes al TMS de cada estación.

La productividad de las microalgas también se ve afectada por la temperatura exterior. El factor restante – Ecuación (13) – modela la cinética de crecimiento de las microalgas en función de la temperatura de cultivo ( $T$ ). Al tratarse de un sistema abierto, esta temperatura se ve influenciada por la temperatura del aire circundante registrada. Además, el agua que compone el sistema de cultivo está en constante movimiento. La idea es obtener la temperatura del medio de cultivo a partir de la del aire utilizando la función establecida en (Kamarianakis et al. 2016) que asocia estos dos parámetros. La Ecuación (13) también

incluye los valores de temperatura mínimo ( $T_{\min}$ ), máximo ( $T_{\max}$ ) y óptimo ( $T_{\text{opt}}$ ) específicos de la microalga seleccionada (*Chlorella vulgaris*).

$$\mu(T) = \frac{(T - T_{\max})(T - T_{\min})^2}{(T_{\text{opt}} - T_{\min})[(T_{\text{opt}} - T_{\min})(T - T_{\text{opt}}) - (T_{\text{opt}} - T_{\max})(T_{\text{opt}} + T_{\min} - 2T)]} \quad (13)$$

### 5.2.3. Proceso de simulación

La implementación computacional del modelo descrito anteriormente se preparó utilizando MATLAB® y Simulink®. Esto nos permitió combinar programación textual y gráfica en el mismo entorno para realizar una multitud de simulaciones paralelas – Figura 5-2 – (Mathworks 2024). Por lo tanto, para una estación meteorológica dada (primavera, verano, otoño o invierno) en la región de Madrid, se simuló la producción por lotes para todos los GMS generados durante este período. En nuestro caso, como se indicó anteriormente, un GMS corresponde a una secuencia de siete días consecutivos formada por los datos de PAR y T. Según cálculos previos (Wane et al. 2023), había 1204 GMS para primavera, 1204 GMS para el verano, 1190 GMS para el otoño y 1184 GMS para el invierno. Por lo tanto, se determinó la concentración diaria promedio de microalgas en cada una de ellas. Los datos diarios promedio de PAR y T de estos GMS se tomaron como parámetros de entrada para la simulación de la producción de microalgas. Estos son los parámetros externos que intervienen en el crecimiento de microalgas y que caracterizan las condiciones ambientales. Las simulaciones se ejecutaron en paralelo con este flujo de trabajo de 7 días, considerando los demás datos de entrada como parámetros de inicialización del proceso.

La Figura 5-2 muestra el diagrama de bloques del modelo de crecimiento de microalgas (células individuales de microalgas, proceso inicial) en un contenedor de aguas residuales sin la adición de otro producto: donde X, N y P representan las concentraciones de microalgas, nitrógeno y fósforo, respectivamente.  $\mu$  y  $\mu_d$  son las tasas específicas de crecimiento y mortalidad, respectivamente. Los coeficientes de eliminación de nitrógeno y fósforo se expresan mediante  $Y_N$  y  $Y_P$ . T y PAR son la temperatura y la radiación fotosintéticamente activa.




Figura 5-2 : Modelo de diagrama de bloques del crecimiento de microalgas en cultivo por lotes.

La inicialización del proceso de simulación se basó en la concentración de inóculo de microalgas y nutrientes presentes inicialmente en la muestra de agua residual utilizada para el experimento de cultivo (Figura 5-1). Para ello, es necesario conocer las características del medio acuoso, la muestra de agua residual y las especies de microalgas. El tipo de agua residual seleccionada para este estudio procedía de una planta depuradora de aguas residuales de un municipio de la Comunidad de Madrid y, por tanto, era de uso doméstico. Su composición global de nitrógeno y fósforo se muestra en la Tabla 5-1. *Chlorella vulgaris* es la cepa de microalga inoculada en el medio de cultivo, y su concentración también se muestra en la Tabla 5-1. Otros parámetros específicos también se muestran en la Tabla 5-1. Además,  $Y_{s,a}$ , que son constantes para todas las estaciones, se obtuvieron tras ajustar el modelo propuesto. Los resultados de este modelo se compararon con los obtenidos en el estudio presentado por (Eze et al. 2018). La temperatura mínima corresponde al umbral aparente para cualquier crecimiento de microalgas, que es de aproximadamente 8 °C (Aleya et al. 2011). Las temperaturas óptima y máxima se tomaron de (Serra-Maia et al. 2016). La tasa de mortalidad se eligió arbitrariamente para que fuera baja en comparación con la tasa

de crecimiento. Se adoptó el mismo valor propuesto por (Eze et al. 2018), aunque funcionó con un tipo diferente de microalga. Finalmente, se estimó que los coeficientes de inhibición y semisaturación se estimaron como constantes durante toda la simulación.

Tabla 5-1 : Valores de los parámetros para realizar la simulación.

| Parámetro                                              | Valor                                      | Referencias                                 |
|--------------------------------------------------------|--------------------------------------------|---------------------------------------------|
| Nitrógeno total inicial (N)                            | 224 mg/l                                   | Este estudio                                |
| Fósforo total inicial (P)                              | 16. mg/l                                   | Este estudio                                |
| Inóculo de microalgas                                  | 100 mg/l                                   | Este estudio                                |
| Temperatura mínima                                     | 8 ° C                                      | (Aleya et al. 2011; Serra-Maia et al. 2016) |
| Temperatura óptima                                     | 23.3 ° C                                   |                                             |
| Temperatura máxima                                     | 35 ° C                                     |                                             |
| Tasa máxima de crecimiento específico ( $\mu_{\max}$ ) | 0.948 día <sup>-1</sup> (1/día)            | (Wang et al. 2010)                          |
| Coeficiente de eliminación de nitrógeno $Y_{N,a}$      | 0.71                                       | Este estudio                                |
| Coeficiente de eliminación de fósforo $Y_{P,a}$        | 0.035                                      | Este estudio                                |
| Tasa de mortalidad ( $\mu_D$ )                         | 0.004 día <sup>-1</sup> (1/día)            | (Eze et al. 2018)                           |
| Constante de inhibición ( $K_i$ )                      | 2400 $\mu\text{E m}^{-2} \text{s}^{-1}$    | (Singh and Singh 2015)                      |
| Constante de semisaturación para la luz ( $K_I$ )      | 124.115 $\mu\text{E m}^{-2} \text{s}^{-1}$ | (Pires et al. 2014)                         |
| Constante de semisaturación del nitrógeno ( $K_N$ )    | 31.5 mg/l                                  | (Shaw et al. 2013)                          |
| Constante de semisaturación del fósforo ( $K_P$ )      | 10.5 mg/l                                  |                                             |

#### 5.2.4. Conjunto de datos para análisis estadístico

Teniendo la concentración de biomasa para cada día del GMS que conforma una estación, el siguiente paso fue concatenar la producción diaria por día. Construir el conjunto de datos por día permite el análisis estadístico calculando la función de distribución de probabilidad (PDF) de la concentración de biomasa de cada grupo de datos por día (D2, D3, D4, D5, D6 o D7). Por ejemplo, la concentración de biomasa se junta para todos los días 2 (D2) de esos GMS, y lo mismo para los días 3 (D3), etc. El día 1 (D1) no se tomó ya que corresponde a la inicialización. La idea fue calcular la PDF de la concentración de microalgas para cada uno de estos conjuntos de datos, agrupados por día. El paso final de la metodología consiste en observar si la concentración de biomasa en un día dado (D2, D3, D4, D5, D6 o D7) del TMS seleccionado en (Wane et al. 2023) está, para el mismo día, en el bin con la PDF más grande.

Para una estación dada, la determinación de la concentración diaria promedio de biomasa se llevó a cabo para todos los GMS generados. Las salidas del modelo para días idénticos (D2, D3, D4, D5, D6 o D7) se utilizaron para calcular sus PDF diarias. Las PDF de las concentraciones de biomasa obtenidas de todos los D2 del GMS para el TMS de verano representativo utilizado como datos de entrada se grafican y discuten en la Sección 5.3.2. Lo mismo se aplicó a los otros días del TMS. Además de mostrar el rango de resultados probables para un día dado en términos de su frecuencia de ocurrencia, esta representación gráfica incluye la concordancia gráfica de la concentración de biomasa para el día correspondiente del mismo día en el TMS. Por lo tanto, fue posible comparar si esta posición de concentración de biomasa pertenecía al bin de concentración con el valor de PDF más alto. Para mayor precisión, la longitud del bin de concentración de biomasa se reduce a 2 mg/l.

## **5.3. Resultados y discusión**

### **5.3.1. Producción estacional de biomasa**

El crecimiento de las microalgas no solo se ve afectado por la radiación solar, la temperatura, el fósforo y el nitrógeno, sino que también depende de otros parámetros como el pH, el dióxido de carbono disuelto, las bacterias, etc. Estos parámetros, no mencionados en este trabajo, se mantienen en su valor óptimo, que corresponde a una tasa de crecimiento específica igual a la unidad. En resumen, el enfoque se centró exclusivamente en la influencia de estos parámetros físicos en la variación del crecimiento de las microalgas. Además, esto ignora las interacciones entre los microorganismos y los diversos componentes del sistema de cultivo, esenciales para la fidelidad del modelo.

La Figura 5-3 ilustra las secuencias meteorológicas típicas (TMS) para cada estación, detallando las estimaciones de PAR y temperatura para cada día de la secuencia.

La Figura 5-4 muestra las curvas de crecimiento para las cuatro estaciones meteorológicas del año utilizando TMS seleccionados de un sitio en el norte de la Comunidad de Madrid (Riosequillo). El resultado de la Figura 5-4 revela la diferencia en la producción de biomasa algal entre las cuatro estaciones del año, con una mayor concentración en verano. Esto podría explicarse por el hecho de que el crecimiento de estos microorganismos depende intrínsecamente de la intensidad de estos dos parámetros físicos. La Figura 5-4 también

muestra que la producción de biomasa es mayor en otoño que en primavera. Esta diferencia en la producción entre estos dos períodos del año parece deberse principalmente a la temperatura, que es más alta en otoño (Figura 5-3). Una comparación de la PAR en estos dos períodos muestra que es mayor en primavera. En primavera e invierno, la concentración de microalgas varía muy poco, llegando incluso a disminuir a 98.5 mg/l el séptimo día en el período de temperatura más baja (invierno). Sin embargo, en la Figura 5-4, parece estacionaria para estas dos estaciones debido a la variación relativamente grande obtenida en verano. Además, un análisis general de las curvas en todas las figuras estacionales (Figura 5-5 y C1–C3) también muestra las concentraciones de biomasa que es más probable obtener a lo largo del día de cultivo.




Figura 5-3 : Datos de secuencias meteorológicas típicas (TMS) de una localidad del norte de la región de Madrid, Riosequillo, para producir las curvas de concentración de biomasa que se muestran en la Figura 5-4.  $T_{\min}$  y  $T_{\max}$  representan la temperatura mínima y máxima diaria promedio.




Figura 5-4 : Variación estacional de la concentración de biomasa algal en función de parámetros meteorológicos (secuencia meteorológica típica, TMS) en la región norte de Madrid (Riosequillo). Estas curvas se obtuvieron aplicando al modelo, como datos de entrada, la temperatura media diaria  $T_{me}$  y los valores de PAR de las TMS seleccionadas, Figura 5-3.

El enfoque de este estudio de caso produjo resultados estadísticamente aceptables. Al comparar los resultados con los obtenidos por (Eze et al. 2018), aunque este último trabajó con una especie de alga diferente, el orden de magnitud de la concentración final de microalgas producidas durante el verano fue de 400 mg/L. Además, el estudio realizado por (Ajala and Alexander 2020) sobre el crecimiento de *Chlorella vulgaris* en cuatro condiciones de cultivo con diferentes propiedades fisicoquímicas tuvo resultados aproximados en el mismo rango. Sin embargo, estos resultados se obtuvieron durante un período de entre 8 y 14 días.

### 5.3.2. Análisis comparativo de la producción de algas

En esta sección, se representa la PDF de la productividad de microalgas para cada día que forma cada GMS de la estación de verano en la zona de estudio. Las cifras de primavera, otoño e invierno se encuentran en el Apéndice A. En la Figura 5-5 y las figuras incluidas en el Apéndice C, el asterisco representa la concentración de biomasa obtenida para cada día de la TMS y se colocó en el centro del intervalo de concentración de biomasa correspondiente. En verano, las estimaciones de concentración de biomasa por TMS coinciden con los valores más probables obtenidos con la metodología propuesta, como muestra la Figura 5-5. Lo mismo se observó con los datos de la estación de primavera, excepto para el caso de los días D2 y D7, Figura C1. La posición de la concentración de biomasa, para D5 en verano (Figura 5-5) y para D2 y D7 en el TMS de primavera (Figura C1), está en el intervalo de concentración con una probabilidad relativamente alta y es

directamente precedida o seguida por el intervalo con el valor más alto de PDF. La metodología parece confirmar la representatividad del TMS para las estaciones de verano y primavera en la ubicación estudiada. De hecho, en estas dos estaciones, casi todos los días de TMS ya seleccionados están en uno de los rangos de concentración de biomasa que tienen las PDF más altas.

Sin embargo, la PDF está más distribuida para la estación de otoño (ver Figura C2). En este caso, la posición de concentración de biomasa de cada uno de los días de TMS no está dentro del bin con las PDF más altas ni dentro de los bins cerca de este último. En la Figura C3, además del día D2, la concentración de biomasa para cada uno de los otros días de TMS que representan el invierno está lejos de estar entre aquellos con la mayor probabilidad de distribución, a pesar de la baja dispersión de los resultados. Además, la concentración apenas aumenta durante este período. En consecuencia, la mayoría de las concentraciones con la mayor probabilidad de distribución están por debajo de la concentración de biomasa inicial. El no crecimiento de la concentración de biomasa puede explicarse por el hecho de que los valores de PAR y temperatura son relativamente bajos durante estos períodos del año y son desfavorables para la proliferación de estos microorganismos. Por ejemplo, según la Figura 5-3, las temperaturas diarias promedio están por debajo del mínimo requerido para el crecimiento de *Chlorella vulgaris*.

Los mejores resultados, en términos de productividad, se obtuvieron en verano y primavera. Esto podría deberse a que ciertos valores del parámetro del modelo se tomaron de referencias que funcionaron en condiciones de luz y temperatura adecuadas, casi similares a las de estas dos épocas del año. Como muestran las Figura 5-3 y Figura 5-4, las otras dos estaciones, otoño e invierno, ofrecen condiciones inadecuadas para el cultivo de microalgas.




Figura 5-5 : Función de distribución de probabilidad (PDF) de la secuencia de concentraciones de biomasa día a día utilizando datos de PAR y temperatura de cada input GMS para el modelo de la temporada de verano en Riosequillo (Madrid). (a–f) Representan la PDF de la concentración de biomasa de cada conjunto de datos de los días D2, D3, D4, D5, D6 y D7, respectivamente.

