



POLITÉCNICA



UNIVERSIDAD POLITÉCNICA DE MADRID

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA
AGRONÓMICA, ALIMENTARIA Y DE BIOSISTEMAS

MÁSTER UNIVERSITARIO EN AGRICULTURA DE PRECISIÓN

DEPARTAMENTO DE MATEMÁTICA APLICADA

*Evaluación del modelo SVEN con datos de
teledetección en pastizales Mediterráneos*

TRABAJO FIN DE MÁSTER

Autor: ARNAU RIBA PALOU

Tutora: Ana M^a Tarquis Alfonso

Cotutora: Mónica García García

Febrero de 2025

ÍNDICE

RESUMEN	5
ABSTRACT	6
PALABRAS CLAVE	7
AGRADECIMIENTOS	8
NOMENCLATURA.....	9
1. INTRODUCCIÓN	12
1.1. Sostenibilidad, barreras y oportunidades.....	12
1.2. Agricultura en pastos	13
1.3. Importancia de los pastos en España.....	14
1.4. Nuevas tecnologías (sensores, bases de datos, modelos)	16
1.4.1. Sensores in situ y en remoto	16
1.4.2. Modelos	18
1.4.3. Precedentes sobre modelización	19
1.5. Agronomía del cultivo	20
1.6. Marco de trabajo	22
2. OBJETIVOS	23
3. MATERIALES Y MÉTODOS.....	24
3.1. Caracterización de la parcela y zona de estudio	24
3.2. Datos meteorológicos y climáticos.....	25
3.2.1. Datos meteorológicos y flujos de superficie	26
3.2.2. Error y corrección datos observados.....	28
3.2.3. Estimación de la producción primaria bruta mediante Eddy Covariance	30
3.2.4. Cálculo del parámetro máxima eficiencia en el uso de la luz	30
3.2.5. Estimación de la radiación de onda larga	31
3.2.6. Estimación del índice de área foliar	32
3.2.7. Estimación de la altura de la vegetación.....	32
3.3. Información de sensores remotos.....	33
3.3.1. Producto de <i>ECOSTRESS</i>	33
3.3.2. Producto de satélite <i>MODIS</i>	34
3.4. Adquisición de datos y generación de la base de datos	36
3.4.1. Base de datos input	36
3.5. Validación datos <i>ECOSTRESS</i> con datos in situ.....	37

3.6.	Modelo de balance energético superficial simple	38
3.6.1.	Descripción del modelo.....	38
3.6.2.	Parámetros del modelo.....	40
3.6.3.	Evaluación y validación de los outputs del modelo.....	42
3.7.	Modelo dinámico de transferencia de energía, agua y flujo de CO₂ entre el suelo-vegetación-atmosfera	43
3.7.1.	Descripción del modelo.....	43
3.7.2.	Parámetros del modelo.....	52
3.7.3.	Calibración de los parámetros del modelo.....	54
3.7.4.	Estimación de la frecuencia óptima de pase para la calibración del modelo.....	55
3.7.5.	Evaluación del modelo y validación de los outputs del modelo.....	56
4.	RESULTADOS	57
4.1.	Relación entre flujos turbulentos y energía disponible	57
4.2.	Evaluación de datos <i>ECOSTRESS</i> de evapotranspiración	57
4.3.	Modelo de predicción simple surface energy balance	58
4.3.1.	Evaluación de los outputs del modelo SEB.....	58
4.4.	Modelo de predicción SVEN	62
4.4.1.	Calibración de los parámetros del modelo.....	62
4.4.2.	Validación de los outputs del modelo SVEN.....	64
4.4.3.	Calibración de los parámetros y evaluación del modelo al variar la frecuencia de observación.....	68
4.4.4.	Correcciones de los datos observados:.....	70
5.	DISCUSIÓN	71
5.1.	Error de la estación EC	71
5.2.	Validación datos <i>ECOSTRESS</i> con in situ	71
5.3.	Modelo de predicción SEB	72
5.4.	Modelo de predicción SVEN	72
6.	CONCLUSIONES	76
7.	BIBLIOGRAFÍA	77

RESUMEN

Los pastizales y el pastoreo son esenciales para la seguridad alimentaria y brindan servicios ecosistémicos clave. Sin embargo, enfrentan amenazas como sequías, degradación y cambios climáticos impredecibles. En España, ocupan el 16,77% del territorio, lo que resalta su importancia en la gestión sostenible.

Para optimizar su manejo, es crucial monitorear la evolución del cultivo mediante el análisis de balances energéticos, hídricos y de carbono. La teledetección y modelos predictivos son herramientas clave en este contexto.

Este estudio busca calibrar y validar el modelo biofísico dinámico SVEN, diseñado para simular los balances de energía, agua y flujos de CO₂ entre el suelo, la vegetación y la atmósfera, en un pastizal semiárido de Almería. Se utilizan datos satelitales y mediciones in situ de una estación Eddy Covariance (EC). Inicialmente, se evaluó un modelo basado en balance energético superficial, pero mostró imprecisiones al no diferenciar suelo y vegetación. Como alternativa, se adoptó SVEN, calibrado con temperatura superficial obtenida por satélite y datos de la estación EC.

Los resultados mostraron que, con un mínimo de siete puntos de calibración, se pueden mantener errores por debajo del 10.5%, permitiendo extrapolar observaciones hasta ocho días sin perder precisión. Esto amplía la aplicabilidad del modelo a escala global en regiones con baja disponibilidad de datos.

En conclusión, el modelo SVEN calibrado y validado demuestra ser una herramienta efectiva para la simulación instantánea de balances energéticos y de carbono en ecosistemas áridos, facilitando su gestión sostenible.

ABSTRACT

Grasslands and grazing are essential for food security and provide key ecosystem services. However, they face threats such as droughts, soil degradation, and unpredictable climate changes. In Spain, grasslands occupy 16.77% of the territory, highlighting their importance in sustainable management.

To optimize their management, it is crucial to monitor crop evolution through the analysis of energy, water, and carbon balances. Remote sensing and predictive models are key tools in this context.

This study aims to calibrate and validate the dynamic biophysical model SVEN, designed to simulate energy, water, and CO₂ flux balances between the soil, vegetation, and atmosphere, in a semi-arid grassland in Almería. Satellite data and in situ measurements from an Eddy Covariance (EC) station were used. Initially, a surface energy balance model was evaluated, but it showed inaccuracies due to its inability to differentiate between soil and vegetation. As an alternative, the SVEN model was adopted, calibrated using land surface temperature obtained from MODIS satellite data and EC station measurements.

The results showed that with a minimum of seven calibration points, errors can be kept below 10.5%, allowing observations to be extrapolated up to eight days without losing precision. This enhances the model's applicability on a global scale, particularly in regions with limited data availability.

In conclusion, the calibrated and validated SVEN model proves to be an effective tool for the instantaneous simulation of energy and carbon balances in arid ecosystems, facilitating their sustainable management.

PALABRAS CLAVE

Evapotranspiración (ET)

Temperatura superficial (LST)

Producción primaria bruta (GPP)

Teledetección (MODIS, ECOSTRESS)

Modelo biofísico dinámico

Zonas Áridas

Stipa tenacissima L. (esparto)

AGRADECIMIENTOS

En primer lugar, me gustaría agradecer el soporte de mi familia y amigos por su apoyo durante el último año que he estado realizando el máster en Agricultura de Precisión en la Universidad Politécnica de Madrid (UPM). Su ayuda en todo momento ha sido muy valiosa, y además he podido disfrutar de los logros alcanzados.

Además, me gustaría expresar mi agradecimiento al grupo del CEIGRAM (Centro de Estudios e Investigación para la Gestión de Riesgos Agrarios y Medioambientales) por ofrecer un espacio de colaboración tan bueno para el desarrollo. En especial, a Mónica García y Ana M^a Tarquis, por ayudarme y tutorarme durante todo el proceso.

También agradecer a Sheng Wang, de la Universidad de Aarhus, por acogerme durante una estancia de investigación en el extranjero, lo que me ha permitido continuar investigando y escribir un artículo científico que está en proceso de revisión.

Finalmente, también agradecer a Cecilio Oyonarte, de la Universidad de Almería, a y Francisco Domingo, del CSIC-EEZA, por darme la oportunidad de seguir colaborando en proyectos de teledetección en el Parque Natural de Cabo de Gata.

Arnau Riba Palou

Madrid, 2025

NOMENCLATURA

ALFABETO LATINO:

alb: Albedo (adimensional)

b : Pendiente de la curva de retención del coeficiente térmico “force-restore”

BB: Balsa Blanca, nombre de la zona experimental

BNCE: Balance Neto de Carbono del Ecosistema

C_d : Periodicidad diurna (h^{-1})

c_p : Capacidad de calor específica del aire ($\text{J}\cdot\text{kg}^{-1}\cdot\text{K}^{-1}$)

C_{sar} : Capacidad calorífica específica del suelo a saturación ($\text{J}\cdot\text{m}^{-3}\cdot\text{K}^{-1}$)

C_{soil} : Capacidad calorífica específica del suelo ($\text{J}\cdot\text{m}^{-3}\cdot\text{K}^{-1}$)

C_{veg} : Coeficiente respectivo de vegetación ($\text{m}^2\cdot\text{K}\cdot\text{J}^{-1}$)

C_T : Capacidad calorífica del suelo ($\text{m}^2\cdot\text{K}\cdot\text{J}^{-1}$)

CWS : Nivel actual de almacenaje de agua en la planta (mm)

CWS_{max} : Valor máximo de almacenaje de agua en la planta (mm)

d : Desplazamiento cero de la altura (m)

d_g : Profundidad radicular del suelo (m)

D_o : Coeficiente empírico para el déficit de presión de vapor

DOY: Día del año (Day Of the Year)

e_0 : Vapor de agua actual

EC: torre Eddy Coavriance

ET: evapotranspiración (mm)

FC: Capacidad de campo (%)

f_c : Fracción vegetal que está cubierta (adimensional)

f_{T_a} : Fracción de la constante de la temperatura de la planta e indica la temperatura límite de la fotosíntesis (adimensional)

f_{APAR} : Fracción de PAR absorbido por la parte verde de la cobertura vegetal (adimensional)

f_{IPAR} : Fracción de PAR interceptado por la cobertura vegetal (adimensional)

f_M : Fracción de la constante de humedad de la planta (adimensional)

f_{VPD} : Fracción de limitación de déficit de presión de vapor representando el ajustamiento de apertura estomacal debido al déficit de saturación de agua atmosférica (adimensional)

f_g : Fracción de la transpiración activa de la planta, conocida también como fracción verde de la planta (adimensional)

f_{wet} : Fracción del indicador de la humedad superficial relativa de la evapotranspiración potencial (adimensional)

f_θ : Fracción de la constante de humedad del suelo, también expresada como (f_{SM}) (adimensional)

g : Aceleración de la gravedad (9.81 ms^{-2})

G : Flujo de calor del suelo (Wm^{-2})

GPP: Producción Primaria Bruta ($\mu\text{Cm}^{-2}\text{s}^{-1}$) o ($\text{gCm}^{-2}\text{dia}^{-1}$)

H : Flujo de calor sensible (Wm^{-2})

h_c : Altura de la planta (m)

k : Constante de von Karman

$k\cdot B^{-1}$: Parámetro para estimar la diferencia entre la temperatura aerodinámica y radiométrica

k_{PAR} : Coeficientes de extinción para el PAR

K_g : Conductividad hidráulica a saturación ($\text{m}\cdot\text{s}^{-1}$)

LAI: Índice de Área Foliar

LE: Flujo de calor latente (Wm^{-2})
 LST o Ts: Temperatura superficial ($^{\circ}C$)
 LUE_{max}: Valor máximo de la eficiencia del uso de la luz ($gCm^{-2}dia^{-1}MJ^{-1}$)
 Lv: Constante de calor latente de vaporización del agua; $2.5 \cdot 10^6$ ($J \cdot kg^{-1}$)
 LW_{in}: Radiación de onda larga incidente (Wm^{-2})
 LW_{out}: Radiación de onda larga saliente (Wm^{-2})
 MAE: Error Absoluto Medio
n: Parámetro de la forma de van Genuchten
 NDVI: Índice de Vegetación Diferenciada Normalizada (adimensional)
 NEE: Intercambio Neto del Ecosistema ($\mu Cm^{-2}s^{-1}$) o ($gCm^{-2}dia^{-1}$)
 NRMSE: Normalización de la raíz del error cuadrático medio (adimensional)
 P: Precipitación (mmh^{-1})
 PAR: radiación fotosintéticamente activa ($MJ \cdot m^{-2} \cdot d^{-1}$)
 PAR_c: PAR interceptado por la planta ($MJ \cdot m^{-2} \cdot d^{-1}$)
 PAR_s: PAR interceptado por el suelo ($MJ \cdot m^{-2} \cdot d^{-1}$)
 Pe: Precipitación efectiva (mmh^{-1})
 PM: Punto de marchitez (%)
 PNCG Parque Natural de Cabo de Gata
 Ps: Presión atmosférica (hPa)
 PT JPT: Priestley-Taylor Jet Propulsion Laboratory
 PAR_c: Radiación diaria fotosintéticamente activa interceptada por la planta ($MJ \cdot m^{-2} \cdot d^{-1}$)
 Q_d: Caudal del drenaje del suelo (mmh^{-1})
 Q_{inf}: Infiltración (mmh^{-1})
 Q_{per}: Percolación (mmh^{-1})
 Q_s: Escorrentía superficial (mmh^{-1})
 Re: Respiración del ecosistema ($\mu Cm^{-2}s^{-1}$) o ($gCm^{-2}dia^{-1}$)
 RH: Humedad Relativa (%)
 RMSE: Raíz del error cuadrático medio (unidades de la variable)
 Rn: Radiación neta (Wm^{-2})
 Rv: Constante gaseosa para el vapor de agua; 461 ($J \cdot kg^{-1} \cdot K^{-1}$)
 r_{aN}: Resistencia aerodinámica en un transporte turbulento en condiciones naturales
 R_{iB}: Número del bulbo (Bulk) de Richardson
 R_{nc}: Flujos de radiación neta de la planta ($W \cdot m^{-2}$)
 R_{ns}: Flujos de radiación neta del suelo ($W \cdot m^{-2}$)
 r_a: Resistencia aerodinámica para el intercambio de calor ($s \cdot m^{-1}$)
 SAVI: Índice de vegetación ajustado al suelo
 SEB: Balance Energético Superficial
 SM, SWC: Contenido de humedad de agua del suelo (m^3/m^3)
 SVEN: Soil-Vegetation atmosphere transfer model
 SW_{in}: Radiación de onda corta incidente (Wm^{-2})
 SW_{out}: Radiación de onda corta saliente (Wm^{-2})
 SWS: Valor actual de contenido de agua en el suelo almacenado (m)
 SWS_{max}: Valor máximo de contenido de agua en el suelo almacenado (m)
 Ta: Temperatura del aire; (K) o ($^{\circ}C$)
 Td: Temperatura del suelo en profundidad (K)
 T_{do}: Temperatura el suelo en profundidad (K) o ($^{\circ}C$)

T_{s0} : Temperatura del suelo superficial (K) o ($^{\circ}\text{C}$)
 T_o : Temperatura óptima para el crecimiento de la planta ($^{\circ}\text{C}$)
 U_a : Velocidad del viento (ms^{-1})
 VPD: Déficit de Presión de Vapor
 $w'c'$: covariancia del CO_2
 z_{0h} : Longitud fricción aerodinámica para la transferencia de calor (m)
 z_{0m} : Altura del momento de fricción aerodinámica (m)
 E_c : Flujo de calor latente de la transpiración, evaporación del suelo (Wm^{-2})
 E_i : Flujo de calor latente del agua interceptada por la planta, transpirada por la planta (Wm^{-2})
 E_s : Flujo de calor latente de la evaporación del suelo y el drenaje (Wm^{-2})

ALFABETO GRIEGO:

Ψ_h : Factor de corrección de la estabilidad del calor latente
 Ψ_m : Factor de corrección de la estabilidad del momento
 θ_e : Contenido de humedad de agua en el suelo efectivo ($\text{m}^3 \cdot \text{m}^{-3}$)
 θ_r : Contenido de humedad de agua en el suelo residual ($\text{m}^3 \cdot \text{m}^{-3}$)
 θ_s : Contenido de humedad de agua en el suelo a saturación ($\text{m}^3 \cdot \text{m}^{-3}$)
 ϕ_h : Factor de corrección de la estabilidad del calor latente
 ϕ_m : Factor de corrección de la estabilidad del momento
 β : Coeficiente de la relación de Bowen
 ε : Emisividad superficial
 ε_a : emisividad atmosférica
 ε_c : Emisividad de la planta (canopy)
 ε_R : Emisividad
 ε_s : Emisividad del suelo
 θ : Contenido de humedad de agua del suelo (m^3/m^3)
 λE : Flujo de calor latente (LE, $\text{W} \cdot \text{m}^{-2}$)
 ρ_a : densidad del aire ($\text{kg} \cdot \text{m}^{-3}$)
 σ : Constante de Stefan-Boltzmann; $5.67 \cdot 10^{-8}$ ($\text{W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$)
 ω : Frecuencia de oscilación 1/24 (h^{-1})
 Δ : Pendiente de la curva de presión de vapor a saturación versus la temperatura
 α : Ratio entre la evapotranspiración potencial y la evapotranspiración potencial en equilibrio.
 γ : Constante psicométrica
 λE_c : Flujo de calor latente de la transpiración, evaporación del suelo (Wm^{-2})
 λE_i : Flujo de calor latente del agua interceptada por la planta, transpirada por la planta (Wm^{-2})
 λE_s : Flujo de calor latente de la evaporación del suelo y el drenaje (Wm^{-2})

1. INTRODUCCIÓN

1.1. Sostenibilidad, barreras y oportunidades

La agricultura es uno de los principales sectores que emiten gases de efecto invernadero a escala mundial y pueden llegar a representar una cuarta parte de las emisiones antropogénicas. Esto se debe al impacto de la agricultura y el cambio en el uso del suelo (FAO, 2018). En cuanto a los impactos ambientales, se producirán cambios irreversibles y perjudiciales, como la erosión y la degradación de suelos y costas, la aparición de climatología adversa, la elevación de la tasa de ácido existente en los océanos. Además de desastres naturales más perjudiciales, como escenarios de inundaciones y sequías frecuentes, la contaminación del terreno, el decrecimiento de la biodiversidad en los ecosistemas con la final desaparición de especies vitales y la extinción de ecosistemas (FAO, 2015; Hauschild et al., 2018).

Nos encontramos en un escenario de cambio climático en el que los factores más críticos para el cultivo, como la temperatura y las precipitaciones, son cada vez más extremos e impredecibles (FAO, 2015). Según fuentes de la FAO, en los próximos cinco años la temperatura media global ascenderá 2°C por encima de la media, mientras que la precipitación se podrá reducir hasta un 11 % en la zona mediterránea. La alteración de estas variables afecta al crecimiento y al desarrollo del cultivo, lo que compromete la seguridad alimentaria y la agricultura como modo de vida de los agricultores (IPCC, 2021).

Según la FAO (2018), una tercera parte de los suelos están clasificados como moderada o altamente degradados, efecto que conlleva a no poder proporcionar los servicios ecosistémicos clave, como la producción de alimentos o el almacenamiento de agua. Sin embargo, aumentar el carbono orgánico en los suelos puede incrementar la producción alimentaria en 17,6 MTn por año, además de mantener la productividad en condiciones más secas.



FIGURA 1.1: ODS relacionados con agricultura propuestos por la Agenda de Desarrollo Sostenible del 2030 y la FAO. Fuente: FAO, 2020.

En general, el sector tiene un gran potencial para reducir las emisiones, actuar como sumidero de carbono, apoyar el desarrollo socioeconómico y reforzar la resiliencia (FAO, 2018). En los últimos años se ha demostrado que la agricultura mundial presenta mayores eficiencias en la emisión de gases de efecto invernadero. La asociación que pretende ayudar a mejorar el valor de las eficiencias en la emisión de gases de efecto invernadero y en la sostenibilidad del cambio climático

es la Agenda de Desarrollo Sostenible del 2030. Además, pretende promover la erradicación de la pobreza y avanzar en la justicia social (González, 2021). Los Objetivos de Desarrollo Sostenible (ODS) fueron adoptados en la asamblea de Naciones Unidas del 25 de setiembre del 2015, y como parte de la Agenda de Desarrollo Sostenible del 2030, suponen un método para fomentar la meta. En la figura 1.1, se muestran algunos de los ODS que están relacionados directa o indirectamente con la agricultura. ODS 1 “Fin de la pobreza”, ODS 2 “Hambre cero”, ODS 5 “Igualdad de género”, ODS 6 “Agua limpia y saneamiento”, ODS 10 “Reducción de las desigualdades”, ODS 12 “Producción y consumo responsable”, ODS 13 “Acción por el clima”, ODS 14 “Vida submarina”, ODS 15 “Vida de ecosistemas terrestres” (FAO, 2020).

El papel de la agricultura es considerado el sector económico que está más presente y arraigado con los ODS, por el hecho de que incide en: a) el hambre; b) la falta de ingresos, c) la pérdida de biodiversidad, d) el desempleo, e) la gestión y los usos del agua, f) el cambio climático, g) la seguridad alimentaria, h) la educación, i) el empoderamiento de la mujer, j) a la desertificación, k) a la energía, l) el consumo, m) a la protección y salvaguarda de los ecosistemas (FAO, 2018).

1.2. Agricultura en pastos

La ganadería hace hincapié en todas las actividades que implican la explotación de animales, ya sean intensivas o extensivas. Dentro de todas las actividades relacionadas con la ganadería, se encuentra la agricultura en pastos, que se ocupa del cuidado de los pastizales y del pastoreo. Esta actividad consiste en un conjunto de técnicas esenciales que contribuyen al sustento de millones de personas y a la seguridad alimentaria, y prestan servicios multifuncionales basados en la naturaleza. No obstante, estos sistemas se enfrentan a diversos desafíos y amenazas, entre ellos las sequías, la degradación, la presión sobre la tierra y el clima cada vez más errático (FAO, 2020).

Varias fuentes destacan que la agricultura es una de las principales fuentes emisoras de gases de efecto invernadero. En 2022, el INE (Instituto Nacional de Estadística) publicó que «El sector de la agricultura, la ganadería, la silvicultura y la pesca lideró las emisiones de metano (63,3 % del total) y de óxido nitroso (63,8 %) generadas por la actividad económica española» (Plataforma Tierra, 2023). Sin embargo, lo que pocas fuentes destacan es que el sector de pastizales en la agricultura presenta, en su mayoría, balances de carbono positivos (FAO, 2023).

De igual forma que los bosques, los pastizales ayudan a la sociedad desde el punto de vista medioambiental, ya que capturan carbono. Soussana et al. (2010) y Henderson et al. (2015) afirmaron que los pastizales tienen un buen potencial para mitigar el cambio climático a través de la captura de carbono. Sus valores podrían alcanzar hasta 148 Tg CO₂ año⁻¹ mediante la implementación de estrategias de gestión del pastoreo.

Zermeño-González et al. (2011) hizo hincapié en la captura de carbono, ya que los pastizales nativos o naturales son sumideros de carbono, y pueden capturar hasta 0,054 Tg CO₂ ha⁻¹ día⁻¹. Entre los aspectos a destacar en estos ecosistemas, remarcar que: a) un pastizal semiárido con una alta cobertura de plantas es neutral en cuanto a su contribución como fuente de carbono, b) mientras que un pastizal de baja cobertura de plantas es un sumidero de carbono (Delgado-Balbuena et al., 2013). Sin embargo, Delgado-Balbuena et al. (2019) estimó que, en escenarios de cambio climático, los pastizales semiáridos podrían pasar de ser sumideros a fuentes de carbono.

Los pastizales y matorrales de las zonas áridas y semiáridas permiten la producción de carne de rumiantes derivada de la ganadería extensiva y, además, tienen un bajo impacto ambiental debido a la captura de carbono. Los pastizales y matorrales han sufrido grandes transformaciones derivadas del cambio de uso del suelo, del sobrepastoreo y del clima, lo que causa un deterioro constante. Algunas de las actividades para rehabilitar los pastizales y así reducir las consecuencias son: a) la resiembra de pastos, una actividad costosa tanto económica como logísticamente (Jurado-Guerra et al., 2021); b) la utilización de mecanismos de fuego como alternativa ecológica, además de presentar bajo coste económico (Jurado et al., 1990; Luna-Luna et al., 2014), pero la más utilizada es c) el ajuste de la carga animal junto con prácticas para mejorar la distribución del pastoreo (Bailey y Brown, 2011; Chávez et al., 2000).

Dentro de la actividad más promocionada, los autores Valletine (1990) y Chávez y Soltero (1993) destacaron a) la utilización de la carga ganadera óptima; b) la determinación de la mejor época de pastoreo; c) la implementación del mejor sistema de pastoreo; d) el uso de la especie o de la combinación de especies animales óptimas; e) el establecimiento de las prácticas para una distribución uniforme del pastoreo.

Las zonas de pastizales que se encuentran en condiciones más extremas y que presentan un mayor condicionante para el crecimiento son las zonas áridas y semiáridas, que cubren aproximadamente dos tercios de la superficie terrestre (Ait Belaid, 1994). Además, estas zonas se ven afectadas por un continuo crecimiento debido a la intensificación antropológica y las sequías asociadas al cambio climático (IPCC, 2007).

Haase et al. (1999) y Ramírez (2006) afirmaron que, en las condiciones actuales, habrá una reducción del crecimiento de las matas (el cultivo predominante en las zonas áridas), una mayor tasa de mortalidad de plántulas y un menor esfuerzo reproductivo, como consecuencia de la mayor evaporación y sequía que probablemente caracterizarán el clima futuro. En conclusión, el cambio climático afectará al mantenimiento y regeneración de las matas de esparto.

El bioma predominante en las zonas áridas es la estepa, que ha permitido adaptarse al clima gracias a las siguientes características: i) capacidad de mantener un contenido de humedad elevado en las hojas cuando las células empiezan a perder turgencia; ii) presentan una pared celular rígida; iii) gran control estomacal de las pérdidas hídricas; iv) gran capacidad para resistir la desecación y proteger la maquinaria fotosintética (Pugnaire y Haase, 1996; Pugnaire et al., 1996; Balaguer et al., 2002; Domingo et al., 2002; Ramírez, 2006).

1.3. Importancia de los pastos en España

La agricultura es una actividad que en España ocupa 16.8 Mha, aproximadamente 1/3 parte de la superficie geográfica. Entre los distintos productos cosechados, destacan los cereales y las frutas, pero aparte, España tiene importantes superficies de prados y pastizales (MAPA, 2023a). A continuación, se exponen las diferencias entre los distintos términos según MAPA (2023b).

- El prado natural son terrenos con cubierta herbácea natural, es decir, no sembrados, constituida por especies vivaces, característica de climas húmedos o subhúmedos. Pero

también existe en climas más secos con suficiente humedad edáfica, es decir, en regadío o en terrenos frescos. Es un cultivo que es susceptible a aprovechamiento mediante siega al menos una vez al año. Presenta una producción poco homogénea en distintas épocas del año, pero más homogénea a lo largo de los años.

- El pastizal es un terreno de pastos naturales característico de zonas con climas seco-subhúmedos, semiáridos y áridos. Sus poblaciones están formadas por especies espontáneas, entre las que predominan las herbáceas, generalmente anuales. Son susceptibles de aprovechamiento mediante pastoreo y no se labran, o al menos periódicamente. Es frecuente una gran variabilidad de producción a lo largo de los años y dentro de periodos en el año.
- El pastizal de alta montaña, son comunidades de herbáceas de montaña, subalpinas y alpinas, constituidas por especies vivaces. El aprovechamiento es exclusivo de animales a diente y preferentemente durante el verano. Desde el punto de vista botánico, se debería utilizar el término «pastizal», pero desde el punto de vista práctico, se emplea con más frecuencia el término «prado natural».
- El pastizal matorral son aquellos terrenos en los que el matorral alcance o supere el 20% de la superficie. Con el fin de que se mantenga el aprovechamiento ganadero de forma prioritaria, no se especifica el límite superior de superficie de matorral.

TABLA 1.1: Superficies dedicadas a cultivos o cubiertas en el 2023. FUENTE: MAPA, 2023a.

Cultivo o cubierta	Secano (ha)	Regadío (ha)	Total (ha)
Prados naturales	842,831	30,557	873,388
Pastizal alta montaña	573,295		573,295
Pastizales	4,592,961		4,592,961
Pastizal matorral	2,443,950		2,443,950
TOTAL	8,453,038	30,557	8,483,595

Las agrupaciones de prados y pastizales representan el 16,77% de la superficie geográfica, un total de 8.5 Mha aproximadamente. Gracias a la tabla 1, proporcionada por el estudio de MAPA (2023a), se puede observar cómo los prados naturales solo representan un 0.36% en esta agrupación. Los pastizales de alta montaña representan el 6.78%, los pastizales matorrales el 28.91% y la superficie restante, el 54.33%, equivale a los pastizales. En España, las principales zonas de pastizales están situadas en las comunidades de Castilla y León, Extremadura y Andalucía, representando un 23.24%, 24.14% y 17.34%, respectivamente del total.

Alados et al. (2003), Maestre (2004) y Maestre et al., (2007), demostraron en varios estudios la existencia de una relación negativa entre la probabilidad de que un espartal evolucione a matorral y la densidad de casas en el área, así como una relación positiva entre dicha probabilidad y la distancia del espartal al núcleo de población más cercano. Por lo tanto, estos estudios remarcan la importancia de las actividades humanas pasadas en el mantenimiento de la estructura y funcionamiento de los espartales en la actualidad. Alados et al. (2004) remarcó que, en los últimos 40 años, el Parque Natural de Cabo de Gata (Almería) ha experimentado un crecimiento de los espartales positivo.

1.4. Nuevas tecnologías (sensores, bases de datos, modelos)

La agricultura global se está enfrentando a importantes retos relacionados con la mejora de la productividad, el manejo eficiente de los recursos naturales y la lucha contra las plagas y enfermedades (Sishodia, 2020). Por suerte, el sector está experimentando una importante revolución tecnológica, donde se están comenzando a implementar sistemas que incluyen alta tecnología.

La gestión de las explotaciones de pastos presenta grandes dificultades debido a la gran extensión de terreno, de difícil acceso, lo que dificulta el control preciso de la gestión. Cabe destacar que las herramientas utilizadas en este sector siempre han sido tradicionales, por lo que la incorporación de nuevas tecnologías podría suponer un gran avance.

La utilización de las nuevas herramientas y tecnologías se dividen en tres grupos: a) captación de datos, así como la utilización de sensores (in situ o en remoto) para la obtención de información (Weiss et al., 2020); b) modelos de predicción, por ejemplo, capaces de simular el crecimiento o la producción del cultivo (Chemura, 2017; Jin et al., 2018); c) optimización del tiempo y de insumos gracias a la utilización de sistemas de información geográfica (SIG) (Reddy y Rao, 1994; Sharma et al., 2018).

1.4.1. Sensores in situ y en remoto

La captación de información es muy relevante para poder conocer con exactitud las condiciones en que se encuentra el cultivo. Se trata de una estrategia que está creciendo al alza, ya que su implementación es fácil y rápida gracias a los sensores. Los principales sensores más utilizados son: a) sensores de contenido de humedad en el suelo; b) estaciones meteorológicas en la parcela; c) utilización de sensores térmicos y multiespectrales que permiten captar información que visualmente es indetectable (Usha y Singh, 2013; Weiss et al., 2020; Guzmán-Álvarez et al., 2022).

La captación de los datos en tiempo real es un factor clave y necesario para poder reaccionar ante los eventos característicos del cambio climático, por el hecho que permiten minimizar el impacto en el sistema alimentario global (Wheeler y von Braun, 2013; Di Falco et al., 2012). Además, para la optimización de inputs requeridos y de las prácticas de manejo, los datos en tiempo real son una fuente imprescindible (Areal et al., 2018; Weiss et al., 2020).

Una de las principales desventajas de los sensores implementados in situ es que pueden presentar características destructivas, mientras que los sensores en remoto no. Algunos de los ejemplos más implementados son la utilización de satélites, sensores adosados a la ISS (Estación Espacial Internacional) o sensores acoplados a aeronaves tripuladas (avionetas) o no tripuladas (UAS) (García et al., 2013; Weiss et al., 2020).

La utilización de sensores en remoto está siendo implementada a todos los niveles, ya sea en fórmulas políticas, a nivel regional y nacional. También están siendo adoptados por ministerios de agricultura o planificación, universidades y centros de investigación agrícola. Las principales funciones son para la estimación de la extensión de los cultivos, la producción, su impacto y la

prevención de desastres naturales. Weiss et al. (2020) remarcó que se trata de una herramienta tecnológica que está en desarrollo, pero que presenta una importante relevancia en el campo de la agricultura de precisión.

Algunas herramientas satelitales comerciales conocidas son: a) MODIS (NASA, USA); b) Landsat (NASA, USA); c) ECOSTRESS (NASA, USA); d) Sentinel (Copernicus, Unión Europea). Cuyos principales sensores son electromagnéticos, que permiten captar las bandas Red-Green-Blue y NIR, además de otros rangos como el LWIR (Infrarrojo de onda larga y el de onda central) y TIRS (Infrarrojo térmico y onda central), que permiten el cálculo de la temperatura superficial (LST).

Con los datos captados desde los sensores remotos, es posible estimar parámetros biofísicos de superficie a diferentes resoluciones espaciales y temporales (Liang et al., 2012). Además, en comparación con los métodos tradicionales, ofrecen la ventaja de ser alternativas más económicas y de poder ser aplicados a gran escala (Gu et al., 2018).

La utilización de sensores satelitales permite abarcar a nivel mundial, sin embargo, el problema más importante es la penalización de la resolución espacial y temporal. En los escenarios con condiciones nubladas, los satélites no son capaces de proveer observaciones ópticas y térmicas de la superficie. Esta problemática se ve especialmente afectada en las regiones con latitudes altas, donde las condiciones nubladas son más frecuentes (Wang et al., 2018b), o bien, en los climas donde el periodo de crecimiento de la planta coincide con la estación de lluvia, como los regímenes monzónicos (García et al., 2013).

Para contrarrestar este problema, se usan los UAS, que permiten acoplar sensores que captan mayor resolución espacial y pudiendo ser utilizados con más frecuencia. El principal inconveniente es el valor económico y la necesidad de un técnico especialista debido al grado de dificultad de pilotaje (Guzmán-Álvarez et al., 2022).

