

UNIVERSIDAD DE COSTARICA
SISTEMA DE ESTUDIOS DE POSGRADO

**“CARACTERIZACIÓN DE LA EFICIENCIA EN EL USO DEL
AGUA EN EL CULTIVO DE CAFÉ A PARTIR DEL USO DE LA
TÉCNICA DE COVARIANZA DE FLUJO”**

Tesis sometida a la consideración de la Comisión del Programa de Estudios de Posgrado en Geografía para optar al grado y título de Maestría Académica en Gestión Integrada del Recurso Hídrico para América Latina y el Caribe

DANIA MARÍA ZÚÑIGA HERRERA

B27463

Ciudad Universitaria Rodrigo Facio, Costa Rica

2024

Dedicatoria

Le dedico este trabajo especialmente a Dios y a mi familia que siempre me han apoyado en mis estudios.

A mis amigas que siempre han estado dándome porras y motivándome a continuar: Susana Molina, Melissa Castro, Gabriela Castro, Gina Miranda y Yessenia Brizuela, Priscila Obando.

A la Dra. Cristina Chinchilla, quién me ha apoyado siempre y fue la impulsora en que me gustara el tema de modelación y recurso hídrico y por la cual me incentivó a matricular la Maestría.

A la Dra. Ana Durán, quién sin su apoyo no hubiera logrado desarrollar este trabajo y quién me enseñó la importancia de creer en mí misma y que si se podía a pesar de las dificultades en el proceso.

“La perseverancia es la clave del éxito” (Thomas Edison)

Agradecimientos

Un especial agradecimiento a la Dra. Ana Durán, quién me dio la oportunidad de participar en el proyecto de investigación y su apoyo durante todo el proceso en la realización de este trabajo.

También a los miembros del comité la Dra. Cristina Chinchilla y el Dra. Marco Gutiérrez, por su indispensable guía en el desarrollo de la tesis.

A Mónica García quien facilitó el modelo SVEN y su apoyo en la modelación.

A la finca La Hilda y su comunidad y al Gerente MBA. Mariano Vargas por su colaboración en el proyecto.

A compañeras de la Universidad de Costa Rica, Raquel Ramírez quien me ayudó en temas de análisis de datos, Mayela Monge por su ayuda en temas técnicos y apoyo en campo y a mis compañeros de maestría.

Al laboratorio de eco fisiología de la Estación Experimental Fabio Baudrit, encargados del mantenimiento de equipos, mediciones en campo.

Al proyecto C0454 Flujos de Carbono y Eficiencia del Uso del Agua en agroecosistemas cafetaleros innovadores.

Al proyecto C361 Dinámica de la captura de carbono en agroecosistemas cafetaleros innovadores DiC2AFE.

Un gran agradecimiento a todos los docentes de la maestría, por mi formación profesional, que sin ellos no fuera sido posible cumplir esta meta.

Y sobre todo muchas gracias a mis familiares y amigos que han sido un gran soporte para culminar esta tesis.

“Esta tesis fue aceptada por la comisión del Programa de Estudios de Posgrado en Geografía de la Universidad de Costa Rica, como requisito parcial para optar al grado y título de Maestría Académica en Gestión Integrada del Recurso Hídrico para América Latina y el Caribe”

Luis Guillermo Artavia Rodríguez
Representante de la Decanatura
Sistema de Estudios de Posgrado

Dra. Ana María Durán Quesada
Directora de Tesis

Dra. Cristina Chinchilla, lectora
Asesora

Dr. Marco Gutiérrez Soto
Asesor

Dr. Christian Birkel Dostal
Representante del Director del Posgrado en Geografía

Licda. Dania Zúñiga Herrera
Candidata

Tabla de contenido

Resumen	vii
Abstract	viii
Capítulo 1. Introducción	1
Capítulo 2. Datos y métodos	12
2.1 Sitio de estudio	12
2.2. Datos y métodos	14
2.2.1. Datos e instrumentos	14
2.2.2. Técnica de covarianza de torbellino	15
2.2.3. Balance de energía	18
2.2.3.1. Cálculo de evapotranspiración	19
2.2.4. Índice de vegetación de diferencia normalizada	23
2.2.5. Cálculo de la altura del dosel	24
2.2.6. Radiación de onda larga entrante	25
2.2.7. Estimación de la eficiencia del uso del agua	29
2.2.8. Descripción del modelo SVEN	30
2.2.8.1. Parámetros del modelo	32
2.2.8.2. Evaluación y validación del modelo	35
2.2.9. Reconstrucción histórica	37
Capítulo 3. Balance de energía en superficie	38
3.1. Ciclo diario de los flujos de superficie e influencia de la advección en el desequilibrio del balance de energía:	39
3.3. Influencia de las condiciones de estabilidad atmosférica	44
3.4. Evapotranspiración	45
Capítulo 4. Estimación de la eficiencia del uso del agua	49