La Figura 5-6 muestra cuatro diagramas de cajas para las diferentes estaciones, agrupando las concentraciones medias diarias de biomasa obtenidas de la simulación por día. Esto permite evaluar los rangos dentro de los cuales se registra la producción diaria de biomasa. Se observa que los resultados son casi similares en primavera y otoño, con cajas más dispersas entre los percentiles 25 y 75 en este último. Sin embargo, la producción diaria está menos dispersa durante el verano y el invierno, mostrando claramente un rendimiento óptimo en verano y niveles de producción insignificantes en invierno.




Figura 5-6 : Los diagramas de caja muestran estadísticas de la serie de producciones diarias promedio de biomasa obtenidas para cada estación.

## 5.4. Conclusiones

En este artículo, presentamos una metodología de simulación y evaluación del crecimiento y la productividad vegetal, que se puede adaptar a todo tipo de cultivos. La aplicación de esta metodología, utilizando conjuntos de datos meteorológicos de largo plazo, permite identificar los escenarios de producción más probables, lo cual resulta de gran ayuda en la toma de decisiones (análisis de viabilidad de proyectos, selección de emplazamientos, planificación y gestión, etc.). Los resultados obtenidos en nuestro caso de estudio confirman la representatividad de las secuencias meteorológicas típicas, muy cercanas al percentil 50, para su uso con programas de simulación más complejos.

**Contribuciones de los Autores:** Conceptualización, L.F.Z. y R.X.V.; metodología, L.F.Z., O.W. y A.A.N.; *software*, O.W.; validación, O.W. y L.F.Z.; análisis formal, L.F.Z., O.W. y F.F.-C.; investigación, O.W., L.F.Z., R.X.V., F.F.-C. y A.A.N.; recursos, R.X.V. y L.F.Z.; conservación de datos, O.W., R.X.V., A.A.N., L.F.Z. y F.F.-C.; redacción—preparación del borrador original, O.W., R.X.V., A.A.N., L.F.Z. y F.F.-C.; Redacción—revisión y edición, O.W., R.X.V., A.A.N., L.F.Z. y F.F.-C.; visualización, O.W. y A.A.N.; supervisión, R.X.V. y L.F.Z.; administración del proyecto, R.X.V. y L.F.Z.; obtención de financiación, R.X.V. Todos los autores han leído y aceptado la versión publicada del manuscrito.

**Financiación:** Esta investigación fue financiada por el Ministerio de Ciencia e Innovación de España (MCIN/AEI/10.13039/501100011033) y la Unión Europea “*Next Generation EU*”/PRTR, TED-DY (TED2021-130366B-I00).

**Declaración del Comité de Revisión Institucional:** No aplica.

**Declaración de Consentimiento Informado:** No aplica.

**Declaración de disponibilidad de datos:** Los datos proporcionados por el ECMWF utilizados en este estudio están disponibles en <https://www.ecmwf.int/en/forecasts/access-forecasts/access-archive-datasets>, referencia [8] (accedido el 17 de abril de 2021). Los datos de CMSAF utilizados en este estudio están disponibles en <https://wui.cmsaf.eu/safira/action/viewProduktList?dId=2&d-1342877-p=6>, referencia [9] (accedido el 14 de abril de 2021). Las contribuciones originales presentadas en el estudio se incluyen en el artículo, para más información contacte con el autor de correspondencia.

**Agradecimientos:** Los autores agradecen al Programa Iberoamericano de Ciencia y Tecnología (CYTED) (a través de RED RENUWAL P320RT0005). O.W. agradece a la Universidad Tecnológica de Gdansk por la subvención otorgada (subvención DEC-6/1/2022/IDUB/II.1a/Au) en el marco del Programa *Aurum Supporting International Research Team Building*.

**Conflictos de intereses:** Los autores declaran no tener ningún conflicto de intereses.

## 5.5. Apéndice C




Figura C1: Función de distribución de probabilidad (PDF) de la secuencia de concentraciones de biomasa día a día utilizando como entrada del modelo datos de PAR y temperatura de cada GMS de la estación de primavera en Riosequillo (Madrid). (a–f) representan la PDF de la concentración de biomasa de cada conjunto de datos de los días D2, D3, D4, D5, D6 y D7, respectivamente.




Figura C2: Función de distribución de probabilidad (PDF) de la secuencia de concentraciones de biomasa día a día utilizando como entrada del modelo datos de PAR y temperatura de cada GMS de la estación de otoño en Riosequillo (Madrid). (a–f) representan la PDF de la concentración de biomasa de cada conjunto de datos de los días D2, D3, D4, D5, D6 y D7, respectivamente.




Figura C3: Función de distribución de probabilidad (PDF) de la secuencia de concentraciones de biomasa día a día utilizando como entrada del modelo datos de PAR y temperatura de cada GMS de la estación de invierno en Riosequillo (Madrid). (a–f) Representan la PDF de la concentración de biomasa de cada conjunto de datos de los días D2, D3, D4, D5, D6 y D7, respectivamente.

**Aviso legal/Nota del editor:** Las declaraciones, opiniones y datos contenidos en todas las publicaciones son exclusivamente de los autores y colaboradores, y no de MDPI ni de sus editores. MDPI y sus editores no se responsabilizan de ningún daño a personas o bienes que resulte de las ideas, métodos, instrucciones o productos mencionados en el contenido.

## 6. Discusión General

El crecimiento y el desarrollo de un organismo fotosintético es intrínsecamente dependiente de la PAR disponible y de la temperatura ambiente. Estos dos parámetros meteorológicos juntos con la GHI, la DHI, la DNI y otros dos parámetros estimados por calculo (ángulo de elevación solar y duración del día solar) constituyeron las series temporales de la base datos que permitió alcanzar los objetivos específicos de este trabajo de investigación.

Para simular la productividad de biomasa a partir de organismos protistas tal y como la *Chlorella* en un entorno natural y en diferentes localizaciones geográficas se requieren datos de PAR y temperatura representativos a largo plazo que representen estadísticamente las condiciones climáticas del lugar de estudio. Por falta de registros PAR a nivel nacional, se desarrollaron modelos de PAR que se usaron para crear los primeros mapas de irradiancia PAR en España (Ferrera-Cobos et al. 2021). Este trabajo ha sido profundizado en el marco de esta tesis con el estudio comparativo de varios modelos regionales de PAR para compensar la escasez de datos PAR en la región de Madrid y poder dar un paso hacia el segundo objetivo específico de la tesis (Wane et al. 2022).

La generación de las TMS representativas de las condiciones de temperatura y de PAR de un lugar determinado, se realizó para dieciocho localizaciones en la región de Madrid. Las TMS de una de estas localizaciones que se tomó como sitio de emplazamiento del sistema de cultivo de microalgas para nuestro caso de estudio, han sido los datos de entrada al programa de simulación de la producción de biomasa algal. La discusión general de los resultados obtenidos y presentados en el capítulo 4 se hará siguiendo el orden de los trabajos realizados para desarrollar modelos regionales de PAR, generar TMS para ubicaciones geográficas de la región de Madrid y conseguir la producción de biomasa algal en función de las TMS una zona determinada en la región norte de Madrid.

## 6.1. Descripción de la solución

La generación de los TMS y TMS pretenden proporcionar serie reducidas de datos estadísticamente representativos de las condiciones meteorológicas de un zona geográfica y ampliamente aplicables para programas de simulación sistema energético o agrícola. Un ejemplo es el TMY, frecuentemente utilizado para la simulación numérica de sistemas energéticos a lo largo de un año. En el contexto de los sistemas de producción agrícola, ha sido necesario desarrollar una metodología de generación de TMS que se adapta al tipo de cultivo ya que, por ejemplo, los cultivos las hortalizas tienen un periodo de desarrollo y producción bastante inferior a un año completo. Al mismo tiempo, resultó importante aplicar los datos TMS generados que representan las condiciones meteorológicas representativas para un lugar y temporada específicos a la simulación de la producción de biomasa algal. Previamente, se desarrollaron modelos de PAR debido al impacto de este parámetro en el proceso de fotosíntesis y su escasez de medida y registro en España.

El primer artículo del compendio presentado en esta tesis se centra en la modelización de la radiación fotosintéticamente activa en España, empleando exclusivamente datos medidos en estaciones radiométricas terrestres (Wane et al. 2022). En estudios previos, se desarrollaron modelos de PAR con datos estimados, cuyos resultados se utilizaron para generar el primer mapa de PAR en España. En esta tesis se realizó, además de la modelización, un análisis comparativo entre la serie temporal de PAR y las demás variables radiométricas para estudiar sus grados de correlación.

El segundo artículo (Wane et al. 2023) describe el procedimiento de generación de las TMS para organismos fotosintéticos en cada estación del año. La nueva metodología propuesta está basa en la aplicación del estadístico de Finkelstein-Schafer sobre una serie de secuencias remuestreadas a partir una serie extensa de las variables representativas en nuestro caso. Finalmente, se determinó la producción estacional de biomasa de especies fotosintéticas aprovechando las TMS generadas como datos de entrada.

El tercer articulo publicado es un ejemplo práctico de la apliccion de las TMS donde se presentan los resultados de la simulación de la producción de biomasa algal combinada con el tratamiento de aguas residual. Como caso de estudio, se eligió, arbitrariamente, las TMS de una localidad llamada Riosequillo (Wane et al. 2023), situada en el norte de la región de Madrid que tiene una EDAR proxima. Estos datos se emplearon para correr el modelo de crecimiento de microalgas desarrollado para el caso de estudio (Wane et al. 2024).

## 6.2. Análisis de los resultados

El cumplimiento de los objetivos de esta tesis se hizo siguiendo una línea de investigación que finalizó con la aplicación de las TMS generadas, y que se emplearon para determinar la productividad de los organismos fotosintéticos en función de las condiciones de irradiancia y de temperatura ambiente. Los resultados se presentan en forma progresiva en los tres artículos publicados.

### 6.2.1. Modelización de la PAR

(Ferrera-Cobos et al. 2021) muestran los resultados de la modelización de la PAR a partir de la combinación de estimaciones de dos modelos desarrollados en (Ferrera-Cobos et al. 2020b), los cuales presentaban rendimientos desiguales en diferentes climas. Los modelos de PAR propuestos han sido modelos de regresión lineal multivariante.

El enfoque metodológico ha permitido establecer la relación entre la PAR medida en estación radiométrica (variable dependiente), y aquella (variable independiente) procedente de estimaciones (satelitales). Los estadísticos de bondad de ajuste del modelo PAR mostraron un rendimiento similar al validarlo con los datos de cada una de las siete estaciones radiométricas (Proyecto GEOPAR, CGL2016-79284-P AEI/FEDER/UE), en las zonas de clima mediterráneo y oceánico de España peninsular. Los coeficientes de regresión (análisis de regresión con la PAR estimada y la PAR medida) de los ajustes lineales entre las estimaciones del modelo PAR y cada uno de los siete conjuntos de datos PAR medidos, oscilaron entre 0,99 y 1,00 para el pendiente de la recta de regresión e inferiores a  $3,70 \mu\text{mol m}^{-2} \text{s}^{-1}$  para la ordenada en el origen. Los coeficientes de determinación fueron superiores a 0,988, mientras que los errores de sesgo estuvieron más cerca del 0%; y las raíces del error medio cuadrático fueron inferiores al 6,21%.

Las comparaciones del modelo con otros encontrados en la bibliografía, basándose en los valores de las pendientes de la recta de regresión (análisis de regresión), muestran resultados satisfactorios en todas las estaciones excepto en la de Álava-NEIKER, donde el valor más cercano a la unidad se obtuvo con el modelo de (Aguiar et al. 2012). Las estimaciones del modelo PAR presentadas en este trabajo se utilizaron, por primera vez, para generar mapas de PAR mensuales y anuales en la España peninsular.

A partir de aquí se planteado en esta tesis desarrollar modelos regionales con datos de GHI, DHI o DNI que son rutinariamente medidos en las estaciones radiométricas. Previamente, los análisis exploratorios de los datos medidos en las estaciones de CEDER-CIEMAT y PSA-CIEMAT ayudaron a caracterizar la relación entre la PAR y los demás parámetros radiométricos antes de abordar la modelización de la PAR. En cada una de las localidades, los resultados del análisis grafico mostraron que la correlación entre la PAR y GHI es mucho mejor que la relación entre la PAR y los demás parámetros (DNI, DHI y  $\alpha$ ) (Wane et al. 2022).

A continuación, se elaboraron modelos regionales de PAR empleando la misma cantidad de datos medidos en las dos estaciones instaladas en el CEDER-CIEMAT y en la PSA-CIEMAT. Los modelos han sido clasificados en dos categorías: completos y por intervalos. Ha habido quince modelos completos y el mismo número de modelo por intervalo de índice de transparencia atmosférica con un total de tres intervalos. En la siguiente Tabla 6-1 se muestran los valores de los coeficientes de regresión de los modelos por intervalos y los modelos completos.

De acuerdo con el primer artículo (Wane et al. 2022), se entrenaron un total de quince modelos para ambas categorías con el conjunto de los datos de entrenamiento. Pero, la validación de cada uno de los modelos “completos” se efectuó en CEDER-CIEMAT y en PSA-CIEMAT, utilizando los datos de validación correspondiente en cada sitio. Asimismo, dicho proceso de validación se hizo con los modelos por intervalo, repartiendo los datos de validación en tres intervalos de índice de transparencia atmosférica. Para cada modelo, los datos estimados por intervalos se concatenaron para su representación gráfica y la determinación de las métricas cuantitativas de validación. Como era de esperar, las estadísticas de validación mostraron una mejora de los datos PAR estimados con los modelos por intervalos en comparación con los datos obtenidos a partir de los modelos completos. Esto se traduce por el hecho de que la agrupación de los datos por intervalos de  $k_t$  (cielo nublado, parcialmente nublado y despejado), reduce el ruido que conllevan y hace que las tendencias sean más evidentes. Lo que hace que las dispersiones sean menores que cuando la serie temporal se consideraba en su totalidad. Las gráficas representadas en la Figura A1 del Apéndice A en el artículo (Wane et al. 2022) mostraron los resultados de las validaciones de los modelos completos y los modelos por intervalos. También se pueden comparar los estadísticos de validación que van incluidos en las gráficas. A modo de resumen, las métricas

cuantitativas de la validación de todos los modelos de PAR desarrollados en esta tesis exponen en la Tabla 6-2.

De manera general, el análisis de comparación de los estadísticos de la validación (Tabla 6-2) mostró que los modelos (completos o por intervalos) que incluyen simultáneamente el seno del ángulo de elevación solar y el índice de transparencia atmosférico tenían los mejores ajustes en ambas localizaciones (CEDER-CIEMAT y PSA-CIEMAT). Dicho de otra manera, el conjunto de los modelos que incluyen en el mismo tiempo  $k_t$  y  $\alpha$  como variables independientes, presentaron las mejores correlaciones con los datos de la validación en ambas localizaciones geográficas (CEDER-CIEMAT y PSA-CIEMAT). Los resultados obtenidos de la validación revelaron que los modelos (completos y por intervalos) con las cuatro variables explicativas ( $\alpha$ ,  $k_t$ ,  $k_d$  y  $k_b$ ) dieron los mejores valores de MPE, MBE y RMSE. Sin embargo, la comparación con el valor del coeficiente de determinación ( $R^2$ ) entre los distintos ajustes no era tan relevante ya que, excepto los modelos que llevan únicamente  $\alpha$  como variable independiente, es superior a 0.99 en todos los casos.