La LST es una variable determinada a partir de la interacción entre la superficie y la atmósfera (Choudhury, 1992), y es un factor clave para separar la energía disponible entre el flujo de calor sensible (H) y el flujo de calor latente (LE) (Kustas y Nomand, 1996). Por esta razón, la LST es una de las variables captadas por sensores en remoto más utilizadas para los modelos de flujos superficiales, como se puede observar en los numerosos artículos (Glenn et al., 2007; Kalma et al., 2008; Kustas y Anderson, 2009).

La LST desarrolla una posición crucial en los procesos superficiales terrestres, además de estar incluida en la lista de parámetros de alta prioridad del programa IGBP (International Geosphere and Biosphere Program) (Townshend et al., 1994). Las variables ambientales y la LST están relacionadas gracias a las ecuaciones del balance energético superficial (Vlassova, 2016). Además de estar relacionada con el transporte de calor entre la superficie terrestre y la capa límite atmosférica (Kustas y Anderson, 2009), que hace posible la estimación del H (Jia et al., 2001) y el LE (Anderson et al., 2012).

La LST proporciona información sobre variaciones en el estado de equilibrio de la superficie y es vital para muchas aplicaciones (Kerr et al., 2004). Por esto, es clave para los modelos hidrológicos (Ambast et al., 2008; Liang, 2004), para el clima (Wild, 2005), predicciones del tiempo (Van der

Hurk et al, 2002) y para la ecología (Gamon et al., 2004) a múltiples escalas. Respecto al crecimiento de la planta, la LST afecta en todos los escenarios de su desarrollo, además de ser un indicador de sanidad vegetal (Moran, 2004; Zarco-Tejada et al., 2003), por la existencia de la relación cercana entre la temperatura del dorsal de la planta y el estrés hídrico que causa el cierre de las estomas de la planta.

Los lugares donde el agua es un factor climático limitante, siendo un total de 2/5 partes de la superficie de la tierra, la evapotranspiración representa el 90% de la precipitación anual (Glenn et al., 2007). En estas regiones existe una relación próxima entre los ciclos de carbono y de agua (Baldocchi, 2008), donde el agua disponible es el principal factor de control de actividad biológica (Brogaard et al., 2005). Giorgi y Lionello (2008) explicaron que las zonas con climas transicionales (como el caso de este estudio) son extremadamente sensibles a cambios climáticos. El hecho de mejorar la estimación temporal y espacial de las variaciones de los flujos de calor latente son cruciales para entender las interacciones entre la superficie y la atmósfera, además de mejorar el manejo hidrológico y agronómico (Yuan et al., 2010).

La ET es difícil de entender, por el hecho de que es un proceso no-lineal constante que depende de muchos factores climáticos, además de interacciones entre ellos y otros. A pesar de su dificultad, es una variable esencial para el cálculo del balance de agua, estimar el agua disponible y de los requerimientos del cultivo.

1.4.2. Modelos

El uso de sensores en la agricultura ha facilitado la tarea de captación de datos e información sobre el estado del cultivo, sin embargo, muchas veces al tener tanta información, es difícil obtener conclusiones. Por esta razón, la existencia de los modelos es otra herramienta muy potente, que permite organizar los datos recogidos en campo para obtener información más útil y fácil de entender, además de poder parametrizar la evolución del cultivo u otras variables deseadas. Estas herramientas también se conocen como Sistemas de Soporte a la Decisión (DSS). Los principales tipos de datos requeridos para los modelos son: meteorológicos, de suelo, cultivo, plagas y enfermedades, entre otros (Guzmán-Álvarez et al., 2022).

Los modelos basados en balances y dinámicas de flujos de agua y energías son esenciales para los hidrólogos y meteorólogos. Les permite hacer predicciones de los escenarios futuros relacionados con el clima o los cambios en el uso del suelo, sobre el rendimiento hídrico u otras variables relacionadas con la evapotranspiración. Estas evaluaciones son un factor clave para los políticos y los gestores de agua sobre la planificación del uso del agua para las condiciones futuras (Margulis y Huning, 2015).

Vezy et al. (2020) explica que la combinación de modelos para el manejo del cultivo es clave, pudiendo utilizar los outputs del modelo como fuente de input para modelos de crecimiento de cultivo. El uso de imágenes digitales y modelos de regresión tiene un gran potencial para la predicción de carbono del suelo, aunque presenten un bajo ajuste (Linares-Fleites et al., 2017). Jurado-Guerra et al. (2018) propone el uso de modelos ecológicos que tengan en cuenta la cobertura de pastos forrajeros, la precipitación media anual y el contenido de arena del suelo como variables principales.

A continuación, se describen los modelos basados en balances y dinámicas de flujos de agua y energías para la predicción de futuros escenarios con altos niveles de detalle espacial y temporal más utilizados, descritos por Fisher et al. (2014):

1. LSM (Land Surface Model) describe el flujo de la superficie mediante ecuaciones físicas y puede acoplarse a modelos climáticos. El modelo LSM pretende minimizar los parámetros del modelo mediante la optimización de los datos obtenidos en campo y centrándose en el proceso con mayor incertidumbre (futura). Sin embargo, puede aplicarse en el presente o con condiciones históricas, de tal forma que puede adoptar información obtenida por satélite o UAV. Los hidrólogos utilizan el modelo para predecir el presente y estimar el uso del agua en la agricultura, el contenido de agua en el suelo y las sequías. También es conocido como modelo de balance energético superficial (SEB). Estos modelos tienen como objetivo principal calcular los flujos de energía que entran y salen de la superficie terrestre, lo que incluye la radiación solar incidente, la radiación reflejada, la radiación emitida por la superficie terrestre, la evaporación, la convección y la conducción de calor. Es un modelo más sencillo porque, al realizar los balances, solo tiene en cuenta el suelo y no la vegetación, utilizando el método «force-restore». Cuando sí se tiene en cuenta la diferenciación entre suelo y vegetación, se habla de modelos Two-Source Energy Balance model (TSEB).
2. Los modelos SVAT (Soil-vegetation-atmosphere transfer) son biofísicos, cuyos realizan balance energético y de agua, además de tener en cuenta el suelo y vegetación como diferentes componentes. En concreto, el modelo SVEN (Soil-Vegetation, Energy, water, and CO₂ traNsfer) realiza balances de energía, de agua y de flujo de CO₂ de forma dinámica entre el suelo-vegetación-atmósfera. Los distintos balances que realiza son: a) balance de energía: cuyo permite estimar la temperatura superficial y el flujo de calor del suelo, basándose en las ecuaciones de balance energético superficial. Además, a diferencia de los otros, el modelo “force-restore” está adaptado para representar los intercambios energéticos entre el suelo y el suelo/vegetación en la superficie; b) balance de agua: incluye el modelo Priestley– Taylor Jet Propulsion Laboratory (PT-JPL) para la estimación de la ET y el modelo simple “bucket” para representar la columna superficial de suelo y simular la dinámica del agua y de escorrentía en el suelo, c) flujo de CO₂: utiliza el modelo de eficiencia en el uso de la luz (LUE) para la estimación de la GPP, el cual está conectado con la ET gracias a que tienen las mismas limitaciones biofísicas que en el dosel de la planta.

1.4.3. Precedentes sobre modelización

Los precedentes del modelo son bastante amplios, por el hecho de que ha sido utilizados a nivel mundial y con distintos cultivos:

- a) Garcia et al. (2013) trabajó en un modelo PT-JPL ET, cuyo se centra en la evapotranspiración potencial a escala diaria. El objetivo del estudio era evaluar el LE entre el dato observado con una estación Eddy Covariance con el valor simulado del modelo, en un ecosistema semiárido. Cuyos modelos fueron calibrados utilizando dos productos diferentes; uno a partir de la LST y el albedo, y el otro a partir del NDVI, LAI y fPAR. El

trabajo demostró que la limitación de la humedad del suelo basándose en el concepto de inercia térmica aparente era un factor clave para la parametrización del modelo. La metodología implementada resultó tener correlaciones (r^2) mayores en el LE que modelos más complejos, como son el Two Source Model o el modelo de Penman-Monteith Leuning. La ubicación del estudio es el mismo que el del propio trabajo, utilizando la misma base de datos.

- b) Morillas et al. (2013a) trabajo con el modelo TSEB con las componentes de suelo y vegetación. La ubicación del estudio es el mismo que el del propio trabajo, utilizando la misma base de datos. Predijo el H utilizando el gradiente térmico entre el aire y la superficie, además del LE con el residuo de las ecuaciones del balance energético superficial. Las comparaciones entre los valores medidos en campo con la estación instalada en campo y los datos obtenidos con TSM permitieron estimar la R_n y el flujo H con errores del 30% y 10%, respectivamente, mientras que para el flujo LE fueron del 90%. También, se pudo demostrar la robustez del proceso iterativo para disgregar una temperatura compuesta con suelo y vegetación en suelos separados y componentes de vegetación en ambientes semiáridos con buenas perspectivas para aplicaciones de imagen.
- c) Kustas et al. (2016) trabajó en la revisión del artículo que se ha comentado anteriormente (Morillas et al., 2013a). Evaluó el modelo TSEB de Norman et al. (1995) teniendo en cuenta las revisiones de Kustas y Norman (1999) sobre un terreno semiárido. Se verificó que el modelo TSEB infravalora los flujos de H y sobreestimar los flujos de LE. Demostró cómo al introducir los parámetros inputs vegetativos correctos en el modelo TSEB y en la formulación de la resistencia del suelo, los estadísticos RMSE y bias mejoraron, obteniendo mejor relación entre los outputs del modelo y los valores medidos en campo sobre las variables H y LE.
- d) Wang et al. (2020) se centró en el cultivo del sauce, utilizando sensores multiespectrales montados en un UAS para la captación de información sobre la LST, el índice NDVI y el contenido de agua en el suelo, para posteriormente, ser utilizados como inputs en el modelo SVEN. Los resultados fueron validados con los datos obtenidos in situ, gracias a la estación EC. Finalmente, obtuvo que el modelo SVEN permite estimar flujos superficiales diariamente de las variables LST, R_n , θ , LE, GPP con valores de Desviación de la Raíz Media Normalizada (NRMSD) de 11.77%, 6.65%, 19.53%, 14.77% y 12.97%, respectivamente.
- e) Pateromichelaki (2020) estuvo trabajando sobre el modelo SVEN en el cultivo del café de Costa Rica. Concluyeron que el modelo era capaz de predecir con suficiente precisión el H, el LE y la R_n . Sin embargo, las variables GPP y LST no fueron predichas con tanta precisión, por el hecho de que el modelo las infravaloraba. Las predicciones que realizaba el modelo se ajustaban mejor con intervalos medio-horarios ($\frac{1}{2}$ hora) que diarios.

1.5. Agronomía del cultivo

Actualmente, las zonas áridas y semiáridas en el mediterráneo representan un total de 630,000 km² (25% aproximadamente), siendo *Stipa tenacissima* L. la variedad que se encuentra en dominancia en todas las zonas (Le Houérou, 2001; Maestre, et al., 2007; Ghiloufi et al., 2015). Respecto a la zona de estudio, el Parque Natural de Cabo de Gata (PNCB), es una zona semiárida, cuya variedad que más frecuente es la *Stipa tenacissima* L.

Es una planta herbácea perenne, que forma un macollo muy denso, compuesto por un conjunto de macollas de crecimiento radial. Las hojas son envainadas, con vaina coriácea que frecuentemente el margen es algodonoso, lamniformes, ásperas por el envés, estrechas y largas, pudiendo llegar a alcanzar más de un metro de largo (figura 1.2.). Tienden a enrollarse sobre ellas mismas (Cano-Ruiz, 2012).

Presenta tallos floridos, fuertes y rígidos, con medidas alrededor de 60-100 cm (pudiendo alcanzar los 150 cm), con panículas densas y pudiendo alcanzan entre 15-60 cm, con numerosas espiguillas (Cano-Ruiz, 2012).

Presenta un gran número de raíces superficiales, que se extienden desde las semillas y los estolones (Rey et al., 2011). La mayor parte de raíces se concentra en los primeros 20 cm (Puigdefábregas et al., 1999), pudiendo llegar a profundidades superiores a 50 cm (Sánchez, 1995). La mayor parte de su biomasa está concentrada en el sistema radical, representando el 61% (Sánchez, 1995).

Tienen la capacidad de vivir en terrenos secos y pobres, del tipo calcáreos y yesíferos. Poseen una gran tolerancia a la sequía, condiciones de estrés hídrico y altas temperaturas, siendo el estrés hídrico estival y el frío invernal las dos condiciones con mayor efecto sobre su desarrollo (Rejos, 2000; Haase et al., 1999).




FIGURA 1.2: a) mata de *Stipa tenacissima* L. en floración; b) espiga de la mata. FUENTE: (Maestre, et al., 2007; Cano-Ruiz, 2012).

Es una especie que suele convivir con *Allium melananthum*, *Armeria castroviejoi*, *Armeria vestita* (Cano-Ruiz, 2012). Actualmente, está considerada como una especie en riesgo vulnerable según la categoría UICN en España (Carapeto y Véla, 2018). El desarrollo de esta investigación presenta especial interés, puesto que es una especie vulnerable, y por lo tanto, permitirá un mayor monitoreo y control de la especie.

Es una especie que ha sido demostrada que permite desarrollar una serie de estrategias cuando se enfrenta a condiciones extremas, como, por ejemplo: a) minimizar la intercepción de luz y la fotoinhibición (Valladares y Pugnaire, 1999); b) cuando no hay agua disponible de las lluvias (Ramírez et al., 2007); c) una rápida respuesta fotosintética a la lluvia (Balaguer et al., 2002).

1.6. Marco de trabajo

El trabajo es desarrollado en colaboración al proyecto “Space Canadian Agency”, gracias a la ayuda del proyecto 21SUESIELH, cuyo ha permitido la financiación y la realización del trabajo. Además, se desarrolló en colaboración con el centro de investigación CEIGRAM (Madrid, España). El trabajo se desarrolló a partir del proyecto INTEGRATYON3 (PID2020-117825GB-C21 y C22) desde el Ministerio de Economía y Competencia de España; proyecto BAGAMET (P20_00016) y adquisición de equipamiento científico-técnico (IE17_5560_EEZA), fundado desde el Consejo de Economía, Innovación Ciencia y Empleabilidad del gobierno de Andalucía. Todos están incluidos en los fondos ERDF de la Unión Europea.

2. OBJETIVOS

El objetivo general del proyecto consiste en calibrar y evaluar el modelo de predicción de evapotranspiración y productividad SVEN con datos in situ, para posteriormente tener un modelo que permita hacer predicciones instantáneas en continuo.

Cuyos objetivos se desglosan y estructuran de la siguiente forma:

1. Obtención de una base de datos in situ homogeneizada a varias escalas de tiempo, incluyendo datos de sensores de Eddy Covariance y micrometeorológicos en fecha del 2011.
2. Creación de una base de datos del sensor en remoto del producto de evapotranspiración (ET) de la misión ECOSTRESS para ser comparado y evaluado con la base de datos in situ de Eddy Covariance.
3. Evaluación de la capacidad de un modelo de balance energético simple para predecir la temperatura superficial y los flujos turbulentos (H y LE).
4. Calibración del modelo de predicción de evapotranspiración y productividad SVEN adaptándolo a las particularidades de la vegetación y el suelo del sitio de estudio.
5. Evaluación de los outputs del modelo SVEN con los datos in situ.
6. Determinación del tiempo de pase óptimo entre observaciones satelitales para la calibración del modelo evaluando la precisión de los outputs.

3. MATERIALES Y MÉTODOS

3.1. Caracterización de la parcela y zona de estudio

El presente estudio se centra en el Parque Natural Cabo de Gata (PNCG, Almería), con una superficie total de 49.5 Mha, de las cuales 37.5 Mha corresponden a zonas terrestres y 12 Mha a zonas marinas. Este entorno, reconocido internacionalmente por la UNESCO como reserva de la Biosfera y Geoparque Mundial, alberga características propias de uno de los ecosistemas más áridos de Europa. Este espacio marítimo-terrestre protegido constituye un entrono donde convergen múltiples medios, incluyendo el marítimo, el litoral y el terrestre, albergando una rica biodiversidad, caracterizada por la presencia de numerosas especies exclusivas (Junta de Andalucía, 2024).




FIGURA 3.1: Representación y localización de la zona de estudio. (a) Vista general del sitio de estudio de flujo de covarianza de remolinos de la pradera de Balsa Blanca situado en el “Parque Natural de Cabo de Gata-Níjar” (zona verde). El punto rojo representa el campo de estudio, denominado Balsa Blanca; (b) y (c) representación de la zona con foto in situ; (d) Visualización de imagen de satélite obtenida de GoogleMaps, el punto rojo representa la localización de la torre de covarianza de remolinos.

La ubicación específica de la parcela de estudio se encuentra en Balsa Blanca (BB), con las siguientes referencias: $36^{\circ}56'24''\text{N}$; $2^{\circ}18'0''\text{W}$ (36.94, -2.03) expresado en el sistema de referencia UTM ETRS89 zona 30N (Figura 3.1). La elección de este punto preciso se fundamenta en su papel como uno de los sitios de calibración y validación de los algoritmos que estiman la temperatura superficial (LST) desde la misión ECOSTRESS (The ECOsystem Spaceborne Thermal Radiometer Experiment on Space Station) de la NASA (Hu et al., 2022). Además, se cuenta con una estación Eddy Covariance, respecto a la cual se dispone de una serie temporal de datos entre los años 2006 y 2020.

Es pertinente señalar que el área de estudio exhibe un especial interés, dado que ha sido designado bajo diversas figuras de protección, entre ellas: a) Zona de especial conservación; b) Zona de especial protección de las aves; c) Lugar de importancia comunitaria; d) Reserva de la biosfera; e) geoparque; f) Sitio Ramsar (Salinas); g) Zona Especialmente Protegida de Importancia para el Mediterráneo (Junta de Andalucía, 2024).

La elección de esta parcela se fundamenta en su capacidad representativa de la distribución del espartal en el contexto del PNCG. La cobertura total de la especie en la parcela alcanza el 91% (García et al., 2013). En consecuencia, la relevancia de la parcela de BB radica en su capacidad para reflejar la del espartal en el PNCG, además de ser una especie de suma importancia en el sudeste peninsular.

BB se encuentra en una región árida, caracterizada por extensos periodos de escasez hídrica. Los días de lluvia se concentran principalmente durante la estación primaveral, mientras que el verano se caracteriza por su aridez y altas temperaturas. De acuerdo con García et al. (2013), la precipitación anual media fue de 375mm, con una temperatura media anual de 18.1°C. Sin embargo, Rey et al. (2011) reportaron que en la estación de Níjar, ubicada a 30 km de BB, la precipitación anual media fue de 200mm.

TABLA 3.1: Características de la zona de estudio BB (Almería, España). Fuente: Morillas et al., 2013a.

Descripción de la característica	
Longitud	2°1'58"W
Latitud	36°56'30"N
Altitud (m)	208
Orientación	NW
Pendiente (%)	2-6
Temperatura media anual (°C)	18.1
Temperatura máxima en verano (°C)	34
Precipitación media anual (mm)	375
Vegetación	Steppe alpha grass
Tipo de suelo	Leptosol lítico mólico (calcárico)
Clase textural de suelo	Franco arenoso
Profundidad de suelo (cm)	0-50
Arcilla (%)	18.3
Limo (%)	22.6
Arena (%)	59.1
Densidad del bulbo (g/cm ³)	1.3
pH	7.9
Contenido de agua anual medio en el suelo (%)	13.8

De acuerdo con los estudios de investigación realizados previamente (Rey et al., 2011; García et al., 2013; Morillas et al., 2013a; Kustas et al., 2016), se logró establecer un consenso respecto a las características de la zona de estudio BB.

3.2. Datos meteorológicos y climáticos

En la zona de trabajo de BB se encuentra una estación Eddy Covariance (EC, figura 3.2.), la cual forma parte de la red FLUXNET e ICOS. Esta red global de estaciones de monitoreo emplea técnicas de covarianza de vórtices y facilita la obtención de información acerca del flujo de gases, la deriva de calor, agua e intercambio de gases entre el ecosistema y la atmósfera (Burba y Anderson, 2010; Pateromichelaki, 2020). Estas estaciones se encuentran diseminadas en una variedad de ecosistemas, tales como bosques, pastizales, cultivos, humedales, entre otros, y se encargan de la recopilación de datos continuos de alta resolución temporal.

La técnica de EC permite la medición continua y no destructiva de flujos de carbono a corto (media hora) y a largo plazo (interanuales). Además, es utilizada para la integración del Balance Neto de Carbono del Ecosistema (BNCE) a escalas continental y global. La estación EC se basa en la medición de las fluctuaciones en las propiedades atmosféricas (tales como la velocidad del viento, la temperatura y la concentración de gases) en un área pequeña y el cálculo de las covarianzas entre dichas fluctuaciones. Estas covarianzas proporcionan información sobre la tasa de intercambio de calor, agua y gases entre la superficie y la atmósfera (MAPA, 2006).




FIGURA 3.2: a) estación de radiometría colocada en el sitio del estudio; b) Sensor medidor de LST en el suelo desnudo; c) estación Eddy Covariance. FUENTE: figuras (a) y (b) obtenidas de Morillas et al. (2013a); figura (c) fuente propia.

3.2.1. Datos meteorológicos y flujos de superficie

Los datos utilizados como fuente de información del modelo fueron adquiridos durante el año 2011, específicamente entre el día 15 de enero hasta el 12 de junio (15 DOY hasta 163 DOY). La elección de este rango de fechas se fundamenta en la premisa de que, durante este período se debería capturar la mayor variabilidad anual sobre el flujo de energía (LE), aunque es solo representa una parte de una temporada de crecimiento completo, que se extiende desde el otoño hasta el principio del verano (Garcia et al., 2013).

La temperatura del aire y la humedad relativa fueron mediadas utilizando un termohigrómetro (HMP45C, Campbell Scientific Ltd.). La precipitación fue medida utilizando un pluviómetro con un basculante de 0.25 mm de resolución (ARG100 Campbell Scientific INC., USA).

En el presente análisis, se ha procedido a la observación de la evolución de la temperatura del aire medida y la precipitación a lo largo de la serie temporal comprendida entre el 15 de enero (15

DOY) hasta 12 de junio (163 DOY), como se muestra en la figura 3.3. Se observa un incremento en la tendencia de la temperatura a medianos de marzo, la cual se mantuvo hasta junio. En lo que respecta a la precipitación, se evidencia una baja frecuencia y estacionamiento temporal, aunque cuando ocurre, son intensas. El patrón de precipitaciones observado se alinea con las características de las zonas áridas, por su escasez y espaciamiento entre eventos.





FIGURA 3.3: Barras de color rojo: representación de la serie temporal de la precipitación diaria (mm) del 15 enero (15 DOY) hasta 12 de junio (163 DOY). Líneas de color azul: representación de la serie temporal de la temperatura media-horaria (°C) del 15 junio (15 DOY) hasta 12 de junio (163 DOY).

El cálculo de la presión se ha llevado a cabo mediante el método de medida del Li-7500 “open path”, el cual se basa en utiliza el efecto de la presión sobre la absorción en el infrarrojo.

La temperatura del suelo se ha medido utilizando el termopar del suelo (TCAV) a 2 y 6 cm de la profundidad, respectivamente, a lo largo de la zona adyacente a los platos de flujo de calor. La temperatura superficial (LST) fue medida con tres sensores “Apogee” sobre el suelo desnudo, la vegetación y un compuesto de suelo desnudo y vegetación (IRTS-P).



FIGUAR 3.4: Representación del equipo utilizado para las mediciones de flujos de calor latente (H) y de calor sensible (LE). a) Sensor CSAT-3 (Campbell Scientific Lt); b) IRGA (open-path infrared gas analyzer, Li-Cor, Li-7500, Campbell Scientific Ltd).

Los sensores de reflectometría dominante en el tiempo (CampbellCS616, Campbell Scientific Ltd) miden volumétricamente (m^3/m^3) el contenido de agua en el suelo (SWC o SWS). Las lecturas se llevaron a cabo en dos condiciones a) en el suelo desnudo y b) bajo la planta, a una profundidad de 4 cm, siendo esta última la medida de contenido de agua en suelo más frecuente.

Los flujos de calor sensible (H) y de calor latente (LE) se midieron mediante la estación EC utilizando el anemómetro-sónico con sistema tridimensional (CSAT-3, Campbell Scientific Ltd) y el IRGA (open-path infrared gas analyzer, Li-Cor, Li-7500, Campbell Scientific Ltd). El anemómetro-sónico, además de medir la velocidad del viento en las tres componentes espaciales, permite la medición de la temperatura sónica. La radiación neta (Rn) se obtuvo mediante la utilización del sensor NR-Lite (Kipp&Zonen).




FIGURA 3.5: Representación de las distintas componentes de la radiación en: a) fecha de 25 de enero (DOY 25); b) fecha de 18 de mayo (DOY 139). Los componentes representados son: Flujo de calor sensible (H); Flujo de calor latente (LE); Flujo de calor del suelo (G); Radiación neta (Rn). Todas las medidas hacen referencia a energía, por lo que las unidades son W/m^2 .

Se instalaron cuatro placas de flujo de calor del suelo (HFP01SC; Campbell Sci. Inc.) a una profundidad de 8 cm bajo tierra, con dos placas dispuestas debajo de una planta y dos adicionales bajo suelo desnudo. Además, se estableció una conexión entre las placas y un datalogger mediante la utilización de un multiplexor. El flujo calorífico del suelo a la superficie se determinó mediante la suma del flujo de calor medido a 8 cm (G) a la energía almacenada en la capa superior de la placa calefactora, estimada a partir de las mediciones de la temperatura y la humedad del suelo.

3.2.2. Error y corrección datos observados

La estación EC manifiesta un error de medición que, de acuerdo con otros estudios (Morillas, et al., 2013a; Garcia, et al., 2013; Kustas, et al., 2016) oscila entre el 20 y el 22%. El procedimiento empleado para la estimación del error fue el mismo utilizado por los autores previamente citados.

Para estimar el error de lectura de la estación EC, se utilizó la ecuación que se muestra a continuación, la cual permite definir el error cometido en las lecturas. Es pertinente mencionar que la metodología anteriormente descrita ha sido implementada por otros investigadores, como Culf et al. (2004) y Pateromichelaki (2020). La metodología implementada por estos últimos se basa en la normalización del error residual mediante el uso de la Rn.

$$Error (\%) = \frac{Rn - G - H - LE}{Rn} \cdot 100 \quad \text{ec 1}$$

En el contexto de la investigación, se identificó un desajuste en el cierre de balance de las medidas de EC. En respuesta a esta situación, se implementaron estrategias específicas para abordar esta imprecisión, las cuales se expondrán a continuación:

1. Relación de Bowen (β ; Twine et al., 2000), cuyo utiliza las siguientes ecuaciones:

$$Incertidumbre \left(\frac{W}{m^2} \right) = \Delta LE + \Delta H \quad \text{ec 2}$$

$$Incertidumbre \left(\frac{W}{m^2} \right) = Rn - G - H - LE \quad \text{ec 3}$$

$$\beta = \frac{H}{LE} \rightarrow \frac{H + \Delta H}{LE + \Delta LE} \quad \text{ec 4}$$

$$\Delta H \left(\frac{W}{m^2} \right) = Incertidumbre - \Delta LE \quad \text{ec 5}$$

$$\Delta LE \left(\frac{W}{m^2} \right) = \frac{Incertidumbre + H - \beta \cdot LE}{\beta + 1} \quad \text{ec 6}$$

Donde “Incertidumbre” se definió como el valor de incertidumbre de la estación (W/m^2). Esta incertidumbre se distribuye entre las variables LE y H según la relación de Bowen (β). Al resolver el sistema de dos ecuaciones con dos incógnitas, se obtienen las incertidumbres correspondientes (ΔLE y ΔH) (W/m^2). Finalmente, se recalculan las variables H y LE, teniendo en cuenta los incrementos calculados, de modo que se obtienen los parámetros corregidos donde el cierre del balance energético es cero.

2. LE residual:

Otra metodología para compensar el error cometido en el cierre del balance energético realizado por la estación EC. Esta metodología se fundamenta en el LE residual. La hipótesis consiste en asignar la diferencia entre Rn, G y H a el LE:

$$LE \text{ residual} \left(\frac{W}{m^2} \right) = Rn - G - H \quad \text{ec 7}$$

Donde, Rn representa el valor de la radiación neta medida por la estación EC (W/m^2), G es el valor del flujo de calor del suelo medido por la estación EC (W/m^2) y H es el valor del flujo de calor latente medido por la estación EC (W/m^2). Ambas metodologías para corregir el cierre de balance fueron aplicadas a escala temporal diaria.

Las mediciones se realizaron a una altura de 3.5 metros. Los sensores fueron calibrados a una frecuencia de 10 Hz, y los flujos fueron estimados y registrados en intervalos de ¼ hora (15

minutos) aplicando las correcciones de los ejes rotativos (Kowalski et al., 1997; McMillen, 1988) y las fluctuaciones de la densidad (Webb et al., 1980).

La información técnica de la estación EC fue obtenida gracias al trabajo de García et al. (2013), quienes utilizaron la misma estación EC. Los datos fueron obtenidos de la misma base de datos que Morillas et al. (2013a), cuya frecuencia de lectura de datos era de 15 minutos. Posteriormente, los datos fueron procesados para que la frecuencia fuese cada 30 minutos y que funcionasen correctamente con el modelo.

3.2.3. Estimación de la producción primaria bruta mediante Eddy Covariance

La producción primaria bruta constituye un componente esencial para el ciclo del carbono terrestre, además de ser un indicador relevante de los flujos de carbono de la biosfera (Zhang et al., 2010). La GPP es requerida para la determinación del secuestro de carbono en los ecosistemas terrestres.

A nivel de ecosistema, la GPP puede ser estimada con precisión gracias a los flujos de CO₂ estimados por la estación EC (Baldocchi, 2003), lo que se basa en el procesamiento de los datos sobre los flujos de CO₂ obtenidos y medidos. La GPP se calcula como la diferencia entre la respiración del ecosistema (Re) y el intercambio neto del ecosistema (NEE), como se muestra en la ecuación (ec. 8). La información derivada de la torre EC, que se utiliza para medir el NEE (Ec. 9), tiene en cuenta la densidad (ρ_a) del aire y la covariancia del CO₂ ($w'c'$).

$$GPP = Re - NEE \quad \text{ec 8}$$

$$NEE = \overline{\rho_a} \cdot \overline{w'c'} \quad \text{ec 9}$$

Para la estimación de la respiración del ecosistema (Re), se utiliza el algoritmo propuesto por Reichstein (2005). La respiración neta diurna se ha extrapolada a los flujos nocturnos mediante la aplicación de la ecuación 10.

$$Re(T) = R_{ref} \cdot e^{E_o \cdot \left(\frac{1}{T_{ref} - T_o} - \frac{1}{T - T_o} \right)} \quad \text{ec10}$$

Donde, E_o (parámetro de activación de la energía) es variable y se estimó mediante el modelo de regresión exponencial propuesto por Lloyd y Taylor (1994). T_{ref} representa la temperatura de referencia y T_o es el parámetro de regresión. El nivel de independencia de la temperatura de la respiración (R_{ref}) se determinó mediante el mismo modelo de regresión (Lloyd y Taylor, 1994), fijando todos los parámetros, a excepción del R_{ref}.

3.2.4. Cálculo del parámetro máxima eficiencia en el uso de la luz

La Eficiencia en el Uso de la Luz (LUE, Light Use Efficiency) es el flujo de moles de dióxido de carbono (CO₂) emitidos por cada fracción de luz incidente en el cultivo. El cálculo de esta variable depende de la GPP (Producción Primaria Bruta) y aPAR (radiación fotosintéticamente activa incidente), como se muestra en la ecuación 11.

$$LUE = \frac{GPP}{aPAR} \left(\frac{gC}{MJ} \right) \quad \text{ec 11}$$

Para la estimación de la GPP se sigue la metodología descrita anteriormente, mientras que la aPAR es calculada gracias a las siguientes ecuaciones:

$$aPAR = PAR * faPAR \left(\frac{W}{m^2} \right) \quad \text{ec 12}$$

$$faPAR = m1 * NDVI + b1 \quad \text{ec 13}$$

$$PAR = \frac{SWin}{2} \left(\frac{W}{m^2} \right) \quad \text{ec 14}$$

La radiación fotosintéticamente activa (PAR) es calculada a partir de la radiación de onda corta incidente (SW_{in}), medida con la torre EC y dividida entre dos (ecuación 14). De acuerdo con Myneni y Williams (1994), la fracción de la radiación fotosintéticamente activa incidente (faPAR) se calcula mediante la ecuación 3.13. Asimismo, Garcia et al. (2013) han implementado esta misma ecuación. En el escenario actual, la variable $m1$ toma valor de 1.16 y $b1$ de -0.14, de acuerdo con la bibliografía de Myneni y Williams (1994). El valor del NDVI se obtuvo mediante el producto de MODIS, descrito en el apartado 3.3. de metodología. Finalmente, mediante la multiplicación de la PAR con faPAR (ecuación 12), se obtuvo la radiación fotosintéticamente activa incidente, utilizada en la ecuación 11 para el cálculo de la LUE.

El modelo SVEN utiliza la LUE_{max} , cuya es estimada siguiendo el procedimiento descrito, enfocándose exclusivamente en el valor de SW_{in} durante las horas de máxima radiación, equivalente a las 12-14 horas solares. En consecuencia, LUE_{max} refleja la eficiencia en el uso de la luz, cuando el cultivo se encuentra en condiciones óptimas.