4.1.1. Eficiencia del uso del agua observada y simulada	55
Capítulo 5: Evaluación del Modelo SVEN	59
5.1. Validación de cada variable	60
Capítulo 6. Reconstrucción histórica	68
6.1. Análisis de tendencia	68
6.2. Análisis de tendencia la EUA simulada	75
Conclusiones	77
Recomendaciones	81
IX. Bibliografía	84
X. Anexos	98

Resumen

Esta tesis explora el análisis de la eficiencia en el uso del agua (EUA) en el cultivo de café mediante la aplicación de la técnica de covarianza de torbellino y el modelo de simulación SVEN. El estudio se realizó en la finca La Hilda, ubicada en San Pedro de Poás, Alajuela, Costa Rica, un sitio que presenta condiciones climáticas variadas para la producción de café. Se utilizaron datos en un lote de sol generados por medio de mediciones con la técnica de covarianza de torbellino como parte de los proyectos Flujos de Carbono y Eficiencia en el uso del agua en agroecosistemas cafetaleros innovadores (2020-2023) y Dinámica de la Captura de Carbono en agroecosistemas cafetaleros innovadores (2023-2024) con el fin de evaluar el balance de energía y el rendimiento del modelo SVEN para reproducir la relación observada entre la productividad primaria bruta (PPB) y la evapotranspiración (ET).

Los resultados muestran que la EUA en el lote de sol de La Hilda es moderadamente alta, con variaciones significativas influenciadas por factores como la temperatura, la humedad relativa y la velocidad del viento. La validación del modelo SVEN mostró limitaciones en su capacidad para estimar la EUA observada, presentando subestimación en ET y PPB, generada por la mala representación de los componentes de la radiación estimados por medio de información satelital.

Se realizó una reconstrucción histórica del periodo (2010-2022) a partir de los resultados del modelo para evaluar el comportamiento interanual en la eficiencia del uso del agua, factor crucial para la sostenibilidad del cultivo de café en el contexto de los impactos de la variabilidad y el cambio climático. Los hallazgos de esta investigación subrayan la importancia de integrar metodologías avanzadas para la cuantificación robusta de los flujos de evapotranspiración como la técnica de covarianza de torbellino y el modelado numérico en la gestión del recurso hídrico, para optimizar la productividad agrícola y generar información para la implementación de acciones para la resiliencia de la producción ante la ocurrencia de eventos extremos.

Palabras clave: eficiencia del uso del agua, lluvia, evapotranspiración, covarianza de torbellino, modelo SVEN, cambio climático, variabilidad climática, cultivo de café.

Abstract

This thesis explores the analysis of water use efficiency (WUE) in coffee cultivation by applying the eddy covariance technique and the SVEN simulation model. The study was carried out at La Hilda farm, located in San Pedro de Poás, Alajuela, Costa Rica, a site that presents varied climatic conditions for coffee production. Data were used in a solar plot generated through measurements with the eddy covariance technique as part of the projects Carbon Fluxes and Water Use Efficiency in Innovative Coffee Agroecosystems (2020-2023) and Carbon Capture Dynamics in Innovative Coffee Agroecosystems (2023-2024) in order to evaluate the energy balance and the performance of the SVEN model to reproduce the observed relationship between gross primary productivity (GPP) and evapotranspiration (ET).

The results show that the WUE at the solar plot in La Hilda is moderately high, with significant variations influenced by factors such as temperature, relative humidity and wind speed. The validation of the SVEN model showed limitations in its capacity to estimate the observed EUA, presenting underestimation in ET and PPB, generated by the poor representation of the radiation components estimated by means of satellite information.

A historical reconstruction of the period (2010-2022) was carried out based on the results of the model to evaluate interannual behavior in the efficiency of water use, a crucial factor for the sustainability of coffee cultivation in the context of the impacts of variability and climate change. The findings of this research underline the importance of integrating advanced methodologies for the robust quantification of evapotranspiration fluxes such as the eddy covariance technique and numerical modeling in water resource management, to optimize agricultural productivity and generate information for the implementation of actions for production resilience in the event of extreme events.

Keywords: water use efficiency, rain, evapotranspiration, eddy covariance, SVEN model, climate change, climate variability, coffee cultivation.