El análisis de los resultados de los estadísticos de la validación de dichos modelos en las dos localidades (CEDER-CIEMAT y PSA-CIEMAT) mostró que el error absoluto medio osciló entre 25 y 29  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ; mientras que se encontró entre 85 y 109  $\mu\text{mol m}^{-2} \text{s}^{-1}$  para los modelos que llevan por separado el seno del ángulo de elevación solar y el índice de transparencia atmosférico. Del mismo modo, se consiguieron los menores valores de la raíz del error medio cuadrado con los modelos que incorporan dichos dos parámetros. Basándose en las métricas de validación, la elección de un modelo entre todos es relativa y depende del parámetro estadístico que se tenga en cuenta. Con respecto a los modelos de la bibliografía, los resultados obtenidos en el marco de esta tesis han mostrado valores similares (Wane et al. 2022).

Por otra parte, las condiciones atmosféricas que influyen mucho en la distribución espectral de la radiación solar, han sido considerados a través de los atributos radiométricos utilizados para modelar la PAR. Por ejemplo, el vapor de agua absorbe principalmente en el infrarrojo cercano, por lo que una mayor profundidad óptica de los aerosoles puede aumentar ligeramente la fracción PAR/GHI al absorber más energía no PAR. Por lo cual, la incorporación de factores causantes de la variabilidad de la ratio PAR/GHI hace que el modelo PAR refleje más las condiciones atmosféricas del entorno. En este estudio, la modelización empírica de la PAR se llevó a cabo mediante mediciones locales realizadas en

dos lugares con cinco grados una diferencia de latitud, incluyendo factores como el índice de transparencia atmosférica, el ángulo de elevación solar, y otros factores específicos de los dos lugares que causan que la fracción PAR/GHI se desvíe de una constante. Esto traduce que el modelo regional de PAR incluye de forma inherente las condiciones atmosféricas como los componentes dominantes que son los aerosoles y el vapor de agua cuyos valores típicos y variabilidad dependen de la latitud. Este enfoque basado en la combinación índices radiométricos específicos de cada uno de los dos lugares permite que los modelos empíricos tienen en cuenta indirectamente las variaciones latitudinales en las fracciones PAR/GHI. entre CEDER-CIEMAT y PSA-CIEMAT. Por lo tanto, los resultados de la modelización podrían mejorarse aún más si, además de los datos de CEDER-CIEMAT y PSA-CIEMAT, se hubieran empleado datos de otras ubicaciones (latitudes) bien distribuidas en el área de estudio.

A pesar del aumento considerable de las bases de datos de medidas de la PAR, la densidad de estaciones de medida es aún insuficiente para cubrir las variaciones espaciales y temporales, ya que es un parámetro que se empezó a medir recientemente. Por ello, la disposición de este enfoque contribuye a solucionar la escasez de datos PAR. Como alternativa,, se pueden obtener estimaciones de este parámetro a partir de datos de GHI, DHI, DNI y/u otros datos más accesibles. Por lo tanto, este artículo contribuye significativamente a la modelización de datos radiométricos para alcanzar los objetivos de esta tesis.

Tabla 6-1 : Coeficientes de regresión de los modelos por intervalo y los modelos completos.

| Modelo                                                   |   | M01    | M02    | M03    | M04   | M05    | M06    | M07    | M08    | M09    | M10    | M11    | M12    | M13    | M14    | M15    |
|----------------------------------------------------------|---|--------|--------|--------|-------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| Cielo nublado<br>$0 \leq k_t \leq 0.3$                   | a | 0.068  | 0.003  | 0.143  | 0.077 | 0.002  | 0.143  | 0.065  | 0.012  | 0.003  | 0.194  | 0.012  | 0.002  | 0.180  | 0.053  | 0.053  |
|                                                          | b | 0.021  | 0.378  | -0.067 | 0.171 | 0.001  | 0.026  | 0.026  | 0.376  | 0.377  | -0.119 | 0.002  | 0.001  | 0.026  | 0.375  | 0.001  |
|                                                          | c |        |        |        |       | 0.377  | -0.080 | 0.213  | -0.009 | 0.012  | -0.164 | 0.374  | 0.372  | -0.118 | -0.051 | 0.374  |
|                                                          | d |        |        |        |       |        |        |        |        |        |        | -0.010 | 0.015  | -0.118 | -0.132 | -0.051 |
|                                                          | e |        |        |        |       |        |        |        |        |        |        |        |        |        |        | -0.129 |
| Cielo<br>parcialmente<br>nublado<br>$0.3 < k_t \leq 0.7$ | a | 0.218  | -0.003 | 0.275  | 0.157 | 0.006  | 0.264  | 0.147  | 0.025  | 0.009  | 0.059  | 0.023  | 0.013  | 0.063  | 0.026  | 0.019  |
|                                                          | b | -0.001 | 0.400  | -0.124 | 0.182 | -0.021 | 0.028  | 0.020  | 0.366  | 0.362  | 0.108  | -0.016 | -0.016 | 0.012  | 0.367  | -0.016 |
|                                                          | c |        |        |        |       | 0.402  | -0.128 | 0.185  | -0.019 | 0.027  | 0.329  | 0.377  | 0.374  | 0.096  | -0.020 | 0.376  |
|                                                          | d |        |        |        |       |        |        |        |        |        |        | -0.013 | 0.020  | 0.315  | -0.002 | -0.008 |
|                                                          | e |        |        |        |       |        |        |        |        |        |        |        |        |        |        | 0.008  |
| Cielo<br>despejado<br>$0.7 < k_t \leq 1$                 | a | 0.311  | 0.045  | 0.291  | 0.287 | 0.051  | 0.306  | 0.297  | 0.045  | 0.053  | 0.059  | 0.051  | 0.052  | 0.026  | 0.087  | 0.058  |
|                                                          | b | -0.022 | 0.321  | 0.027  | 0.014 | -0.042 | -0.020 | -0.026 | 0.318  | 0.331  | 0.261  | -0.041 | -0.041 | -0.049 | 0.395  | -0.040 |
|                                                          | c |        |        |        |       | 0.351  | 0.022  | 0.028  | 0.014  | -0.024 | 0.304  | 0.350  | 0.353  | 0.319  | -0.091 | 0.364  |
|                                                          | d |        |        |        |       |        |        |        |        |        |        | 0.003  | -0.005 | 0.394  | -0.133 | -0.016 |
|                                                          | e |        |        |        |       |        |        |        |        |        |        |        |        |        |        | -0.025 |
| Modelo completo                                          | a | 0.189  | 0.007  | 0.318  | 0.128 | 0.018  | 0.295  | 0.125  | 0.025  | 0.009  | 0.093  | 0.028  | 0.019  | 0.094  | 0.073  | 0.056  |
|                                                          | b | 0.109  | 0.372  | -0.204 | 0.256 | -0.030 | 0.035  | 0.006  | 0.353  | 0.365  | 0.039  | -0.029 | -0.030 | 0.001  | 0.373  | -0.025 |
|                                                          | c |        |        |        |       | 0.385  | -0.198 | 0.254  | -0.014 | 0.006  | 0.303  | 0.373  | 0.380  | 0.038  | -0.072 | 0.383  |
|                                                          | d |        | -      | -      | -     |        |        |        |        |        |        | -0.008 | 0.004  | 0.301  | -0.087 | -0.044 |
|                                                          | e |        |        |        |       |        |        |        |        |        |        |        |        |        |        | -0.053 |

Tabla 6-2 : Métricas cuantitativas (o estadísticos) de la validación de todos los modelos de PAR desarrollados en esta tesis

| Modelos        | Métricas de validación                        | Sitio de validación | M01    | M02   | M03    | M04    | M05   | M06     | M07     | M08   | M09   | M10     | M11    | M12   | M13    | M14   | M15   |
|----------------|-----------------------------------------------|---------------------|--------|-------|--------|--------|-------|---------|---------|-------|-------|---------|--------|-------|--------|-------|-------|
| Por intervalos | MPE (%)                                       | CEDER               | -11.86 | -1.19 | -7.01  | -6.84  | -1.02 | -6.77   | -6.63   | -1.00 | -1.08 | -6.80   | -0.93  | -0.96 | -6.50  | -1.12 | -0.95 |
|                |                                               | PSA                 | -0.99  | 1.22  | -0.61  | -0.63  | 1.22  | -060    | -0.67   | 1.15  | 1.17  | -0.50   | 1.17   | 1.18  | -0.57  | 1.33  | 1.25  |
|                | MBE ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ )  | CEDER               | 21.29  | 9.72  | 0.68   | 0.76   | 3.95  | 4.33    | 3.10    | 7.94  | 8.40  | 2.07    | 3.53   | 3.63  | 1.58   | 9.37  | 3.86  |
|                |                                               | PSA                 | -6.42  | 0.34  | -4.08  | -1.50  | -5.97 | -2.94   | -1.44   | -0.29 | -0.48 | 2.69    | -5.90  | -5.86 | 0.41   | -2.54 | -6.26 |
|                | RMSE ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) | CEDER               | 137.48 | 33.99 | 92.92  | 90.52  | 29.81 | 94.56   | 91.37   | 32.39 | 32.55 | 79.66   | 29.26  | 29.12 | 80.08  | 34.59 | 29.31 |
|                |                                               | PSA                 | 109.55 | 42.49 | 86.43  | 83.25  | 32.96 | 83.02   | 79.54   | 41.79 | 41.26 | 76.42   | 32.96  | 32.88 | 68.17  | 39.45 | 32.88 |
|                | R <sup>2</sup>                                | CEDER               | 0.92   | 1.00  | 0.96   | 0.97   | 1.00  | 0.96    | 0.97    | 1.00  | 1.00  | 0.97    | 1.00   | 1.00  | 0.97   | 1.00  | 1.00  |
|                |                                               | PSA                 | 0.94   | 0.99  | 0.96   | 0.97   | 0.99  | 0.97    | 0.97    | 0.99  | 0.99  | 0.97    | 0.99   | 0.99  | 0.98   | 0.99  | 0.99  |
| Completos      | MPE (%)                                       | CEDER               | -69.05 | -2.11 | -17.19 | -19.24 | -1.80 | -16.34  | -19.15  | -2.15 | -2.21 | -20.34  | -1.82  | -1.85 | -20.29 | -1.07 | -1.16 |
|                |                                               | PSA                 | -12.28 | 1.43  | -1.73  | -1.65  | 1.25  | -1.28   | -1.60   | 1.30  | 1.40  | -1.81   | 1.19   | 1.23  | -1.80  | 1.30  | 1.20  |
|                | MBE ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ )  | CEDER               | 151.51 | 10.98 | -2.00  | 5.50   | 3.24  | 6.33    | 7.14    | 9.44  | 10.63 | 8.66    | 2.54   | 2.99  | 8.77   | 8.82  | 3.082 |
|                |                                               | PSA                 | 6.88   | -1.05 | -25.53 | -13.66 | -6.25 | -18.12  | -12.32  | -0.79 | -0.80 | -11.21  | -6.04  | -6.15 | -11.12 | -3.02 | -6.52 |
|                | RMSE ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) | CEDER               | 356.35 | 35.79 | 147.85 | 136.71 | 33.42 | 145.848 | 136.50  | 34.88 | 35.49 | 136.944 | 33.18  | 33.36 | 136.90 | 35.51 | 33.08 |
|                |                                               | PSA                 | 232.07 | 44.15 | 128.26 | 116.63 | 36.64 | 127.03  | 116.862 | 44.92 | 44.62 | 115.78  | 37.433 | 36.98 | 115.84 | 41.00 | 36.04 |
|                | R <sup>2</sup>                                | CEDER               | 0.56   | 1.00  | 0.91   | 0.92   | 0.99  | 0.91    | 0.92    | 0.99  | 1.00  | 0.92    | 1.00   | 0.99  | 0.92   | 1.00  | 1.00  |
|                |                                               | PSA                 | 0.74   | 0.99  | 0.92   | 0.93   | 0.99  | 0.92    | 0.93    | 0.99  | 0.99  | 0.94    | 0.99   | 0.99  | 0.94   | 0.99  | 0.99  |

### **6.2.2. Secuencias meteorológicas de crecimiento**

El segundo artículo (Wane et al. 2023) presenta los resultados del estudio sobre la generación de las TMS para su uso en la fase final de este proceso de investigación que corresponde a la simulación del crecimiento de organismos fotosintéticos. Estas secuencias tipo se obtuvieron a partir de series temporales de un periodo de quince años para representar estadísticamente las condiciones meteorológicas medias cada estación del año, utilizadas para simulaciones.

Aunque la TMS y el TMY son herramientas fundamentales en la modelización climática, estos dos conceptos se diferencian claramente. La TMS es dinámica y específica, centrado en como interactúan las condiciones climáticas con las etapas de crecimiento, de desarrollo y de reproducción de un organismo fotosintético ya que sea una planta, protista o bacteria. De hecho, el propósito principal de las TMS es la optimización de las prácticas agrícolas que son la determinación anticipada del periodo de ideal para sembrar, regar o fertilizar, por ejemplo, parcelas agrícolas y la predicción de los rendimientos en función de condiciones climáticas reales.

Otra diferencia entre una TMS y un TMY, es la escala temporal que corresponde a un periodo específico para una TMS y un año completo para el TMY. Con respecto a la metodología empleada para la generación de los TMY, la de las TMS es adaptable y puede aplicarse a cualquier tipo de cultivo.

Para el caso de estudio presentado en esta memoria, una TMS está constituida por siete días consecutivos que corresponde más o menos al tiempo de retención hidráulica para el crecimiento de microalgas (Zou et al. 2020). Dos secuencias consecutivas, que aspiran a ser seleccionadas como TMS, son diferentes en tan solo un día. Este procedimiento de remuestreo detallado en la publicación aumentó en un 700% el número de secuencias candidatas para la TMS, que correspondían aproximadamente a más de mil semanas candidatas para cada una de las cuatro estaciones meteorológicas del año. Esta etapa de obtención de las secuencias difiere de la metodología clásicos de logro de los meses candidatos para el TMY, para los que los meses candidatos se toman directamente a partir de la serie meteorológica disponible (Skeiker 2004).

Por otro lado, para el procedimiento de selección de las cinco secuencias meteorológicas, se ha adaptado el método propuesto por Sandia National Laboratory (Hall et al. 1978). Los

factores de peso (wf) se eligieron para que correspondieran en un 50% a los parámetros radiométricos y en un 50% a las temperaturas. En otras palabras, en la metodología propuesta se otorgó la misma importancia a los parámetros radiométricos y a los de temperaturas. Dado que las TMS se generaron con la PAR media diaria, la duración del día solar (parámetros radiométricos) y el máximo, el mínimo, la media y el rango de temperaturas, se seleccionaron arbitrariamente nueve casos de asignación de relevancia (factor de peso) a estos parámetros de cultivo. Para cada opción, el máximo de los factores de peso se dio a la PAR y la temperatura media; ya que los coeficientes de ponderación tienen un efecto considerable en el proceso de selección de las secuencias candidatas. A la diferencia del método de generación de los TMY, que considera una opción de asignación los factores de peso, estas nueve alternativas permitieron obtener, como resultado de la aplicación del estadístico de Finkelstein-Schafer, nueve bloques de cinco secuencias candidatas seleccionadas para cada opción.