3.2.5. Estimación de la radiación de onda larga

La radiación de onda larga (LW_{in}) es una variable que no fue directamente medida, sino que fue obtenida gracias a la combinación de parámetros meteorológicos, entre ellos la temperatura del aire. Para la estimación se aplicó la ley de Stefan Boltzmann, considerando los valores de la emisividad atmosférica (ϵa) y la constante de Stefan-Boltzmann. A continuación, se muestra el procedimiento seguido para su determinación:

$$LWin = \epsilon a * \sigma * Ta^4 \quad \text{ec 15}$$

$$\epsilon a = 1 - (1 + \delta)e^{-\sqrt{(1.2+3\delta)}} \quad \text{ec 16}$$

$$\delta = \frac{46.5}{Ta} * e0 \quad \text{ec 17}$$

$$e0 = RH \cdot 6.11e^{\left[\frac{Lv}{Rv} \left(\frac{1}{273.15} - \frac{1}{Ta} \right) \right]} \quad \text{ec 18}$$

Donde e_0 es el vapor de agua actual estimado basándose en la ecuación de Clausius-Clapeyron. El calor latente de vaporización (L_v) del agua es de $2.5 \cdot 10^6$ ($J \cdot kg^{-1}$) y la constante gaseosa para el vapor de agua (R_v) es de 461 ($J \cdot kg^{-1} \cdot K^{-1}$). T_a es la temperatura del aire ($^{\circ}K$). σ es la constante de Stefan-Boltzmann, que toma valor de $5.67 \cdot 10^{-8}$ ($W \cdot m^{-2} \cdot K^{-4}$). La figura 3.6. muestra la evolución de la LW_{in} calculada mediante el método propuesto.




FIGURA 3.6: Representación de la serie temporal de la radiación de onda larga (W/m^2) desde el 15 de enero (15 DOY) hasta el 12 de junio (163 DOY).

3.2.6. Estimación del índice de área foliar

Para la estimación del índice de área foliar (LAI) se realizó mediante la revisión bibliografía del trabajo realizado por García et al. (2013) en estudios anteriores sobre la misma zona. El cálculo se realizó mediante la siguiente expresión:

$$LAI = -\frac{\ln(1 - fc)}{kPAR} \quad \text{ec 19}$$

$$fc = fIPAR = m2 * NDVI + b2 \quad \text{ec 20}$$

Donde, fc es la fracción vegetal que está cubierta, que según el trabajo de García et al. (2013) tiene el mismo valor que la fracción de PAR interceptada por la cubierta vegetal (fIPAR). $kPAR$ toma valor de 0.5 según la bibliografía de Brownsey et al. (1976). El valor de $m2$ fue de 1 y $b2$ de -0.05 según Fisher et al. (2008).

3.2.7. Estimación de la altura de la vegetación

La altura de la vegetación es un parámetro que fue obtenido mediante la revisión bibliografía de varios autores que trabajaron con el mismo cultivo sobre la misma zona. Según Garcia et al. (2013), Morillas et al. (2013a) y Kustas et al. (2016), la altura de la vegetación era de 0.7m.

3.3. Información de sensores remotos

3.3.1. Producto de *ECOSTRESS*

El ECOSTRESS (ECOsystem Spaceborne Thermal Radiometer Experiment on Space Station) es una misión científica que utiliza sensores radiométricos montados en la Estación Espacial Internacional (ISS). La misión de lanzamiento se realizó el 29 de junio del 2018, en Cape Cañaveral (Florida, USA) dentro de la cápsula Dragon (SpaceX, USA). El sensor utilizado recolecta datos multispectrales de la banda infrarroja y térmica. La banda térmica mide la temperatura de la superficie terrestre y no la temperatura del aire. El propósito de esta misión es proporcionar información sobre los efectos de las olas de calor y las sequías en los cultivos (NASA, 2018).

Los datos están disponibles en el Land Processes Distributed Active Archive Center (LP DAAC), es un centro de gestión de datos, dirigido por el Servicio Geológico de los Estados Unidos (United States Geological Survey, USGS). La descarga de los datos se puede realizar mediante varias plataformas, pero los autores recomiendan utilizar la aplicación AppEEARS (Application for Extracting and Exploring Analysis Ready Samples) (Appears Team, 2020).

El sensor radiométrico se construyó en el laboratorio de Jet Propulsion de la NASA (JPL) y contiene cinco bandas espectrales en el infrarrojo térmico (8-12 micron) y una banda en el infrarrojo cercano (usada para la geolocalización). Presenta una resolución de 70x70m (NASA, 2018).

TABLA 3.2: Representación de la información de ET proporcionada por el producto ECOSTRESS. FUENTE: NASA, 2018.

Grupo	Tipología	Unidades	Descripción
ET inst	Float32	W/m2	Evapotranspiración instantánea
ET canopy	Float32	%	Evapotranspiración de la vegetación
ET soil	Float32	%	Evapotranspiración del suelo
ET interception	Float32	%	Evapotranspiración interceptada
ET instUncertainty	Float32	W/m2	incertidumbre de la evapotranspiración instantánea

Para el estudio se utilizó el producto denotado “ECO3ETPTJPL.001”, cuyo es de nivel L3, es decir, un producto preprocesado. Utiliza el algoritmo PT-JPL (Priestley-Taylor, 1972), una versión reducida del Penman-Monteith, que elimina la necesidad de parametrizar la resistencia estomacal y aerodinámica, teniendo en cuenta únicamente el equilibrio evaporativo multiplicado por una constante “ α ”, con valor de 1.26 (Fisher et al., 2008). Por otro lado, la NASA modificó el algoritmo PT-JPL para: a) adaptarlo a ciclos diurnos (integral o promedio diario, en vez de las 10:30 como en el MODIS) y b) mejorar la resolución espacial, de modo que alcanza una precisión de 70m, en vez de 1.000m como en el MODIS, (NASA, 2018).

Para conocer con exactitud cuándo se realizó la lectura del sensor, se debe utilizar la información proporcionada por el documento del metadatos, cuyo formato es el siguiente: “ECOSTRESS_<PROD_TYPE>_<OOOOO>_<SSS>_<YYYYMMDD>T<hhmmss>_<BBBB>_<VV>.<TYPE>”

Donde, *PROD_TYPE*: Define el producto seleccionado; *OOOOO*: Numero de la órbita en que se inició la misión, ascendiendo el cruce ecuatorial; *SSS*: ID de la escena, inicio a la primera escena

de la primera órbita; *YYYYMMDD*: Año, mes, día en que se realizó la lectura; *hhmmss*: Hora, minuto, segundo en que se realizó la lectura; *BBbb*: ID del software que generó el producto, contiene dígitos en mayúscula y minúscula (2+2 dígitos); *VV*: Numero de la versión del producto (2 dígitos); *TYPE*: Tipo de extensión del documento. Pudiendo ser: “h5” para los documentos de datos o “h5.xml” para los documentos de metadato.

A continuación, se muestra un ejemplo de la información proporcionada por los metadatos y el procedimiento de extracción siguiendo la metodología explicada:

ECOSTRESS_L1B_GEO_03369_004_20190208T115725_0601_03.h5

- PROD_TYPE: L1B_GEO
- OOOOO: 03369
- SSS: 004
- YYYYMMDD: 20190208
- hhmmss: 115725
- BBbb: 0601
- VV: 03
- TYPE: .h5

3.3.2. Producto de satélite *MODIS*

Otro producto utilizado en el proyecto, también basado en teledetección, es MODIS (MODerate resolution Imaging Spectroradiometer), cuya misión fue lanzada por la NASA el 23 de mayo de 1999. MODIS está compuesto por dos modelos, Terra y Aqua, que pueden cubrir la superficie de la Tierra con imágenes diarias o cada dos días. Tiene 36 bandas espectrales con rangos de onda que van desde los 0.4 hasta los 14.385 μm . La resolución espacial varía en función del producto seleccionado, pero los distintos rangos son de 250m, 500m y 1km, mientras que la resolución temporal presenta una frecuencia de 8 días o 16 días (Kahn et al., 2009; Zhang y Reid, 2009; Shi et al., 2012; Acharya y Sreekish, 2013).

La descarga de los datos se realiza desde la misma plataforma que los datos de ECOSTRESS, es decir, PL DAAC AppEEARS (Appears Team, 2020). Se decidió utilizar este producto para obtener los valores de NDVI (Índice de Vegetación Diferenciada Normalizado), que se obtuvo gracias a los productos de los modelos MOD09Q1 y MOD13Q1, además de la información de la calidad de la banda. Cuando la calidad de la banda era inferior a “calidad ideal/buena calidad”, el dato no era utilizado. El criterio utilizado es similar al descrito por Sanz et al. (2024).

Los índices de vegetación se utilizan para medir la intensidad de la biomasa en función del comportamiento espectral de la vegetación viva (Campbell y Wynne, 2011). Diferentes componentes de la vegetación en crecimiento corresponden a diferentes respuestas espectrales; por ejemplo, la clorofila absorbe la luz roja (R), mientras que los tejidos mesofílicos reflejan la radiación infrarroja (IR). Por lo tanto, la relación IR/R se puede utilizar como indicador de la actividad fotosintética y de la biomasa vegetal. Al mismo tiempo, cuando no hay vegetación (suelo desnudo), no se muestra esta diferencia en la respuesta espectral, por lo que los valores de la relación IR/R son más bajos (Pateromichelaki, 2020).

El Índice de Vegetación de Diferencia Normalizada (NDVI), que se utilizó en este estudio, se calcula mediante el contraste entre la radiación en el espectro rojo (RED) y el infrarrojo cercano (NIR), como se observa en la ecuación 21.

El efecto de las nubes sobre el cálculo del NDVI es un factor a tener en cuenta, ya que las nubes tienen un impacto relativamente mayor sobre el efecto del rojo que del infrarrojo cercano. Este efecto da como resultado un NDVI subestimado en condiciones nubladas (Schlundt et al., 2011).

El producto *MOD09Q1* presentaba una composición temporal de 8 días con una resolución espacial de 250 m de píxel (Huete et al., 2002). El cálculo del NDVI con este producto se realizó mediante la ecuación correspondiente, ya que se disponía de la información de las bandas del infrarrojo cercano y rojo.

$$NDVI = \frac{NIR - RED}{NIR + RED} = \frac{\text{banda 1} - \text{banda 2}}{\text{banda 1} + \text{banda 2}} \quad \text{ec 21}$$

El segundo producto de MODIS, *MOD13Q1*, presentaba una frecuencia temporal de 16 días y una resolución espacial de 250 m por píxel. En este caso, el producto proporcionaba directamente el valor del NDVI.

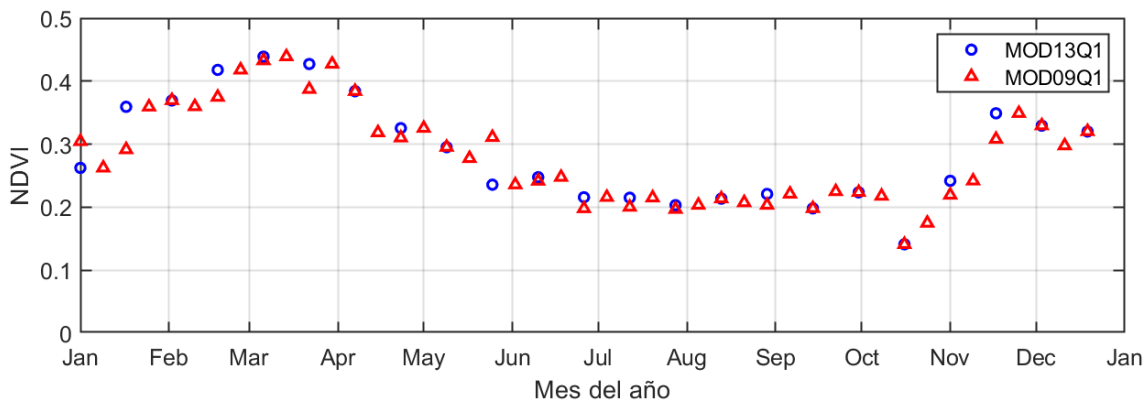


FIGURA 3.7: Representación de la serie temporal del 2011 de los valores de NDVI de los distintos productos de MODIS. Los círculos de color azul son el producto MOD13Q1, mientras que los triángulos de color rojo son del producto MOD09Q1.

Como se puede observar en la figura 3.7, la serie temporal de los dos productos MODIS es muy similar. Se puede apreciar que el valor máximo se da alrededor de la semana 10 y el mínimo en la semana 37. Solo 9 datos del producto MOD13Q1 coinciden con el mismo valor que el producto MOD09Q1.

Además del NDVI, también se utilizó el producto de temperatura superficial LST (MOD11A1), descargado de la plataforma PL DAAC AppEARS (Appears Team, 2020). El producto utilizado presenta una resolución espacial de 1x1 km² y una resolución temporal diaria. Además del valor del producto, también se obtuvo la información de la calidad de la banda. Cuando la calidad de la banda era inferior a “calidad ideal/buena calidad”, el dato no era utilizado. El criterio utilizado fue el mismo que describió Sanz et al. (2024) en su trabajo. En la figura 3.8 se muestra la serie temporal de la temperatura superficial observada por la estación EC y la serie temporal de la temperatura superficial observada según el producto MOD11A1.




FIGURA 3.8: Representación de la serie temporal de la temperatura superficial observada por la estación EC (línea de color negro) y la serie temporal de la temperatura superficial observada según el producto de MOD11A1 (punto de color violeta).

3.4. Adquisición de datos y generación de la base de datos

Los datos se adquirieron de los distintos sensores mencionados y posteriormente se agruparon en una base de datos como archivo de entrada del modelo.

3.4.1. Base de datos input

La homogenización de los datos es un factor clave para poder utilizar correctamente la base de datos como entrada del modelo. El objetivo final es que todas las variables de entrada del modelo presenten la misma frecuencia.

En el caso de los datos obtenidos mediante la torre EC, la frecuencia era de 15 minutos, por lo que se agruparon cada 30 minutos. Para las variables SW_{in} , LW_{in} , T_{air} , U_a , RH y P_s se calculó la media aritmética, mientras que la variable P se calculó mediante la suma. Al ser una serie temporal considerablemente larga, se utilizó el complemento de “Desarrollador” en Visual Basic de Excel, que permite automatizarlo.

En el caso de que las variables medidas con la estación EC presenten valores vacíos, se utilizó la imputación mediante la librería “imputeTS”, concretamente la imputación de Kalman Smoothing, ya que es de las más extendidas (Zheng et al., 2020). En este caso, el código se desarrolló en el lenguaje de programación R, en el entorno R-Studio. Dicha librería permite visualizar los datos, localizar los valores sin datos (NA) y realizar el rellenado y la sustitución. Las variables U_a y SW_{in} presentaron un 2.17% y un 0.32% de valores faltantes, respectivamente.

Respecto a la variable GPP, representa el flujo de gramos de C producido por la fotosíntesis en unidad de superficie durante un periodo de tiempo determinado, por lo que los flujos negativos no tienen sentido y deben ser renombrados como valores nulos. Por otro lado, la variable LE puede presentar valores negativos, que pueden ser lógicos. Sin embargo, se debe tener en cuenta la radiación de onda corta incidente (SW_{in}), que será la variable limitante. Cuando SW_{in} presente valores negativos ($SW_{in} < 0$), el flujo de calor latente (LE) debe ser nulo (cero).

Respecto al NDVI, finalmente se descartó el producto MOD13Q1, con una frecuencia de 16 días, porque la calidad de las bandas en algunas medidas no era “ideal”, pero sí lo es la del producto MOD09Q1. El índice de vegetación diferenciado normalizado es una variable que no presenta gran inercia de cambio, por lo que se puede estimar en momentos de tiempo cortos. En concreto, se realizó una interpolación lineal para rellenar los datos con la frecuencia deseada.

Para suavizar el efecto de los cambios de tendencia tras la interpolación lineal, se utilizó el algoritmo de Savitzky-Golay (Savitzky y Golay, 1964) en el lenguaje de MATLAB. En la figura 3.9 se muestra el valor del NDVI original (línea discontinua de color negro) y los distintos suavizados obtenidos con este algoritmo. La utilización de esta librería depende del grado del polinomio que se desee utilizar y de la ventana que se utilice para hacer el suavizado.

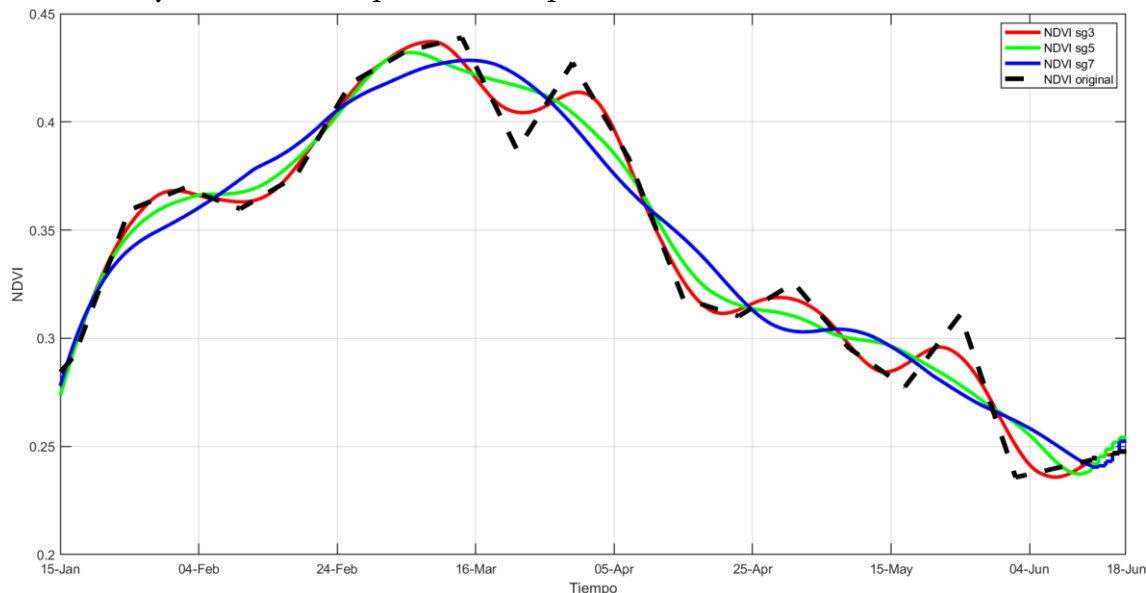


FIGURA 3.9: La línea discontinua de color negro representa los valores originales de NDVI del producto MOD09Q1. Línea de color rojo representa los valores de NDVI aplicando el suavizado Savitzky-Golay con una ventana de 3. Línea de color verde representa los valores de NDVI aplicando el suavizado Savitzky-Golay con una ventana de 5. Línea de color azul representa los valores de NDVI aplicando el suavizado Savitzky-Golay con una ventana de 7.

Como se puede observar en la figura 3.9, la línea de color azul corresponde a una ventana de 7, la línea de color verde representa una ventana de 5 y la línea de color rojo representa una ventana de 3. El candidato que representa los valores de NDVI se determinó según el mismo criterio que describieron Sanz et al. (2024), con una ventana de 7.

3.5. Validación datos ECOSTRESS con datos in situ

Los datos de la misión ECOSTRESS se obtuvieron desde la plataforma PL DAAC AppEEARS, como se ha mencionado anteriormente en el apartado 3.3. Al ser una misión joven, solo hay datos disponibles desde 2018.

Para validar los datos del ECOSTRESS, se utilizaron los de la estación EC que coincidían en el tiempo con los del ECOSTRESS. Para obtener la información exacta de cuándo se obtuvieron los datos del ECOSTRESS, hay que seguir el procedimiento explicado en la metodología (apartado 3.3), donde se utilizan las variables “YYYYMMDD” y “hh:mm:ss” de la información del metadato.

La comparación se realizó con el producto ET instantánea (ET_{inst}) y se comparó con el valor de la ET medida por la estación EC en el mismo instante de tiempo (o el más próximo). Por otro lado, también se evaluó la variable ET diaria (ET_{daily}) de ECOSTRESS y se comparó con el valor de la ET diaria que se tuvo que calcular previamente.

En las dos metodologías es esencial tener en cuenta las unidades, ya que ECOSTRESS proporciona la información en unidades de energía ($W \cdot m^{-2}$). Para la conversión en unidades agronómicas (mm), se debe utilizar el factor de conversión 0.0352, considerando que la densidad del agua es de $1,000 \text{ Kg} \cdot m^{-3}$ y que su capacidad calorífica es de $1.454 \cdot 10^3 \text{ J} \cdot \text{Kg}^{-1}$.

3.6. Modelo de balance energético superficial simple

Para entender cómo funcionan los modelos de superficie de la Tierra, se ha seguido el ejemplo propuesto por Margulis y Huning (2015) quien utiliza un modelo de balance energético superficial simple (SEB, Surface Energy Balance) basado en el flujo de calor del suelo y la transferencia de masa en un flujo turbulento, es decir, basado en el flujo de calor sensible y latente. El modelo es capaz de simular los flujos turbulentos (LE y H) gracias a las ecuaciones clásicas de transferencia de masa, ecuaciones basadas en los gradientes de vapor de agua y térmicos, respectivamente, y la temperatura superficial del suelo (LST) y el flujo de calor del suelo (G) gracias al modelo “force-restore”.

La predicción del modelo está forzada a realizarse cada 30 minutos, con datos micro-meteorológicos captados gracias a una estación EC.

TABLA 3.4: Tabla resumen de las variables input utilizadas en el modelo.

Abreviación	Descripción	Unidades	Fuente
SW_{in}	Radiación incidente de onda corta	$W \cdot m^{-2}$	Dato meteorológico
LW_{in}	Radiación incidente de onda larga	$W \cdot m^{-2}$	Estimación empírica
T_{air}	Temperatura del aire	$^{\circ}C$	Dato meteorológico
U	Velocidad horizontal del viento	$m \cdot s^{-1}$	Dato meteorológico
RH	Humedad relativa	%	Dato meteorológico
Ps	Presión atmosférica	hPa	Dato meteorológico
P	Precipitación	$mm \cdot h^{-1}$	Dato meteorológico
h	Altura de la planta	m	Literatura y medición in-situ
θ	Contenido de humedad de agua en el suelo	$m^3 \cdot m^{-3}$	Literatura y medición in-situ
NDVI	Índice de vegetación de diferencia normalizada	adim	MODIS <i>MOD09Q1</i> , <i>procesado</i>

El modelo SEB requiere una serie de variables de entrada para poder ejecutar todos los módulos correctamente. La información de estas variables se ha recopilado de diferentes formas: a) el valor de la radiación incidente de onda corta (SW_{in}), la temperatura del aire (T_{air}), la velocidad del viento (U_a), la humedad relativa (RH), la presión atmosférica (Ps) y la precipitación (P) se recogieron gracias a la estación meteorológica; b) mediante la consulta de la literatura y mediciones in situ se determinó la altura de la planta (h), radiación incidente de onda larga (LW_{in}) y el contenido de humedad de agua en el suelo (SWS); c) mediante el uso de información satelital para determinar el índice NDVI (explicado en el apartado 3.3), gracias al producto del satélite *MODIS MOD09Q1*.

3.6.1. Descripción del modelo

Como se ha mencionado anteriormente, el modelo SEB se basa en el flujo de calor, utilizando el modelo “force-restore” en el suelo y la transferencia de masa en un flujo turbulento. El método “force-restore”, permite estimar el cambio de la temperatura superficial, que tiene en cuenta dos

efectos opuestos de la temperatura. El primero ($R_n - \lambda E - H$), que representa la inercia G y cuya magnitud se ve modificada a lo largo del tiempo por el efecto de la temperatura superficial. El segundo término ($T_s - T_d$) representa el gradiente de temperatura entre la superficie y el suelo en profundidad, cuyo objetivo es estabilizar la temperatura superficial con el valor de la temperatura del suelo en profundidad (T_d).

$$\frac{dT_s}{dt} = C_T(R_n - \lambda E - H) - C_d(T_s - T_d) \quad \text{ec 3.22}$$

$$\frac{dT_d}{dt} = \omega(T_s - T_d) \quad \text{ec 3.23}$$

$$C_T = 1/(C_{soil}d_g) \quad \text{ec 3.24}$$

$$C_d = 2\pi\omega \quad \text{ec 3.25}$$

Donde, T_s es la temperatura superficial del suelo (LST, °C). T_d es la temperatura del suelo en profundidad (°C). C_T es la capacidad calorífica del suelo ($m^2 \cdot K \cdot J^{-1}$). C_d es la periodicidad diurna (h^{-1}). C_{soil} es la capacidad calorífica específica del suelo ($J \cdot m^{-3} \cdot K^{-1}$). d_g es la profundidad del suelo (m). R_n es la radiación neta ($W \cdot m^{-2}$). λE es el flujo de calor latente (LE, $W \cdot m^{-2}$). H es el flujo de calor sensible ($W \cdot m^{-2}$). ω es la frecuencia de oscilación $1/24$ (h^{-1}).

Para el cálculo de la estimación del flujo de calor sensible se basa en el gradiente entre la superficie y el aire.

$$H = \rho \cdot c_p \cdot (T_s - T_a)/r_a \quad \text{ec 26}$$

Donde, ρ es la densidad del aire ($kg \cdot m^{-3}$); c_p es la capacidad de calor específica del aire ($J \cdot kg^{-1} \cdot K^{-1}$); T_s es la temperatura superficial del suelo (LST, °C); T_a es la temperatura del aire (°C); r_a es la resistencia aerodinámica para el intercambio de calor ($s \cdot m^{-1}$).

La resistencia aerodinámica en un transporte turbulento en condiciones naturales (r_{aN} , ecuación 27) se puede expresar según lo propuso Brutsaert (1982). La disipación de la energía en forma de flujo de calor sensible (H) está definida por la resistencia aerodinámica que describe la velocidad del viento horizontal en la estructura de la planta.

$$r_{aN} = \frac{(\ln(\frac{z-d}{z_0}))^2}{k^2 \cdot u} \quad \text{ec 27}$$

$$d = 0.7 \cdot h \quad \text{ec 28}$$

$$z_0 = 0.17 \cdot h \quad \text{ec 29}$$

Donde, h es la altura de la planta (m). z es la velocidad a la altura de referencia (m). d es el desplazamiento cero de la altura (m). u es la velocidad horizontal del viento a la altura de referencia ($m \cdot s^{-1}$). z_{0m} es la altura del momento de fricción aerodinámica (m).

La resistencia aerodinámica en un transporte turbulento en condiciones naturales se puede expresar según lo defendió Margulis y Huning (2015).

$$r_a = r_{aN} \cdot \phi_m \cdot \phi_h \quad \text{ec 30}$$

$$\phi_h = \phi_m^2 = (1 - 15 \cdot R_{iB})^{-1/2} \quad R_{iB} \leq 0 \text{ (inestable)} \quad \text{ec 31}$$

$$\phi_h = \phi_m = (1 - 5 \cdot R_{iB})^{-1} \quad 0 \leq R_{iB} < 0.2 \text{ (estable)} \quad \text{ec 32}$$

$$R_{iB} = \frac{\left(\frac{g}{T_s}\right) \cdot \partial T / \partial z}{\left(\frac{\partial u}{\partial z}\right)^2} \quad \text{ec 33}$$

Donde, ϕ_m es el factor de corrección de la estabilidad del momento. ϕ_h es el factor de corrección de la estabilidad del calor latente. En condiciones inestables, es decir, con gradientes negativos de temperatura, el factor de corrección de la estabilidad es menor de 1.0, lo que permite reducir la resistencia y mejorar la turbulencia. Mientras que, en condiciones estables, es decir, gradientes positivos de temperatura, el factor de corrección de la estabilidad es mayor de 1.0, lo que permite incrementar la resistencia y reducir la turbulencia. R_{iB} es el número del bulbo (Bulk) de Richardson. g es la aceleración de la gravedad.

Para el cálculo del flujo de calor latente, se utilizó el procedimiento de transferencia de masa, similar a las ecuaciones de transferencia de calor. Todo el procedimiento se ha obtenido gracias al trabajo de Noilhan y Planton (1989).

Una suposición que hace el modelo es asimilar que humedad superficial en el modelo de transferencia de masa por evaporación es igual a la humedad específica de saturación, efecto que implica evaporación potencial.

3.6.2. Parámetros del modelo

El modelo SEB requiere una serie de variables y parámetros, como se puede observar en la figura 3.10. Las variables meteorológicas (representadas en verde en la figura 3.10) se explican al inicio del apartado 3.6. Las condiciones de inicialización son: a) la capacidad de campo (FC) y el punto de marchitez (PM), cuyos valores se obtuvieron gracias a los análisis realizados en el trabajo de Kustas et al. (2016), expresados en unidades volumétricas (% , m^3/m^3) y b) los valores de temperatura del suelo superficial (T_{s0}) y del suelo en profundidad (T_{s0}) para inicializar el modelo. Basándonos en el trabajo de Wang et al. (2020), estos deben tomarse como el mismo valor que la temperatura del aire (T_{air}) en el tiempo inicial ($^{\circ}\text{K}$).

Otro aspecto que hay que tener en cuenta en el modelo son los diferentes parámetros, que deben determinarse para las condiciones de la parcela. En la tabla 3.3 se encuentra el resumen de los distintos parámetros, con sus respectivos valores, unidades y referencia para su determinación.

La emisividad (ϵR , ϵR) se determinó mediante la metodología utilizada por Morillas et al. (2013a), utilizando la ecuación 34.

$$\epsilon R = fc \cdot \epsilon c + (1 - fc) \cdot \epsilon s \quad \text{ec 34}$$

Donde fc es la fracción de planta (canopy), que toma valor de 0.6; ϵR es el valor de la emisividad; ϵc es el valor de la emisividad de la planta (canopy), con el valor 0.99; ϵs es el valor de la emisividad

del suelo, con el valor 0.95. Los valores se han obtenido del trabajo realizado por Morillas et al. (2013a), ya que la zona de estudio fue la misma y se realizó con la base de datos del mismo año (2011).

La profundidad radicular del suelo (dg) se estimó de igual forma gracias al trabajo de Morillas et al. (2013a) y Kustas et al. (2016), cuya profundidad fue de $3 \cdot 10^{-1}$ m.

La capacidad calorífica volumétrica del suelo (C_{soil}) se calibró mediante el método de optimización sencillo, ya que es un valor razonable para el suelo que nos encontramos. Se determinó que $0.8 \cdot 10^{-6}$ ($J \cdot m^{-3} \cdot K^{-1}$) era suficiente precisión en el modelo y tenía sentido físico respecto a la característica del suelo.

Por último, el valor de *albedo* se determinó gracias al estudio realizado por Kustas et al. (2016), ya que realizaron las mediciones de la variable albedo en el campo. Al ser una variable medida por la estación EC, la frecuencia de los datos fue medio-horaria. Se seleccionaron los momentos de mayor radiación, es decir, a las 14:00 horas solares, y se calculó la media de todos los datos. El valor final fue de 0.151.

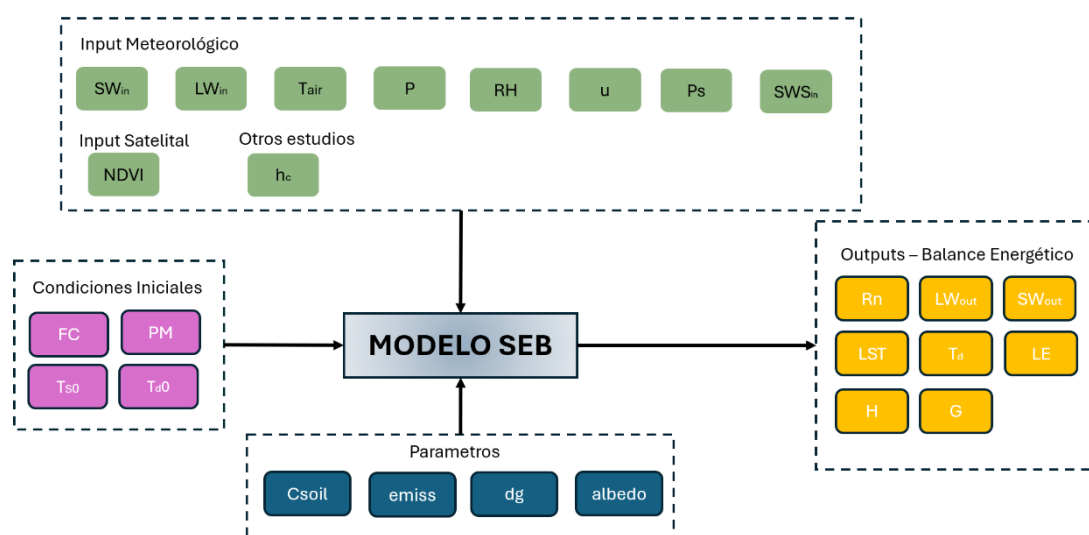


FIGURA 3.10: Esquema del modelo SEB utilizado en el estudio. Las variables meteorológicas y la medición a partir de sensor remoto están representadas en color verde. Las condiciones iniciales están representadas en color violeta. Los parámetros utilizados están representados en color azul y se obtuvieron mediante tablas de referencia, calibraciones o referencias a otros estudios similares. En color amarillo están representados los resultados.

TABLA 3.3: Información de modelo SEB sobre los distintos parámetros utilizados con los valores.

Parámetro	Descripción	Valor	Unidades	Referencia
Csoil	Capacidad calorífica volumétrica del suelo	$0.8 \cdot 10^{-6}$	$J \cdot m^{-3} \cdot k^{-1}$	Calibrado según modelo
emiss	Emisividad	0.974	-	Kustas et al. (2016)
dg	Profundidad del suelo	0.300	m	Morillas et al. (2013a); Kustas et al. (2016)
albedo	Albedo	0.151	-	Kustas et al. (2016)

3.6.3. Evaluación y validación de los outputs del modelo

Para evaluar el modelo, la base se dividió en un 70% para el entrenamiento y la calibración del modelo, y el 30% restante para la validación (desde el 29 de abril hasta el 12 de junio). Para la evaluación se emplearon los siguientes estadísticos, que permiten cuantificar estadísticamente lo robusto que es el modelo.

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (Obs_i - Sim_i)^2} \quad \text{ec 35}$$

$$NRMSE (\%) = \frac{RMSE}{Obs_i^{max} - Obs_i^{min}} \cdot 100 \quad \text{ec 36}$$

$$Bias = \frac{1}{n} \cdot \sum_{i=1}^n (Obs_i - Sim_i) \quad \text{ec 37}$$

$$MAE = \frac{1}{n} \cdot \sum_{i=1}^n |Obs_i - Sim_i| \quad \text{ec 38}$$

$$R^2 = \frac{(\sum_{i=1}^n (Obs_i - \overline{Obs}) \cdot (Sim_i - \overline{Sim}))^2}{\sum_{i=1}^n (Obs_i - \overline{Obs})^2 \cdot \sum_{i=1}^n (Sim_i - \overline{Sim})^2} \quad \text{ec 39}$$

Wang et al. (2020) describieron que los estadísticos R^2 , RMSE y NRMSE son adecuados para evaluar el modelo. Además, también se utilizó el criterio de Pateromichelaki (2020), que añadió el estadístico MAE. Finalmente, se llegó al consenso de que el estadístico bias era necesario para poder evaluar si el modelo subestima o sobreestima las medidas observadas.

3.7. Modelo dinámico de transferencia de energía, agua y flujo de CO₂ entre el suelo-vegetación-atmosfera

3.7.1. Descripción del modelo

La base del modelo SVEN es igual al modelo más simple descrito anteriormente (modelo de balance energético superficial, SEB), ya que utiliza el modelo “force-restore” y de transferencia de masa. La ventaja del modelo “force-restore”, es que permite disgregar entre la componente del suelo y la vegetación, mejorando la precisión. Además, el modelo es ampliado con dos módulos: a) el módulo del balance de agua, que utiliza el modelo ET propuesto por Priestley-Taylor Jet Propulsion Laboratory ET (PT JPL-ET) y el modelo “bucket” para estimar el contenido de humedad de agua en el suelo y b) el módulo del flujo de CO₂, que permite determinar la GPP en remoto utilizando el modelo de la eficiencia en el uso de la luz (LUE), relacionado con la ET gracias a las limitaciones biofísicas de la planta. El conjunto de los tres módulos está compuesto por modelos y submodelos que permiten crear un modelo dinámico (Wang et al., 2018a). La figura 3.11 muestra el diagrama de flujo de los distintos módulos, modelos y submodelos.

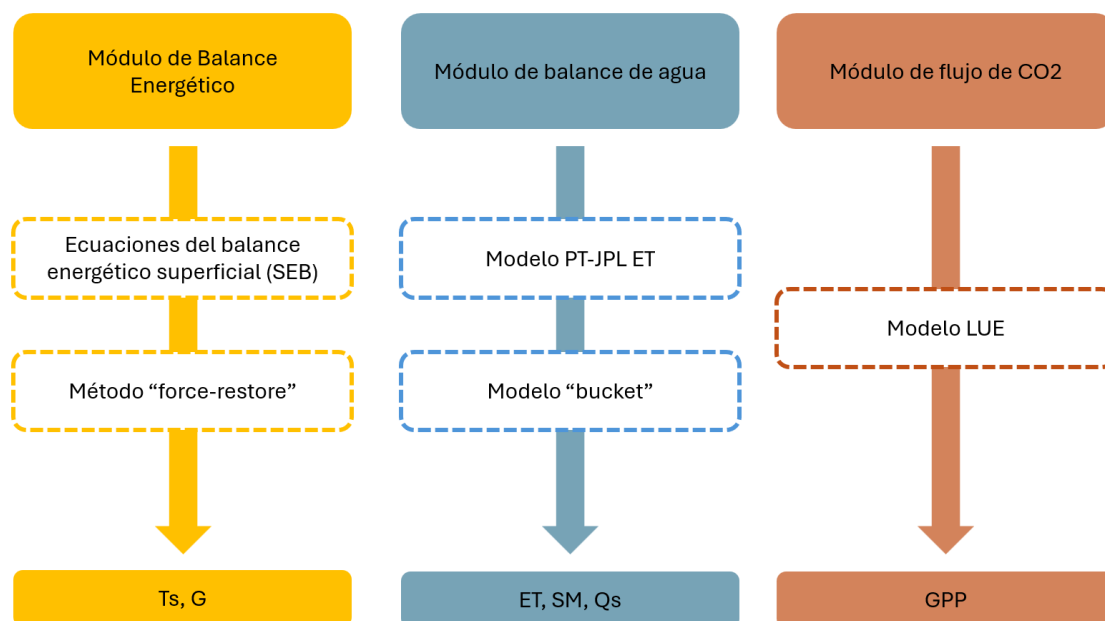


FIGURA 3.11: Representación del diagrama de flujo de los distintos módulos, modelos y submodelos que emplea el modelo SVEN, con sus respectivos resultados. El balance energético está representado en amarillo; el balance de agua en azul; y el flujo de CO₂ en naranja.

En la figura 3.12 se puede observar la recreación del escenario de flujos de energía, agua e intercambios de CO₂. En la parte superior se aprecian la mayoría de los intercambios de energía para los que es necesario aplicar el módulo de balance energético. Las distintas variables que se parametrizan e interactúan son la radiación de onda corta entrante (SW_{in}), la radiación de onda corta saliente (SW_{out}), la radiación de onda larga entrante (LW_{in}), la radiación de onda larga saliente (LW_{out}), la radiación neta (R_n), el flujo de calor del suelo (G), la temperatura superficial (T_s), la temperatura del suelo en profundidad (T_d) y el flujo de calor sensible (H). Por debajo de la línea discontinua de color azul, se pueden visualizar intercambios energéticos relacionados con los flujos de agua y las diferentes componentes del módulo de balance de agua. Las distintas variables que se parametrizan y que interactúan son la precipitación (P), el flujo de calor latente (LE o λE), el flujo de calor latente del agua interceptada (λE_i), el flujo de calor latente de la

transpiración (λE_c), el flujo de calor latente de la evaporación del suelo (λE_s), el contenido de agua de la planta (CWS), el contenido de agua del suelo (SWS), la infiltración (Q_{inf}), la percolación (Q_{per}) y la escorrentía superficial (Q_s). Finalmente, la variable de color verde, ubicada en la parte superior derecha, hace referencia al último módulo del modelo: el flujo de CO_2 , cuya principal variable es la producción primaria bruta (GPP).




FIGURA 3.12: Resumen del proceso tierra-superficie de la simulación del modelo SVEN. Las distintas variables observarles son: SW_{in} : Radiación de onda corta entrante; SW_{out} : Radiación de onda corta saliente; LW_{in} : Radiación de onda larga entrante; LW_{out} : Radiación de onda larga saliente; R_n : Radiación neta; G : Flujo de calor del suelo; T_s : Temperatura superficial; T_d : Temperatura del suelo en profundidad; H : Flujo de calor sensible; P : precipitación; λE : Flujo de calor latente (LE); λE_i : Flujo de calor latente del agua interceptada; λE_c : Flujo de calor latente de la transpiración; λE_s : Flujo de calor latente de la evaporación del suelo; CWS : Contenido de agua de la planta; SWS : Contenido de agua del suelo, Q_{inf} : Infiltración; Q_{per} : Percolación; Q_s : Escorrentía superficial; GPP : Productividad primaria bruta. FUENTE: Wang et al. (2020).

TABLA 3.4: Tabla resumen de las variables input utilizadas en el modelo. *Dato calculado a partir de una ecuación empírica con datos meteorológicos.

Abreviación	Descripción	Unidades	Fuente
SW_{in}	Radiación incidente de onda corta	$W \cdot m^{-2}$	Dato meteorológico
LW_{in}	Radiación incidente de onda larga	$W \cdot m^{-2}$	Estimación empírica*
T_{air}	Temperatura del aire	$^{\circ}C$	Dato meteorológico
U	Velocidad horizontal del viento	$m \cdot s^{-1}$	Dato meteorológico
RH	Humedad relativa	%	Dato meteorológico
P_s	Presión atmosférica	hPa	Dato meteorológico
P	Precipitación	$mm \cdot h^{-1}$	Dato meteorológico
h	Altura de la planta	m	Literatura y medición in-situ
NDVI	Índice de vegetación de diferencia normalizada	adim	MODIS <i>MOD09Q1</i>

El modelo SVEN requiere una serie de variables de entrada para poder ejecutar correctamente todos los módulos. La información de estas variables se ha recopilado de las siguientes formas: a) la estación meteorológica permitió medir la radiación incidente de onda corta (SW_{in}), la temperatura del aire (T_{air}), la velocidad del viento (U), la humedad relativa (RH), la presión

atmosférica (Ps) y la precipitación (P); b) gracias a la literatura y a mediciones in situ, se determinó la altura de la planta (h) y la radiación incidente de onda larga (LWin); c) la utilización de información satelital permitió determinar el índice NDVI (explicado en el apartado 3.3), se realizó mediante el producto *MOD09Q1*. A continuación, se explicarán los distintos módulos del modelo paso a paso, con todas las ecuaciones internas necesarias para realizar los métodos y balances correspondientes.

A. Módulo del balance superficial energético

El módulo del balance energético superficial se basa en las ecuaciones del balance energético superficial y en el método “force-restore”, cuyo método fue definido por Noilhan y Mahfouf (1996) y Noilhan y Planton (1989). El resultado es la obtención de la temperatura superficial (LST) y del flujo de calor del suelo (G). El balance energético superficial permite estimar la radiación neta (Rn, Wm⁻²) de forma instantánea basándose en la ecuación 3.37.

$$\begin{aligned} Rn &= SW_{in} - SW_{out} + LW_{in} - LW_{out} \\ &= (1 - alb) \cdot SW_{in} + (1 - \varepsilon) \cdot LW_{in} - \varepsilon \sigma T_s^4 \end{aligned} \quad \text{ec 40}$$

Donde, SW_{in} y SW_{out} son la radiación de onda corta incidente y emitida (Wm⁻²), respectivamente; LW_{in} y LW_{out} son la radiación de onda larga incidente y emitida (Wm⁻²), respectivamente; *alb* es el coeficiente de albedo, que se define a partir de la ecuación 41, basada en la relación del índice vegetativo (SR, ecuación 42); ε es la emisividad superficial, que se obtiene a partir de la ecuación 43, basada en la relación empírica del índice NDVI, propuesto por Van De Griend y Owe (1993); y σ es la constante de Stefan-Boltzmann, que toma el valor de $5.670367 \cdot 10^{-8} \text{ W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$; T_s es la temperatura superficial (°K).

$$alb = 0.28 - 0.14 \cdot e^{\left(\frac{6.08}{SR^2}\right)} \quad \text{ec 41}$$

$$SR = (1 + NDVI)/(1 - NDVI) \quad \text{ec 42}$$

$$\varepsilon = \begin{cases} 0.986 & (NDVI > 0.608) \\ 1.0094 + 0.047 \cdot \ln(NDVI) & (0.131 < NDVI < 0.608) \\ 0.914 & (NDVI < 0.131) \end{cases} \quad \text{ec 43}$$

En la superficie, la Rn es disipada en forma de flujos de calor del suelo, sensible y latente. La ecuación 44 describe el balance energético superficial y calcula el intercambio de calor almacenado ($\frac{dS}{dt}$) (W/m²). El flujo de calor latente (λE) se estima a partir del modelo PT-JPL ET (modulo balance de agua). El flujo de calor sensible (H) se calcula a partir del gradiente de temperatura entre el aire, el suelo y la resistencia aerodinámica del bulk (ecuación 49). El flujo de calor del suelo (G) se calcula mediante el método “force-restore” (Noilhan y Planton, 1989). Todas las variables son términos de energía, por lo que las unidades están expresadas en W·m⁻².

$$\frac{dS}{dt} = SW_{in} - SW_{out} + LW_{in} - LW_{out} - H - \lambda E - G \quad \text{ec 44}$$

El método “force-restore” (ecuación 40) permite estimar el cambio de la temperatura superficial, que tiene en cuenta dos efectos opuestos de la temperatura. El primero (Rn- λE -H), que representa

la inercia G , y cuya magnitud se ve modificada a lo largo del tiempo por el efecto de la temperatura superficial. El segundo describe el efecto regulador de la temperatura del suelo en profundidad al asimilar el calor absorbido desde la superficie. En general, la temperatura del suelo en profundidad (T_d) fluctúa menos que la temperatura superficial del suelo (T_s), por lo que se debe de tener en cuenta el gradiente ($T_s - T_d$).

Gracias al gradiente del suelo y a la inercia de la atmósfera a través de la suma de flujos de calor ($R_n - H - \lambda E$) que actúan en la interfaz entre la atmósfera y el suelo, es posible determinar la temperatura superficial ($\frac{dT_s}{dt}$), (ecuación 45).

$$\frac{dT_s}{dt} = C_T(R_n - \lambda E - H) - C_d(T_s - T_d) \quad \text{ec 45}$$

$$\frac{dT_d}{dt} = \omega(T_s - T_d) \quad \text{ec 46}$$

$$\frac{1}{C_T} = \frac{1 - f_c}{C_{sat} \cdot \left(\frac{SWS_{max}}{SWS}\right)^{\frac{b}{2 \cdot \ln(10)}}} + \frac{f_c}{C_{veg}} \quad \text{ec 47}$$

$$C_d = 2\pi\omega \quad \text{ec 48}$$

Donde T_s es la temperatura superficial del suelo (LST, °C). T_d es la temperatura del suelo en profundidad (°C). C_T es la capacidad calorífica del suelo ($\text{m}^2 \cdot \text{K} \cdot \text{J}^{-1}$). C_d es la periodicidad diurna (h^{-1}). C_{sat} es la capacidad calorífica específica del suelo a saturación ($\text{J} \cdot \text{m}^{-3} \cdot \text{K}^{-1}$). C_{veg} es el coeficiente respectivo de vegetación ($\text{m}^2 \cdot \text{K} \cdot \text{J}^{-1}$). ω es la frecuencia de oscilación $1/24$ (h^{-1}). b es la pendiente de la curva de retención del coeficiente térmico “force-restore”. f_c es la fracción cubierta de vegetación, cuyo valor se asume que es igual a la f_{IPAR} (fracción de radiación fotosintéticamente activa interceptada por la planta) según el trabajo de Fisher et al. (2008). SWS_{max} es el valor máximo de contenido de agua en el suelo (m). SWS es el valor actual de contenido de agua en el suelo (m).

El cálculo del flujo de calor sensible se basa en el gradiente entre la superficie y el aire (ecuación 49).

$$H = \frac{\rho \cdot c_p \cdot (T_s - T_a)}{r_a} \quad \text{ec 49}$$

Donde ρ es la densidad del aire ($\text{kg} \cdot \text{m}^{-3}$). c_p es la capacidad de calor específica del aire ($\text{J} \cdot \text{kg}^{-1} \cdot \text{K}^{-1}$). (T_s) es la temperatura superficial del suelo (LST, °C). T_a es la temperatura del aire (°C) r_a es la resistencia aerodinámica para el intercambio de calor ($\text{s} \cdot \text{m}^{-1}$).

La resistencia aerodinámica en un transporte turbulento en condiciones naturales (r_{aN} , ecuación 50) se puede expresar según defendió Brutsaert (1982). La disipación de la energía en forma de flujo de calor sensible (H) está definida por la resistencia aerodinámica descrita por la velocidad del viento horizontal en la estructura de la planta.

$$r_{aN} = \frac{\ln\left(\frac{z-d}{z_{0m}}\right) \cdot \ln\left(\frac{z-d}{z_{0h}}\right)}{k^2 * u} \quad \text{ec 50}$$

$$d = 0.67 \cdot h_c \quad \text{ec 51}$$

$$z_{0m} = 0.1 \cdot h_c \quad \text{ec 52}$$

$$z_{0h} = \frac{z_{0m}}{e^{k \cdot B^{-1}}} \quad \text{ec 53}$$

Donde, h_c es la altura de la planta (m). z es la velocidad a la altura de referencia (m). d es el desplazamiento cero de la altura (m). u es la velocidad horizontal del viento a la altura de referencia ($\text{m} \cdot \text{s}^{-1}$). z_{0m} es la longitud de fricción aerodinámica para un momento (m). z_{0h} es la longitud de fricción aerodinámica para la transferencia de calor (m). $k \cdot B^{-1}$ es un parámetro para estimar la diferencia entre la temperatura aerodinámica y radiométrica. Es un parámetro constante que, en este estudio, toma el valor 2.3, como describieron Garratt y Hicks (1973). k es la constante de von Karman, que toma el valor 0.4.

Margulis y Huning (2015) propusieron una metodología para corregir la resistencia aerodinámica para la estabilidad atmosférica (ecuación 54). Donde, Ψ_m es el factor de corrección de la estabilidad del momento y Ψ_h es el factor de corrección de la estabilidad del calor latente. En condiciones inestables, es decir, gradientes negativos de temperatura, el factor de corrección de la estabilidad es menor de 1.0, lo que permite reducir la resistencia y mejorar la turbulencia. Mientras que, en condiciones estables, es decir, gradientes positivos de temperatura, el factor de corrección de la estabilidad es mayor de 1.0, lo que permite incrementar la resistencia y reducir la turbulencia.

$$r_a = r_{aN} \cdot \Psi_m \cdot \Psi_h \quad \text{ec 54}$$

Cuando las condiciones atmosféricas son inestables ($R_{iB} \leq 0$), Ψ_m y Ψ_h , sigue la ecuación 55.

$$\Psi_h = \Psi_m^2 = (1 - 15 \cdot R_{iB})^{-1/2} \quad R_{iB} \leq 0 \text{ (inestable)} \quad \text{ec 55}$$

Sin embargo, cuando las condiciones atmosféricas son estables, ($0 \leq R_{iB} < 0.2$) Ψ_m y Ψ_h siguen la ecuación 56.

$$\Psi_h = \Psi_m = (1 - 5 \cdot R_{iB})^{-1} \quad 0 \leq R_{iB} < 0.2 \text{ (estable)} \quad \text{ec 56}$$

$$R_{iB} = \frac{\left(\frac{g}{T_s}\right) \cdot \partial T / \partial z}{\left(\frac{\partial u}{\partial z}\right)^2} \quad \text{ec 57}$$

R_{iB} es el número del bulbo de Richardson (Bulk). g es la aceleración de la gravedad.

B. Módulo del balance de agua

En el modelo simple (SEB), el procedimiento de transferencia de masa es utilizado para el cálculo del flujo de calor latente (LE), que implementa un seguido de ecuaciones similares a las de transferencia de calor. Sin embargo, el modelo SVEN utiliza el módulo de balance de agua, que integra varios submodelos más sofisticados.

El módulo de balance de agua permite simular el agua interceptada por la evapotranspiración (E_i), la transpiración de la planta (E_c), la evaporación del suelo (E_s), la infiltración del suelo y el drenaje. Se basa en la combinación de dos modelos: a) el modelo de ET Priestley-Taylor Jet Propulsion Laboratory (PT-JPL ET). El modelo PT-JPL ET utiliza las ecuaciones que fueron descritas en su trabajo (Priestley y Taylor, 1972). Fisher et al. (2008) utilizó las ecuaciones de Priestley-Taylor para obtener el modelo, que posteriormente fue modificado y ajustado como explicaron Wang et al. (2018a). Según los autores Chen et al. (2014), Ershadi et al. (2014), Miralles et al. (2016) y Vinukollu et al. (2011), el modelo PT-JPL ET es uno de los mejores algoritmos para la evaluación global de la ET con sensores en remoto; b) como segundo modelo implementado en el módulo de balance de agua, se incorpora un modelo simple “bucket”, que representa la columna del suelo superficial para obtener la ET, los componentes de agua del suelo y las pérdidas superficiales.

La combinación de ambos modelos permite estimar la evapotranspiración potencial y, gracias a las limitaciones ecofisiológicas, ajustar y determinar la evapotranspiración actual.

$$\lambda ET = \lambda E_i + \lambda E_c + \lambda E_s \quad \text{ec 58}$$

$$\lambda E_i = f_{wet} \cdot \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot R_{nc} \quad \text{ec 59}$$

$$\lambda E_c = (1 - f_{wet}) \cdot f_g \cdot f_M \cdot f_{T_a} \cdot \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot R_{nc} \quad \text{ec 60}$$

$$\lambda E_s = f_\theta \cdot \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot (R_{ns} - G) \quad \text{ec 61}$$

El λET (λLE) es el flujo de calor latente de la evapotranspiración total ($W \cdot m^{-2}$). λE_i es el flujo de calor latente del agua interceptada por la evapotranspiración ($W \cdot m^{-2}$). λE_c es el flujo de calor latente de la transpiración ($W \cdot m^{-2}$). λE_s es el flujo de calor latente de la evaporación del agua del suelo ($W \cdot m^{-2}$). Los flujos están limitados por las condiciones ambientales, que se reflejan en las ecuaciones superiores a través de diversos factores que varían entre 0 y 1, indicando la reducción relativa de la evapotranspiración potencial.

Los distintos factores de corrección de las condiciones ambientales son: f_{wet} es el indicador de la humedad superficial relativa de la evapotranspiración potencial; f_g es la fracción de la transpiración activa de la planta, también conocida como fracción verde de la planta; f_M expresa la constante de humedad de la planta; f_{T_a} es la constante de la temperatura de la planta e indica la temperatura límite de la fotosíntesis; f_θ es la constante de humedad del suelo, también expresada como (f_{SM}), y se expresa en la ecuación 62; Δ es el pendiente de la curva de presión de vapor a saturación en función de la temperatura; γ es la constante psicométrica; α es el cociente entre la evapotranspiración potencial y la evapotranspiración potencial en equilibrio. Para el modelo PT-JPL ET, Fisher et al. (2008) determinó empíricamente que el valor era de 1.26; G representa el flujo de calor del suelo ($W \cdot m^{-2}$); R_{nc} y R_{ns} representan los flujos de radiación neta de la planta y del suelo ($W \cdot m^{-2}$), respectivamente. La expresión utilizada para su determinación se muestra en la tabla 3.5.

$$f_\theta = f_{SM} = \theta_e \quad \text{ec 62}$$

En el modelo original de Fisher et al. (2008), el factor de corrección f_{wet} se estimaba a partir de la humedad relativa del aire. En este estudio, el factor de corrección f_{wet} siguió la ecuación 63, donde CWS es el nivel actual de almacenamiento de agua en la planta (mm) y CWS_{max} es el valor máximo de almacenamiento de agua en la planta (mm), descrito por Noilhan y Planton (1989), además de que Wang et al. (2020) y Pateromichelaki (2020), también lo utilizaron en sus trabajos. La determinación del CWS_{max} se calcula mediante el estudio de Dickinson et al. (2008), que utilizó la siguiente expresión: $0.2 \cdot LAI$ ($kg \cdot m^{-2}$).

$$f_{wet} = \frac{CWS}{CWS_{max}} = \frac{CWS}{0.2 \cdot LAI} \quad \text{ec 63}$$

Para determinar el CWS se utilizó una ecuación pronóstica (ecuación 64), solo cuando la constante CWS era menor que CWS_{max} .

$$\frac{dCWS}{dt} = f_c \cdot P - E_i \quad \text{ec 64}$$

Donde, f_c es la fracción de cobertura por vegetación, también conocida como f_{IPAR} , como describieron Fisher et al. (2008). P es la precipitación total ($m \cdot s^{-1}$) y E_i es la evaporación del agua interceptada ($m \cdot s^{-1}$).

La precipitación efectiva (P_e) se estima a partir del residuo entre la precipitación (P) y la variación del CWS , como se muestra en la ecuación 65.

$$P_e = P - dCWS \quad \text{ec 65}$$

A continuación, se describe el modelo “bucket” para estimar los balances de agua con la columna de referencia del suelo superficial. El caudal de infiltración (Q_{inf}) es igual a la precipitación efectiva (P_e) cuando el agua del suelo no está en saturación y, por lo tanto, SWS se calcula a partir de una ecuación pronóstica, con la restricción de que SWS debe ser inferior a SWS_{max} .

$$Q_{inf} = P_e \quad \text{ec 66}$$

$$\frac{dSWS}{dt} = Q_{inf} - E_c - E_s - Q_d \quad \text{ec 67}$$

Por otro lado, cuando el agua del suelo está a saturación, el SWS es igual a SWS_{max} y aparece escorrentía superficial (Q_s).

$$Q_{inf} = E_c + E_s + Q_d \quad \text{ec 68}$$

$$Q_s = P_e - Q_{inf} \quad \text{ec 69}$$

Donde, SWS es el nivel actual de almacenamiento de agua en el suelo (m); P_e es la precipitación efectiva ($m \cdot s^{-1}$); E_c es la transpiración ($m \cdot s^{-1}$); E_s es la evapotranspiración del suelo ($m \cdot s^{-1}$); Q_d es el drenaje ($m \cdot s^{-1}$); Q_s es la escorrentía superficial ($m \cdot s^{-1}$).

El drenaje del agua a través del suelo (Q_d) se estima mediante el modelo tradicional de Mualem (Mualem, 1976), aplicando la conductividad hidráulica en suelos no saturados y asumiendo un

gradiente hidráulico vertical uniforme. Sin embargo, Wang et al. (2020) determinaron Q_d como una fuga por debajo del límite inferior del dominio del flujo, tal y como describieron Romano et al. (2011). Para ello, se asume la condición de una unidad de gradiente del potencial hidráulico total en el límite inferior y se utiliza la relación de retención suelo-agua de van Genuchten (1980). La expresión utilizada se muestra en la ecuación 70.

$$Q_d = K_s \cdot \sqrt{\theta_e \cdot (1 - (1 - \theta_e^{(1/(1-1/n))})^{((1-1/n)^2)})} \quad \text{ec 70}$$

$$\theta_e = \frac{\theta - \theta_r}{\theta_s - \theta_r} \quad \text{ec 71}$$

$$\theta = \frac{SWS}{SWS_{max}} \cdot \theta_s \quad \text{ec 72}$$

Donde, K_s es la conductividad hidráulica a saturación ($\text{m}\cdot\text{s}^{-1}$); n es el parámetro de la forma de van Genuchten (1980), que depende de la relación de retención suelo-agua y de la distribución de poro-tamaño; θ es el contenido de humedad de agua en el suelo ($\text{m}^3\cdot\text{m}^{-3}$); θ_r es contenido de humedad de agua en el suelo residual ($\text{m}^3\cdot\text{m}^{-3}$); θ_s es contenido de humedad del agua en el suelo a saturación ($\text{m}^3\cdot\text{m}^{-3}$); θ_e es el contenido de humedad del agua en el suelo efectivo ($\text{m}^3\cdot\text{m}^{-3}$).

C. Módulo del flujo de CO_2

El tercer y último módulo del modelo SVEN se basa en los flujos de CO_2 desprendido de la fotosíntesis para estimar la GPP mediante el modelo de Eficiencia en el Uso de la Luz (LUE), descrito por Wang et al. (2018a). Las limitaciones ambientales y ecofisiológicas de la transpiración de la planta en el modelo PT-JPL ET se aplican para estimar la asimilación de carbono.

El modelo “LUE GPP” es robusto y ampliamente utilizado para estimar la GPP en varios ecosistemas y regímenes climáticos (McCallum et al., 2009). El modelo se basa en la suposición de que las plantas optimizan la LUE del dosel, como describen el modelo Carnegie Ames Stanford Approach (CASA; Potter et al., 1993) o el algoritmo de MODIS (Running et al., 2004). Wang et al. (2019b) explicaron que el modelo LUE GPP se calcula a partir de la ecuación 73, que está parcialmente basada en el modelo CASA (Potter et al., 1993). Las limitaciones del modelo que hay que tener en cuenta son: a) la regulación térmica (Wang et al., 2018a) refleja la variación de la LUE debido a factores ambientales, de igual forma que se explicó para regular la transpiración de la planta (módulo del balance de agua, ecuación 60) y b) en referencia a la fracción de planta que es fotosintéticamente activa (Fisher et al., 2008).

$$GPP = LUE_{max} \cdot PAR_c \cdot f_g \cdot f_M \cdot f_{T_a} \cdot f_{VPD} \quad \text{ec 73}$$

Donde LUE_{max} es el valor máximo de LUE ($\text{g}\cdot\text{C}\cdot\text{MJ}^{-1}$); PAR_c es la radiación fotosintéticamente activa diaria ($\text{MJ}\cdot\text{m}^{-2}\cdot\text{d}^{-1}$) interceptada por la planta. Se calcula a partir de la ley de Beer-Lambert, utilizando la extinción del PAR a través del dosel de la planta; f_g es la fracción verde de la planta (Fisher et al., 2008); f_M es la limitación del contenido de humedad del agua de la planta (Fisher et al., 2008); f_{T_a} es la limitación debida a la temperatura del aire, que refleja la limitación térmica de la fotosíntesis (Potter et al., 1993); f_{VPD} es la limitación debida al déficit de presión de vapor, que representa el ajuste de apertura estomacal debido al déficit de saturación de agua atmosférica.

Todos los factores varían entre un rango de cero y uno, y representan la reducción máxima de la GPP en condiciones ambientales limitantes (ecuaciones 74 a 77).

$$f_g = \frac{f_{APAR}}{f_{IPAR}} \quad \text{ec 74}$$

$$f_M = \frac{f_{APAR}}{\max(f_{APAR})} \quad \text{ec 75}$$

Donde, f_{APAR} es la fracción de PAR absorbido por la cobertura vegetal; f_{IPAR} es la fracción de PAR interceptado por la cobertura vegetal (Fisher et al., 2008).

$$f_{T_a} = 1.1814 \cdot (1 + e^{0.3 \cdot (-T_o - 10 + T_a)^{-1}}) \cdot [1 + e^{0.2 \cdot (-T_o - 10 + T_a)^{-1}}]^{-1} \quad \text{ec 76}$$

Donde, T_a es la temperatura del aire (°C); T_o es la temperatura óptima para el crecimiento de la planta (°C), cuyo valor es de 25°C.

$$f_{VPD} = \frac{1}{1 - VPD/D_o} \quad \text{ec 77}$$

Donde, D_o es el coeficiente empírico para el VPD, cuyo es igual a 15 hPa (Leuning, 1995).

La forma en que el PAR intercepta en la cobertura vegetal varía en función de las características estructurales de la planta, como la densidad de plantación, el espacio entre hileras, como la densidad de hojas por planta. La distribución del PAR entre la planta y el suelo depende del índice de área foliar (LAI), al igual que el coeficiente de extinción lumínica k_{PAR} (Liang et al., 2012). En el modelo se ha implementado una ecuación empírica que calcula el LAI en función del índice NDVI, obtenido a partir de la información de reflectancia satelital. El NDVI se utiliza para estimar la fracción de PAR interceptada por toda la planta, mientras que el índice de vegetación ajustado al suelo (SAVI) se utiliza para calcular la fracción del PAR absorbida por la fracción de vegetación verde (Huete, 1987).

TABLA 3.5. Parámetros y ecuaciones utilizadas durante el modelo (Wang et al., 2018a). Los coeficientes de extinción para el PAR (k_{PAR}) y para la radiación neta (k_{Rn}) equivalen a 0.5 y 0.6, respectivamente (Ross, 1976; Impens y Lemur, 1969; Fisher et al., 2008).

Parámetro	Descripción	Ecuación	Referencia
R_{nc}	Radiación neta de la plana	$R_{nc} = R_n - R_{ns}$	Fisher et al., 2008
R_{ns}	Radiación neta del suelo	$R_{ns} = R_n \cdot e^{-k_{Rn} \cdot LAI}$	Fisher et al., 2008
f_{APAR}	Fracción de PAR interceptada por la fracción verde de la planta	$f_{APAR} = 1.4 \text{ SAVI} - 0.05$	Fisher et al., 2008
f_{IPAR}	Fracción de PAR interceptada por toda la cobertura vegetal	$f_{IPAR} = 1.0 \text{ NDVI} - 0.05$	Fisher et al., 2008
LAI	Índice de área foliar	$LAI = -\ln(1 - f_{IPAR})/k_{PAR}$	Ruimy et al., 1999
PARc	PAR interceptado por la planta	$PARc = PAR - PARs$	Ruimy et al., 1999
PARs	PAR interceptado por el suelo	$PARs = PAR \cdot e^{-k_{PAR} \cdot LAI}$	Ruimy et al., 1999
SAVI	Índice de vegetación ajustado al suelo	$SAVI = 0.45 \text{ NDVI} + 0.132$	Huete, 1988

3.7.2. Parámetros del modelo

El modelo SVEN requiere una serie de parámetros, como se puede observar en la figura 3.13. Las variables meteorológicas se explicaron al inicio del apartado 3.7. Las condiciones de inicialización son las siguientes: a) el contenido de agua en el suelo (SWS_{in}); b) el contenido de agua en la planta (CWS_{in}); c) la temperatura del suelo superficial (T_{s0}) y del suelo en profundidad (T_{d0}). Los valores de cada variable se ajustaron siguiendo el trabajo de Wang et al. (2020) y en las condiciones específicas del ensayo, cuyos valores se muestran en la tabla 3.6. En el caso del SWS_{in} , se estimó que era del 25% de su valor máximo, mientras que el CWS_{in} se estimó que era del 0.01% respecto al inicial. Para la T_{s0} y T_{d0} se determinó que era igual a la temperatura del aire (T_{air}) en el momento inicial ($^{\circ}C$).

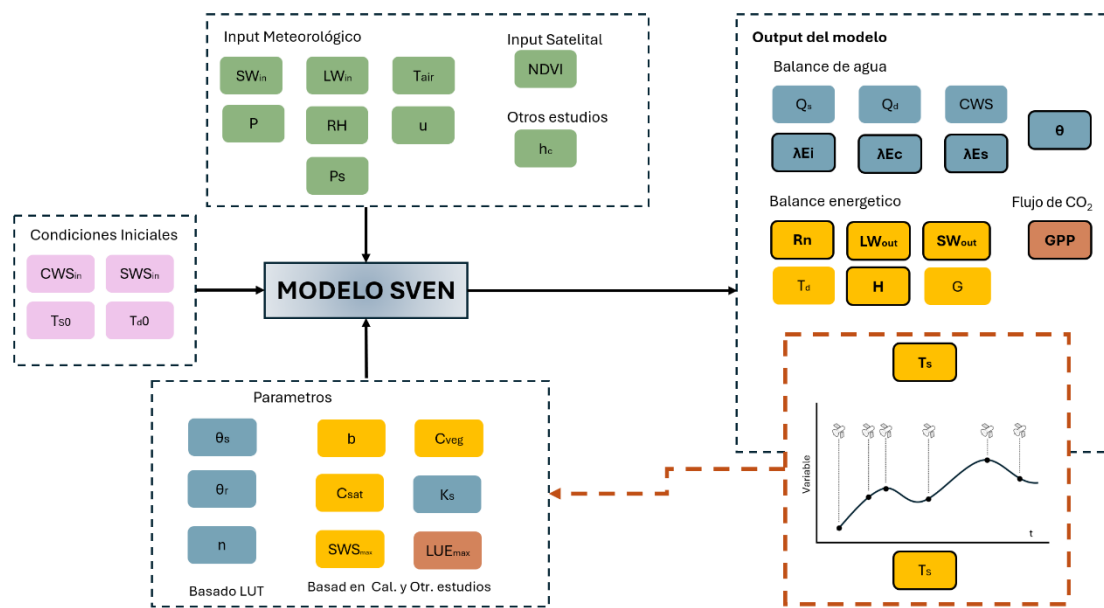


FIGURA 3.13: Esquema del modelo SVEN utilizado en el estudio. Los datos de color verde son las variables input. Los datos de color violeta son las condiciones de inicialización del modelo. Los parámetros se han clasificado por colores, en función a que modulo actúan y por la metodología utilizada en su determinación. Los valores de la derecha son los outputs, agrupades en función del balance que formen parte.