La etapa final de selección de la “mejor” secuencia (TMS) entre todas las candidatas difiere de los métodos encontrados en las referencias bibliográficas (Pissimanis et al. 1988; Skeiker 2007) y, en nuestro caso, debido a que disponíamos de datos diarios (no horarios), la selección se hizo sobre la base de la frecuencia (número de ocurrencias) de repetición y la diferencia en las horas de luz diarias de los días que se encuentran a la mitad de la secuencia dada, y de la secuencia situada en la mitad de la serie estacional.

Así, la serie temporal extensa de partida se reduce a cuatro secuencias, en lugar de doce meses (secuencias) como es el caso de los métodos de generación de los TMY. Esta aproximación podría ser beneficiosa en la medida en que las secuencias reflejen, de manera precisa, la variabilidad estacional del clima, disminuyendo el tiempo de simulación numérica.

En la siguiente Figura 6-1, se representan las TMS (por estación del año) que muestran las variaciones en promedio diarios de las temperaturas (media, máxima y mínima) y de la irradiancia PAR de catorce de las dieciocho localidades de la comunidad de Madrid estudiadas en esta tesis. Los cuatro representaciones graficas de las TMS ya figuraron en el cuerpo del texto y anexo del artículo que forma parte del capítulo 4. Para ubicar estas localidades de Madrid se indican, previamente, en la Tabla 6-3, las coordenadas geográficas. La Tabla 6-3 incluye también la fecha del día inicial de las TMS por estación del año y por localidad. Al comparar las curvas de las TMS entre localidades por estación meteorológica

del año, se puede observar que la diferencia no es tan significativa desde el punto de vista de los valores numéricos de la PAR y, por un lado, de las temperaturas, por otro lado. Esta diferencia mínima se debe a que las localidades estudiadas se ubican en zonas geográficas con latitudes muy próximas (Tabla 6-3).

Tabla 6-3 : Coordenadas geográficas de los sitios estudiados y fecha del día inicial de las TMS por estación del año y por localidad.

| Localidad               | Latitud<br>Longitud<br>(°C) | Estación | Año  | Mes | Día | Localidad                 | Latitud<br>Longitud<br>(°C) | Estación | Año  | Mes | Día |
|-------------------------|-----------------------------|----------|------|-----|-----|---------------------------|-----------------------------|----------|------|-----|-----|
| Aranjuez                | 40.02<br>-3.64              | Spring   | 1994 | 03  | 20  | Orusco de<br>Tajuña       | 40.28<br>-3.21              | Spring   | 2003 | 04  | 20  |
|                         |                             | Summer   | 1997 | 06  | 20  |                           |                             | Summer   | 1995 | 06  | 19  |
|                         |                             | Autumn   | 1993 | 11  | 06  |                           |                             | Autumn   | 1996 | 11  | 20  |
|                         |                             | Winter   | 1996 | 12  | 18  |                           |                             | Winter   | 1992 | 12  | 18  |
| Batres                  | 40.21<br>-3.92              | Spring   | 1993 | 05  | 02  | Pezuela de<br>las Torres  | 40.41<br>-3.16              | Spring   | 1993 | 05  | 02  |
|                         |                             | Summer   | 1991 | 06  | 19  |                           |                             | Summer   | 1997 | 06  | 15  |
|                         |                             | Autumn   | 1996 | 10  | 19  |                           |                             | Autumn   | 1996 | 09  | 08  |
|                         |                             | Winter   | 1996 | 12  | 14  |                           |                             | Winter   | 1994 | 12  | 16  |
| Colmenarejo<br>Este     | 40.55<br>-4.00              | Spring   | 1998 | 04  | 09  | Riosequillo               | 40.95<br>-3.65              | Spring   | 2002 | 04  | 09  |
|                         |                             | Summer   | 1994 | 06  | 16  |                           |                             | Summer   | 1994 | 06  | 17  |
|                         |                             | Autumn   | 1996 | 09  | 20  |                           |                             | Autumn   | 1994 | 10  | 13  |
|                         |                             | Winter   | 1996 | 12  | 18  |                           |                             | Winter   | 2000 | 12  | 18  |
| Conjunta de<br>Gascones | 41.01<br>-3.64              | Spring   | 2003 | 04  | 19  | Robledo                   | 40.51<br>-4.27              | Spring   | 1995 | 04  | 03  |
|                         |                             | Summer   | 1991 | 06  | 19  |                           |                             | Summer   | 1991 | 06  | 19  |
|                         |                             | Autumn   | 1996 | 11  | 21  |                           |                             | Autumn   | 1996 | 09  | 20  |
|                         |                             | Winter   | 1995 | 12  | 14  |                           |                             | Winter   | 1996 | 12  | 15  |
| Estremera               | 40.00<br>-3.64              | Spring   | 1993 | 03  | 17  | Rozas de<br>Puerto Real   | 40.31<br>-4.50              | Spring   | 1996 | 03  | 27  |
|                         |                             | Summer   | 1994 | 06  | 19  |                           |                             | Summer   | 1998 | 06  | 19  |
|                         |                             | Autumn   | 1996 | 11  | 20  |                           |                             | Autumn   | 2001 | 09  | 27  |
|                         |                             | Winter   | 1996 | 12  | 16  |                           |                             | Winter   | 1996 | 12  | 15  |
| Fresno-<br>Ribatejada   | 40.58<br>3.41               | Spring   | 2002 | 04  | 11  | San Martin<br>Noreste     | 40.39<br>-4.36              | Spring   | 2001 | 05  | 18  |
|                         |                             | Summer   | 1991 | 06  | 19  |                           |                             | Summer   | 2000 | 06  | 15  |
|                         |                             | Autumn   | 1996 | 09  | 08  |                           |                             | Autumn   | 1999 | 10  | 11  |
|                         |                             | Winter   | 1995 | 12  | 14  |                           |                             | Winter   | 1996 | 12  | 15  |
| Fuentidueña             | 40.10<br>-3.16              | Spring   | 2003 | 04  | 20  | Santa Mª de<br>la Alameda | 40.41<br>-3.40              | Spring   | 1998 | 05  | 20  |
|                         |                             | Summer   | 1995 | 06  | 19  |                           |                             | Summer   | 1994 | 06  | 16  |
|                         |                             | Autumn   | 1998 | 09  | 21  |                           |                             | Autumn   | 1996 | 09  | 20  |
|                         |                             | Winter   | 1996 | 12  | 16  |                           |                             | Winter   | 1996 | 12  | 15  |
| Lozoyuela               | 40.92<br>-3.60              | Spring   | 2002 | 04  | 09  | Talamanca<br>del Jarama   | 40.73<br>-3.50              | Spring   | 2003 | 04  | 19  |
|                         |                             | Summer   | 1997 | 06  | 20  |                           |                             | Summer   | 1997 | 06  | 20  |
|                         |                             | Autumn   | 1996 | 09  | 20  |                           |                             | Autumn   | 1996 | 09  | 20  |
|                         |                             | Winter   | 2000 | 12  | 18  |                           |                             | Winter   | 1994 | 12  | 16  |
| Navalafuente            | 40.81<br>-3.66              | Spring   | 2003 | 04  | 19  | Valdelaguna               | 40.16<br>-3.37              | Spring   | 1993 | 05  | 02  |
|                         |                             | Summer   | 1997 | 06  | 20  |                           |                             | Summer   | 1997 | 06  | 20  |
|                         |                             | Autumn   | 1994 | 10  | 13  |                           |                             | Autumn   | 1998 | 09  | 21  |
|                         |                             | Winter   | 1996 | 12  | 16  |                           |                             | Winter   | 1992 | 12  | 18  |




Figura 6-1. Continúa




Figura 6-1. Continúa




Figura 6-1. Continúa




Figura 6-1 : Representaciones graficas de las TMS (por estación del año y por localidad) que muestran las variaciones en promedio diarios de las temperaturas (media, máxima y mínima) y de la irradiancia PAR de catorce de las dieciocho localidades estudiadas de la Comunidad de Madrid

### 6.2.3. Simulación del crecimiento de organismo fotosintético

La simulación numérica de la productividad de un sistema de crecimiento, empleando las TMS como datos de entrada, puede resultar beneficiosa para anticipar la toma de decisiones sobre la implantación del mismo. En el tercer artículo (Wane et al. 2024), se presenta como caso de estudio el tratamiento de aguas residuales basado en el crecimiento de una especie de microalga, concretamente, la *Chlorella vulgaris*. Las microalgas se cultivan en diferentes medios de cultivo; entre ellos se incluyen las aguas residuales que contienen los nutrientes útiles para el crecimiento y desarrollo de dichos organismos. También, el cultivo de las microalgas depende de factores externos como la irradiancia PAR (luz) y la temperatura que afectan el periodo de cultivo. La duración de cultivo en este caso concreto es de siete días correspondientes al tiempo de retención del agua residual. Este estudio aplicado a una localidad del norte de la Comunidad de Madrid, ha permitido determinar las variaciones estacionales en la concentración de la biomasa algal en función de los TMS obtenidos previamente para esa localidad.

De acuerdo con los resultados de simulación de la producción de biomasa algal, la concentración de nutrientes disminuye a medida que aumenta la de las microalgas. Ante concentraciones muy bajas de nutrientes, el crecimiento de las microalgas, que ha alcanzado su valor máximo, comienza a disminuir ligeramente, incluso a temperaturas y PAR óptimas. La tasa de mortalidad es mayor que la de crecimiento. Esto se observa en la Figura 5-4 que representa la variación estacional de la concentración de biomasa algal en función de parámetros meteorológicos (TMS) en la región norte de Madrid. Los resultados de simulación del crecimiento, mostraron que durante la primavera la concentración de microalgas se incrementó levemente para luego disminuir con el paso de los días, mientras que en invierno la cantidad de microalgas decrecía un día después de la introducción del inóculo. Los datos correspondientes al verano, señalaron este periodo como el más favorable para cultivo de cultivo de *Chlorella vulgaris* en la región de Madrid, con una concentración que alcanza los 430 mg l<sup>-1</sup>. La variación de la concentración de biomasa algal durante el primer día en otoño, ha sido equivalente a la del verano, para luego reducirse y mantenerse próxima a 210 mg l<sup>-1</sup>. Los resultados corroboran la representatividad de las TMS. Los resultados obtenidos con las simulaciones de producción de biomasa algal, en el marco de esta tesis, son comparables con los obtenidos a partir de modelos de crecimiento de microalgas encontrados en la bibliografía (Eze et al. 2018; Zou et al. 2020).

Por otro lado, las curvas de variación estacional en la concentración de biomasa algal en función de los datos TMS en la zona norte de la región de Madrid muestran cómo la variabilidad meteorológica afecta de forma consistente a la productividad de biomasa. En verano, con valores elevados de PAR y temperaturas medias en torno a los 23°C, se favorece la reproducción de la *Chlorella* y se eliminan los nutrientes presentes en el medio de cultivo.

Según los resultados alcanzados, el cultivo de microalgas en aguas residuales es una estrategia prometedora para la biorremediación y la producción de biomasa. Sin embargo, su éxito depende críticamente de las condiciones meteorológicas, ya que la PAR y la temperatura influyen directamente en la productividad de las algas. Otro aspecto a tener en cuenta es el riesgo de que el agua residual (medio de cultivo) se vuelva tóxica y entrena la reducción de la tasa de crecimiento de las microalgas. Lo que hará que, debido a una concentración elevada de amonio, la tasa de mortalidad de las últimas sea mayor que la tasa de crecimiento. En esta situación, se ralentiza el crecimiento, desarrollo y reproducción de las *Chlorellas*, incluso pueden llegar a morir si la toxicidad es muy elevada o que las condiciones meteorológicas no acompañan. Es más, o menos lo que reflejaron las curvas de variación de la biomasa de *Chlorella* para las estaciones de invierno y primavera, utilizando las TMS que representan las condiciones meteorológicas de un emplazamiento del norte de la Comunidad de Madrid (Riosequillo). En estas estaciones del año en ese lugar, las estimaciones de la concentración de la *Chlorella* varían a menudo y descienden hasta los 98,5 mg/L el séptimo día durante el periodo de las temperaturas bajas de invierno.

## 6.3. Conclusiones, aportaciones y futuras líneas de investigación

### 6.3.1. Conclusiones

A la vista del proceso de investigación y de los resultados reflejados en los artículos publicados, cabe afirmar que se han logrado los objetivos generales y específicos establecidos al comienzo de esta tesis. Como se ha mencionado previamente, las secuencias meteorológicas tipo (TMS) presentan dos puntos fuertes que son la adaptabilidad del número de días al tipo de cultivo según el ciclo de cosecha y su representatividad meteorológica para una estación del año o una temporada de cultivo en particular.

La TMS es una herramienta operativa y fundamental enfocada en la planificación agrícola y la caracterización meteorológica de un periodo específico que puede cubrir desde solo días, semanas o meses en función de actividad del cultivo.

Además, el enfoque metodológico para la modelización de la PAR mediante datos medidos in situ, la creación de las TMS con datos de reanálisis y la simulación del crecimiento de organismos fotosintéticos a partir de registros meteorológicos extensos representados estadísticamente por TMS, permite formular las siguientes conclusiones más importantes de la presente tesis doctoral:

- Los objetivos específicos de la tesis, tratados en tres etapas y presentados en el compendio de tres artículos publicados (capítulos 3 a 5 de esta memoria), han sido alcanzados con las metodologías propuestas en cada etapa del proceso de investigación. La consecución de estos objetivos cubre un vacío en el estado del arte de la modelización PAR, la generación de secuencias meteorológicas características aplicadas en agronomía y la simulación numérica de la producción agrícola.
- La PAR es fundamental para el desarrollo de los organismos fotosintéticos y no hay suficientes estaciones meteorológicas que registren ni existen series de datos extensas que permitan cubrir las variabilidades espacial y temporal de la Península Iberica en general y, en particular, del área geográfica de la Comunidad de Madrid.
- La modelización de la PAR representa una opción adecuada para obtener series temporales robustas en áreas con escasez de datos registrados in situ, ya que permite superar las limitaciones de mediciones directas mediante la combinación de parámetros radiométricos disponibles en el lugar de estudio.
- La generación de TMS propuesta es un método adecuado para la simulación numérica de modelos crecimiento de plantas, algas, protistas y algunas bacterias por estación del año, temporada de cultivo, periodo de actividad del cultivo, rotación de cultivo, etc
- Los resultados de la simulación numérica de producción de biomasa algal en función de las condiciones de irradiancia PAR y de temperatura, en el caso estudiado, son satisfactorios en términos de orden de magnitud de las concentraciones obtenidas para las distintas estaciones del año y en la eficiencia. Además, este enfoque minimiza los recursos materiales, a diferencia de los experimentos llevados a cabo en laboratorio o a gran escala.