TABLA 3.6: Valores de las variables para inicializar el modelo. FUENTE: Wang et al. (2020).

Condiciones iniciales	Descripción	Unidades	Valor inicial
CWS_{in}	Contenido de agua en la planta	m	0.01
SWS_{in}	Contenido de agua en el suelo	m	0.25
T_{s0}	Temperatura del suelo superficial	$^{\circ}C$	T_{air}
T_{d0}	Temperatura del suelo en profundidad	$^{\circ}C$	T_{air}

Además de las condiciones inicializadoras, también se determinaron diferentes parámetros que calibrarse para las condiciones de la parcela en cuestión. En la tabla 3.7 se muestra un resumen de dichos parámetros, junto con sus respectivos valores, unidades y referencias para su determinación.

Los parámetros pueden ser determinados mediante tres metodologías, a) a partir de la literatura y la revisión bibliográfica; b) utilizando tablas (look-up-tables, LUT) con las mismas condiciones de

suelo y bioma; c) mediante calibración a partir de medidas in situ o sensores en remoto. Los parámetros están relacionados con las características del suelo y con la dinámica de la vegetación, y también influir en la atenuación de la radiación a través de la planta.

TABLA 3.7: Información de modelo SVEN sobre los distintos parámetros utilizados con los valores. * el valor del parámetro varía según la optimización realizada. [-] no existe rango de valores porque es un valor único. (-) el valor es adimensional.

Parámetro	Descripción	Valor	Rango	Unidades	Referencia
n	Parámetro de la relación de retención suelo-agua de van Genuchten (1980)	1.89	[1.01, 2.50]	(-)	Carsel y Parrish (1988)
θ_s	Contenido de humedad de agua en el suelo a saturación	0.410	[0.360, 0.460]	$\text{m}^3 \cdot \text{m}^{-3}$	Carsel y Parrish (1988)
θ_r	Contenido de humedad de agua en el suelo residual	0.065	[0.034, 0.100]	$\text{m}^3 \cdot \text{m}^{-3}$	Carsel y Parrish (1988)
K_s	Conductividad hidráulica a saturación	*	[1.00, 2.00]	$\text{mm} \cdot \text{h}^{-1}$	Optimizado - Carsel y Parrish (1988)
SWS_{max}	Contenido de humedad de agua en el suelo máximo	*	[1.00, 2.50]	10^{-3} m	Optimizado
C_{sat}	Coefficiente térmico “force-restore” para el suelo saturado	*	[4.00, 10.00]	$10^{-6} \cdot \text{K} \cdot \text{m}^{-2} \cdot \text{J}^{-1}$	Optimizado - Noilhan y Planton (1989)
b	Pendiente de la curva de retención del coeficiente térmico “force-restore”	*	[4.61, 6.91]	(-)	Optimizado - Noilhan y Planton (1989)
C_{veg}	Coefficiente térmico “force-restore” para cubierta vegetal	*	[1.00, 4.00]	$10^{-6} \cdot \text{K} \cdot \text{m}^{-2} \cdot \text{J}^{-1}$	Optimizado - Calvet et al. (1998)
α	Coefficiente de Priestley-Taylor	1.26	[-]	(-)	Fisher et al. (2008)
k_{PAR}	Coefficiente de extinción del PAR	0.5	[-]	(-)	Ross (1976); Impens y Lemur (1969); Brownsey et al. (1976)
k_{Rn}	Coefficiente de extinción de la radiación neta	0.6	[-]	(-)	Impens y Lemeur (1969); Fisher et al. (2008)
T_o	Temperatura óptima para el crecimiento de la planta	25	[-]	$^{\circ}\text{C}$	Kustas et al. (2016)
LUE_{max}	Eficiencia en el uso de la luz máxima	1.69	[0.00, 5.00]	$\text{g} \cdot \text{C} \cdot \text{m}^{-2} \cdot \text{MJ}^{-1}$	Optimizado - Zhou et al. (2015)

El primer conjunto de parámetros de la tabla 3.7 hace referencia a la textura del suelo y se utilizan para determinar la dinámica de almacenamiento de agua y drenaje del modelo “bucket”. El segundo conjunto de parámetros de la tabla se utilizó para implementar el modelo “force-restore”, que definen las propiedades del suelo y de la planta.

Las variables θ_r , θ_s y n se obtuvieron a partir de las tablas del trabajo de Carsel y Parrish (1988), teniendo en cuenta que el suelo pertenece a la clasificación “franco-arenoso” según la clasificación USDA.

Se realizó una calibración previa de rangos a partir de la literatura y de tablas basadas en el tipo de vegetación y de textura del suelo. Los rangos de los parámetros C_{sat} y b se estimaron en función de la clasificación USDA del suelo, siguiendo el trabajo de Noilhan y Planton (1989). K_s se estimó a partir de Carsel y Parrish (1988), teniendo en cuenta la clase textural. El rango de valores para el parámetro SWS_{max} se estimó en función de la zona radicular del cultivo en cuestión, ya que, según otros estudios (Morillas et al., 2013a; Rey et al., 2011), la máxima profundidad en la que se encuentra densidad de raíces en el espantal es de 25 cm. Los rangos para el parámetro C_{veg} eran muy amplios en función de la bibliografía consultada, desde valores de 10^{-6} hasta valores de 10^{-3} $K \cdot m^2 \cdot J^{-1}$ (Calvet et al., 1998; Noilhan y Planton, 1989; Noilhan y Mahfouf, 1996). Al presentar rangos tan amplios, se mantuvo inicialmente el rango propuesto por Wang et al. (2018a) de 1 a $10 \cdot 10^{-6}$ $K \cdot m^2 \cdot J^{-1}$, y se ajustó a las condiciones de la parcela. Pateromichelaki (2020) mencionó que se trataba de un parámetro con rangos abstractos y de indicaban poca significación. Posteriormente, se aplicó el método de optimización Monte Carlo con los rangos de valores para cada parámetro. Se realizaron 5,000 repeticiones siguiendo una distribución uniforme continua. Los rangos de cada parámetro se muestran en la tabla 3.7.

El último conjunto de parámetros está relacionado con el tipo específico de planta del estudio, afectando al proceso de evapotranspiración de la planta y a la atenuación de la radiación solar en ellas. El coeficiente de Priestley-Taylor (α) es 1.26 y se obtuvo a partir del modelo PT-JPL original (Priestley y Taylor, 1972). La temperatura óptima de crecimiento (T_o) se determinó a partir del trabajo de Kustas et al. (2016), donde se indica que es de 25°C. Los coeficientes de extinción para el PAR (k_{PAR}) y para la radiación neta (k_{Rn}) equivalen a 0.5 y 0.6, respectivamente (Ross, 1976; Impens y Lemur, 1969; Fisher et al., 2008).

Por último, se debe determinar la LUE_{max} , un parámetro esencial para definir el nivel de carbono asimilado por la planta y, en consecuencia, la GPP. Sin embargo, los rangos posibles son muy variados, ya que existen diferentes formas de realizar la estimación en función de la planta. Zhou et al. (2015) estudiaron una gran variedad de biomas a escala mundial y sugiriendo un valor de 1.19 $gC \cdot MJ^{-1}$ para la LUE_{max} . Además, siguiendo el trabajo de Wang et al. (2020), se aplicó una optimización en el módulo de flujo de CO_2 , lo que permitió obtener el valor de LUE_{max} y hacer que la simulación se ajustara lo máximo posible a los valores observados. Finalmente, la LUE_{max} se determinó mediante un consenso múltiple siguiendo la metodología explicada anteriormente (apartado 3.2.4), más el valor propuesto por Zhou et al. (2015), y aplicando la optimización únicamente al módulo de flujo de CO_2 . El valor de consenso fue de 1.699 $gC \cdot MJ^{-1}$.

3.7.3. Calibración de los parámetros del modelo

Para la calibración de los parámetros C_{sat} , b , K_s , SWS_{max} y C_{veg} se realizó mediante la optimización Monte Carlo, como se ha explicado anteriormente, mientras que en la evaluación se compararon observaciones medidas de distintas fuentes. Siguiendo el procedimiento que realizó Wang et al. (2020) para la calibración de los parámetros, estos fueron calibrados a partir de observaciones con sensores en remoto. En este estudio se realizó mediante la temperatura

superficial (LST) obtenida a partir de tres fuentes distintas: a) datos medidos in-situ con la estación eddy covariance (EC LST); datos obtenidos a partir de sensores en remoto satelitales (MODIS LST); datos obtenidos a partir de la fuente de MODIS, pero siendo preajustados (MODIS LST adjusted).

En la figura 3.14, en el primer módulo (1), se puede observar las tres distintas fuentes de LST utilizadas para la calibración de los parámetros. Finalmente, los outputs de los tres escenarios fueron evaluados con los estadísticos RMSE y NRMSE y así para poder seleccionar que fuente de información de LST observada era mejor para la calibración.

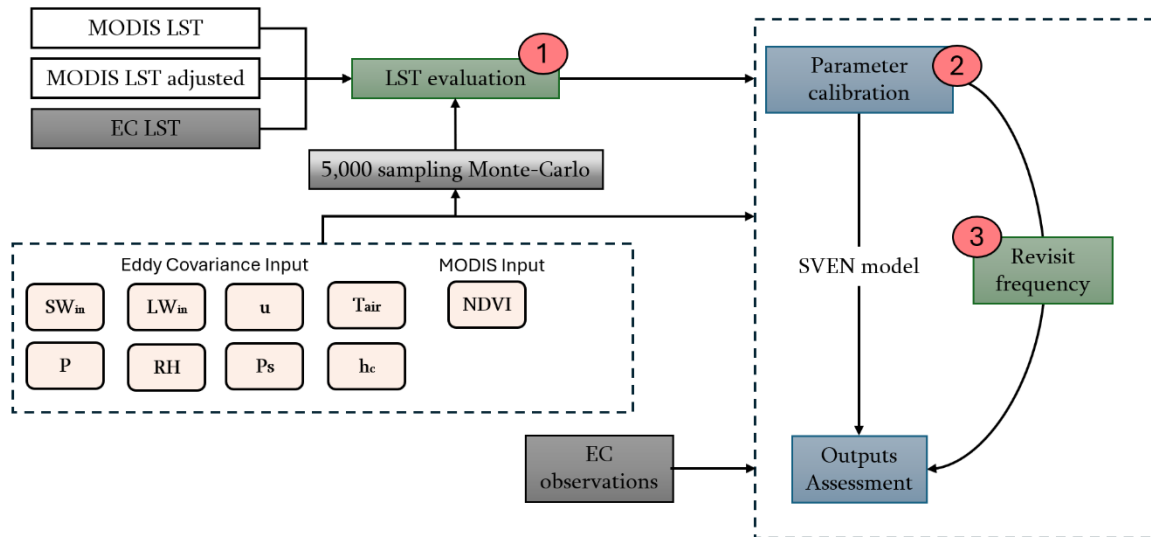


FIGURA 3.14: Esquema del proceso de calibración de parámetros para el modelo SVEN. 1-2: selección y análisis de la mejor fuente para la calibración de los parámetros a través de la variable LST; 3: análisis del tiempo óptimo de la frecuencia de pase para la calibración del modelo. SW_{in} : Radiación incidente de onda corta, LW_{in} : Radiación incidente de onda larga, u : velocidad del viento, T_{air} : Temperatura del aire, NDVI: Índice de vegetación diferenciada normalizada, P : precipitación, RH : Humedad relativa, Ps : Presión, hc : altura del canopy.

La calibración de los parámetros se realizó a escala diaria, por el hecho de que el producto que marcaba la pauta era de fuente satelital (MODIS). Como se ha mencionado en el apartado 3.3.2., MODIS LST es un producto diario instantáneo, por lo que, utilizando la información del metadato se conocía la hora y minuto en que se había realizado la medida. Posteriormente, se seleccionó la observación a la misma hora y minuto de la fuente EC y de la simulación para poder realizar la calibración de las distintas fuentes manteniendo la escala temporal y el instante de medida.

3.7.4. Estimación de la frecuencia óptima de pase para la calibración del modelo

Un siguiente desafío en los sensores en remoto es el límite de resolución temporal de las observaciones, donde la mayoría de los productos disponibles presentan una frecuencia de 8, 18 o incluso 30 días (e.g. MODIS, ECOSTRESS, Landsat, Sentinel). En el apartado anterior, durante la calibración de los parámetros se utilizó el producto de la LST donde la periodicidad era diaria. El próximo reto que se plantea a continuación es variar la frecuencia de pase de la observación satelital para evaluar la calibración de los parámetros (C_{sat} , b , K_s , SWS_{max} y C_{veg}). Para la evaluación, se decidió realizarlo a partir del número mínimo necesario de puntos de calibración, es decir, determinar el número mínimo de puntos de calibración necesarios cuya precisión del modelo no se vea altamente afectada. De tal forma que, se relaciona el número de puntos con la

frecuencia de revisión de pase de observación. Posteriormente, los diferentes escenarios fueron validados por el modelo, evaluando la precisión con los estadísticos RMSE y NRMSE. La etapa está ilustrada en la figura 3.14, por el módulo 3.

El objetivo consiste en estimar la frecuencia de pase óptima entre observaciones satelitales de LST para la calibración de los parámetros del modelo, manteniendo la precisión y exactitud del modelo.

3.7.5. Evaluación del modelo y validación de los outputs del modelo

Para la evaluación del modelo, la base de datos fue dividida en el 70% para el entrenamiento y calibración del modelo, mientras que el 30% restante fue utilizado para la validación (desde el 29 de abril hasta el 12 de junio), donde se emplearon los mismos estadísticos que para la evaluación del modelo SEB. Para realizar la evaluación, se tuvo en cuenta el problema del cierre de balance energético (Wilson et al., 2002; Cluf et al., 2004). El error es dado porque los flujos turbulentos, la suma del calor sensible (H) y el calor latente (LE), no siempre es igual a la energía disponible, la diferencia entre la radiación neta (Rn) y el flujo de calor del suelo (G). En el apartado 3.2.2, se han explicado las distintas correcciones posibles de los datos para ajustar el cierre de balance y corregir los errores de la estación EC.

La idea del modelo era interpolar de forma continua los datos de LST, LE, H, Rn, GPP y θ , por el hecho de que algunos son proporcionados por satélites (MODIS, ECOSTRESS). Para la validación, se utilizaron los datos de la estación EC y fueron evaluados a escala medio-horaria y diaria. Los estadísticos utilizados son los mismos que los utilizados para el modelo SEB (ec 35 hasta 39).

4. RESULTADOS

4.1. Relación entre flujos turbulentos y energía disponible

La estación EC comete un error de lectura, cuya incertidumbre medida fue del 22% en el caso de Balsa Blanca. Para obtener más información se obtuvo que la relación entre los flujos turbulentos (LE+H), y la energía disponible (Rn-G), cuyo coeficiente de Pearson (r^2) fue de 0.95. La recta de regresión lineal entre las dos variables sigue la siguiente expresión:

$$LE + H = 0.8788 \cdot (Rn - G) + 12.184$$

Según el estudio realizado por Wilson et al. (2002), el error asociado es del 20-22%.

4.2. Evaluación de datos *ECOSTRESS* de evapotranspiración

Para realizar la validación del producto de evapotranspiración instantánea (LE inst) de *ECOSTRESS* se utilizó los datos observados de la estación EC, cuyo también media la LE de forma instantánea. En la figura 4.1., se muestran los datos que se recogieron, según se ha explicado en la metodología (apartado 3.5).

Como se puede observar, el primer dato disponible para la ET de *ECOSTRESS* fue en el mes de agosto del 2018, cuando fue lanzado. El primer año (2018), se recopilaron un total de cuatro datos, donde la diferencia entre ellos era considerable. El dato más bajo se dio el 5 de agosto de 2024, con una ET de 61 W/m², correspondiendo a 2.15mm/día, mientras que el dato observado por la estación EC fue de 30 W/m², correspondiendo a 1.06mm/día. El 31 de agosto, se dio el valor más alto, con una ET de 264 W/m², correspondiendo a 9.30mm/día, mientras que el dato observado por la estación EC fue de 12.63 W/m², correspondiendo a 0.44mm/día.

Para el 2019, se recopilaron un total de once datos. La ET menor se dio el 13 de agosto, con valor de 53.07 W/m², correspondiendo a 1.87mm/día, mientras que el dato observado por la estación EC en la misma fecha fue de 13.16 W/m², correspondiendo a 0.46mm/día. La ET mayor se dio el 17 de junio, con valor de 253.36 W/m², correspondiendo a 8.93mm/día, mientras que el dato observado por la estación EC fue de 20.54 W/m², correspondiendo a 0.72mm/día.

Para el 2020, se recopilaron un total de seis datos. La ET menor se dio el 19 de julio, con valor de 62.26 W/m², correspondiendo a 2.19mm/día, mientras que el dato observado por la estación EC fue de 118.31 W/m², correspondiendo a 4.16mm/día. La ET mayor se dio el 27 de abril, con valor de 495.22 W/m², correspondiendo a 17.44mm/día, mientras que el dato observado por la estación EC no recopiló ningún dato.

Durante el año de 2021, el producto de *ECOSTRESS* presentaba huecos, de tal forma que no se pudo obtener información del valor instantáneo, además de presentar valores que no corresponden ni en rango ni en correlación.

Por último, en el 2022 se recopilaron un total de tres datos. La ET menor se dio el 5 de junio, con valor de 82.97 W/m², correspondiendo a 2.92mm/día, mientras que la estación EC no recopiló

ningún dato. La ET mayor se dio el 7 de junio, con valor de 334.64 W/m^2 , correspondiendo a 17.78mm/día , mientras que la estación EC no recopiló ningún dato.




FIGURA 4.1: Serie temporal de los datos recogidos de LE. Cruces rojas representan los valores de LE de la torre EC; redondas negras representan los valores de LE de ECOSTRESS, con sus respectivas incertidumbres. El último dato disponible de la estación EC (observado) es en abril del 2020.

Las fechas en que el valor de LE medido por ECOSTRESS fue más próximo al valor observado por la estación EC, fueron: a) 22 de mayo del 2019 a las 19:00 horas (GTM +2), con valor de 55.46 W/m^2 , correspondiendo a 1.95mm/día , mientras que el dato observado por la estación EC fue de 58.63 W/m^2 , correspondiendo a 2.06mm/día ; b) 10 de diciembre del 2019 a las 11:00 horas (GTM +2), con valor de 183.50 W/m^2 , correspondiendo a 6.46mm/día , mientras que el dato observado por la estación EC fue de 187.90 W/m^2 , correspondiendo a 6.62mm/día .

Remarcar que desde 2020 hasta finales del 2023, ECOSTRESS ha recopilado un total de nueve datos, de los cuales, solo se dispone información observada por la estación EC de uno, en el 27 de abril de 2020.

4.3. Modelo de predicción simple surface energy balance

Para realizar la evaluación del modelo que llamamos SEB, desarrollado por Margulis y Huning (2015), se utilizaron los estadísticos mencionados en la metodología, cuyos intervalos temporales de las variables son medio-horarios y diarios. Para la evaluación se utilizaron únicamente el 30% de los datos restantes, es decir, des del 29 de abril hasta el 12 de junio.

4.3.1. Evaluación de los outputs del modelo SEB

La variable de la temperatura superficial (LST) fue medida en campo en tres escenarios y en cada uno se obtuvieron resultados diferentes. La variable LST canopy, fue la que presento una temperatura observada media más baja, mientras que la LST soil fue la más alta. Las tres variables presentaron estadísticos muy buenos, con r^2 superiores al 0.85. En los tres casos, las variables LST del modelo fueron subestimadas, por el hecho de que el estadístico bias fue positivo. La variable que presentó los mejores estadísticos fue la LST canopy, donde el RMSE fue de 1.99 °C en escala

medio-horaria y de 1.58°C en escala diaria. El error normalizado (NRMSE) fue del 7.41% en escala medio-horaria y del 15.32% en escala diaria. Mientras que la variable con la peor precisión fue la LST soil, presentando un aumento del RMSE del 46.79% y 38.99% a escala medio-horaria y diaria, respectivamente. Por lo consecuente, únicamente se representó la serie temporal y la correlación de la variable LST canopy (figura 4.2a, 4.2e, 4.3a y 4.4a). Como se puede apreciar en las figuras mencionadas, hasta el 24 de mayo, el modelo subestima mayormente, mientras que después, la precisión mejora. Además, observando la correlación a escala medio-horaria (figura 4.3a), en la temperatura de 23°C se presencia un cambio de tendencia, donde a temperaturas superiores, el pendiente es menor comparado con las temperaturas inferiores. Otro punto a remarcar es que, a escala diaria, los errores normalizados (NRMSE) presentan el doble de error.

TABLA 4.1: Resumen de los estadísticos del modelo SEB con los intervalos de tiempo medio-horarios y diarios. *, el resultado es superior al 100%. A escala medio-horaria se utilizaron un total de 2,159 muestras, mientras que a escala diaria fueron 45.

SEB	Estadísticos	LST mix (°C)	LST soil (°C)	LST canopy (°C)	LE (W/m ²)	Rn (W/m ²)	H (W/m ²)
Medio-horario	Media obs	21.01	21.91	20.78	32.56	144.29	98.28
	Media sim	19.53	19.53	19.53	83.49	156.23	69.38
	RMSE	2.26	3.74	1.99	135.52	54.39	117.91
	MAE	1.77	2.88	1.55	66.09	39.86	76.22
	bias	1.48	2.38	1.26	-50.10	-11.94	28.90
	R ²	0.92	0.88	0.92	0.63	0.97	0.51
	NRMSE (%)	8.85	12.72	8.10	54.36	5.85	18.09
Diario	Media obs	21.01	21.91	20.78	32.56	144.29	98.28
	Media sim	19.53	19.53	19.53	83.49	156.23	69.38
	RMSE	1.76	2.59	1.58	86.85	20.26	75.35
	MAE	1.48	2.37	1.28	60.65	17.50	62.14
	bias	1.48	2.37	1.25	-50.07	-11.94	28.86
	R ²	0.91	0.89	0.91	0.80	0.97	0.45
	NRMSE (%)	17.02	24.58	15.32	*	11.00	51.38

Por otro lado, enfocándonos en los parámetros energéticos, la Rn obtuvo la r^2 más alta de todas las variables, con valor de 0.97 a escala medio-horaria y diaria. Presentó un error normalizado (NRMSE) de 5.85% a escala media-horaria, mientras que, a escala diaria, ascendió hasta 11.00%, siendo de los más bajos respecto todas las variables. En las dos escalas temporales, se puede apreciar como el modelo sobreestimaba ligeramente, por el hecho de que el bias fue negativo. Viendo la serie temporal, se puede observar como los máximos, los tiende a sobreestimar.

La H obtuvo un r^2 de 0.51 a escala medio-horaria y de 0.45 a escala diaria. El 24 de mayo, el modelo presenta un cambio de tendencia muy marcado, pasando de subestimar a sobreestimar. Durante el periodo del 29 de abril hasta el 13 de mayo, solo presenta valores negativos y a partir de entonces, la simulación se aproxima más a las observaciones, pero sobrepasándose. En RMSE obtenido es superior al valor promedio simulado en las dos escalas temporales, por lo que da una información muy relevante de la precisión obtenida. El 7 de mayo se observó un mínimo a escala medio-horaria, con valor de $-443\text{W}\cdot\text{m}^{-2}$.

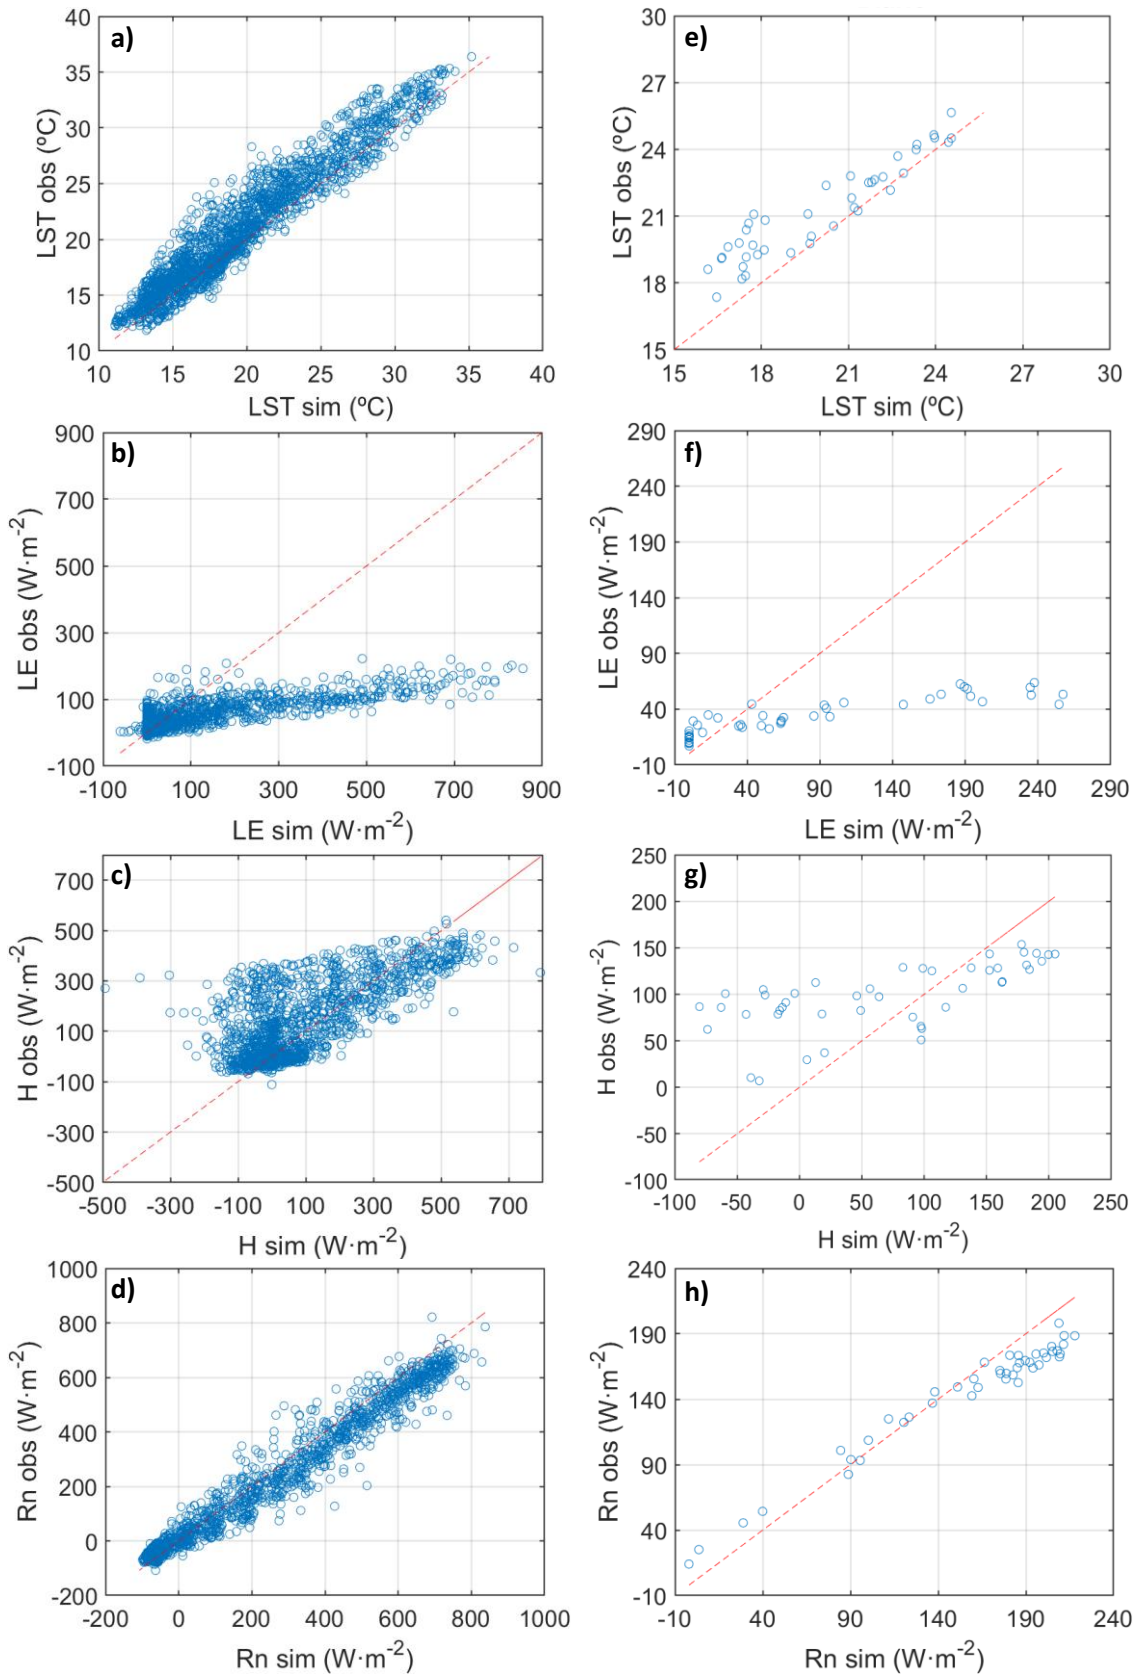


FIGURA 4.3: Correlaciones individuales observado-simulado de cada variable. Columna izquierda representa escala medio-horaria y la derecha escala diaria. a) LST canopy a escala medio-horaria; b) LE a escala medio-horaria; c) H a escala medio-horaria; d) Rn a escala medio-horaria; e) LST canopy a escala diaria; f) LE a escala diaria; g) H a escala diaria; h) Rn a escala diaria.




FIGURA 4.4: Representación de la serie temporal observado-simulado de los outputs del modelo a escala medio-horaria. a) LST canopy a escala medio-horaria; b) H a escala medio-horaria; c) LE a escala medio-horaria; d) Rn a escala medio-horaria. En color rojo está representado los datos simulados y en negro los observados.

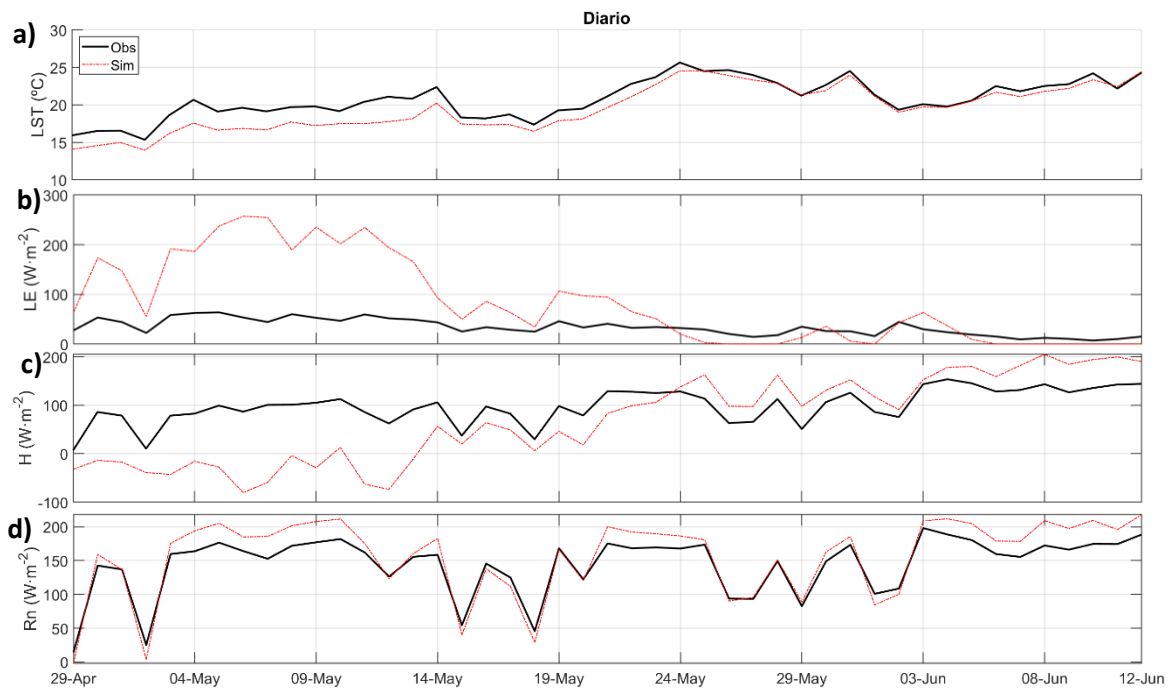


FIGURA 4.5: Representación de la serie temporal observado-simulado de los distintos outputs a escala diaria. a) LST canopy a escala diaria; b) H a escala diaria; c) LE a escala diaria; d) Rn a escala diaria. En color rojo está representado los datos simulados y en negro los observados.

La última variable por comentar es la LE, cuya obtuvo un r^2 de 0.63 a escala medio-horaria y de 0.80 a escala diaria. Presentó un error normalizado (NRMSE) del 54.36% a escala media-horaria, mientras que, a escala diaria, ascendió hasta valores anormales, superiores al 100%. Como se puede

apreciar en la correlación (figura 4.3b y 4.3f), presenta bastantes instantes donde el modelo simula valores de cero, mientras que sí se midió flujo de calor latente. En las dos escalas temporales se puede apreciar como el modelo sobreestimaba, especialmente hasta el 14 de mayo, donde se obtienen valores muy por encima del valor observado con la estación EC. A partir del 24 de mayo la tendencia es alterada, haciendo que el modelo subestime y obteniendo valores próximos al cero. El modelo comete un error de 135.80 W/m^2 en predecir la LE, que equivale a 4.75 mm/día , mientras que escala diaria, el error fue de 86.85 W/m^2 , que equivale a 3.06 mm/día . Todo y tener valores de correlación altos, se observa un gran desfase entre la tendencia de simulación-observación y la relación 1:1.