- El empleo de las TMS podría implementarse para cultivos específicos y en otros ecosistemas agrícolas, como la producción en invernaderos inteligentes, donde se podría controlar las condiciones ambientales. De este modo, las TMS adecuadas al tipo de cultivo podrían integrarse con los dispositivos de control, permitiendo reproducir las condiciones de PAR (fuente de iluminación) y temperatura (calor) del invernadero.
- Los resultados del caso de estudio propuesto muestran la posibilidad del tratamiento de aguas residuales mediante microalgas. Tras la depuración de las aguas residuales se obtiene como producto una biomasa microalgal que podrá ser empleada como biofertilizante y bioestimulante para la agricultura. Pero, también, se puede obtener un agua apta para el riego de cultivos agrícolas.
- Los modelos de PAR desarrollados y basados exclusivamente en el uso de datos comúnmente disponibles tal y como la GHI, DHI, DNI y el ángulo de elevación solar presentan limitaciones significativas debido a la simplificación de procesos atmosféricos complejos. La rigidez espectral y atmosférica limita su precisión, especialmente en regiones con alta variabilidad de aerosoles/humedad.
- Las TMS presentan una limitación relativa a la dependencia con datos locales de alta resolución temporal, especialmente en regiones remotas con topografía compleja o fenómenos locales no modelizados. Además, la reducción del volumen de datos puede ocultar variabilidades climáticas extremas (patrones críticos) e impactantes.
- Las TMS son útiles para análisis preliminares basados en simulaciones en condiciones “promedio”, pero fallan en escenarios o donde la variabilidad o extremos son relevantes. Además, las TMS se basan en datos pasados, sin incorporar tendencias futuras lo que limitan su aplicación en estudios de largo plazo o bajo cambio climático.

### 6.3.2. Aportaciones de la tesis

Una de las principales aportaciones realizadas a lo largo de esta tesis doctoral es la modelización de la PAR, ya que es clave para generar series temporales en zonas con escasez de datos in situ y permite superar las limitaciones de mediciones directas mediante técnicas y fuentes alternativas. Los modelos regionales de PAR desarrollados aquí se hicieron tras unir los datos radiométricos registrados en dos estaciones ubicadas en la meseta norte (CEDER-CIEMAT en

Soria) y al sureste (PSA-CIEMAT en Almería) de la Península Ibérica; lo cual permitiría su uso en otras localizaciones fuera de nuestra área de estudio situada entre ambos sitios. Además, los resultados satisfactorios de la validación de los modelos, por separado, en estas dos localizaciones y de las comparaciones con modelos de PAR existentes en la bibliografía, muestran que la modelización de la PAR ofrece una alternativa viable, garantizando la disponibilidad de datos para el análisis y la toma de decisiones. En el ámbito social, esta alternativa de acceso a datos de PAR puede contribuir al empoderamiento de las comunidades agrícolas, al facilitar predicciones de este parámetro radiométrico que permite optimizar prácticas como el riego y siembra.

En cuanto a las TMS son fundamentales para mejorar la producción vegetal de manera sostenible, especialmente en el contexto del cambio climático. Su creación permite no solo avanzar en modelos de crecimientos, sino también generar soluciones prácticas para la agricultura, con un enfoque interdisciplinar que combine meteorología y agronomía. Las TMS generadas pueden:

- ser clave en modelos de crecimiento de cultivos para simular los rendimientos bajo diferentes escenarios
- guiar la selección de cultivos o variedades tolerantes a nuevas condiciones meteorológicas.
- permitir la identificación de ventanas óptimas de siembra para evitar estrés térmico o hídrico en etapas críticas del cultivo y diseñar calendarios de siembra de cultivos tolerantes a las condiciones meteorológicas.

La simulación de escenarios de crecimiento estacional de la *Chlorella vulgaris* empleando las TMS como datos de entrada, mostró la adaptabilidad centrada justo al periodo de cultivo, ayudando a generar pronósticos estacionales de producción de biomasa algal. Respecto a su adaptabilidad a otro tipo de cultivo, las TMS podrían constituir una herramienta replicable y transferible para adaptar estrategias probadas en una región a otras con condiciones meteorológicas similares pero datos limitados.

### **6.3.3. Futuras líneas de investigación**

Frente al cierre de esta tesis doctoral que trata la creación de TMS mediante series temporales extensas de datos PAR y de temperatura para su aplicación a la simulación de la producción

vegetal en una localización concreta, se abren perspectivas de posibles líneas de futura investigación. Por ejemplo, como elemento de estudio y perspectiva futura de mejora de los datos PAR estimados, se podría plantear incluir, en la modelización, técnicas de interpolación para mejorar la resolución espacial usando técnicas como machine learning con datos topográficos (altitud, pendiente, ...), clave en áreas heterogéneas.

La metodología propuesta consideró datos en promedio diario de temperatura y PAR para la creación de las TMS. La reformulación de esta metodología de generación de las TMS, empleando inicialmente series temporales a largo plazo más extensas, completas y en promedio horario o 1-minuto, permitirá mejorar la obtención de las secuencias con una caracterización de alta resolución temporal. Esto a su vez, reforzará el tratamiento estadístico, haciéndolo más robusto y convirtiendo las TMS en una de las herramientas principales para la creación de conjuntos de datos condensados de series temporales multi-estacionales para la simulación computacional de la producción vegetal, ya sea por estación del año o por temporada de cultivo.

Los resultados obtenidos han permitido establecer las bases para la metodología de generación de las TMS. A partir de ello, puede ser útil plantear futuras revisiones/actualizaciones del estado del arte e ir optimizando la metodología mediante el ajuste de los parámetros y la introducción de otros datos meteorológicos relevantes en relación con la producción vegetal, como la evapotranspiración y la precipitación, que son importantes para la planificación del riego de los cultivos.

La elección del tamaño del TMS (número de días) resulta fundamental, ya que una secuencia reducida puede ocultar fenómenos meteorológicos extremos como sequías, cambios en estacionalidad y temperaturas extremas. De hecho, se puede seguir evaluando las TMS mediante la comparación de los resultados de simulación de producción vegetal con los que se lograrían a partir de experimentos en laboratorio o en plantas piloto.

#### **6.3.4. Conclusions**

Taking into account both the research procedure implemented and the results reflected in the published articles, it can be affirmed that the general and specific objectives established at the beginning of this thesis have been achieved. As mentioned previously, typical meteorological sequences (TMS) have two strengths, which are the adaptability of the number of days to the type of crop according to the harvest cycle and their meteorological representativeness for a particular season of the year or growing season.

The TMS is an operational and fundamental tool focused on agricultural planning and meteorological characterisation of a specific period that can cover days, weeks, or months depending on crop activity.

Furthermore, the following key findings of the current doctoral thesis can be formulated thanks to the methodological approach for PAR modelling using data measured in situ, the creation of the TMS with reanalysis data, and the simulation of photosynthetic organism growth from extensive meteorological data collected statistically represented by TMS:

- The main objectives of the thesis, dealt with in three stages and presented in a compendium of three published articles (Chapters 3 to 5 of this thesis), have been achieved with the methodologies proposed at each stage of the research process. The achievement of these objectives fills a gap in the state of the art of PAR modelling, the generation of characteristic meteorological sequences applied in agronomy, and the numerical simulation of agricultural production.
- PAR is fundamental for the development of photosynthetic organisms, and there are not enough meteorological stations to record, and there are no extensive data sets to cover the spatial and temporal variability of the Iberian Peninsula in general and, in particular, the geographical area of the region of Madrid. PAR modelling represents a suitable option to obtain robust time series in areas with a scarcity of in situ recorded data, as it overcomes the limitations of direct measurements by combining radiometric parameters available at the study site.
- The proposed TMS generation is a suitable method for numerical simulation of plant, algae, protist, and some bacteria growth models by season of the year, seasonal crop, or crop rotation.
- The results of the numerical simulation of the production of algal biomass as a function of PAR irradiance and temperature conditions, in the case studied, are satisfactory in terms of the order of magnitude of the concentrations obtained for the different seasons of the year and in efficiency. In contrast to large-scale or laboratory research, this method also uses fewer material resources.
- The use of TMS could be implemented for specific crops and in other agricultural ecosystems, such as production in smart greenhouses, where environmental conditions could be controlled. In this way, TMS appropriate to the type of crop could be integrated

with control devices, allowing one to reproduce the PAR (light source) and temperature (heat) conditions of the greenhouse.

- The results of the proposed case study show the possibility of wastewater treatment using microalgae. After wastewater purification, a microalgal biomass is obtained as a product that can be used as a biofertilizer and biostimulant for agriculture. But it is also possible to obtain suitable water for irrigation of agricultural crops.
- PAR models developed and based exclusively on the use of commonly available data such as GHI, DHI, DNI and solar elevation angle have significant limitations due to the simplification of complex atmospheric processes. Spectral and atmospheric rigidity limits their accuracy, especially in regions with high aerosol/humidity variability.
- TMS have a limitation related to the reliance on local data of high temporal resolution, especially in remote regions with complex topography or unmodelled local phenomena. In addition, the reduced data volume may mask extreme climate variabilities (critical patterns) and impacts.
- TMS are useful for preliminary analyses based on simulations under ‘average’ conditions, but fail in scenarios or where variability or extremes are relevant. In addition, TMS are based on past data, without incorporating future trends, which limits their application in long-term studies or under climate change.

### **6.3.5. Contributions of the thesis**

PAR modelling is one of the main contributions made throughout this doctoral thesis, as it is essential for the creation of time series in areas with a scarcity of data and allows overcoming the limitations of direct measurements by using alternative techniques and sources. The regional PAR models developed here were made by merging radiometric data recorded at two stations located in the northern plateau (CEDER-CIEMAT in Soria) and southeast (PSA-CIEMAT in Almería) of the Iberian Peninsula; which would allow their use in other locations outside our study area located between both sites.. This would allow them to be used in other locations outside of our study area, which lies between these two places. Furthermore, the satisfactory results of the separate validation of the models at these two locations and comparisons with existing PAR models in the literature show that PAR modelling offers a viable alternative, ensuring the availability of data for analysis and decision-making. In the social sphere, this alternative access to PAR data can contribute to the empowerment of agricultural communities

by facilitating predictions of this radiometric parameter that allows the optimisation of practices such as irrigation and sowing.

Regarding TMSs, they are essential to improve crop production in a sustainable way, especially in the context of climate change. Their creation allows not only to advance growth models, but also to generate practical solutions for agriculture, with an interdisciplinary approach combining meteorology and agronomy. The generated TMS can:

- be key in crop growth models to simulate yields under different scenarios,
- guide the selection of crops or varieties tolerant to new weather conditions,
- allow for the identification of optimal sowing windows to avoid heat or water stress at critical crop stages and design weather-tolerant crop sowing schedules.

Numerical simulation of seasonal growth scenarios for *Chlorella vulgaris* using TMS as input data showed adaptability focused on the growing season, helping to generate seasonal forecasts of algal biomass production. Regarding its adaptability to other crop types, TMS could be a replicable and transferable tool to adapt strategies tested in one region to others with similar weather conditions but limited data.

### **6.3.6. Future lines of research**

Opportunities for potential future research directions are presented in the conclusion of this doctoral thesis, which focusses on developing TMS using large time series of PAR and temperature data for application to the simulation of plant production at a particular location. For instance, as part of the research and as a way to improve the estimated PAR data in the future, it might be thought to incorporate interpolation techniques into the modelling process to increase the spatial resolution using methods like machine learning with topographic data (slope, altitude), which is important for heterogeneous areas.

The proposed methodology considered the daily average temperature and PAR data for the creation of the TMS. The reformulation of this TMS generation methodology, initially employing more extensive, complete, and hourly or 1-minute averaged long-term time series, will improve the obtaining of sequences with a high temporal resolution characterisation. The statistical treatment will be strengthened, making it more robust and making TMS one of the main tools for the creation of condensed multiseasonal time series data sets for the computational simulation of plant production, either by season of the year or by growing season.

The results obtained have made it possible to establish the basis for the TMS generation methodology. From this it may be useful to consider future revisions/update of the state-of-the-art and to optimise the methodology by adjusting the parameters and introducing other relevant meteorological data related to crop production, such as evapotranspiration and precipitation, which are important for crop irrigation planning.

The choice of the size of the TMS (number of days) is critical, as a small sequence can mask extreme weather events such as droughts, changes in seasonality, and extreme temperatures. In fact, TMS can be further evaluated by comparing the results of plant production simulations with those achieved through laboratory or pilot plant experiments.



## Referencias

Ación FG, Gómez-Serrano C, Morales-Amaral MM, Fernández-Sevilla JM, Molina-Grima E. 2016. Wastewater treatment using microalgae: how realistic a contribution might it be to significant urban wastewater treatment? *Appl Microbiol Biotechnol*. 100(21):9013–9022. <https://doi.org/10.1007/s00253-016-7835-7>

Agencia Estatal de Meteorología (AEMET), Instituto de Meteorologia de Portugal (IM). 2011. Atlas Climático Ibérico—Iberian Climate Atlas. AEMET-Ministerio de Medio Ambiente, y Medio Rural y Marino and Instituto de Meteorologia de Portugal. Madrid, Spain.

Aguiar LJG, Fischer GR, Ladle RJ, Malhado ACM, Justino FB, Aguiar RG, da Costa JMN. 2012. Modeling the photosynthetically active radiation in South West Amazonia under all sky conditions. *Theor Appl Climatol*. 108(3–4):631–640. <https://doi.org/10.1007/s00704-011-0556-z>

Aiba S. 1982. Growth kinetics of photosynthetic microorganisms. In: *Microbial Reactions*. *Adv in Biochem Eng*. 23. [https://doi.org/10.1007/3540116982\\_3](https://doi.org/10.1007/3540116982_3)

Ajala SO, Alexander ML. 2020. Assessment of *Chlorella Vulgaris*, *Scenedesmus Obliquus*, and *Oocystis Minuta* for Removal of Sulfate, Nitrate, and Phosphate in Wastewater. *Int. J. Energy Environ Eng*. 11:311–326. <https://doi.org/10.1007/s40095-019-00333-0>

Akitsu T, Kume A, Hirose Y, Ijima O, Nasahara KN. 2015. On the stability of radiometric ratios of photosynthetically active radiation to global solar radiation in Tsukuba, Japan. *Agric For Meteorol*. 209–210:59–68. <https://doi.org/10.1016/j.agrformet.2015.04.026>

Akitsu TK, Nasahara KN, Ijima O, Hirose Y, Ide R, Takagi K, Kume A. 2022. The Variability and Seasonality in the Ratio of Photosynthetically Active Radiation to Solar Radiation: A Simple Empirical Model of the Ratio. *Int J Appl Earth Obs Geoinf*. 108. <https://doi.org/10.1016/j.jag.2022.102724>

Alados I, Foyo-Moreno I, Alados-Arboledas L. 1996. Photosynthetically active radiation: Measurements and modelling. *Agric For Meteorol*. 78(1–2):121–131. [https://doi.org/10.1016/0168-1923\(95\)02245-7](https://doi.org/10.1016/0168-1923(95)02245-7)

Alazaiza MYD, He S, Su D, Abu Amr SS, Toh PY, Bashir MJK. 2023. Sewage Water Treatment Using *Chlorella Vulgaris* Microalgae for Simultaneous Nutrient Separation and Biomass Production. *Separations*. 10(4). <https://doi.org/10.3390/separations10040229>

Alcón-Martín A. 1999. Desarrollo de Modelos Cinéticos para Bioprocesos: Aplicación a la Producción de Xantano. Madrid: Universidad Complutense de Madrid.

- Aleya L, Dauta A, Reynolds CS. 2011. Endogenous Regulation of the Growth-Rate Responses of a Spring-Dwelling Strain of the Freshwater Alga, *Chlorella Minutissima*, to Light and Temperature. *Eur. J. Protistol.* 47(4):239–244. <https://doi.org/10.1016/j.ejop.2011.05.003>
- Ali H, Park CW. 2017. Numerical Multiphase Modeling of CO<sub>2</sub> Absorption and Desorption in Microalgal Raceway Ponds to Improve Their Carbonation Efficiency. *Energy.* 127: 358–371. <https://doi.org/10.1016/j.energy.2017.03.143>
- AlMomani FA, Örmeci B. 2016. Performance Of *Chlorella Vulgaris*, *Neochloris Oleoabundans*, and Mixed Indigenous Microalgae for Treatment of Primary Effluent, Secondary Effluent and Centrate. *Ecol. Eng.* 95:280–289. <https://doi.org/10.1016/j.ecoleng.2016.06.038>
- Arcila JS, Buitrón G. 2017. Influence of Solar Irradiance Levels on the Formation of Microalgae-Bacteria Aggregates for Municipal Wastewater Treatment. *Algal Res.* 27:190–197. <https://doi.org/10.1016/j.algal.2017.09.011>
- Baneshi M, Gonome H, Maruyama S. 2020 Wide-Range Spectral Measurement of Radiative Properties of Commercial Greenhouse Covering Plastics and Their Impacts into the Energy Management in a Greenhouse. *Energy.* 210. <https://doi.org/10.1016/j.energy.2020.118535>
- Barlow KM, Christy BP, O’Leary GJ, Riffkin PA, Nuttall JG. 2015. Simulating the impact of extreme heat and frost events on wheat crop production: A review. *Field Crops Res.* 171:109–119. <https://doi.org/10.1016/j.fcr.2014.11.010>
- Baxevanou C, Fidaros D, Katsoulas N, Mekeridis E, Varlamis C, Zachariadis A, Logothetidis S. 2020. Simulation of Radiation and Crop Activity in a Greenhouse Covered with Semitransparent Organic Photovoltaics. *Appl Sci.* 10(7). <https://doi.org/10.3390/app10072550>
- Béchet Q, Shilton A, Guieysse B. 2013. Modeling the effects of light and temperature on algae growth: State of the art and critical assessment for productivity prediction during outdoor cultivation. *Biotechnol Adv.* 31(8):1648–1663. <https://doi.org/10.1016/j.biotechadv.2013.08.014>
- Beck HE, Zimmermann NE, McVicar TR, Vergopolan N, Berg A, Wood EF. 2018. Present and Future Köppen-Geiger Climate Classification Maps at 1-Km Resolution. *Scienti Data.* 5. <https://doi.org/10.1038/sdata.2018.214>
- Behera B, Aly N, Balasubramanian P. 2018. Biophysical Modeling of Microalgal Cultivation in Open Ponds. *Ecol Modell.* 388:61–71. <https://doi.org/10.1016/j.ecolmodel.2018.09.024>
- Beltrami E. 1987. Chapter Four - Growth and Decay. Academic Press. 61–82. <https://doi.org/10.1016/B978-0-12-085555-1.50008-9>

- Bernard O, Rémond B. 2012. Validation of a Simple Model Accounting for Light and Temperature Effect on Microalgal Growth. *Bioresour Technol.* 123:520–527. <https://doi.org/10.1016/j.biortech.2012.07.022>
- Breuer G, Lamers PP, Martens DE, Draaisma RB, Wijffels RH. 2013. Effect of Light Intensity, PH, and Temperature on Triacylglycerol (TAG) Accumulation Induced by Nitrogen Starvation in *Scenedesmus Obliquus*. *Bioresour Technol.* 143:1–9. <https://doi.org/10.1016/j.biortech.2013.05.105>
- Buchanan NA, Young P, Cromar NJ, Fallowfield HJ. 2018. Performance of a High Rate Algal Pond Treating Septic Tank Effluent from a Community Wastewater Management Scheme in Rural South Australia. *Algal Res.* 35:325–332. <https://doi.org/10.1016/j.algal.2018.08.036>
- Cabello J, Toledo-Cervantes A, Sánchez L, Revah S, Morales M. 2015. Effect of the Temperature, PH and Irradiance on the Photosynthetic Activity by *Scenedesmus Obtusiusculus* under Nitrogen Replete and Deplete Conditions. *Bioresour Technol.* 181:128–135. <https://doi.org/10.1016/j.biortech.2015.01.034>
- Cebecauer T, Suri M. 2015. Typical Meteorological Year Data: SolarGIS Approach. *Energy Procedia.* 69:1958–1969. <https://doi.org/10.1016/j.egypro.2015.03.195>
- Cemek B, Demir Y, Uzun S, Ceyhan V. 2006. The Effects of Different Greenhouse Covering Materials on Energy Requirement, Growth and Yield of Aubergine. *Energy.* 31(12):1780–1788. <https://doi.org/10.1016/j.energy.2005.08.004>
- Chan ALS, Chow TT, Fong SKF, Lin JZ. 2006. Generation of a Typical Meteorological Year for Hong Kong. *Energy Convers Manag.* 47(1):87–96. <https://doi.org/10.1016/j.enconman.2005.02.010>
- Choi H-J, Lee S-M. 2013. Performance of *Chlorella vulgaris* for the removal of ammonia-nitrogen from wastewater. *Environ Eng Res.* 18(4):235–239. <https://doi.org/10.4491/eer.2013.18.4.235>
- Darvehei P, Bahri PA, Moheimani NR. 2018. Modeling the Effect of Temperature on Microalgal Growth under Outdoor Conditions. In: *Comp Aided Chem Eng.* 143:55–60. <https://doi.org/10.1016/B978-0-444-64235-6.50012-7>
- De Miguel A, Bilbao J. 2005. Test Reference Year Generation from Meteorological and Simulated Solar Radiation Data. *Solar Energy.* 78(6):695–703. <https://doi.org/10.1016/j.solener.2004.09.015>
- Díez-Montero R, Belohlav V, Ortiz A, Uggetti E, García-Galán MJ, García J. 2020. Evaluation of daily and seasonal variations in a semi-closed photobioreactor for microalgae-based bioremediation of agricultural runoff at full-scale. *Algal Res.* 47. <https://doi.org/10.1016/j.algal.2020.101859>

- Domínguez A, Martínez-Romero A, Leite KN, Tarjuelo JM, de Juan JA, López-Urrea R. 2013. Combination of typical meteorological year with regulated deficit irrigation to improve the profitability of garlic growing in central Spain. *Agric Water Manag.* 130:154–167. <https://doi.org/10.1016/j.agwat.2013.08.024>
- Escobedo JF, Gomes EN, Oliveira AP, Soares J. 2009. Modeling Hourly and Daily Fractions of UV, PAR and NIR to Global Solar Radiation under Various Sky Conditions at Botucatu, Brazil. *Appl Energy*, 86(3):299–309. <https://doi.org/10.1016/j.apenergy.2008.04.013>
- Eze VC, Velasquez-Orta SB, Hernández-García A, Monje-Ramírez I, Orta-Ledesma MT. 2018. Kinetic modelling of microalgae cultivation for wastewater treatment and carbon dioxide sequestration. *Algal Res.* 32:131–141. <https://doi.org/10.1016/j.algal.2018.03.015>
- FAO, IFAD, WHO, WFP, UNICEF. 2024. El estado de la seguridad alimentaria y la nutrición en el mundo 2024: Financiación para acabar con el hambre, la inseguridad alimentaria y la malnutrición en todas sus formas. Roma: FAO. <https://doi.org/10.4060/cd1254es>
- FAO, ONU-Agua. 2022. Progreso del cambio en la eficiencia del uso del agua. Estado mundial y necesidades de aceleración del indicador 6.4.1 de los ODS, 2021. FAO ; Organización de Naciones Unidas Agua (ONU-Agua), editor. Roma. <https://doi.org/10.4060/cb6413es>
- Farrelly DJ, Everard CD, Fagan CC, McDonnell KP. 2013. Carbon Sequestration and the Role of Biological Carbon Mitigation: A Review. *Renew Sustain Energy Rev.* 21:712–727. <https://doi.org/10.1016/j.rser.2012.12.038>
- Fernández MD, López JC, Baeza E, Céspedes A, Meca DE, Bailey B. 2015. Generation and Evaluation of Typical Meteorological Year Datasets for Greenhouse and External Conditions on the Mediterranean Coast. *Int J Biometeorol.* 59:1067–1081. <https://doi.org/10.1007/s00484-014-0920-7>
- Fernández-Peruchena CM, Ramírez L, Silva-Pérez MA, Lara V, Bermejo D, Gastón M, Moreno-Tejera S, Pulgar J, Liria J, Macías S, et al. 2016. A Statistical Characterization of the Long-Term Solar Resource: Towards Risk Assessment for Solar Power Projects. *Solar Energy.* 123:29–39. <https://doi.org/10.1016/j.solener.2015.10.051>
- Fernández-Peruchena CM, Vignola F, Gastón M, Lara-Fanego V, Ramírez L, Zarzalejo LF, Silva M, Pavón M, Moreno S, Bermejo D, et al. 2018. Probabilistic Assessment of Concentrated Solar Power Plants Yield: The EVA Methodology. *Renew Sustain Energy Rev.* 91:802–811. <https://doi.org/10.1016/j.rser.2018.03.018>
- Ferrera-Cobos F, Vindel JM, Valenzuela RX, González JA. 2020a. Analysis of Spatial and Temporal Variability of the PAR/GHI Ratio and PAR Modeling Based on Two Satellite Estimates. *Remote Sens.* 12(8). <https://doi.org/10.3390/rs12081262>

- Ferrera-Cobos F, Vindel JM, Valenzuela RX, González JA. 2020b. Models for estimating daily photosynthetically active radiation in oceanic and mediterranean climates and their improvement by site adaptation techniques. *Adv in Space Res.* 65(8):1894–1909. <https://doi.org/10.1016/j.asr.2020.01.018>
- Ferrera-Cobos F, Vindel JM, Wane O, Navarro AA, Zarzalejo LF, Valenzuela RX. 2021. Combination of Models to Generate the First PAR Maps for Spain. *Remote Sens.* 13(23). <https://doi.org/10.3390/rs13234950>
- Festa R, Ratto CF. 1993. Proposal of a numerical procedure to select Reference Years. *Solar Energy.* 50(1):9–17. [https://doi.org/10.1016/0038-092X\(93\)90003-7](https://doi.org/10.1016/0038-092X(93)90003-7)
- Foyo-Moreno I, Alados I, Alados-Arboledas L. 2017. A New Conventional Regression Model to Estimate Hourly Photosynthetic Photon Flux Density under All Sky Conditions. *Int J Climatol.* 37:1067–1075. <https://doi.org/10.1002/joc.5063>
- García J, Green BF, Lundquist T, Mujeriego R, Hernández-Mariné M, Oswald WJ. 2006. Long Term Diurnal Variations in Contaminant Removal in High Rate Ponds Treating Urban Wastewater. *Bioresour Technol.* 97(14):1709–1715. <https://doi.org/10.1016/j.biortech.2005.07.019>
- García-Malea MC, Acién FG, Fernández JM, Cerón MC, Molina E. 2006. Continuous production of green cells of *Haematococcus pluvialis*: Modeling of the irradiance effect. *Enzyme Microb Technol.* 38(7):981–989. <https://doi.org/10.1016/j.enzmictec.2005.08.031>
- García-Rodríguez A, García-Rodríguez S, Granados-López D, Díez-Mediavilla M, Alonso-Tristán C. 2022. Extension of PAR Models under Local All-Sky Conditions to Different Climatic Zones. *Appl Sci.* 12(5). <https://doi.org/10.3390/app12052372>
- García-Rodríguez A, Granados-López D, García-Rodríguez S, Díez-Mediavilla M, Alonso-Tristán C. 2021. Modelling Photosynthetic Active Radiation (PAR) through Meteorological Indices under All Sky Conditions. *Agric For Meteorol.* 310. <https://doi.org/10.1016/j.agrformet.2021.108627>
- Garfí M, Flores L, Ferrer I. 2017. Life Cycle Assessment of Wastewater Treatment Systems for Small Communities: Activated Sludge, Constructed Wetlands and High Rate Algal Ponds. *J Clean Prod.* 161:211–219. <https://doi.org/10.1016/j.jclepro.2017.05.116>
- Georgiou G, Eftekhari M, Eames P, Mourshed M. 2013. A study of the effect of weighting indices for the development of TMY used for building simulation. In *Proceedings of the BS2013: 13th Conference of International Building Performance Simulation Association*. Chambéry France. <https://doi.org/10.26868/25222708.2013.2241>
- Gerotto C, Norici A, Giordano M. 2020. Toward Enhanced Fixation of CO<sub>2</sub> in Aquatic Biomass: Focus on Microalgae. *Front Energy Res.* 8. <https://doi.org/10.3389/fenrg.2020.00213>