4.4. Modelo de predicción SVEN

4.4.1. Calibración de los parámetros del modelo

Previamente a evaluar la precisión y exactitud del modelo, se muestran los resultados obtenidos en el proceso de la calibración de los parámetros. Como se ha mencionado en la metodología, la calibración de los parámetros se realizó mediante tres fuentes distintas. Como es de esperar, la fuente que presentó mejor exactitud con los datos de entrenamiento fue la estación EC (figura 4.6a), con un RMSE de 1.57°C . El principal inconveniente de la instalación de esta estación es el elevado coste económico y de mantenimiento que requiere, por lo que se optó por evaluar el producto satelital. La fuente de MODIS presentó un RMSE mínimo de 3.36°C comparando los datos de entrenamiento. Posteriormente, se representó el diagrama de dispersión entre la fuente EC y MODIS (figura 4.7a), donde se pudo presenciar cierta correlación. La relación era de carácter lineal, con un pendiente de 0.73 y el término independiente de 3.23. Aplicando la ecuación de regresión lineal (mostrada a continuación) al producto de MODIS, la exactitud alcanzó un valor mínimo de RMSE de 2.35°C .

$$MODIS_{adj} = 0.73 * MODIS - 3.23$$

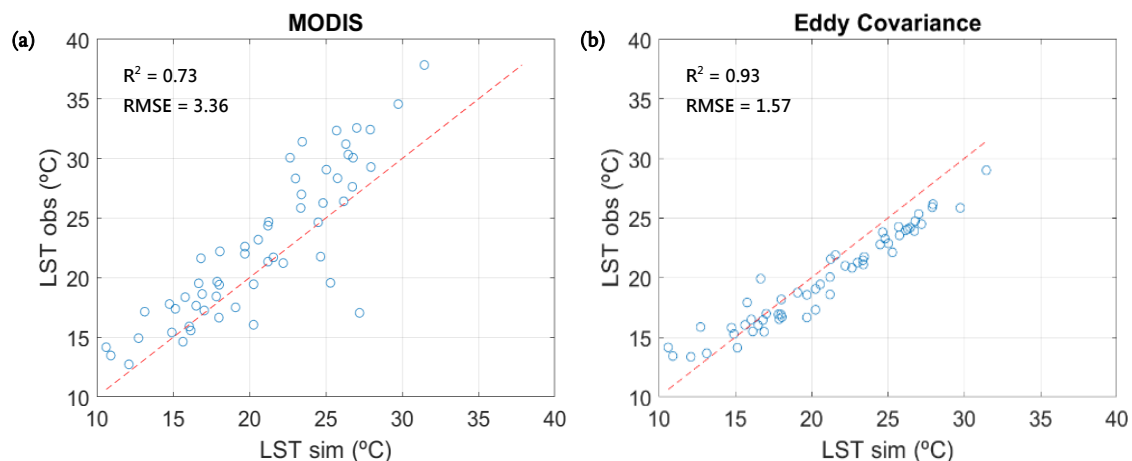


FIGURA 4.6. Diagrama de dispersión de los valores observados comparado con los resultados del modelo SVEN: a) data observada a partir del producto de MODIS; b) data observada a partir de la estación EC.

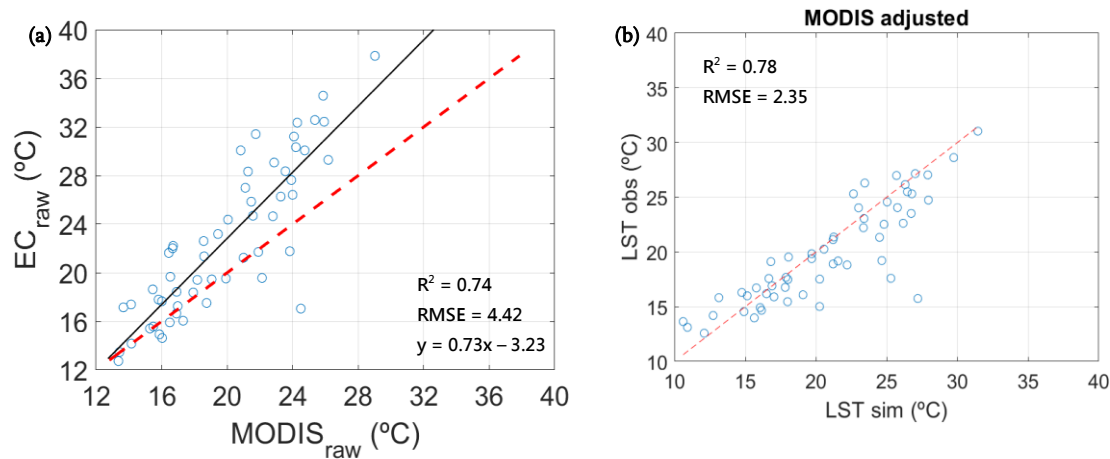


FIGURA 4.7. Diagrama de dispersión de los valores observados comparado con los resultados del modelo SVEN: a) data observada a partir del producto de MODIS; b) data obtenida a partir del producto EC.

TABLA 4.2. Tabla resumen de los diferentes parámetros calibrados a través de las diferentes fuentes de observación (EC LST, MODIS LST, MODIS LST ajustada), además del análisis estadístico del modelo. * La información no está disponible por el hecho de que el modelo no pudo compilar. (-) Las unidades del parámetro son adimensionales.

		MODIS	EC	MODIS ajustada		
Parámetros	C_{sat} ($\cdot 10^{-6} \text{ K} \cdot \text{m}^{-2} \cdot \text{J}^{-1}$)	7.104	9.711	9.595		
	b (-)	6.696	5.817	5.632		
	SWS_{max} ($\cdot 10^{-1} \text{ m}$)	2.227	1.082	2.292		
	C_{veg} ($\cdot 10^{-6} \text{ K} \cdot \text{m}^{-2} \cdot \text{J}^{-1}$)	3.987	2.306	2.190		
	K_s ($\text{mm} \cdot \text{h}^{-1}$)	1.189	1.949	1.016		
Evaluación			RMSE	NRMSE (%)	RMSE	NRMSE (%)
	LST (°C)	*	2.15	8.43	1.99	7.84
	LE ($\text{W} \cdot \text{m}^{-2}$)	*	26.15	10.49	28.21	11.32
	Rn ($\text{W} \cdot \text{m}^{-2}$)	*	53.12	5.72	52.71	5.67
	H ($\text{W} \cdot \text{m}^{-2}$)	*	49.05	7.52	50.90	7.81
θ ($\text{m}^3 \cdot \text{m}^{-3}$)	*	1.99	11.03	1.19	6.59	

En la tabla 4.2 se muestra el resumen de los valores obtenidos en la calibración de los parámetros para cada fuente de observación, además de mostrar la evaluación estadística de cada uno. La evaluación estadística se realizó compilando el modelo con los parámetros correspondientes y posteriormente, siendo evaluado los outputs simulados con las mediciones de la estación EC. Solo se evaluó el 30% restante de la base de datos, ya que el primer 70% se utilizó para hacer el entrenamiento de los parámetros.

En la tabla 4.2 se puede apreciar como los parámetros calibrados a partir de la fuente directa de MODIS no compilaron, por lo que ese escenario queda invalido para la comparación. Como podría ser de esperar, según los previos resultados obtenidos con los datos de entreno, la fuente de EC tendría que presentar la mejor exactitud, pero no fue cierto del todo. La mayoría de las variables energéticas no mostraron diferencia entre las dos fuentes, sin embargo, la LE sí que mostró ser un 7.30% más precisas utilizando la fuente de EC. Mientras que las variables de LST y θ sí que mostraron ser más precisas con la calibración a partir de los datos MODIS-ajustados, siendo 8.04% y 67.22% más precisas, respectivamente. La evaluación de la variable GPP no se llevó a cabo, por el hecho de que los parámetros que se calibran no influyen en su estimación. Finalmente, se llegó

al consenso de que los parámetros obtenidos a través de la calibración con las observaciones de MODSI ajustadas eran las más precisas.

4.4.2. Validación de los outputs del modelo SVEN

A continuación, se realiza la evaluación estadística al detalle de los resultados simulados a partir de los parámetros obtenidos (C_{sat} , b , SWS_{max} , C_{veg} , K_s) con las observaciones de MODSI ajustado, cuyos valores son $9.595 \cdot 10^{-6} \text{ K}\cdot\text{m}^{-2}\cdot\text{J}^{-1}$, 5.632 , $2.292 \cdot 10^{-1} \text{ m}$, $2.190 \cdot 10^{-6} \text{ K}\cdot\text{m}^{-2}\cdot\text{J}^{-1}$, $1.016 \text{ mm}\cdot\text{h}^{-1}$, respectivamente. De igual forma que se ha mencionado, la evaluación de los resultados solo se realiza con el 30% restante de la base de datos, es decir, desde el 28 de abril hasta el 12 de junio.

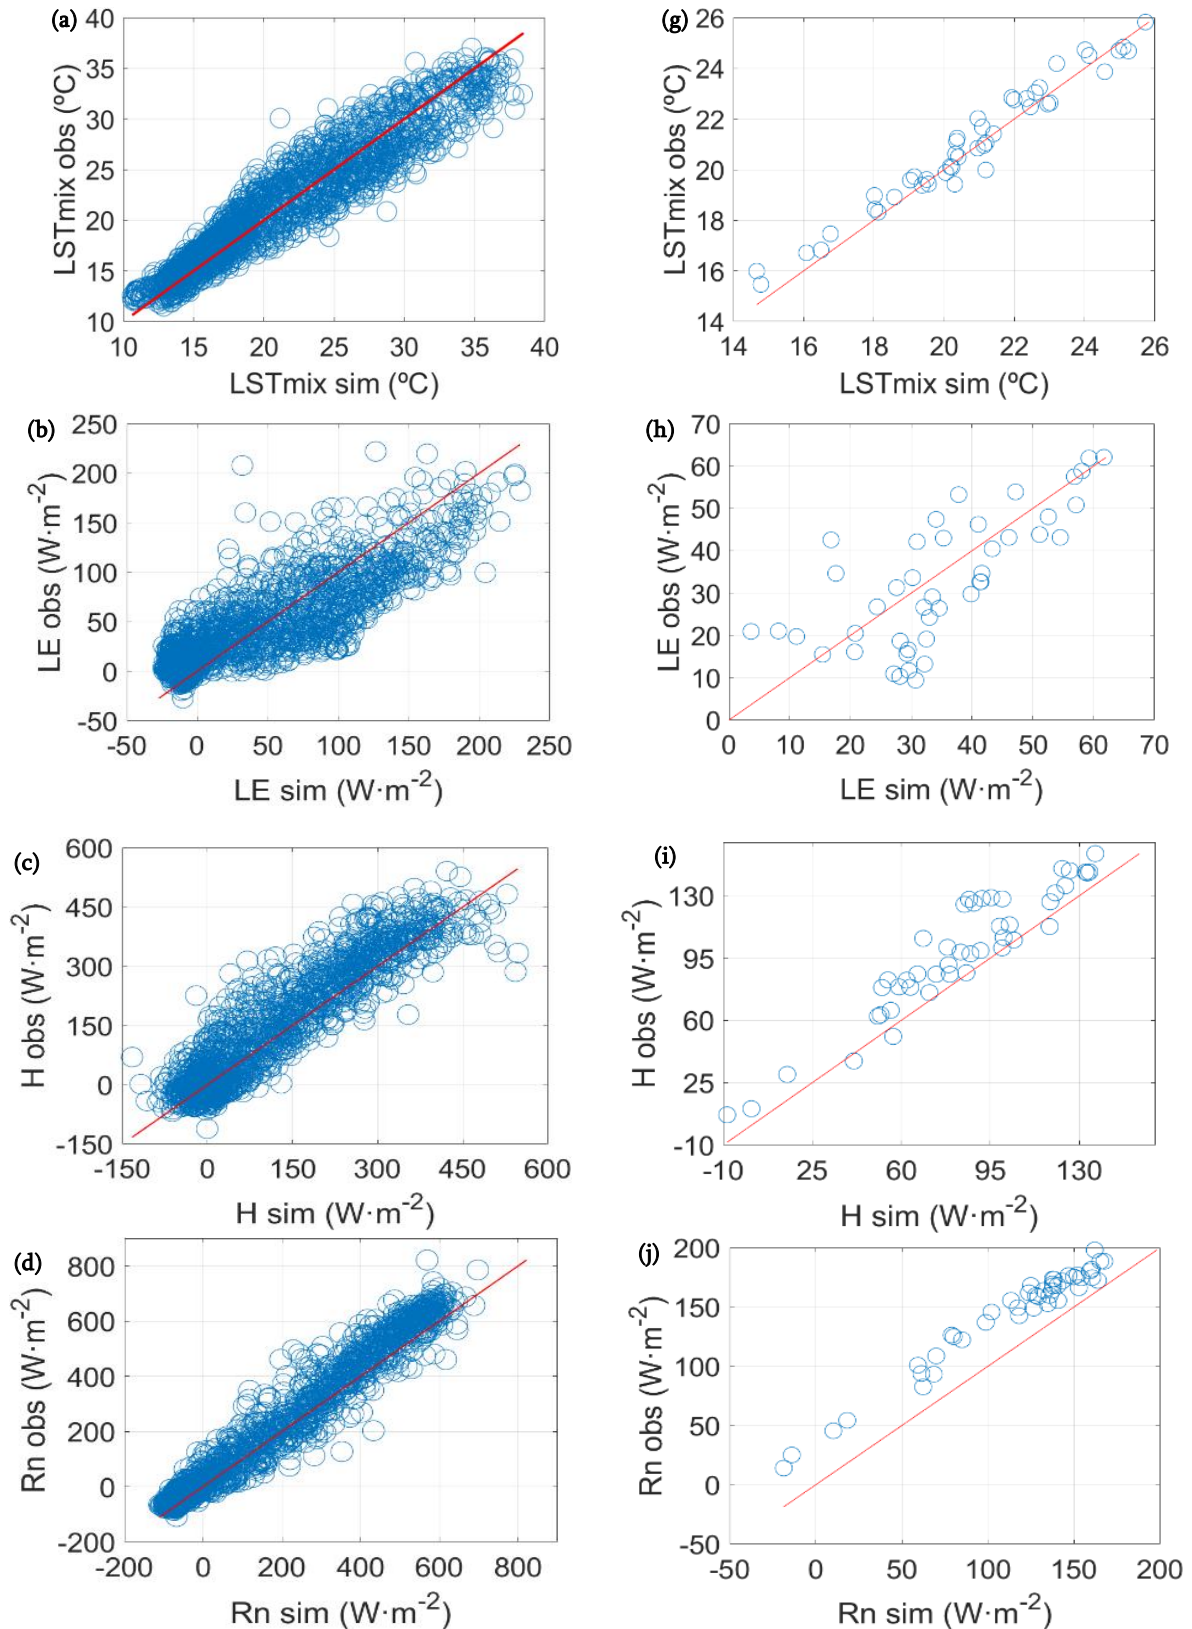
TABLA 4.3: Resumen de los estadísticos del modelo SVEN con los intervalos de tiempo medio-horarios y diarios.

SVEN	Estadísticos	LST mix (°C)	LST soil (°C)	LST canopy (°C)	LE (W/m ²)	Rn (W/m ²)	H (W/m ²)	GPP (gC/ s ⁻¹ ·m ²)	SWS (m ³ /m ³)
	n	2,160	2,160	2,160	2,160	2,160	2,160	1,692	2,160
	Media obs	21.01	21.91	20.79	32.56	144.29	98.28	2.76	10.28
	Media sim	20.78	20.78	20.78	33.94	114.48	83.09	2.55	10.33
Medio-horario	RMSE	1.99	2.63	2.10	25.97	52.71	50.9	1.59	1.19
	MAE	1.59	2.09	1.65	16.54	39.56	34.42	1.13	0.77
	bias	0.23	1.12	0.01	-1.37	29.81	15.19	0.21	-0.05
	R²	0.90	0.89	0.90	0.75	0.97	0.89	0.63	0.95
	NRMSE (%)	7.84	8.94	8.54	10.81	5.67	7.81	14.52	6.59
	n	45	45	45	45	45	45	45	45
	Media obs	21.01	21.91	20.79	32.56	144.29	98.28	2.17	10.28
	Media sim	20.78	20.78	20.78	33.94	114.48	83.09	2.02	10.33
Diario	RMSE	0.58	1.29	0.56	11.52	31.17	19.21	0.62	1.12
	MAE	0.47	1.19	0.45	9.42	29.81	15.89	0.51	0.76
	bias	0.23	1.12	-0.01	-1.38	29.81	15.2	0.15	-0.04
	R²	0.96	0.94	0.96	0.50	0.97	0.89	0.29	0.96
	NRMSE (%)	5.68	12.22	5.45	21.88	16.93	13.10	23.89	6.53

La variable de la temperatura superficial (LST) fue medida en campo en tres escenarios y en cada uno se obtuvieron resultados diferentes. La variable LST canopy, fue la que presentó una temperatura observada media más baja, mientras que la LST soil fue la más alta. Las tres variables presentaron estadísticos muy buenos, con r^2 superiores al 0.89, tanto a escala medio-horaria como diaria. En los tres casos, las variables LST del modelo fueron subestimadas, por el hecho de que el estadístico bias fue positivo. La variable que presentó los mejores estadísticos fue la LST mix, donde el RMSE fue de 1.99 °C en escala medio-horaria y de 0.58°C en escala diaria. El error normalizado (NRMSE) fue del 7.84% en escala medio-horaria y del 5.68% en escala diaria. El modelo SVEN aumentó la precisión de la LST en un 63.29% a escala diaria, mientras que, a escala medio-horaria, la diferencia era negligible.

La Rn obtuvo el r^2 más alto en comparación con todos los outputs, con valor de 0.97 a escala medio-horaria y de 0.97 a escala diaria. Presentó un error normalizado (NRMSE) de 5.67% a escala

media-horaria, sin embargo, a escala diaria, ascendió hasta 16.93%. En las dos escalas temporales, se puede apreciar como el modelo subestima, por el hecho de que el bias es positivo. En la serie temporal diaria de la Rn (figura 4.8d) se puede apreciar como simula perfectamente las caídas de la Rn, sin embargo, se puede apreciar el desfase entre simulado-observado.



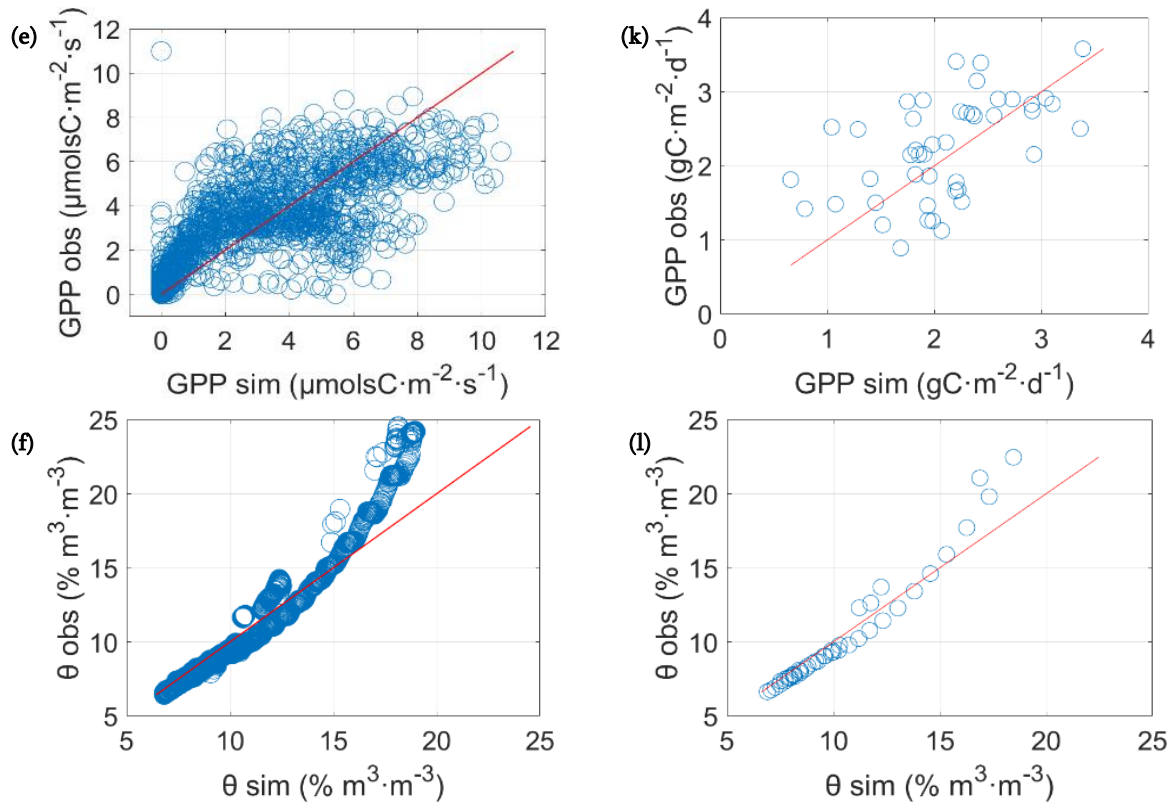


FIGURA 4.6: Representación de la correlación entre los datos simulados y observados en el periodo de validación (29 de abril hasta 12 de junio) a escala medio-horaria en la izquierda (a-f) y escala diaria en la derecha (e-l). (a) y (g) muestra la temperatura superficial (LST, °C); (b) y (h) muestran el flujo de calor latente (ET o LE, $W m^{-2}$); (c) y (i) muestran el flujo de calor sensible (H, $W m^{-2}$); (d) y (j) muestran la radiación neta (Rn, $W m^{-2}$); (e) y (k) muestran la productividad primaria bruta (GPP, $\mu molsC/s^{-1}\cdot m^{-2}$, $gC/d^{-1}\cdot m^{-2}$); (f) y (l) muestran en contenido de humedad en el suelo (θ , $m^3 m^{-3}$).

La LE obtuvo un r^2 de 0.75 a escala medio-horaria y de 0.50 a escala diaria. Presentó un error normalizado (NRMSE) del 10.81% a escala media-horaria, mientras que, a escala diaria, ascendió hasta 21.88%. La serie temporal diaria de la LE (figura 4.7b) se puede apreciar como la simulación se adecua correctamente a los valores observados y respetando las fluctuaciones de subida y bajada correctamente. El principal problema es cuando la radiación está en los máximos y mínimos, porque sobreestima y subestima, respectivamente. A escala diaria, se puede apreciar como a partir del 21 de mayo, el modelo tiende a sobreestimar.

La H obtuvo un r^2 de 0.89 a escala medio-horaria y diaria. Presentó un error normalizado (NRMSE) del 7.81% a escala media-horaria, mientras que a escala diaria, ascendió hasta 13.10%. En las dos escalas temporales, se puede apreciar como el modelo subestima, por el hecho de que el bias es positivo. La serie temporal diaria de H (figura 4.8c) se puede apreciar como el modelo tiende a subestimar. Mientras que a escala medio-horaria (figura 4.7c) siguen tendencias iguales, pero se puede apreciar como cuando H toma valores máximos y mínimos, el modelo tiende a sobreestimar y subestimar, respectivamente.




FIGURA 4.7: Representación de la serie temporal de observada y simulada en el periodo de validación (29 de abril hasta 12 de junio) a escala medio-horaria. (a) muestra la temperatura superficial (LST, °C); (b) muestra la evapotranspiración o flujo de calor latente (ET or LE, $W\ m^{-2}$); (c) muestra el flujo de calor sensible (H, $W\ m^{-2}$); (d) muestra la radiación neta (Rn, $W\ m^{-2}$); (e) muestra la producción primaria bruta (GPP $\mu\text{molsC}/\text{s}^{-1}\cdot\text{m}^{-2}$); (f) muestra el contenido de humedad del suelo (θ , $\text{m}^3\ \text{m}^{-3}$).

La GPP obtuvo un r^2 de 0.63 a escala medio-horaria y de 0.29 a escala diaria. Presentó un error normalizado (NRMSE) del 14.52% a escala media-horaria, mientras que a escala diaria, ascendió hasta 23.89%. En las dos escalas temporales, se puede apreciar como el modelo subestima, por el hecho de que el bias es positivo. En la serie temporal diaria de la GPP (figura 4.8e) se puede apreciar como las predicciones no son precisas. A lo largo de la serie temporal, hay momentos en que la diferencia entre observado-simulado es muy marcada, como por ejemplo des del 10 hasta el 31 de mayo.

La θ obtuvo un r^2 de 0.95 a escala medio-horaria y de 0.96 a escala diaria. Presentó un error normalizado (NRMSE) del 6.59% a escala media-horaria, mientras que a escala diaria, ascendió hasta 6.53%. En las dos escalas temporales, se puede apreciar como el modelo subestima, por el hecho de que el bias es positivo. Tanto en la figura 4.7f) y 4.8f) (serie temporal medio-horaria y diaria de la θ) se puede apreciar como en todo momento la simulación respeta las fluctuaciones de aumento y disminución de contenido de humedad del suelo, en el instante indicado, pero de forma más o menos exagerada.

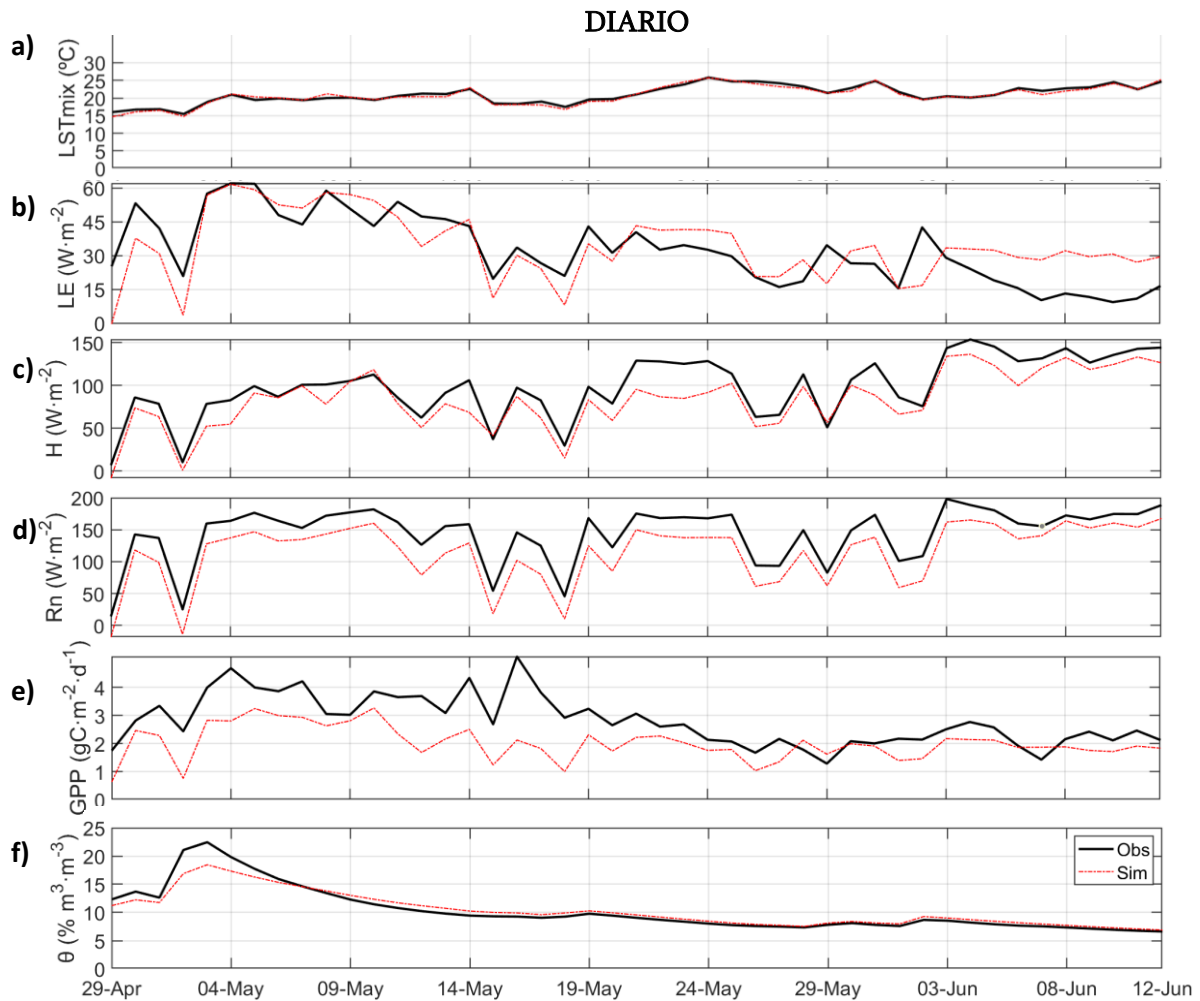


FIGURA 4.8: Representación de la serie temporal de observada y simulada en el periodo de validación (29 de abril hasta 12 de junio) a escala diaria. (a) muestra la temperatura superficial (LST, °C); (b) muestra la evapotranspiración o flujo de calor latente (ET or LE, $W m^{-2}$); (c) muestra el flujo de calor sensible (H , $W m^{-2}$); (d) muestra la radiación neta (R_n , $W m^{-2}$); (e) muestra la producción primaria bruta (GPP $gC/d^{-1} \cdot m^{-2}$); (f) muestra el contenido de humedad del suelo (θ , $m^3 m^{-3}$).

Remarcar y dar especial énfasis que, todos los outputs presentan errores próximos o por debajo del 22%, es decir menos que el error propio del sistema de la estación EC, a excepción del LE y GPP a escala diaria.

4.4.3. Calibración de los parámetros y evaluación del modelo al variar la frecuencia de observación

En la tabla 4.4 se muestra los parámetros calibrados obtenidos en el análisis de la frecuencia optima de revisión satelital. La frecuencia utilizada está dentro de los rangos de los productos de acceso libre, como son MODIS, Landsat, ECOSTRESS y Sentinel, cuya frecuencia varia de 2 hasta 16 días. Para el análisis, se ha utilizado el número de puntos de calibración (n° puntos de calibración) que está asociado con la frecuencia de revisión.

En la figura 4.9 se puede apreciar como hasta 7 puntos en la calibración de los parámetros, la precisión del modelo no se ve afectada significativamente. Sin embargo, cuando el número es

inferior (e.i. 4 muestras) el error incrementa drásticamente. Cuando el número de puntos de calibración es menor de 7, se puede observar cómo hay ciertos parámetros, que exhiben rangos cercanos (e.i. SWSmax y Csat), mientras que otros parámetros presentan rangos bastante diferentes (e.i. b, Cveg, Ks).

TABLA 4.4. Resumen de los diferentes parámetros calibrados en función de la frecuencia de pase satelital y el número de muestras en la calibración.

Frecuencia de revisión	nº puntos	Csat ($\cdot 10^{-6} \text{ K}\cdot\text{m}^{-2}\cdot\text{J}^{-1}$)	b (-)	SWSmax ($\cdot 10^{-1} \text{ m}$)	Cveg ($\cdot 10^{-6} \text{ K}\cdot\text{m}^{-2}\cdot\text{J}^{-1}$)	Ks ($\text{mm}\cdot\text{h}^{-1}$)
1 día	56	9.595	5.632	2.292	2.194	1.016
2 días	28	9.004	5.586	2.308	2.383	1.016
4 días	14	9.571	6.401	2.439	2.397	1.083
6 días	9	8.978	6.797	2.352	2.505	1.001
8 días	7	9.514	6.604	2.490	2.403	1.173
16 días	4	9.801	4.849	2.361	3.906	1.880

En la figura 4.9, se puede observar el error cometido en todos los outputs evaluados según los parámetros de calibración utilizados. La LST y H son las variables en que se comete un mayor error, aumentando el error un 23.33% y 37.5%, respectivamente. La precisión de los outputs Rn y θ también fueron afectados, pero con menos severidad, ya que el incremento del error fue del orden de 13.33% y 16.67%, respectivamente. Por último, la precisión del output LE no fue afectada y se mantuvo constante.




FIGURA 4.9: Representación de los errores cometidos en cada escenario. Cada escenario está asociado a un número de puntos de calibración, que corresponde a la frecuencia de pase del satélite. a) análisis a partir del RMSE; b) análisis a partir del NRMSE. Outputs de color azul hacen referencia a variables energéticas (Rn, LE, H), mientras que color naranja representa la LST y θ .

Finalmente, mencionar cuando el número de muestras para la calibración es superior a 7, es decir, con una frecuencia de revisión del satélite de 8 días, los errores de las variables se mantienen estables, con solo cometiendo un error del 0.42 hasta 10.53% en función de los outputs.

Hacer mención que la simulación que fue calibrada con solo 4 puntos, presento irregularidades al compilar el 30 de mayo y el 7 de junio, por presencia de datos anómalos (outliers). Gracias a la

aplicación del método z-score con valor “3” para identificar outliers, se demostró como para los outputs LST, LE, H, Rn, SM había 0.79%, 0.56%, 0.88%, 0.19% y 2.08%, respectivamente de outliers. El análisis estadístico del escenario de 4 muestras para la calibración se realizó con los outliers eliminados. Pero, incluso habiendo eliminado los valores atípicos, la evaluación salió desfavorable.

4.4.4. Correcciones de los datos observados:

En referencia al error cometido por la estación EC, distintos autores proponen métodos para corregir el error de la incertidumbre. Además, la parcela de estudio BB está ubicada en un ecosistema de espartal semiárido, donde los flujos de LE son tan bajos que puede suceder que la medida observada se encuentre dentro del propio error residual, por lo que son necesario métodos de corrección.

Para ajustar el error del cierre de balance energético medido por la estación EC, se utilizaron dos metodologías: a) según la relación “*Bowen*” y b) según el procedimiento “*LE residual*”, explicados en el apartado 3.4 en la metodología. A continuación, se muestra la figura resumen de la serie temporal al comparar las distintas medidas: a) LE observada directa de la EC; b) LE corregida según el método *Bowen ratio*; c) la LE corregida según el método *residual*.




FIGURA 4.10: Serie temporal de todas las correcciones de cierre de energía de los datos con diferentes valores de flujo de calor latente diario (LE). La línea negra representa los datos de LE simulados por SVEN, la línea magenta representa los datos brutos de LE de la estación Eddy Covariance, la línea roja representa los datos de LE corregidos por la metodología de la razón de Bowen, y la línea azul representa los datos de LE corregidos por la metodología residual.