- Gilman P, Dobos A, Kasberg M. 2012. P50/P90 Analysis for Solar Energy Systems Using the System Advisor Model: Preprint. 2012. Paper presented at 2012 World Renewable Energy Forum, Denver, Colorado.
- Gu L, Baldocchi D, Verma SB, Black TA, Vesala T, Falge EM, Dowty PR. 2002. Advantages of Diffuse Radiation for Terrestrial Ecosystem Productivity. *J Geophys Res Atmos.* 107(D6). <https://doi.org/10.1029/2001JD001242>
- Habte A, Lopez A, Sengupta M, Wilcox S. 2014. Temporal and Spatial Comparison of Gridded TMY, TDY, and TGY Data Sets. <https://doi.org/10.2172/1126297>
- Hall IJ, Prairie RR, Anderson HE, Boes EC. 1978. Generation of typical meteorological years for 26 SOLMET stations. Albuquerque, NM (USA).
- Hatfield JL, Prueger JH. 2015. Temperature extremes: Effect on plant growth and development. *Weather Clim Extrem.* 10:4–10. <https://doi.org/10.1016/j.wace.2015.08.001>
- Hegnar H, Müller G, Nespor V, Ohmura A, Steigrad R, Gilgen H. 1998. Update of the Technical Plan for BSRN Data Management. Zurich.
- Heinemann PH, Walker PN. 1987. Effects of Greenhouse Surface Heating Water on Light Transmission. *Transactions of the ASAE.* 30(1):0215-0220. <https://doi.org/10.13031/2013.30430>.
- Hernández D, Riaño B, Coca M, García-González MC. 2013. Treatment of agro-industrial wastewater using microalgae-bacteria consortium combined with anaerobic digestion of the produced biomass. *Bioresour Technol.* 135:598–603. <https://doi.org/10.1016/j.biortech.2012.09.029>
- Hersbach H, Bell B, Berrisford P, Hirahara S, Horányi A, Muñoz-Sabater J, Nicolas J, Peubey C, Radu R, Schepers D, et al. 2020. The ERA5 global reanalysis. *Quart J of the Royal Meteor Socie.* 146(730):1999–2049. <https://doi.org/10.1002/qj.3803>
- Hindersin S, Leupold M, Kerner M. 2014. Key parameters for outdoor biomass production of *Scenedesmus obliquus* in solar tracked photobioreactors. *J Appl Phycol.* 26:2315–2325. <https://doi.org/10.1007/s10811-014-0261-2>
- Holzworth DP, Huth NI, de Voil PG, Zurcher EJ, Herrmann NI, McLean G, Chenu K, van Oosterom EJ, Snow V, Murphy C et al. 2014. APSIM – Evolution towards a New Generation of Agricultural Systems Simulation. *Environ Model Softw.* 62:327–350. <https://doi.org/10.1016/j.envsoft.2014.07.009>
- Hu B, Wang Y, Liu G. 2007. Spatiotemporal characteristics of photosynthetically active radiation in China. *J Geophys Res Atmos.* 112(D14):1–12. <https://doi.org/10.1029/2006JD007965>

- Huesemann MH, Crowe B, Waller P, Chavis A, Hobbs S, Edmundson S, Wigmosta MS. 2016. Validated Model to Predict Microalgae Growth in Outdoor Pond Cultures Subjected to Fluctuating Light Intensities and Water Temperatures. *Algal Res.* 13:195–206. <https://doi.org/10.1016/j.algal.2015.11.008>
- Huld T, Müller R, Gambardella A. 2012. A new solar radiation database for estimating PV performance in Europe and Africa. *Sol Energy.* 86(6):1803–1815. <https://doi.org/10.1016/j.solener.2012.03.006>
- Huld T, Paietta E, Zangheri P, Pascua IP. 2018. Assembling Typical Meteorological Year Data Sets for Building Energy Performance Using Reanalysis and Satellite-Based Data. *Atmosphere.* 9(2). <https://doi.org/10.3390/atmos9020053>
- Iasimone F, Panico A, De Felice V, Fantasma F, Iorizzi M, Pirozzi F. 2018. Effect of Light Intensity and Nutrients Supply on Microalgae Cultivated in Urban Wastewater: Biomass Production, Lipids Accumulation and Settability Characteristics. *J Environ Manag.* 223:1078–1085. <https://doi.org/10.1016/j.jenvman.2018.07.024>
- Iqbal, M. 1983. *An Introduction to Solar Radiation*. Academic Press. Toronto. ISBN: 978-0-12-373750-2
- Jabri HA, Taleb A, Touchard R, Saadaoui I, Goetz V, Pruvost J. 2021. Cultivating Microalgae in Desert Conditions: Evaluation of the Effect of Light-temperature Summer Conditions on the Growth and Metabolism of *Nannochloropsis* Qu130. *Appl Sci.* 11(9). <https://doi.org/10.3390/app11093799>
- Janssen M. 2016. Microalgal Photosynthesis and Growth in Mass Culture. In *Adv in Chem Eng.* 48:185–256. <https://doi.org/10.1016/bs.ache.2015.11.001>
- Kalogirou SA. 2003. Generation of Typical Meteorological Year (TMY-2) for Nicosia, Cyprus. *Renew Energy.* 28:2317–2334. [https://doi.org/10.1016/S0960-1481\(03\)00131-9](https://doi.org/10.1016/S0960-1481(03)00131-9)
- Kamarianakis Y, Ayuso SV, Rodríguez EC, Velasco MT. 2016. Water Temperature Forecasting for Spanish Rivers by Means of Nonlinear Mixed Models. *J Hydrol Reg Stud.* 5:226–243. <https://doi.org/10.1016/j.ejrh.2016.01.003>
- Kato S, Ackerman TP, Mather JH, Clothiaux EE. 1999. The k-distribution method and correlated-k approximation for a shortwave radiative transfer model. *J Quant Spectrosc Radiat Transf.* 62(1):109–121. [https://doi.org/10.1016/S0022-4073\(98\)00075-2](https://doi.org/10.1016/S0022-4073(98)00075-2)
- Kephe PN, Ayisi KK, Petja BM. 2021. Challenges and Opportunities in Crop Simulation Modelling under Seasonal and Projected Climate Change Scenarios for Crop Production in South Africa. *Agric Food Secur.* 10. <https://doi.org/10.1186/s40066-020-00283-5>
- Kidder SQ, Vonder Haar TH. 1995. *Satellite Meteorology—An Introduction*. Academic Press. Cambridge, MA, USA. ISBN 978-0124064300

- Kim TH, Lee Y, Han SH, Hwang SJ. 2013. The Effects of Wavelength and Wavelength Mixing Ratios on Microalgae Growth and Nitrogen, Phosphorus Removal Using *Scenedesmus* Sp. for Wastewater Treatment. *Bioresour Technol.* 130:75–80. <https://doi.org/10.1016/j.biortech.2012.11.134>
- Köppen W, Geiger R. 1936. Das Geographische System Der Klimate. In: Köppen W and Geiger R. Eds. *Handbuch der Klimatologie*. Verlag Gebrüder Borntrager, Berlin (DE) (In German).
- Leblon B, Guerif M, Baret F. 1991. The use of remotely sensed data in estimation of PAR use efficiency and biomass production of flooded rice. *Remote Sens Environ.* 38(2):147–158. [https://doi.org/10.1016/0034-4257\(91\)90076-I](https://doi.org/10.1016/0034-4257(91)90076-I)
- Lee C, Hoes P, Cóstola D, Hensen JLM. 2019. Assessing the performance potential of climate adaptive greenhouse shells. *Energy.* 175:534–545. <https://doi.org/10.1016/j.energy.2019.03.074>
- Leite KN, Martínez-Romero A, Tarjuelo JM, Domínguez A. 2015. Distribution of Limited Irrigation Water Based on Optimized Regulated Deficit Irrigation and Typical Meteorological Year Concepts. *Agric Water Manag.* 148:164–176. <https://doi.org/10.1016/j.agwat.2014.10.002>
- Li J, Pan K, Tang X, Li Y, Zhu B, Zhao Y. 2021. The molecular mechanisms of *Chlorella* sp. responding to high CO<sub>2</sub>: A study based on comparative transcriptome analysis between strains with high- and low-CO<sub>2</sub> tolerance. *Science of the Total Environment.* 763. <https://doi.org/10.1016/j.scitotenv.2020.144185>
- Liem SH, Van Paassen AH. 1984. Establishment of Short Reference Years for Calculation of Annual Solar Heat Gain or Energy Consumption in Residential and Commercial Buildings Part 1 and 2; Technical Report: EUR 8912 EN. Commission of the European Communities Luxembourg.
- Liu BYH, Jordan RC. 1960. The Interrelationship and Characteristic Distribution of Direct, Diffuse and Total Solar Radiation. *Sol Energy.* 4(3):1–19. [https://doi.org/10.1016/0038-092X\(60\)90062-1](https://doi.org/10.1016/0038-092X(60)90062-1)
- Liu X, Ying K, Chen G, Zhou C, Zhang W, Zhang X, Cai Z, Holmes T, Tao Y. 2017. Growth of *Chlorella vulgaris* and nutrient removal in the wastewater in response to intermittent carbon dioxide. *Chemosphere.* 186:977–985. <https://doi.org/10.1016/j.chemosphere.2017.07.160>
- Long CN, Dutton EG. 2002. BSRN Global Network recommended QC tests, V2.0. Bremerhaven, PANGAEA. <https://doi.org/10013/epic.38770.d001>

- Long CN, Shi Y. 2008. An Automated Quality Assessment and Control Algorithm for Surface Radiation Measurements. *The Open Atmospheric Science Journal*. 2:23–37. <https://doi.org/10.2174/1874282300802010023>
- López-Sánchez A, Silva-Gálvez AL, Aguilar-Juárez Ó, Senés-Guerrero C, Orozco-Nunnelly D.A., Carrillo-Nieves D, Gradilla-Hernández M.S. 2022. Microalgae-Based Livestock Wastewater Treatment (MbWT) as a Circular Bioeconomy Approach: Enhancement of Biomass Productivity, Pollutant Removal and High-Value Compound Production. *J. Environ Manag.* 308. <https://doi.org/10.1016/j.jenvman.2022.114612>
- Lozano IL, Sánchez-Hernández G, Guerrero-Rascado JL, Alados I, Foyo-Moreno I. 2022. Analysis of Cloud Effects on Long-Term Global and Diffuse Photosynthetically Active Radiation at a Mediterranean Site. *Atmos Res.* 268. <https://doi.org/10.1016/j.atmosres.2021.106010>
- Lund H. 1985. Short reference years and test reference years for EEC countries, Technical Report: EUR 10208 EN. Thermal Insulation Laboratory-Technical University of Denmark. Lyngby, Denmark.
- Lund H. 1991. The Design Reference Year. In: 91th Conference, International Building Performance Simulation Association. Sophia-Antipolis Nice France. 600–606.
- Marbis J.M. 2001. CO<sub>2</sub> Enrichment and Hot Water Heat in a Greenhouse as a Mean of Recovering Bioresources from Swine Waste. North Carolina State University. Raleigh NC USA.
- Marion W, Urban K. 1995. User's Manual for TMY2s (Typical Meteorological Years) - Derived from the 1961–1990 National Solar Radiation Data Base. <https://doi.org/10.2172/87130>
- Martínez-Romero A, Domínguez A, Landeras G. 2019. Regulated Deficit Irrigation Strategies for Different Potato Cultivars under Continental Mediterranean-Atlantic Conditions. *Agric Water Manag.* 216:164–176. <https://doi.org/10.1016/j.agwat.2019.01.030>
- MathWorks. 2024. Centro de Ayuda – Ejecutar Varias Simulaciones. Available online: <https://es.mathworks.com/help/simulink/run-multiple-parallel-simulations.html> (accessed on 5 November 2024)
- Metsoviti MN, Papapolymerou G, Karapanagiotidis IT, Katsoulas N. 2020. Effect of light intensity and quality on growth rate and composition of *Chlorella vulgaris*. *Plants*. 9(1). <https://doi.org/10.3390/plants9010031>
- Mizoguchi Y, Yasuda Y, Ohtani Y, Watanabe T, Kominami Y, Yamanoi K. 2014. A Practical Model to Estimate Photosynthetically Active Radiation Using General Meteorological

Elements in a Temperate Humid Area and Comparison among Models. *Theor Appl Climatol.* 115:583–589. <https://doi.org/10.1007/s00704-013-0912-2>

Molinari RL, Garzoli SL, Katz J, Harrison E, Richardson PL, Reverdin G. 1986. A Synthesis of the First GARP Global Experiment (FGGE) in the Equatorial Atlantic Ocean. *Prog Oceanogr.* 16:91–112. [https://doi.org/10.1016/0079-6611\(86\)90008-X](https://doi.org/10.1016/0079-6611(86)90008-X)

Monod J. 1949. The growth of bacterial cultures. *Annu Rev Microbiol.* 3:371–394. <https://doi.org/10.1146/annurev.mi.03.100149.002103>

Müller R, Pfeifroth U. 2022. Remote sensing of solar surface radiation-a reflection of concepts, applications and input data based on experience with the effective cloud albedo. *Atmos Meas Tech.* 15(5):1537–1561. <https://doi.org/10.5194/amt-15-1537-2022>

Müller R, Pfeifroth U, Träger-Chatterjee C, Trentmann J, Cremer R. 2015. Digging the METEOSAT Treasure-3 Decades of Solar Surface Radiation. *Remote Sens.* 7(6):8067–8101. <https://doi.org/10.3390/rs70608067>

National Renewable Energy Laboratory. 1993. Users Manual for SERf QC Software—Assessing the Quality of Solar Radiation. National Renewable Energy Laboratory (NREL). Denver, Colorado.

Oswald WJ, Gotaas HB. 1957. Photosynthesis in Sewage Treatment. *Trans Am Soc Civ Eng.* 122(1):73–97. <https://doi.org/10.1061/TACEAT.0007483>

Pashiardis S, Kalogirou S, Pelengaris A. 2017. Characteristics of Photosynthetic Active Radiation (PAR) Through Statistical Analysis at Larnaca, Cyprus. *SM J Biometrics Biostat.* 2(2):1–16. ISSN: 2573-5470

Pawłowski A, Guzmán JL, Berenguel M, Acien FG, Dormido, S. 2018. Application of Predictive Feedforward Compensator to Microalgae Production in a Raceway Reactor: A Simulation Study. *Energies.* 11(1):123. <https://doi.org/10.3390/en11010123>

Peel MC, Finlayson BL, McMahon TA. 2007. Updated World Map of the Köppen-Geiger Climate Classification. *Hydrol Earth Syst Sci.* 11(5):1633–1644. <https://doi.org/10.5194/hess-11-1633-2007>

Pinker RT, Zhao M, Wang H, Wood EF. 2010. Impact of satellite based PAR on estimates of terrestrial net primary productivity. *Int J Remote Sens.* 31(19):5221–5237. <https://doi.org/10.1080/01431161.2010.496474>

Pires JCM, Gonçalves AL, Martins FG, Alvim-Ferraz MCM, Simões M. 2014. Effect of Light Supply on CO<sub>2</sub> Capture from Atmosphere by *Chlorella Vulgaris* and *Pseudokirchneriella Subcapitata*. *Mitig Adap. Strateg Glob Chang.* 19:1109–1117. <https://doi.org/10.1007/s11027-013-9463-1>

- Pissimanis D, Karras G, Notaridou V, Gavra K. 1988. The generation of a “typical meteorological year” for the city of Athens. *Sol Energy*. 40(5):405–411. [https://doi.org/10.1016/0038-092X\(88\)90095-3](https://doi.org/10.1016/0038-092X(88)90095-3)
- Prasad R, Gupta SK, Shabnam N, Oliveira CYB, Nema AK, Ansari FA, Bux F. 2021. Role of microalgae in global CO<sub>2</sub> sequestration: Physiological mechanism, recent development, challenges, and future prospective. *Sustainability (Switzerland)*. 13(23). <https://doi.org/10.3390/su132313061>
- Ramírez-Pérez LJ, Morales-Díaz AB, De Alba-Romenus K, González-Morales S, Benavides-Mendoza A, Juárez-Maldonado A. 2017. Determination of Micronutrient Accumulation in Greenhouse Cucumber Crop Using a Modeling Approach. *Agronomy*. 7(4). <https://doi.org/10.3390/agronomy7040079>
- Ras M, Steyer JP, Bernard O. 2013. Temperature effect on microalgae: A crucial factor for outdoor production. *Rev Environ Sci Biotechnol*. 12(2):153–164. <https://doi.org/10.1007/s11157-013-9310-6>
- Raymond Hunt, JRE. 1994. Relationship between Woody Biomass and PAR Conversion Efficiency for Estimating Net Primary Production from NDVI. *Int J Remote Sens*. 15(8):1725–1729. <https://doi.org/10.1080/01431169408954203>
- Robles Á, Capson-Tojo G, Galès A, Ruano MV, Sialve B, Ferrer J, Steyer JP. 2020. Microalgae-Bacteria Consortia in High-Rate Ponds for Treating Urban Wastewater: Elucidating the Key State Indicators under Dynamic Conditions. *J Environ Manag*. 261. <https://doi.org/10.1016/j.jenvman.2020.110244>
- Roderick ML, Farquhar GD, Berry SL, Noble IR. 2001. On the direct effect of clouds and atmospheric particles on the productivity and structure of vegetation. *Oecologia*. 129(1):21–30. <https://doi.org/10.1007/s004420100760>
- Rodríguez F, Castro A, Marín F, Roldán G, Viteri Moya F. 2019. Typical Meteorological Year Based on the Precipitation of Nanegalito and Pacto-Ecuador. *Enfoque UTE*. 10(1):197–204. <https://doi.org/10.29019/enfoqueute.v10>
- Rosso L, Lobry JR, Flandrois JP. 1993. An Unexpected Correlation between Cardinal Temperatures of Microbial Growth Highlighted by a New Model. *J Theor Biol*. 162(4):447–463. <https://doi.org/10.1006/jtbi.1993.1099>
- Sacristán de Alva M, Luna-Pabello VM, Cadena E, Ortiz E. 2013. Green Microalga *Scenedesmus Acutus* Grown on Municipal Wastewater to Couple Nutrient Removal with Lipid Accumulation for Biodiesel Production. *Bioresour. Technol*. 146:744–748. <https://doi.org/10.1016/j.biortech.2013.07.061>
- Salazar G, Raichijk C. 2014. Evaluation of Clear-Sky Conditions in High Altitude Sites. *Renew Energy*. 64:197–202. <https://doi.org/10.1016/j.renene.2013.11.003>

Schirmer M, Posten C. 2016. Modeling of Microalgae Bioprocesses. *Adv in Chem Eng.* 48:151–184. <https://doi.org/10.1016/bs.ache.2015.12.001>

Schmidt JJ, Gagnon GA, Jamieson RC. 2016. Microalgae Growth and Phosphorus Uptake in Wastewater under Simulated Cold Region Conditions. *Ecol Eng.* 95:588–593. <https://doi.org/10.1016/j.ecoleng.2016.06.114>

Schulz J, Albert P, Behr H-D, Caprion D, Deneke H, Dewitte S, Fuchs P, Gratzki A, Hechler P, Hollmann R, et al. 2009. Operational climate monitoring from space: the EUMETSAT Satellite Application Facility on Climate Monitoring (CM-SAF). *Atmos Chem Phys.* 9:1687–1709. <https://doi.org/10.5194/acp-9-1687-2009>

Sengupta M, Habte A, Kurtz S, Dobos A, Wilbert S, Lorenz E, Stoffel T, Renné D, Gueymard C, Myers D et al. 2015. Best Practices Handbook for the Collection and Use of Solar Resource Data for Solar Energy Applications. Technical Report: NREL/TP-5D00-63112. National Renewable Energy Laboratory (NREL). Denver, Colorado.

Sengupta M, Habte A, Wilbert S, Gueymard C, Remund J. 2021. Best Practices Handbook for the Collection and Use of Solar Resource Data for Solar Energy Applications: Third Edition. <https://doi.org/10.2172/2448063>

Sengupta M, Habte A, Wilbert S, Gueymard C, Remund J, Lorenz E, van Sark W, Jensen AR. 2024. Best Practices Handbook for the Collection and Use of Solar Resource Data for Solar Energy Applications: Fourth Edition. <https://doi.org/10.2172/2448063>

Serra-Maia R, Bernard O, Gonçalves A, Bensalem S, Lopes F. 2016. Influence of temperature on *Chlorella vulgaris* growth and mortality rates in a photobioreactor. *Algal Res.* 18:352–359. <https://doi.org/10.1016/j.algal.2016.06.016>

Shaw A, Takács I, Pagilla KR, Murthy S. 2013 A New Approach to Assess the Dependency of Extant Half-Saturation Coefficients on Maximum Process Rates and Estimate Intrinsic Coefficients. *Water Res.* 47(16):5986–5994. <https://doi.org/10.1016/j.watres.2013.07.003>

Shen QH, Jiang JW, Chen LP, Cheng LH, Xu XH, Chen HL. 2015. Effect of Carbon Source on Biomass Growth and Nutrients Removal of *Scenedesmus Obliquus* for Wastewater Adv Treatment and Lipid Production. *Bioresour Technol.* 190:257–263. <https://doi.org/10.1016/j.biortech.2015.04.053>

Shoener BD, Schramm SM, Béline F, Bernard O, Martínez C, Plósz BG, Snowling S, Steyer JP, Valverde-Pérez B, Wágner D et al. 2019. Microalgae and cyanobacteria modeling in water resource recovery facilities: A critical review. *Water Res X.* 2. <https://doi.org/10.1016/j.wroa.2018.100024>

Silambarasan S, Logeswari P, Sivaramakrishnan R, Incharoensakdi A, Cornejo P, Kamaraj B, Chi NTL. 2021. Removal of nutrients from domestic wastewater by microalgae coupled to lipid augmentation for biodiesel production and influence of deoiled algal biomass as

- biofertilizer for *Solanum lycopersicum* cultivation. *Chemosphere*. 268.  
<https://doi.org/10.1016/j.chemosphere.2020.129323>
- Singh SP, Singh P. 2015. Effect of temperature and light on the growth of algae species: A review. *Renew Sustain Energy Rev*. 50:431–444. <https://doi.org/10.1016/j.rser.2015.05.024>
- Skeiker K. 2004. Generation of a typical meteorological year for Damascus zone using the Filkenstein-Schafer statistical method. *Energy Convers Manag*. 45(1):99–112.  
[https://doi.org/10.1016/S0196-8904\(03\)00106-7](https://doi.org/10.1016/S0196-8904(03)00106-7)
- Skeiker K. 2007. Comparison of methodologies for TMY generation using 10 years data for Damascus, Syria. *Energy Convers Manag*. 48(7):2090–2102.  
<https://doi.org/10.1016/j.enconman.2006.12.014>
- Su H, Zhang Y, Zhang C, Zhou X, Li J. 2011 Cultivation of *Chlorella Pyrenoidosa* in Soybean Processing Wastewater. *Bioresour Technol*. 102(21):9884–9890.  
<https://doi.org/10.1016/j.biortech.2011.08.016>
- Sun J, Li Z, Xiao F. 2017. Analysis of Typical Meteorological Year Selection for Energy Simulation of Building with Daylight Utilization. *Procedia Eng*. 205:3080–3087.  
<https://doi.org/10.1016/j.proeng.2017.10.303>
- Tang W, Qin J, Yang K, Jiang Y, Pan W. 2022. Mapping long-term and high-resolution global gridded photosynthetically active radiation using the ISCCP H-series cloud product and reanalysis data. *Earth Syst Sci Data*. 14(4):2007–2019. <https://doi.org/10.5194/essd-14-2007-2022>
- Trofimchuk OA, Petikar PV, Turanov SB, Romanenko SA. 2019. The Influence of PAR Irradiance on Yield Growth of *Chlorella Microalgae*. *IOP Conf Ser Mater Sci Eng*. 510.  
<https://doi.org/10.1088/1757-899X/510/1/012017>
- Vadiveloo A, Moheimani NR, Cosgrove JJ, Bahri PA, Parlevliet D. 2015. Effect of Different Light Spectra on the Growth and Productivity of Acclimated *Nannochloropsis* Sp. (*Eustigmatophyceae*). *Algal Res*. 8:121–127. <https://doi.org/10.1016/j.algal.2015.02.001>
- Vindel JM, Valenzuela RX, Navarro A.A, Zarzalejo LF, Paz-Gallardo A, Souto J, Méndez-Gómez R., Cartelle D, Casares J. 2018. Modeling Photosynthetically Active Radiation from Satellite-Derived Estimations over Mainland Spain. *Remote Sens*. 10(6).  
<https://doi.org/10.3390/rs10060849>
- Viruela A, Murgui M, Gómez-Gil T, Durán F, Robles Á, Ruano MV, Ferrer J, Seco A. 2016. Water Resource Recovery by Means of Microalgae Cultivation in Outdoor Photobioreactors Using the Effluent from an Anaerobic Membrane Bioreactor Fed with Pre-Treated Sewage. *Bioresour Technol*. 218:447–454. <https://doi.org/10.1016/j.biortech.2016.06.116>

Wandji Nyamsi W, Espinar B, Blanc P, Wald L. 2015. Estimating the photosynthetically active radiation under clear skies by means of a new approach. *Adv in Science and Research*. 12(1):5–10. <https://doi.org/10.5194/asr-12-5-2015>

Wane O, Ceballos JAR, Ferrera-cobos F, Navarro AA, Valenzuela RX, Zarzalejo LF. 2022. Comparative Analysis of Photosynthetically Active Radiation Models Based on Radiometric Attributes in Mainland Spain. *Land*. 11(10). <https://doi.org/10.3390/land11101868>

Wane O, Zarzalejo LF, Ferrera-Cobos F, Navarro AA, Rodríguez-López A, Valenzuela RX. 2023. Generation of Typical Meteorological Sequences to Simulate Growth and Production of Biological Systems. *Appl Sci*. 13(8). <https://doi.org/10.3390/app13084826>

Wane O, Zarzalejo LF, Ferrera-Cobos F, Navarro AA, Valenzuela RX. 2024. A Novel Methodological Approach to Simulating the Growth of Photosynthetic Organisms Using Long-Term Meteorological Sequences: A Case Study of Microalgae (*Chlorella vulgaris*). *Appl Sci*. 14(22). <https://doi.org/10.3390/app142210580>

Wang C, Du J, Liu Y, Chow D. 2021. A climate-based analysis of photosynthetically active radiation availability in large-scale greenhouses across China. *J Clean Prod*. 315. <https://doi.org/10.1016/j.jclepro.2021.127901>

Wang L, Gong W, Hu B, Lin A, Li H, Zou L. 2015. Modeling and Analysis of the Spatiotemporal Variations of Photosynthetically Active Radiation in China during 1961–2012. *Renew Sustain Energy Rev*. 49:1019–1032. <https://doi.org/10.1016/j.rser.2015.04.174>

Wang L, Gong W, Ma Y, Hu B, Zhang M. 2014a. Photosynthetically Active Radiation and Its Relationship with Global Solar Radiation in Central China. *Int J Biometeorol*. 58:1265–1277. <https://doi.org/10.1007/s00484-013-0690-7>

Wang L, Gong W, Lin A, Hu B. 2014b. Analysis of Photosynthetically Active Radiation under Various Sky Conditions in Wuhan, Central China. *Int J Biometeorol*. 58:1711–1720. <https://doi.org/10.1007/s00484-013-0775-3>

Wang L, Min M, Li Y, Chen P, Chen Y, Liu Y, Wang Y, Ruan R. 2010. Cultivation of Green Algae *Chlorella* sp. in Different Wastewaters from Municipal Wastewater Treatment Plant. *Appl Biochem Biotechnol*. 162:1174–1186. <https://doi.org/10.1007/s12010-009-8866-7>

Wigmosta MS, Coleman AM, Skaggs RJ, Huesemann MH, Lane LJ. 2011. National Microalgae Biofuel Production Potential and Resource Demand. *Water Res*. 47:1–13. <https://doi.org/10.1029/2010WR009966>

World Meteorological Organization - WMO. 2023. Guide to Instruments and Methods of Observation Volume V - Quality Assurance and Management of Observing Systems. WMO editor. Geneva.

- Wu C, Niu Z, Tang Q, Huang W, Rivard B, Feng, J. 2009. Remote Estimation of Gross Primary Production in Wheat Using Chlorophyll-Related Vegetation Indices. *Agric For Meteorol.* 149(6–7):1015–1021. <https://doi.org/10.1016/j.agrformet.2008.12.007>
- Wu J, Wang J, Hui W, Zhao F, Wang P, Su C, Gong W. 2022. Physiology of Plant Responses to Water Stress and Related Genes: A Review. *Forests.* 13(2). <https://doi.org/10.3390/f13020324>
- Xia X, Li Z, Wang P, Chen H, Cribb M. 2007. Estimation of Aerosol Effects on Surface Irradiance Based on Measurements and Radiative Transfer Model Simulations in Northern China. *J Geophys Res.* 112(D22). <https://doi.org/10.1029/2006JD008337>
- Yang L, Wan KKW, Li DHW, Lam JC. 2011. A New Method to Develop Typical Weather Years in Different Climates for Building Energy Use Studies. *Energy.* 36(10):6121–6129. <https://doi.org/10.1016/j.energy.2011.07.053>
- Yu X, Wu Z, Jiang W, Guo X. 2015. Predicting Daily Photosynthetically Active Radiation from Global Solar Radiation in the Contiguous United States. *Energy Convers Manag.* 89:71–82. <https://doi.org/10.1016/j.enconman.2014.09.038>
- Zang H, Xu Q, Bian H. 2012. Generation of Typical Solar Radiation Data for Different Climates of China. *Energy.* 38(1):236–248. <https://doi.org/10.1016/j.energy.2011.12.008>
- Zarzalejo LF, Téllez FM, Heras M. 1995. Creation of TMY for Southern Spanish Cities. In *Proceedings of the International Symposium Passive Cooling of Buildings, Athens, Greece.*
- Zhang J, Zhao L, Deng S, Xu W, Zhang Y. 2017. A Critical Review of the Models Used to Estimate Solar Radiation. *Renew. Sustain. Energy Rev.* 70:314–329. <https://doi.org/10.1016/j.rser.2016.11.124>
- Zo IS, Jee JB, Kim BY, Lee KT. 2017. Baseline Surface Radiation Network (BSRN) Quality Control of Solar Radiation Data on the Gangneung-Wonju National University Radiation Station. *Asia-Pacific J Atmos Sci.* 53:11–19. <https://doi.org/10.1007/s13143-016-0029-5>
- Zou G, Liu Y, Zhang Q, Zhou T, Xiang S, Gu Z, Huang Q, Yan H, Zheng H, Wu X, et al. 2020. Cultivation of *chlorella vulgaris* in a Light-Receiving-Plate (LRP)-enhanced raceway pond for ammonium and phosphorus removal from pretreated pig urine. *Energies.* 13(7). <https://doi.org/10.3390/en13071644>