El análisis estadístico reveló que el LE corregido con la metodología de la razón de Bowen presentó la menor precisión y correlación, mientras que los datos brutos de la torre EC mostraron el mejor RMSE y un R² superior. Finalmente, se pudo comprobar como los datos corregidos por los dos métodos, no mejoraban los estadísticos, por lo que se decidió utilizar directamente los valores observados de la estación EC. Respecto a las dos metodologías correctoras explicadas, resaltar que la metodología de *LE residual* presentó mejores similitudes con los valores observados que la metodología *LE Bowen ratio*.

5. DISCUSIÓN

5.1. Error de la estación EC

La estación EC del presente estudio se encuentra en un ecosistema semiárido, donde los flujos de LE son tan bajos que, en muchas ocasiones, el valor observado se encuentra dentro del error residual de la propia estación, por lo que ciertas correcciones estandarizadas pueden llegar a distorsionar los resultados. Nuestra hipótesis es que las correcciones no mejoran los datos de LE. Las diferentes correcciones propuestas para su evaluación son la relación Bowen (Twine et al., 2000) y la LE residual (Morillas et al., 2013a). Como se ha podido observar en los resultados de la tabla 4.5., los valores de la LE sin corregir son los que presentan un menor error, lo que confirma la hipótesis inicial.

Como se ha mencionado anteriormente, la propia estación presenta un error residual del 22 %, tal y como han descrito otros científicos (Wilson et al., 2002; Morillas et al., 2013a; Kustas et al., 2016). Me gustaría hacer especial énfasis en los resultados del presente estudio, específicamente en los del modelo SVEN, ya que los errores (NRMSE) en los resultados de LST, LE, H y Rn están por debajo del 10 %, es decir, son inferiores al error propio del sistema de la estación EC. Esto es un factor importante, ya que estamos al mismo nivel de incertidumbre del método de validación.

5.2. Validación datos *ECOSTRESS* con in situ

Una de las posibles hipótesis del trabajo era utilizar los datos del producto ET-*ECOSTRESS* como datos observados para calibrar el modelo. Sin embargo, al comparar los resultados del producto con los valores medidos con la estación EC en el campo, se descartó la hipótesis. Como se puede observar en la figura 4.1, los datos de ET-*ECOSTRESS* presentaron errores de medición muy importantes, llegando a ser diez veces mayores. Además, hay que tener en cuenta que, durante casi dos años, no hubo información disponible, por lo que no se podría haber llevado a cabo la calibración de los parámetros en esas fechas. Sin embargo, no se descarta la utilización del producto como fuente de LE observada en lugares cuya herramienta tenga una precisión y error aceptables.

Fisher et al. (2020) realizó la primera validación global del producto *ECOSTRESS*, en la que participaron un total de 82 estaciones EC de todo el mundo. Los resultados obtenidos mostraron conclusiones positivas, ya que la relación entre ET-*ECOSTRESS* y ET-EC fue con un R^2 de 0.89, y se obtuvo un RMSE normalizado del 8%. De este modo, se confirmó que, en determinadas ubicaciones donde la disponibilidad de datos no sea un factor limitante, sí es una herramienta precisa.

Como mencionan Fisher et al. (2020) en su trabajo, el producto del flujo de calor latente LE de *ECOSTRESS* es fruto de la combinación de la LST y la emisividad, además de datos atmosféricos y superficiales auxiliares. Por lo tanto, el producto de la LST debe de tener una precisión aceptable. El proyecto desarrollado por Hu et al. (2022) analizó y validó los datos de LST-*ECOSTRESS* en comparación con los datos obtenidos in situ con la estación EC. Además, la estación de Cabo de Gata – Balsa Blanca, fue uno de los puntos utilizados. Los resultados mostraron un RMSE de hasta 2°C, por lo que la falta de precisión del producto ET-*ECOSTRESS* puede deberse a esto.

5.3. Modelo de predicción SEB

El modelo SEB se rige por las ecuaciones propuestas por Margulis y Huning (2015). Realizar la evaluación del balance energético en función del ecosistema que se quiera simular es una tarea complicada, sobre todo si no se pueden representar correctamente ciertas funciones, lo que repercutirá en la precisión.

En cuanto a los resultados, cabe destacar que tanto la LST como el H presentan porcentajes de error inferiores al 20 %, es decir, inferiores al error propio del sistema de la estación EC. Esto es importante para entender que la estimación de la LST y la H se realiza con precisión.

Por otro lado, el resultado LE presentó errores importantes, debido principalmente a una mala calibración de los parámetros del modelo, en concreto del parámetro C_{soil} , puesto que los otros tres parámetros sí se calibraron a partir de mediciones de campo.

Morillas et al. (2013a) también implementó un modelo para estimar variables energéticas. En este caso, Morillas utilizó el modelo TSEB, que fue calibrado y validado con la misma estación EC que se utilizó en el presente estudio. La zona de estudio fue la misma, es decir, el parque natural de Cabo de Gata (Almería, España). El modelo TSM se basa en el modelo simple propuesto por Norman et al. (1995), e incluye las mejoras propuestas por Kustas y Norman (1999). Basándose en las ecuaciones del balance energético superficial (SEB), pero pudiendo diferenciar entre planta y suelo, lo que influye en la temperatura en la capa límite entre la planta y la atmosfera (Morillas et al., 2013a). Sin embargo, para el cálculo de la LE se basaron en el modelo Priestley-Taylor. Las comparaciones entre los valores medidos in situ y los obtenidos con TSM permitieron estimar a escala diaria la R_n y el flujo H con un error del 30% y del 10%, respectivamente.

Al comparar los resultados del modelo SEB estudiado en el presente trabajo, se observa que la R_n presentó un error tres veces más bajo, mientras que el H fue cinco veces mayor. El output LE de Morillas presentó un error relativo del 90% y un RMSE de alrededor de 105 – 135 Wm^{-2} a escala diaria, mientras que el modelo SEB presentó un error relativo superior, pero con un RMSE un 26.9% inferior.

El principal problema del presente modelo es que no realiza la diferenciación entre suelo y planta en el balance energético, por lo que lo trata todo como un conjunto. Como propuesta de mejora del modelo SEB, se sugiere modificar la metodología de calibración del parámetro de capacidad calorífica del suelo (C_{soil}). La hipótesis que se plantea es utilizar un valor constante en el tiempo, ya que la fenología de la *Stipa tenacissima* no siempre es la misma, lo que podría inferir en cierto modo la capacidad calorífica del suelo. Sin embargo, el procedimiento podría ser complicado y no mostrar resultados eficientes, por lo que se sugieren modelos que permitan diferenciar el suelo de la vegetación, como hace el SVEN.

5.4. Modelo de predicción SVEN

Tradicionalmente, la aplicación de modelos superficiales se ve limitada por la compleja parametrización y la escasa disponibilidad de información in situ, conocida también como “ground truth” para realizar la calibración. Zhang et al. (2009), Stisen et al. (2011) y Wang et al.

(2020) afirmaron que la utilización de medidas “ground truth”, hacen que la calibración de los parámetros sea más precisa. En el presente estudio, se muestra cómo el uso de información satelital relacionada con “ground truth” es una solución a esta limitación. La calibración de los parámetros se realizó mediante datos combinados con información satelital y de la estación in situ de EC, una herramienta que puede escalarse a escala global. Sin embargo, el hecho de utilizar únicamente el producto satelital, cuya resolución espacial es de 1x1 km, hace que la observación tenga mucho ruido. Por lo tanto, al utilizarse únicamente para la calibración, el modelo no permite compilar. Sin embargo, cuando en la calibración se utiliza información de la estación EC (“ground truth”), el modelo sí permite reflejar bien el escenario de balances de energía, agua y flujos de CO₂.

Como se puede observar en el apartado de resultados 4.4, el modelo SVEN es capaz de interpolar correctamente a distintas escalas temporales y siempre manteniendo el error normalizado por debajo del propio error de la torre EC, es decir, inferior al 22% (a excepción del resultado GPP a escala diaria).

A continuación, se comentará el estudio que Wang et al. (2020) realizaron para calibrar y validar el modelo SVEN en la región de Risoe (Dinamarca). En el proyecto, utilizaron una estación EC como medida in situ, además de sensores térmicos y radiométricos a bordo de un UAS. El campo experimental se encontraba en una plantación de bioenergía de sauce, donde la temperatura media anual era de 8.5°C y la precipitación media anual era de 600 mm año⁻¹. El hecho ser dos ecosistemas tan diferentes entre sí dificultaba su comparación, por lo que se analizaron los errores normalizados. Wang et al. (2020) obtuvieron errores normalizados en los resultados energéticos diarios destacables, ya que la LE y la Rn fueron un 18.28% y un 45.12% más precisas, respectivamente. Sin embargo, a escala medio-horaria, el error del LE fue ligeramente igual y, en el caso de la Rn, el modelo SVEN fue 32.6% más preciso. Respecto los resultados diarios de LST y θ , los del presente trabajo presentaron una precisión de hasta el 51.7% y el 66.6% mayor, respectivamente. El último resultado que se debe de mencionar es la GPP, donde Wang et al. (2020) obtuvo una mayor precisión, llegando a ser el doble a escala medio-horaria y diaria.

El estudio de Pateromichelaki (2020) también calibro el modelo SVEN en la región del volcán Poás (Costa Rica). En el proyecto, utilizaron una estación EC como medida in situ, además de sensores radiométricos instalados en el campo y satelitales. El campo experimental se encontraba en una plantación de café, con una temperatura media anual de 20.5°C y una precipitación media anual era de 2,500 mm año⁻¹. En el estudio de Pateromichelaki (2020) los errores fueron mucho más altos que en el presente proyecto. Los resultados de H y Rn son los que más se diferenciaron, llegando a ser entre diez veces mayores. Los errores de la LE y la LST a escala diaria fueron más similares, pero llegando a errores de un 26.7% y un 18.9% mayores, respectivamente.

Por último, me gustaría mencionar que tanto en el estudio de Wang et al. (2020), como en el de Pateromichelaki (2020), el RMSE de la LST nunca llega a ser inferior a 2°C, mientras que, en el presente estudio, tanto a escala medio-horaria como diaria, es inferior, llegando incluso a la precisión de 0.6°C a escala diaria.

De igual forma, también es interesante comparar el trabajo de Morillas et al. (2013a). Las comparaciones entre los valores medidos in situ con la estación EC y los datos obtenidos con TSM permitieron estimar la Rn y el flujo H a escala diaria con un error del 30% y del 10%,

respectivamente. En comparación, el modelo SVEN permite reducir el error a la mitad en la R_n , mientras que el H se mantiene igual. La sección que presenta un mayor potencial del modelo es el resultado LE, ya que Morillas obtuvo un error relativo del 90% y un RMSE alrededor de 105 – 135 Wm^{-2} a escala diaria, mientras que el modelo SVEN, presentó un error relativo del 22% y un RMSE diez veces menor, del orden de 11.52 Wm^{-2} .

Tras realizar todas las comparaciones realizadas sobre los diferentes trabajos explicados, los autores ponen de manifiesto un factor común: para obtener un modelo capaz de predecir con exactitud y precisión, es esencial calibrar los parámetros con información basada en “ground truth”.

Domingo et al. (2011) afirmó que los modelos deben adaptarse a las particularidades de la vegetación semiárida y de secano, presentar un fuerte control estomático y tener en cuenta la importancia del balance hídrico del suelo en respuesta a los pulsos de lluvia, además de ser capaces de interpolar temporalmente cuando no hay datos satelitales diurnos y estacionales. Por eso, es necesario desarrollar modelos de predicción que nos ayuden a entender de forma continua la sensibilidad de la variable.

Desde el punto de vista crítico, se plantea que el módulo para el cálculo del flujo de CO_2 no es el óptimo, ya que los resultados obtenidos no son tan precisos ni de tan buena calidad como el balance energético y de agua. El problema aparente es que el modelo “LUEmax” es demasiado simple y no puede representar la totalidad de los intercambios complejos que realiza la planta con exactitud. Zhou et al. (2015) propone utilizar el modelo TL-LUE (Two-Leaf Light Use Efficiency), en el que la planta se representa como hojas con radiación solar incidente y otras con sombra. Zhou validó el modelo gracias a la red de estaciones EC a nivel global y en diferentes biomas, llegando a la conclusión de que permite simular la GPP mejor que el modelo LUE simple. Esto hace que sea menos sensible a alteraciones en la radiación fotosintéticamente activa (PAR), por lo que se obtiene una mayor precisión. Sin embargo, el bioma que representa el presente trabajo, clasificado como sabana boscosa en el trabajo de Zhou et al. (2015), fue de los que obtuvo peor precisión, lo que demuestra una vez más la complejidad del ecosistema estudiado.

Otros modelos más complejos permiten simular mejor la fotosíntesis, como el modelo Ball-Berry, utilizado por (Wei et al., 2018). Otra posible mejora es la que propone el artículo de Jingyi Bu et al. (2024), en el que se simula la GPP mediante la fluorescencia. El propósito del autor es estimar la LE, por lo que necesita la GPP para poder estimar la conductancia estomática mediante un modelo “optimal stomal conductance”, propuesto por Medlyn et al. (2011).

Como se puede observar, el hecho de obtener una buena correlación con el resultado de θ , permite asegurar una buena predicción con la LE. En otras pruebas realizadas en el mismo trabajo, se obtuvieron correlaciones inferiores a 0.5 ($R^2 < 0.5$), sin embargo, el error en la predicción de la LE era aceptable. En todo caso, el uso de la precipitación y un modelo de balance hídrico sencillo, como el implementado en SEVN, es mejor que usar la inercia térmica para estimar la fracción de humedad del suelo, como describieron Garcia et al. (2013), basándose en el déficit de presión de vapor (VPD) (Fisher et al., 2008). Además, cabe mencionar que el producto de ET-ECOSTRESS (NASA, 2023), utiliza la metodología de Garcia et al. (2013).

El uso de la θ presenta ventajas frente a la utilización de parámetros basados en la lluvia antecedente, como realizaron Morillas et al. (2013b) y Zhang et al. (2010). La hipótesis de partida asume que el efecto de la lluvia sobre el agua disponible en el suelo es limitado al periodo establecido (n días), por lo que la simulación predice que el valor máximo se mantendrá durante el periodo establecido y que, una vez pasado este, se producirá una bajada drástica. Esta representación no es realista del patrón del θ , ya que el decrecimiento es progresivo una vez finalizado el evento de lluvia y no de forma brusca como hace la simulación (Morillas et al., 2013b).

El módulo del balance de agua utilizado (“bucket model”), es un modelo simple, ya que solo tiene en cuenta el movimiento del agua almacenada en el suelo en una única dirección (figura 3.12; Wang et al., 2020). En el caso del presente estudio, los resultados son de buena calidad, por lo que el uso de este del modelo simple permite reducir la dificultad de parametrización. El hecho de que el modelo solo tenga en cuenta el movimiento del agua almacenada en el suelo en una única dirección hace que ciertas orografías no puedan reflejarse en él. Además, la capa profunda del suelo hace referencia a la máxima profundidad en que la planta puede extraer agua, un factor que no es constante en el tiempo (Guderle y Hildebrandt, 2015), pero que se simplificó en el modelo SVEN para reducir la complejidad de parametrización.

Además de la θ , hay más factores que afectan a la LE y parece ser que el módulo de ET de SVEN basado en el PT-JPL (Priestley-Taylor Jet Propulsion Laboratory) es capaz de simular correctamente el comportamiento del espantal.

El trabajo de Kustas et al. (2016) mejoró el estudio de Morillas et al. (2013a). El principal problema que encontraron era la incertidumbre en la estimación de ciertas variables relacionadas con el índice de vegetación NDVI, como las f_{APAR} , f_{IPAR} , albedo y LAI. Por lo tanto, el autor propuso medir el LAI, para poder diferenciar entre la radiación neta recibida por la planta y la radiación neta recibida por el suelo y así poder estimar los parámetros mencionados anteriormente (f_{APAR} , f_{IPAR} y albedo), reduciendo la incertidumbre y la sensibilidad a la utilización de valores erróneos en el modelo. Finalmente, llegó a la conclusión de que la metodología propuesta, junto con ciertas correcciones a la resistencia del suelo, permitió reducir el error RMSE un 42.3%, casi hasta la mitad. Para futuras mejoras del modelo, se propone utilizar el LAI medido en campo en lugar de la estimación realizada a partir del índice de vegetación NDVI.

Respecto a la frecuencia de observación, los resultados fueron lógicos y similares a los de Alfieri et al. (2017), ya que este afirmó que para obtener errores relativos menores del 20% en la LE diaria, la frecuencia de pase de revisión no tenía que ser superior a cinco días. Además, Wang et al. (2020) afirmó que, para calibrar los parámetros del modelo, eran necesarias siete observaciones, distanciadas entre ellas 25 días, que permitían interpolar la LE diaria acuradamente en un periodo de 180 días. En el presente proyecto se demostró que, con un mínimo de siete puntos para la calibración de los parámetros del modelo se puede simular a escala medio-horaria la LE, manteniendo los errores hasta un máximo del 10.5%. El hecho de poder extrapolar la frecuencia de pase hasta ocho días sin perder mucha precisión permite que estas herramientas se extiendan a nivel global a lugares donde no tienen la capacidad de poder captar información a una frecuencia tan elevada como la del presente trabajo.

6. CONCLUSIONES

El objetivo general del proyecto ha consistido en calibrar y evaluar el modelo de predicción de evapotranspiración y productividad SVEN con datos in situ de la estación EC, con el fin de disponer posteriormente de un modelo que permita hacer predicciones de los flujos superficiales instantáneamente.

El producto de ET-ECOSTRESS no está lo suficientemente desarrollado en la región de Balsa Blanca, ya que se ha comprobado como las observaciones estiman valores hasta veinte veces superiores a los medidos por la estación EC, como se dio el 31 de agosto del 2018. Además, en muchos casos, la propia incertidumbre del producto ET-ECOSTRESS es superior al valor observado por la estación EC. Sin embargo, en un futuro próximo, cuando hayan actualizado y mejorado el procesamiento, podría ser un producto interesante.

La calibración de los parámetros mediante “ground truth” e información satelital de MODIS permitió obtener una precisión del RMSE para los resultados de LST, LE, Rn, H, GPP y θ de 1.99 °C, 25.97 W m⁻², 52.71 W m⁻², 50.90 W m⁻², 1.44 $\mu\text{molsC}\cdot\text{s}^{-1}\cdot\text{m}^{-2}$ y 1.19 m³m⁻³ a escala medio-horaria, respectivamente. Mientras que a escala diaria la precisión fue de 0.58 °C, 11.52 W m⁻², 31.17 W m⁻², 19.21 W m⁻², 0.62 gCm⁻²d⁻¹ y 1.12 m³m⁻³, respectivamente.

El aumento del tiempo entre intervalos de pase de satélite implica una reducción del número de puntos para la calibración de los parámetros, lo que reduce la precisión del modelo. Sin embargo, se ha observado que, con un mínimo de siete puntos para la calibración, reflejando una frecuencia de pase del satélite de ocho días, la precisión del modelo no se ve considerablemente afectada, únicamente incrementándose el RMSE de las variables entre un 0.42% y un 10.53% a escala medio-horaria.

En definitiva, el modelo dinámico se ha calibrado con la LST obtenida con teledetección y se ha validado con los datos in situ medidos por la estación EC. Se ha demostrado que es una herramienta efectiva para la simulación instantánea de balances energéticos, de agua y flujos de CO₂ en la única área subdesértica protegida de Europa.

7. BIBLIOGRAFÍA

- Acharya, P., y Sreekes, S. (2013). Seasonal variability in aerosol optical depth over India: a spatio-temporal analysis using the MODIS aerosol product. *International Journal of Remote Sensing*, 34(13), 4832–4849. <https://doi.org/10.1080/01431161.2013.782114>
- Ait Belaid M. (1994). Les systèmes d'information pour l'environnement: Développement et formation. *Géo observateur*, 5, 61–69.
- Alados, C. L., Pueyo, Y., Barrantes, O., Escos, J., Giner, L., y Robles, A. B. (2004). Variations in landscape patterns and vegetation cover between 1957 and 1994 in a semiarid Mediterranean ecosystem. *Landscape Ecology*, 19, 545–561.
- Alados, C. L., Pueyo, Y., Giner, M. L., Navarro, T., Escos, J., Barroso, F., Cabezudo, B. y Emlen, J.M. (2003). Quantitative characterization of the regressive ecological succession by fractal analysis of plant spatial patterns. *Ecological Modelling*, 163 (1-2), 1-17. [https://doi.org/10.1016/S0304-3800\(02\)00294-6](https://doi.org/10.1016/S0304-3800(02)00294-6)
- Alfieri, J. G., Anderson, M. C., Kustas, W. P., y Cammalleri, C. (2017). Effect of the revisit interval and temporal upscaling methods on the accuracy of remotely sensed evapotranspiration estimates. *Hydrology and Earth System Sciences*, 21(1), 83–98. <https://doi.org/10.5194/hess-21-83-2017>
- Ambast, S.K., Keshari, A.K., y Gosain, A.K. (2008). Estimating Regional Evapotranspiration Using Remote Sensing: Application to Sone Low Level Canal System, India. *Journal of Irrigation and Drainage Engineering*, 134, 13-25. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2008\)134:1\(13\)](https://doi.org/10.1061/(ASCE)0733-9437(2008)134:1(13))
- Anderson, M.C., Allen, R.G., Morse, A. y Kustas, W.P. (2012). Use of Landsat thermal imagery in monitoring evapotranspiration and managing water resources. *Remote Sensing of Environment*, 122, 50-65. <https://doi.org/10.1016/j.rse.2011.08.025>
- Appears Team. (2020). Application for extracting and exploring analysis ready samples (AppEEARS). NASA EOSDIS Land Processes Distributed Active Archive Center (LP DAAC), USGS/Earth Resources Observation and Science (EROS) Center. <https://lpdaacsvc.cr.usgs.gov/appears/>
- Areal, F.J., Jones, P.J., Mortimer, S.R., y Wilson, P. (2018). Measuring sustainable intensification: combining composite indicators and efficiency analysis to account for positive externalities in cereal production. *Land Use Policy*, 75, 314–326. <https://doi.org/10.1016/j.landusepol.2018.04.001>
- Bailey, D. D., y Brown, J. R. (2011). Rotational grazing systems and livestock grazing behavior in shrub-dominated semiarid and arid rangelands. *Rangeland Ecology and Management*, 64(1), 1-9. <https://doi.org/10.2111/REM-D-09-00184.1>

- Balaguer, L., Pugnaire, F. I., Martínez-Ferri, E., Armas, C., Valladares, F., y Manrique, E. (2002). Ecophysiological significance of chlorophyll loss and reduced photochemical efficiency under extreme aridity in *Stipa tenacissima* L. *Plant and Soil*, 240, 343-352. <http://doi.org/10.1023/a:1015745118689>
- Baldocchi, D. (2003). Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems: Past, present and future. *Global Change Biology*, 9(4):479-492. <https://doi.org/10.1046/j.1365-2486.2003.00629.x>
- Baldocchi, D. (2008). Breathing of the terrestrial biosphere: Lessons learned from a global network of carbon dioxide flux measurement systems. *Australian Journal of Botany*, 56, 1-26. <http://doi.org/10.1071/BT07151>
- Bennetzen, E. H. (2016). Greenhouse Gas Emissions from Agricultural Production. Master's thesis, Department of Plant and Environmental Sciences, Faculty of Science, University of Copenhagen.
- Brogaard, S., Runnstrom, M., y Seaquist, J. (2005). Primary production of Inner Mongolia, China, between 1982 and 1999 estimated by a satellite data-driven light use efficiency model. *Global and Planetary Change*, 45(4), 313-332. <https://doi.org/10.1016/j.gloplacha.2004.09.012>
- Brownsey, G. J., Eldridge, J. W., Jarvis, D. A., Ross, G., y Sanders, I. (1976). New light-scattering photogoniometer for accurate measurements. *Journal of Physics E: Scientific Instruments*, 9, 654-658. <https://doi.org/10.1088/0022-3735/9/8/016>
- Brutsaert, W. (1982) *Evaporation into the Atmosphere: Theory, History, and Applications*. Springer, Dordrecht, p299. <http://dx.doi.org/10.1007/978-94-017-1497-6>
- Bu, J., Gan, G., Chen, J., Su, Y., Yuan, M., Gao, Y., Domingo, F., López-Ballesteros, A., Migliavacca, M., El-Manday, T., Gentine, P., Xiao, J., y García, M. (2024). Dryland evapotranspiration from remote sensing solar-induced chlorophyll fluorescence: Constraining an optimal stomatal model within a two-source energy balance model. *Remote Sensing of Environmental*, 303, 1-24. <https://doi.org/10.1016/j.rse.2024.113999>
- Burba, G., y Anderson, D. J. (2010). *A Brief Practical Guide to Eddy Covariance Flux Measurements: Principles and Workflow Examples for Scientific and Industrial Applications*. <https://doi.org/10.13140/RG.2.1.1626.4161>
- Cabo-Ruiz, Judith. (2012). *Stipa tenacissima*. En *asturnatura.com* [en línea] Num. 392, 01/10/2012 [consultado el 8/1/2025]. Disponible en *asturnatura.com* ISSN 1887-5068. Obtenido de https://www.asturnatura.com/especie/stipa-tenacissima?expand_article=1
- Calvet, J. C., Noilhan, J., y Bessemoulin, P. (1998). Retrieving the RootZone Soil Moisture from Surface Soil Moisture or Temperature Estimates: A Feasibility Study Based on Field

- Measurements. *Journal of Applied Meteorology and Climatology*, 37, 371–386. [https://doi.org/10.1175/1520-0450\(1998\)037<0371:RTRZSM>2.0.CO;2](https://doi.org/10.1175/1520-0450(1998)037<0371:RTRZSM>2.0.CO;2)
- Campbell, J., y Wynne, R. (2011). *Introduction to Remote Sensing*, Fifth Edition. Guilford Publications. Obtenido de https://www.guilford.com/excerpts/campbell2_old_ch1.pdf?t=1
- Carapeto, A., y Véla, E. (2018). *Stipa tenacissima*. The IUCN Red List of Threatened Species 2018: e.T57471077A125468612. Obtenido de <https://dx.doi.org/10.2305/IUCN.UK.2018-1.RLTS.T57471077A125468612.en>
- Carsel, R. F., y Parrish, R. S. (1988). Developing joint probability distributions of soil water retention characteristics. *Water Resources Research*, 24(5), 755–769, <https://doi.org/10.1029/WR024i005p00755>
- Chávez, A. H., Pérez, A., y Sánchez, E. (2000). Intensidades de pastoreo y esquemas de utilización en la selección de la dieta del ganado durante la sequía. *Técnica Pecuaria en México*, 38(1), 19-34. <https://www.redalyc.org/pdf/613/61338102.pdf>
- Chávez, R. M. G., y Soltero, S. (1993). Manejo del pastoreo y utilización del recurso pastizal. En: Aguado A, Chávez G editores. *Guía para el manejo de ranchos ganaderos del Altiplano Central*. Ojuelos, Jalisco, México: SARH-INIFAP, páginas:10-21.
- Chemura, A. (2017). *Modelling spatial variability of coffee (Coffea Arabica L.) crop condition with multispectral remote sensing data* [Doctoral Dissertation, University of KwaZulu-Natal]. University of KwaZulu-Natal Repository. <https://researchspace.ukzn.ac.za/xmlui/handle/10413/16233>.
- Chen, Y., Xia, J., Liang, S., Feng, J., Fisher, J. B., Li, X., Li, X., Liu, S., Ma, Z., Miyata, A., Mu, Q., Sun, L., Tang, J., Wang, K., Wen, J., Xue, Y., Yu, G., Zha, T., Zhang, L., Zhang, Q., Zhao, T., Zhao, L., y Yuan, W. (2014). Comparison of satellite-based evapotranspiration models over terrestrial ecosystems in China. *Remote Sensing of Environment*, 140, 279–293. <https://doi.org/10.1016/j.rse.2013.08.045>
- Choudhury, B. J. (1992). Multispectral satellite observations for arid land studies. *ISPRS Journal of Photogrammetry and Remote Sensing*, 47, 101–126.
- Culf, A., Foken, T., y Gash, J. (2004). The Energy Balance Closure Problem. In: Kabat P. et al. (eds) *Vegetation, Water, Humans and the Climate. Global Change — The IGBP Series*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-18948-7_13
- Delgado-Balbuena, J., Arredondo, J. T., Loescher, H. W., Huber-Sannwald, E., Chávez-Aguilar, G., Luna-Luna, M., y Barretero-Hernandez, R. (2013). Differences in plant cover and species composition of semiarid grassland communities of central Mexico and its effects on net ecosystem Exchange. *Biogeosciences*, 10(7), 4673-4690. <https://doi.org/10.5194/bg-10-4673-2013>.

- Delgado-Balbuena, J., Arredondo, J. T., Loescher, H. W., Pineda, M. L. F., Carbajal, J. N., y Vargas, R. (2019). Seasonal precipitation legacy effects determine the carbon balance of a semiarid grassland. *Biogeosciences*, 124(4), 987-1000. <https://doi.org/10.1029/2018JG004799>
- Di Falco, S., Yesuf, M., Kohlin, G., y Ringler, C. (2012). Estimating the impact of climate change on agriculture in low-income countries: household level evidence from the Nile basin, Ethiopia. *Environmental and Resource Economics*, 52, 457-478. <https://doi.org/10.1007/s10640-011-9538-y>
- Domingo, F., Gutiérrez, L., Brenner, A. J., y Aguilera, C. (2002). Limitation to carbon assimilation of two perennial species in semiarid southeast. *Biología Plantarum*, 45, 213-220. <https://link.springer.com/article/10.1023/A:1015136421445>
- Domingo, F., Serrano-Ortiz, P., Were, A., Villagarcía, L., García, M., Ramírez, D. A., Kowalski, A. S., Moro, M. J., Rey, A., y Oyonarte, C. (2011). Carbon and water exchange in semiarid ecosystems in SE Spain. *Journal of Arid Environments*, 75(12), 1271-1281. <https://doi.org/10.1016/j.jaridenv.2011.06.018>
- Ershadi, A., McCabe, M. F., Evans, J. P., Chaney, N. W., y Wood, E. F. (2014). Multi-site evaluation of terrestrial evaporation models using FLUXNET data. *Agricultural and Forest Meteorology*, 187, 46-61, <https://doi.org/10.1016/j.agrformet.2013.11.008>
- Fisher, J. B., Huntzinger, D. N., Schwalm, C. R., y Sitch, S. (2014). Modeling the Terrestrial Biosphere. *Annual Review of Environment and Resources*, 39, 91-123. <https://doi.org/10.1146/annurev-environ-012913-093456>.
- Fisher, J. B., Lee, B., Purdy, A. J., Halverson, G. H., Dohlen, M. B., Cawse-Nicholson, K., Wang, A., Anderson, R. G., Aragon, B., Arain, M. A., Baldocchi, D. D., Baker, J. M., Barral, H., Bernacchi, C. J., Bernhofer, C., Biraud, S. C., Bohrer, G., Brunsell, N., Cappelaere, B., Castro-Contreras, S., Chun, J., Conrad, B. J., Cremonese, E., Demarty, J., Desai, A. R., Ligne, A. D., Foltynová, L., Goulden, M. L., Griffis, T. J., Grünwald, T., Johnson, M. S., Kang, M., Kelbe, D., Kowalska, N., Lim, J. H., Maïnassara, I., McCabe, M. F., Missik, J. E. C., Mohanty, B. P., Moore, C. E., Morillas, L., Morrison, R., Munger, J. W., Posse, G., Richardson, A. D., Russell, E. S., Ryu, Y., Sanchez-Azofeifa, A., Schmidt, M., Schwartz, E., Sharp, I., Šigut, L., Tang, Y., Hulley, G., Anderson, M., Hain, C., French, A., Wood, E., y Hook, S. (2020). ECOSTRESS: NASA's Next Generation Mission to measure evapotranspiration from the International Space Station. *Water Resources Research*, 56, e2019WR026058. <https://doi.org/10.1029/2019WR026058>
- Fisher, J. B., Tu, K. P., y Baldocchi, D. D. (2008). Global estimates of the land-atmosphere water flux based on monthly AVHRR and ISLSCP-II data, validated at 16 FLUXNET sites. *Remote Sensing of Environment*, 112(3), 901-919. <https://doi.org/10.1016/j.rse.2007.06.025>
- Food and Agriculture Organization (FAO). (2015). Construyendo una visión común para la agricultura y alimentación sostenibles. Principios y enfoques. Roma, Italia.

- Food and Agriculture Organization (FAO). (2018). Transformar la alimentación y la agricultura para alcanzar los ODS: 20 acciones interconectadas para guiar a los encargados de adoptar decisiones. Roma, Italia. Enlace: <https://openknowledge.fao.org/server/api/core/bitstreams/65e7524f-9f38-4e3c-b98c-e25a45737800/content>
- Food and Agriculture Organization (FAO). 2020a. Labor de la FAO en relación con los pastizales y el pastoreo y propuesta para un Año Internacional de los Pastizales y los Pastores (COAG/2020/19). Obtenido de: <https://openknowledge.fao.org/server/api/core/bitstreams/cff0d2f6-dda6-476b-9e09-343da11e9cf2/content>
- Food and Agriculture Organization (FAO). (2023, 14/02/2023). FAO publishes its first global assessment of soil carbon in grasslands. Obtenido de <https://www.fao.org/newsroom/detail/fao-publishes-its-first-global-assessment-of-soil-carbon-in-grasslands/en>
- Gamon, J.A., Huemmrich, K.F., Peddle, D.R., Chen, J., Fuentes, D., Hall, F.G., Kimball, J.S., Goetz, S., Gu, J., McDonald, K.C., Miller, J.R., Moghaddam, M., Rahman, A.F., Roujean, J.L., Smith, E.A., Walthall, C.L., Zarco-Tejada, P., Hu, B., Fernandes, R., y Cihlar, J. (2004). Remote sensing in BOREAS: Lessons learned. *Remote Sensing of Environment*, 89, 139-162. <https://doi.org/10.1016/j.rse.2003.08.017>
- Garcia, M., Sandholt, I., Ceccato, P., Ridler, M., Mougin, E., Kergoat, L., Morillas, L., Timouk, F., Rensholt, R., y Domingo, F. (2013). Actual evapotranspiration in drylands derived from in-situ and satellite data: Assessing biophysical constraints. *Remote Sensing of Environment*, 131, 103–118. <http://dx.doi.org/10.1016/j.rse.2012.12.016>
- Garratt, J. R., y Hicks, B. B. (1973). Momentum, heat and water vapour transfer to and from natural and artificial surfaces. *Quarterly Journal of the Royal Meteorological Society*, 99(422), 680–687, <https://doi.org/10.1002/qj.49709942209>
- Ghiloufi, W., Quéro-Pérez, J. L., García-Gómez, M., y Chaieb, M. (2015). "Assessment of species diversity and state of *Stipa tenacissima* steppes," *Turkish Journal of Botany*: Vol. 39: No. 2. <https://doi.org/10.3906/bot-1404-57>
- Giorgi, F., y Lionello, P. (2008). Climate change projections for the Mediterranean region. *Global and Planetary Change*, 63, 90–104. <https://doi.org/10.1016/j.gloplacha.2007.09.005>
- Glenn, E. P., Huete, A. R., Nagler, P. L., Hirschboeck, K. K., y Brown, P. (2007). Integrating remote sensing and ground methods to estimate evapotranspiration. *Critical Reviews in Plant Sciences*, 26, 139–168. <https://doi.org/10.1080/07352680701402503>
- González, Costa, F.J. (2021). La agricultura y la alimentación en el centro de los 17 ODS. Trabajo final de grado, Facultad de ciencias de la empresa, Universidad Politécnica de Cartagena. <http://hdl.handle.net/10317/9279>

- Gu, C., Ma, J., Zhu, G., Yang, H., Zhang, K., Wang, Y., y Gu, C. (2018). Partitioning evapotranspiration using an optimized satellite-based et model across biomes. *Agricultural and Forest Meteorology*, 259, 355-363. <https://doi.org/10.1016/j.agrformet.2018.05.023>
- Guderle, M., y Hildebrandt, A. (2015). Using measured soil water contents to estimate evapotranspiration and root water uptake profiles – a comparative study. *Hydrology and Earth System Sciences*, 19(1), 409–425. <https://doi.org/10.5194/hess-19-409-2015>
- Guzmán-Álvarez, J. A., González-Zuñiga, M., Sandoval, J. A., y Calvo-Alvarado, J.C. (2022). Uso de sensores remotos en la agricultura: aplicaciones en el cultivo del banano. *Agronomía Mesoamericana*, 33(3), 48279. <https://doi.org/10.15517/am.v33i3.48279>
- Haase, P., Pugnaire, F.I., Clark, S.C., y Incoll, L.D. (1999). Environmental control of canopy dynamics and photosynthetic rate in the evergreen tussock grass *Stipa tenacissima*. *Plant Ecology*, 145, 327-339.
- Hauschild, M. Z., Rosenbaum, R. K., y Olsen, S. I. (2018). *Life Cycle Assessment – Theory and Practice*. Springer. <https://doi.org/10.1007/978-3-319-56475-3>
- Henderson, B. B., Gerber, P. J., Hilinski, T. E., Falcucci, A., Ojima, D. S., Salvatore, M., y Richard, T. C. (2015). Greenhouse gas mitigation potential of the world’s grazing lands: modeling soil carbon and nitrogen fluxes of mitigation practices. *Agriculture, Ecosystems and Environment*, 207, 91-100. <https://doi.org/10.1016/j.agee.2015.03.029>
- Hu, T., Mallick, K., Hulley, G. C., Planells, Ll. P., Göttsche, F. M., Schlerf, M., Hitzelberger, P., Didry, Y., Szantoi, Z., Alonso, I., Sobrino, J. A., Skoković, D., Roujean, J. L., Boulet, G., Gamet, P., y Hook, S. (2022). Continental-scale evaluation of three ECOSTRESS land surface temperature products over Europe and Africa: Temperature-based validation and cross-satellite comparison. *Remote Sensing of Environment*, 282, 113296. <https://doi.org/10.1016/j.rse.2022.113296>
- Huete, A. (1987). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., y Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Impens, I., y Lemeur, R. (1969). Extinction of net radiation in different crop canopies. *Archiv für Meteorologie. Geophysik und Bioklimatologie Serie B*, 17, 403–412. <https://doi.org/10.1007/BF02243377>
- Intergovernmental Panel on Climate Change (IPCC). (2007). *Climate Change 2007: Synthesis Report. Contribution of working groups I, II, III to the fourth assessment report of the*

intergovernmental panel on climate change [Core Writing Team, Pachauri RK and Reisinger A (eds.)]. Geneva, Switzerland, p 104.

Intergovernmental Panel on Climate Change (IPCC). (2021). Climate change 2021: The physical science basis. Summary for policymakers (Spanish version). Obtenido de https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC_AR6_WG1_SPM_Spanish.pdf

Jia, L., Menenti, M., Su, Z., Li, ZL., Djepa, V., Wang, J. (2001). Modeling sensible heat flux using estimates of soil and vegetation temperatures: the HEIFE and IMGRASS experiments. In: Beniston, M., Verstraete, M.M. (eds) Remote Sensing and Climate Modeling: Synergies and Limitations. Advances in Global Change Research, vol 7. Springer, Dordrecht. https://doi.org/10.1007/0-306-48149-9_2

Jin, X., Kumar, L., Li, Z., Feng, H., Xu, X., Yang, G., y Wang, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141–152. <https://doi.org/10.1016/j.eja.2017.11.002>.

Junta de Andalucía. (2024). Cabo de Gata-Níjar. Portal Ventana del Visitante. Obtenido de https://www.juntadeandalucia.es/medioambiente/portal/web/ventanadelvisitante/detalle-buscador-mapa/-/asset_publisher/1lboxh2qB3NwR/content/cabo-de-gata-n%C3%8Djar/255035

Jurado, G. P., Negrete, R. L. F. y Chávez, R. M. G. (1990). Efecto del fuego sobre el control de escobilla (*Haplopappus venetus*) y la productividad de un pastizal en Jalisco. *Manejo Pastiz.* 3(3):33-36.

Jurado-Guerra, P., Juárez, M. M., Saucedo, T. R. A., Morales, N. C. y Martínez, S. M. (2018). Modelo ecológico de predicción de carbono en pastizales de Chihuahua. En: Paz F, Velázquez A, Rojo M editores. Estado actual del conocimiento del ciclo del carbono y sus interacciones en México: Síntesis a 2018. Texcoco, Estado de México. PMC-ITS. Páginas:62-69.

Jurado-Guerra, P., Velázquez-Martínez, M., Sánchez-Gutiérrez, R. A., Álvarez-Holguín, A., Domínguez-Martínez, P. A., Gutiérrez-Luna, R., y Chávez-Ruiz, M. G. (2021). Los pastizales y matorrales de zonas áridas y semiáridas de México: Estatus actual, retos y perspectivas. *Revista Mexicana De Ciencias Pecuarias*, 12, 261–285 <https://doi.org/10.22319/rmcp.v12s3.5875>.

Kahn, R. A., Nelson, D. L., Garay, M. J., Levy, R. C., Bull, M. A., Diner, D. J., Martonchik, J. V., Paradise, S. R., Hansen, E. G., y Remer, L. A. (2009). MISR aerosol product attributes and statistical comparisons with MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 47(12), 4095–4114. <https://doi.org/10.1109/TGRS.2009.2023115>

- Kalma, J., McVicar, T. y McCabe, M. (2008). Estimating Land Surface Evaporation: A Review of Methods Using Remotely Sensed Surface Temperature Data. *Surveys in Geophysics*, 29, 421-469. <https://doi.org/10.1007/s10712-008-9037-z>
- Kerr, Y.H., Lagouarde, J.P., Nerry, F., y Ottlé, C. (2004). Land surface retrieval techniques and applications: Case of AVHRR, in: Quattrocci, D.A., Luvall, J.C. (Eds.), Thermal remote sensing in land surface processes. CRC Press, Florida, USA, pp. 33-109. <https://doi.org/10.1201/9780203502174-c3>
- Kowalski, A. S., Anthoni, P. M., Vong, R. J., Delany, A. C., y Maclean, G. D. (1997). Deployment and evaluation of a system for ground-based measurement of cloud liquid water turbulent fluxes. *Journal of Atmospheric and Oceanic Technology*, 14, 468-479. <https://www.ugr.es/~andyk/pubs/003.pdf>
- Kustas, W. P., Nieto, H., Morillas, L., Anderson, M. C., Alfieri, J. G., Hipps, L. E., Villagarcia, L., Domingo, F., y Garcia, M. (2016). Revisiting the paper “Using radiometric surface temperature for surface energy flux estimation in Mediterranean drylands from a two-source perspective”. *Remote Sensing of Environment*, 184, 645-653. <https://doi.org/10.1016/j.rse.2016.07.024>
- Kustas, W. P., y Norman, J. M. (1996). Use of remote sensing for evapotranspiration monitoring over land surfaces. *Hydrological Sciences Journal*, 41, 495-516. <https://doi.org/10.1080/02626669609491522>
- Kustas, W. P., y Norman, J. M. (1999). Reply to comments about the basic equations of dual-source vegetation-atmosphere transfer models. *Agricultural and Forest Meteorology*, 94(3-4), 275-278. [https://doi.org/10.1016/S0168-1923\(99\)00012-X](https://doi.org/10.1016/S0168-1923(99)00012-X)
- Kustas, W., y Anderson, M. (2009). Advances in thermal infrared remote sensing for land surface modeling. *Agricultural and Forest Meteorology*, 149, 2071-2081. <https://doi.org/10.1016/j.agrformet.2009.05.016>
- Le Houérou H. N. (2001). Biogeography of the arid steppe land north of the Sahara. *Journal of Arid Environmental*, 48, 103-128. <https://doi.org/10.1006/jare.2000.0679>
- Liang, S., (2004). Quantitative Remote Sensing of Land Surfaces. ISBN: 9780471281665. Wiley & Sons, Hoboken, NJ, USA. <https://doi.org/10.1002/047172372X>
- Liang, S., Li, X., y Wang, J. (2012). Advanced Remote Sensing. Amsterdam: Academic Press. <http://dx.doi.org/10.1016/C2010-0-67304-4>
- Linares-Fleites, G., Tenorio, M. G., Torres, E., y Oroza, H. A. A. (2017). Estimación del carbono orgánico en suelos por teledetección y modelos de regresión. *Revista Latinoamericana el Ambiente y las Ciencias*, 8(18), 26-40. <https://rlac.buap.mx/sites/default/files/8%2818%29-3.pdf>

- Lloyd, J., y Taylor, J. (1994). On the temperature-dependence of soil respiration. *Functional Ecology*, 8(3), 315–323. <https://doi.org/10.2307/2389824>
- Luna-Luna, M., Britton, C. M., Rideout-Hanzak, S., Villalobos, C., Sosebee, R. E., y Wester, D. B. (2014). Season and intensity of burning on two grass species of the Chihuahuan desert. *Rangeland Ecology and Management*, 67(6), 614–620. <https://doi.org/10.2111/REM-D-13-00156.1>
- Maestre, F. T. (2004). On the importance of patch attributes, abiotic factors and past human impacts as determinants of plant species richness and diversity in Mediterranean semi-arid steppes. *Diversity and Distributions*, 10, 21–29. <https://maestrelab.com/wp-content/uploads/2015/10/dad2004.pdf>
- Maestre, F. T., Ramirez, D., y Cortina, J. (2007). Ecología del esparto (*Stipa tenacissima* L.) y los espartales de la Península Ibérica. *Ecosistemas*, 16(2), 111–130. <https://www.researchgate.net/publication/39439901>
- Margulis, S., y L. Huning. (2015). A coupled e-textbook and modular watershed model for hydrology education, CUASHI Virtual Workshop on Data-Driven Hydrology Education
- McCallum, I., Wagner, W., Schmulilius, C., Shvidenko, A., Obersteiner, M., Fritz, S., y Nilsson, S. (2009). Satellite-based terrestrial production efficiency modeling. *Carbon Balance and Management*, 4, 1–14. <https://doi.org/10.1186/1750-0680-4-8>
- McMillen, R. T. (1988). An Eddy-Correlation technique with extended applicability to non-simple terrain. *Boundary-Layer Meteorology*, 43, 231–245. <https://link.springer.com/article/10.1007/BF00128405>
- Medlyn, B.E., Duursma, R.A., Eamus, D., Ellsworth, D.S., Prentice, I.C., Barton, C.V., Crous, K.Y., De Angelis, P., Freeman, M., y Wingate, L. (2011). Reconciling the optimal and empirical approaches to modelling stomatal conductance. *Global Change Biology*, 17(6), 2134–2144. <https://doi.org/10.1111/j.1365-2486.2010.02375.x>
- Ministerio de Agricultura, Pesca y Alimentación (MAPA). (2006). Red de Monitorización de los Flujos de Carbono en Ecosistemas Mediterráneos Españoles Cuantificación y estudio de procesos (CARBORED-II). Obtenido de <https://www.ceam.es/CARBOREDII/paginas/estaciones/Balsablanca.htm>
- Ministerio de Agricultura, Pesca y Alimentación (MAPA). (2023a). Encuesta sobre superficies y rendimientos de Cultivos (ESYRCE). Obtenido de https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/boletin20231_tcm30-690544.pdf
- Ministerio de Agricultura, Pesca y Alimentación (MAPA). (2023b). Definiciones y usos de suelo en la encuesta sobre superficies y rendimientos de cultivos (ESYRCE). Obtenido de

<https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/definicionesesyrcetcm30-122349.pdf>

- Miralles, D. G., Jiménez, C., Jung, M., Michel, D., Ershadi, A., McCabe, M. F., Hirschi, M., Martens, B., Dolman, A. J., Fisher, J. B., Mu, Q., Seneviratne, S. I., Wood, E. F., y Fernández-Prieto, D. (2016). The WACMOS-ET project – Part 2: Evaluation of global terrestrial evaporation data sets. *Hydrology and Earth System Sciences*, 20(2), 823–842, <https://doi.org/10.5194/hess-20-823-2016>
- Moran, M. (2004). Thermal infrared measurement as an indicator of plant ecosystem health, in: Dale, A., Quattrochi, D., Luvall, J.C. (Eds.), *Thermal Remote Sensing in Land Surface Processing*. CRC Press, pp. 257-282. <https://doi.org/10.1201/9780203502174>
- Morillas, L., Garcia, M., Nieto, H., Villagarcia, L., Sandholt, I., Gonzalez-Dugo, M.P., Zarco-Tejada, P. J., y Domingo, F. (2013a). Using radiometric surface temperature for surface energy flux estimation in Mediterranean drylands from a two-source perspective. *Remote Sensing of Environment*, 136, 234-246. <http://dx.doi.org/10.1016/j.rse.2013.05.010>
- Morillas, L., R. Leuning, L. Villagarcia, M. Garcia, P. Serrano-Ortiz y F. Domingo. (2013b). Improving evapotranspiration estimates in Mediterranean drylands: The role of soil evaporation. *Water Resources Research*, 49(10), 6572–6586. <https://doi.org/10.1002/wrcr.20468>
- Mualem, Y. (1976). A new model for predicting the hydraulic conductivity of unsaturated porous media. *Water Resources Research*, 12(3), 513–522. <https://doi.org/10.1029/WR012i003p00513>
- Myneni, R. B., y Williams, D. L. (1994). On the relationship between FAPAR and NDVI. *Remote Sensing of Environment*, 49(3), 200–211. [https://doi.org/10.1016/0034-4257\(94\)90016-7](https://doi.org/10.1016/0034-4257(94)90016-7)
- NASA Jet Propulsion Laboratory (JPL). (2018). ECOSTRESS Science Data Products Product Specification Document (PSD) Level 3 PT-JPL, Version 4. Obtenido de https://ecostress.jpl.nasa.gov/downloads/psd/ECOSTRESS_SDS_PSD_L3_PT-JPL_v4.pdf
- Noilhan, J., y Mahfouf, J. F. (1996). The ISBA land surface parameterisation scheme. *Global and Planetary Change*, 13(1-4), 145–159. [https://doi.org/10.1016/0921-8181\(95\)00043-7](https://doi.org/10.1016/0921-8181(95)00043-7)
- Noilhan, J., y Mahfouf, J. F. (1996). The ISBA land surface parameterisation scheme. *Global and Planetary Change*, 13(1-4), 145–159, [https://doi.org/10.1016/0921-8181\(95\)00043-7](https://doi.org/10.1016/0921-8181(95)00043-7)
- Noilhan, J., y Planton, S. (1989). A simple parameterization of land surface processes for meteorological models. *Monthly Weather Review*, 117(3), 536-549. [https://doi.org/10.1175/1520-0493\(1989\)117<0536:ASPOLS>2.0.CO;2](https://doi.org/10.1175/1520-0493(1989)117<0536:ASPOLS>2.0.CO;2)
- Norman, J. M., Kustas, W. P., y Humes, K. S. (1995). Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature.

Agricultural and Forest Meteorology, 77(3-4), 263–293. [https://doi.org/10.1016/0168-1923\(95\)02265-Y](https://doi.org/10.1016/0168-1923(95)02265-Y)

Pateromichelaki, I. M. (2020). Modelling of interactions within the soil-vegetation-atmosphere continuum in a coffee plantation in Costa Rica. Technical University of Denmark, Department of Environmental Engineering.

Plataforma Tierra. (2023, 23 de noviembre). La agricultura, ganadería y pesca emiten el 63% del metano y óxido nitroso en España. <https://www.plataformatierra.es/actualidad/agricultura-ganaderia-pesca-emiten-63-metano-oxido-nitroso-espana>

Potter, C. S., Randerson, J. T., Field, C. B., Matson, P. A., Vitousek, P. M., Mooney, H. A., y Klooster, S. A. (1993). Terrestrial ecosystem production: A process model based on global satellite and surface data. *Global Biogeochemical Cycles*, 7(4), 811–841. <https://doi.org/10.1029/93GB02725>

Priestley, C. H. B., y Taylor, R. J. (1972). On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly Weather Review*, 100, 81–92. [https://doi.org/10.1175/1520-0493\(1972\)100<0081:OTAOSH>2.3.CO;2](https://doi.org/10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2)

Pugnaire, F. I., Haase, P., Incoll, L., y Clark, S.C. (1996). Response of tussock grass *Stipa tenacissima* to watering in a semi-arid environment. *Functional Ecology*, 10, 265–274. <https://www.jstor.org/stable/2389852>

Pugnaire, F. I., y Haase, P. (1996). Comparative physiology and growth of two perennial tussock grass species in a semi-arid environment. *Annals of Botany*, 77, 81–86. <https://doi.org/10.1006/anbo.1996.0010>

Puigdefábregas, J., Solé-Benet, A., Gutiérrez, L., Del Barrio, G., y Boer, M. (1999). Scales and processes of water and sediment redistribution in drylands: results from the Rambla Honda field site in Southeast Spain. *Earth-Science Reviews*, 48, 39–70. [http://www.eeza.csic.es/Documentos/Publicaciones/Puigdefabregas-et al\(ESR-1999\).pdf](http://www.eeza.csic.es/Documentos/Publicaciones/Puigdefabregas-et al(ESR-1999).pdf)

Ramírez, D. A. (2006). Estudio de la transpiración del esparto (*Stipa tenacissima* L.) en una cuenca del semiárido alicantino: un análisis pluriescalar. Tesis doctoral. Universidad de Alicante, Alicante.

Ramírez, D. A., Bellot, J., Domingo, F., y Blasco, A. (2007). Can water responses in *Stipa tenacissima* L. during the summer season be promoted by non-rainfall water gains in soil? *Plant and Soil*, 291, 67–79. <https://doi.org/10.1007/s11104-006-9175-3>

Reddy, M. N., y Rao, N. H. (1994). GIS Based Decision Support Systems in Agriculture. *National Academy of Agricultural Research Management*. pp 1–11. <https://www.researchgate.net/publication/240617973>.

Reichstein, M., Falge, E., Baldocchi, D., Papale, D., Aubinet, M., Berbigier, P., Bernhofer, C.,

Buchmann, N., Gilmanov, T., Granier, A., Grünwald, T., Havránková, K., Ilvesniemi, H., Janous, D., Knohl, A., Laurila, T., Lohila, A., Loustau, D., Matteucci, G., Meyers, T., Miglietta, F., Ourcival, J., Pumpanen, J., Rambal, S., Rotenberg, E., Sanz, M., Tenhunen, J., Seufert, G., Vaccari, F., Vesala, T., Yakir, D., y Valentini, R. (2005). On the separation of net ecosystem exchange into assimilation and ecosystem respiration: review and improved algorithm. *Global Change Biology*, 11(9), 1424–1439. <https://doi.org/10.1111/j.1365-2486.2005.001002.x>

Rejos, F. J. (2000). La Atocha (*Stipa tenacissima* Loefl. ex L.) en el centro peninsular: aspectos vegetativos y reproductivos. Tesis Doctoral, Universidad de Alcalá.

Rey, A., Pegoraro, E., Oyonarte, C., Were, A., Escribano, P., y Raimundo, J. (2011), Impact of land degradation on soil respiration in a steppe ecosystem in the SE of Spain, *Soil Biology and Biochemistry*, 43, 393–403, <https://doi.org/10.1016/j.soilbio.2010.11.007>

Romano, N., Palladino, M., y Chirico, G. B. (2011). Parameterization of a bucket model for soil-vegetation-atmosphere modeling under seasonal climatic regimes. *Hydrology and Earth System Sciences*, 15(12), 3877–3893, <https://doi.org/10.5194/hess-15-3877-2011>

Ross, J. (1976). Radiative transfer in plant communities. In J. L. Monteith (Ed.), *Vegetation and the atmosphere* (pp. 13–56). London: Academic Press.

Ruimy, A., Kergoat, L., y Bondeau, A. (1999). Comparing global models of terrestrial net primary productivity (NPP): Analysis of differences in light absorption and light-use efficiency. *Global Change Biology*, 5(1), 56–64. <https://doi.org/10.1046/j.1365-2486.1999.00007.x>

Running, S. W., Nemani, R. R., Heinsch, F. A., Zhao, M., Reeves, M., y Hashimoto, H. (2004). A continuous satellite-derived measure of global terrestrial primary production. *Bioscience*, 54(6), 547. [https://doi.org/10.1641/0006-3568\(2004\)054\[0547:ACSMOG\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2004)054[0547:ACSMOG]2.0.CO;2)

Sánchez, G. (1995). Arquitectura y dinámica de las matas de esparto (*Stipa tenacissima* L.), efectos en el medio e interacciones con la erosión. Tesis Doctoral. Universidad Autónoma de Madrid.

Sanz, E., Almeida-Ñaulay, A. F., Díaz-Ambrona, C. G. H., Mínguez, S. Z., y Tarquis, A. M. (2024). Joint multiscale dynamics in soil–vegetation–atmosphere systems: Multifractal cross-correlation analysis of arid and semiarid rangelands. *Vadose Zone Journal*, e20374. <https://doi.org/10.1002/vzj2.20374>

Savitzky, A., y Golay, M. J. E. (1964). Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*, 36(8), 1627–1639. <https://doi.org/10.1021/ac60214a047>

Sharma, R., Kamble, S. S., y Gunasekaran, A. (2018). Big GIS analytics framework for agriculture supply chains: A literature review identifying the current trends and future perspectives. *Computers and Electronics in Agriculture*, 155, 103–12.

<https://doi.org/10.1016/j.compag.2018.10.001>.

- Shi, Y., Zhang, J., Reid, J. S., Liu, B., y Deshmukh, R. (2012). Critical evaluation of cloud contamination in MISR aerosol product using collocated MODIS aerosol and cloud products. *American Geophysical Union*, A13J-0310. Obtained from: <https://ui.adsabs.harvard.edu/abs/2012AGUFM.A13J0310S/abstract>
- Sishodia, R. P., Ray, R. L., y Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing of Environment*, 12(19), 3136. <https://doi.org/10.3390/rs12193136>
- Soussana, J. F., Tallec, T., y Blanfort, V. (2010). Mitigating the greenhouse gas balance of ruminant production systems through carbon sequestration in grasslands. *Animal*, 4(3):334-350.
- Stisen, S., McCabe, M. F., Refsgaard, J. C., Lerer, S., y Butts, M. B. (2011). Model parameter analysis using remotely sensed pattern information in a multi-constraint framework. *Journal of Hydrometeorology*, 409(1-2), 337-349. <https://doi.org/10.1016/j.jhydrol.2011.08.030>
- Townshend, J.R.G., Justice, C.O., Skole, D., Malingreau, J.P., Cihlar, J., Teillet, P., Sadowski, F., y Ruttenberg, S. (1994). The 1 km resolution global data set: needs of the International Geosphere Biosphere Programme. *International Journal of Remote Sensing*, 15, 3417-3441. <https://doi.org/10.1080/01431169408954338>
- Twine, T. E., Kustas, W. P., Norman, J. M., Cook, D. R., Houser, P.R., Meyers, T. P., Prueger, J. H., Starks, P. J., y Wesely, M. L. (2000). Correcting eddy-covariance flux underestimates over a grassland. *Agricultural and Forest Meteorology*, 103(3), 279-300. [https://doi.org/10.1016/S0168-1923\(00\)00123-4](https://doi.org/10.1016/S0168-1923(00)00123-4)
- Usha, K., y Singh, B. (2013). Potential applications of remote sensing in horticulture—A review. *Scientia Horticulturae*, 153, 71-83. <https://doi.org/10.1016/j.scienta.2013.01.008>
- Valladares, F., y Pugnaire, F. I. (1999). Tradeoffs between irradiance capture and avoidance in semi-arid environments assessed with a crown architecture model. *Annals of Botany*, 83, 459-469. <https://doi.org/10.1006/anbo.1998.0843>
- Valletine, J. F. (1990). Grazing management. San Diego, USA: Academic Press Inc.
- Van De Griend, A., A., y Owe, M. (1993). On the Relationship between Thermal Emissivity and the Normalized Difference Vegetation Index for Nature Surfaces *International Journal of Remote Sensing*, 14(6), 1119-1131. <https://doi.org/10.1080/01431169308904400>
- van den Hurk, B. J. J. M., Jia, L., Jacobs, C., Menenti, M., y Li, Z. L. (2002). Assimilation of land surface temperature data from ATSR in an NWP environment--a case study. *International Journal of Remote Sensing*, 23(24), 5193-5209. <https://doi.org/10.1080/01431160110107770>

- van Genuchten, M. T. (1980). A Closed-form Equation for Predicting the Hydraulic Conductivity of Unsaturated Soils. *Soil Science Society of America Journal*, 44(5), 892–898. <https://doi.org/10.2136/sssaj1980.03615995004400050002x>
- Vezy, R., le Maire, G., Christina, M., Georgiou, S., Imbach, P., Hidalgo, H. G., Alfaro, E. J., Blitz-Frayret, C., Charbonnier, F., Lehner, P., Loustau, D., y Roupsard, O. (2020). Dynacof: A process-based model to study growth, yield and ecosystem services of coffee agroforestry systems. *Environmental Modelling and Software*, 124, 104609. <https://doi.org/10.1016/j.envsoft.2019.104609>
- Vinukollu, R. K., Meynadier, R., Sheffield, J., y Wood, E. F. (2011). Multi-model, multi-sensor estimates of global evapotranspiration: climatology, uncertainties and trends. *Hydrological Processes*, 25, 3993–4010. <https://doi.org/10.1002/hyp.8393>
- Vlassova, L. (2016). Land Surface Temperature (LST) estimated from Landsat images: applications in burnt areas and tree-grass woodlands (dehesas). Tesis doctoral, Departamento de Geografía y Ordenación del Territorio, Universidad de Zaragoza. <https://zaguan.unizar.es/record/48313/files/TESIS-2016-108.pdf>
- Wang, S., Baum, A., Zarco-Tejada, P. J., Dam-Hansen, C., Thorseth, A., Bauer-Gottwein, P., Bandini, F., y Garcia, M. (2019b). Unmanned Aerial System multispectral mapping for low and variable solar irradiance conditions: Potential of tensor decomposition. *ISPRS Journal of Photogrammetry and Remote Sensing*, 155, 58–71. <https://doi.org/10.1016/j.isprsjprs.2019.06.017>
- Wang, S., Garcia, M., Bauer-Gottwein, P., Jajobse, J., Zarco-Tejada, P. J., Bandini, F., Paz, V. S., y Ibrom, Andreas. (2019a). High spatial resolution monitoring land surface energy, water and CO₂ fluxes from an Unmanned Aerial System. *Remote Sensing of Environment*, 229, 14-31, <https://doi.org/10.1016/j.rse.2019.03.040>
- Wang, S., Garcia, M., Ibrom, A., Jakobsen, J., Josef Köppl, C., Mallick, K., Looms, M., y Bauer-Gottwein, P. (2018b). Mapping Root-Zone Soil Moisture Using a Temperature–Vegetation Triangle Approach with an Unmanned Aerial System: Incorporating Surface Roughness from Structure from Motion. *Remote Sensing of Environment*, 10(12), 1978. <https://doi.org/10.3390/rs10121978>
- Wang, S., Garcia, M., Ibrom, A., y Bauer-Gottwein, P. (2020). Temporal interpolation of land surface fluxes derived from remote sensing – results with an unmanned aerial system. *Hydrology and Earth System Sciences*, 24, 3643–3661, <https://doi.org/10.5194/hess-24-3643-2020>
- Wang, S., Ibrom, A., Bauer-Gottwein, P., y Garcia, M. (2018a). Incorporating diffuse radiation into a light use efficiency and evapotranspiration model: An 11-year study in a high latitude deciduous forest. *Agricultural and Forest Meteorology*, 248, 479–493. <https://doi.org/10.1016/j.agrformet.2017.10.023>

- Webb, E. K., Pearman, G. I., y Leuning, R. (1980). Correction of flux measurements for density effects due to heat and water-vapor transfer. *Quarterly Journal of the Royal Meteorological Society*, 106, 85–100. <https://doi.org/10.1002/qj.49710644707>
- Wei, Z., Du, T., Li, X., Fang, L., y Liu, F. (2018). Simulation of stomatal conductance and water use efficiency of tomato leaves exposed to different irrigation regimes and air CO₂ concentrations by a modified “Ball-Berry” model. *Frontiers in Plant Science*, 9, 445. <https://doi.org/10.3389/fpls.2018.00445>
- Weiss, M., Jacob, F., y Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402. <https://doi.org/10.1016/j.rse.2019.111402>
- Wheeler, T., y von Braun, J. (2013). Climate change impacts on global food security. *Science*, 341(6145), 508-513. <https://doi.org/10.1126/science.1239402>
- Wild, M. (2005). Solar radiation budgets in atmospheric model intercomparisons from a surface perspective. *Geophysical Research Letters*, 32(7). <https://doi.org/10.1029/2005GL022421>
- Wilson, K., Goldstein, A., Falge, E., Aubinet, M., Baldocchi, D., Berbigier, P., Bernhofer, C., Ceulemans, R., Dolman, H., Field, C., Grelle, A., Ibrom, A., Law, B. E., Kowalski, A., Meyers, T., Moncrieff, J., Monson, R., Oechel, W., Tenhunen, J., Valentini, R., y Verma, S. (2002). Energy balance closure at FLUXNET sites, *Agricultural and Forest Meteorology*, 113, 223–243. [https://doi.org/10.1016/S0168-1923\(02\)00109-0](https://doi.org/10.1016/S0168-1923(02)00109-0)
- Yuan, W., Liu, S., Yu, G., Bonnefond, J.-M., Chen, J., Davis, K., Desai, A. R., Goldstein, A. H., Gianelle, D., Rossi, F., Suyker, A. E., y Verma, S. B. (2010). Global estimates of evapotranspiration and gross primary production based on MODIS and global meteorology data. *Remote Sensing of Environment*, 114, 1416–1431. <https://doi.org/10.1016/j.rse.2010.01.022>
- Zarco-Tejada, P.J., Rueda, C.A., y Ustin, S.L. (2003). Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*, 85(1), 109-124. [https://doi.org/10.1016/S0034-4257\(02\)00197-9](https://doi.org/10.1016/S0034-4257(02)00197-9)
- Zermeño-González, A., Ríos-Estudillo, J. A., Gil, M. J. A., Cadena-Zapata, M., y Villarreal-Quintanilla, J. A. (2011). Dinámica del flujo de carbono y de energía sobre un pastizal natural del norte de México. *Bioagro*, 23(1), 35-42. <https://www.redalyc.org/articulo.oa?id=85719247005>
- Zhang, J., y Guo, F. (2009). "The Study in Photovoltaic Control System Based on FPGA," 2009 International Conference on Research Challenges in Computer Science, Shanghai, China. pp. 172-173. <https://doi.org/10.1109/ICRCCS.2009.51>

- Zhang, Y., Chiew, F. H. S., Zhang, L., y Li, H. (2009). Use of remotely sensed actual evapotranspiration to improve rainfall-runoff modeling in Southeast Australia. *Journal of Hydrometeorology*, 10, 969–980. <https://doi.org/10.1175/2009JHM1061.1>
- Zhang, Y., Leuning, R., Hutley, L. B., Beringer, J., McHugh, I., y Walker, J. P. (2010). Using long-term water balances to parameterize surface conductances and calculate evaporation at 0.05 spatial resolution. *Water Resources Research*, 46(5), W05512. <https://doi.org/10.1029/2009WR008716>
- Zheng, Y., Albergel, C., Munier, S., Bonan, B., y Calvet, J.-C. (2020). An offline framework for high-dimensional ensemble Kalman filters to reduce the time to solution. *Geoscientific Model Development*, 13(8), 3607–3625. <https://doi.org/10.5194/gmd-13-3607-2020>
- Zhou, Y., Wu, X., Ju, W., Chen, J. M., Wang, S., Wang, H., Yuan, W., Andrew, T. B., Jassal, R., Ibrom, A., Han, S., Yan, J., Margolis, H., Rouspard, O., Li, Y., Zhao, F., Kiely, G., Starr, G., Pavelka, M., Montagnani, L., Wohlfahrt, G., D'Odorico, P., Cook, D., Arain, M. A., Bonal, D., Beringer, J., Blanken, P. D., Loubet, B., Leclerc, M. Y., Matteucci, G., Nagy, Z., Olejnik, J., Paw, K. T. U., y Varlagin, A. (2015). Global parameterization and validation of a two-leaf light use efficiency model for predicting gross primary production across FLUXNET sites. *Journal of Geophysical Research: Biogeosciences*, 121(4), 1045–1072. <https://doi.org/10.1002/2014JG002876>