Lista de Tablas

Tabla 1. Datos históricos de cosecha en fanegas por hectárea del lote de sol, finca La Hilda	14
Tabla 2. Tipos de evapotranspiración	20
Tabla 3. Altura del dosel de plantas de café en el lote de sol,2022	25
Tabla 4.Descripción de condiciones iniciales y datos de entrada del modelo SVEN	33
Tabla 5. <i>Parámetros del modelo SVEN según literatura</i>	34
Tabla 6. Cierre de balance energético (EMC) obtenido de regresión lineal ordinaria, bajo diferentes condiciones de estabilidad atmosférica y EBR promedio durante 2020-2021. ..	45
Tabla 7. Desempeño del modelo SVEN a diferentes escalas de tiempo, 2020-2021.....	60

Lista de Figuras

Figura 1. Impactos directos proyectados para el cultivo del café resultado de la variabilidad climática.....	2
Figura 2. Sitio de estudio Finca la Hilda, San Pedro de Poás, Alajuela	12
Figura 3. <i>Índice de vegetación de diferencia normalizada, en finca La Hilda, 2010-2022</i>	24
Figura 4. <i>Comparación de métodos de cálculo de radiación de onda larga entrante (LW_{in}), en la finca La Hilda, 2010-2022.</i>	27
Figura 5. <i>Fracción de nubes diaria, del periodo 2010-2022, Finca La Hilda</i>	28
Figura 6. <i>Radiación de onda larga entrante (LW_{in}) diarios en W/m^2, en la finca La Hilda, 2010-2022.</i>	28
Figura 7. Descripción general de los procesos de la superficie terrestre simulados por el modelo SVEN.....	31
Figura 8. Módulos y submódulos del modelo SVEN.....	32
Figura 9. Datos de entrada, condiciones iniciales, parámetros y salidas del Modelo SVEN.	35
Figura 10. Ciclo diurno en finca La Hilda de Poás, Alajuela periodo 2020-2021.....	40
Figura 11. Advección y parámetro de estabilidad 2020-2021.	41

Figura 12. Cierre de balance de energía agregado mensual (EBC) para el periodo 2020-2021.	42
Figura 13. <i>Comparación de la evapotranspiración (mm/mensual) estimada mediante tres métodos durante el periodo 2010-2022 de datos de la estación meteorológica Davis Vantage Pro2 Plus.</i>	47
Figura 14. Comparación de los métodos de cálculo de ET estimada y ET con el de la técnica de covarianza de torbellino (EC) en el periodo de estudio 2020-2021 a escala mensual.	48
Figura 15. Temperatura del aire diaria en °C, radiación neta diaria en % y humedad relativa diaria en % para el año 2020 y 2021 en la finca La Hilda.	51
Figura 16. Precipitación mensual del 2020 y 2021, en la finca La Hilda.	52
Figura 17. <i>Ciclo anual de la eficiencia del uso del agua en la finca La Hilda, 2020-2021.</i>	53
Figura 18. Comportamiento de EUA observada y simulada por el Modelo SVEN, periodo 2020-2021 a escala mensual.	56
Figura 19. Comportamiento de EUA observada y simulada por el Modelo SVEN, por mes del periodo 2020-2021.	57
Figura 20. Diagramas de dispersión de datos observados y simulados, del periodo 2020-2021 a escala media hora de las variables temperatura del suelo, radiación neta, flujo de calor latente y sensible, productividad primaria bruta y evapotranspiración.	61
Figura 21. Comparación de datos observados y simulados de la temperatura del suelo (Kelvin), del periodo 2020-2021 a escala diaria.	62
Figura 22. Comparación de datos observados y simulados de la radiación neta (W/m^2), del periodo 2020-2021 a escala diaria.	63
Figura 23. Comparación de datos observados y simulados de flujo de calor latente (W/m^2), del periodo 2020-2021 a escala diaria.	64
Figura 24. <i>Comparación de datos observados y simulados de flujo de calor sensible (W/m^2), del periodo 2020-2021 a escala diaria.</i>	65
Figura 25. Comparación de datos observados y simulados de productividad primaria neta ($G\ cm^2/día$), del periodo 2020-2021 a escala diaria.	66
Figura 26. Comparación de datos observados y simulados de evapotranspiración (mm), del periodo 2020-2021 a escala diaria.	67

Figura 27. <i>Reconstrucción histórica de las variables simuladas radiación neta, flujo de calor latente, evapotranspiración, productividad primaria bruta, flujo de calor sensible y temperatura del suelo, durante el periodo 2010-2022.</i>	69
Figura 28. Comportamiento de la radiación neta (RN) simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.	70
Figura 29. Comportamiento de la LE simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.....	71
Figura 30. Comportamiento de ET simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.	72
Figura 31. <i>Comportamiento de H simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.</i>	73
Figura 32. Comportamiento de la PPB simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.....	74
Figura 33. Comportamiento de la EUA simulada por el Modelo SVEN del periodo 2010-2022 a escala diaria.....	75

Lista de abreviaturas

- CATIE: Centro Agronómico Tropical de Investigación y Enseñanza.
- EUA: Eficiencia del uso del agua.
- ESA: Agencia Espacial Europea.
- ENOS: El Niño Oscilación del Sur.
- FAO: Organización de las Naciones Unidas para la Alimentación y la Agricultura.
- IAEA: Organismo Internacional de Energía Atómica.
- ICAFE: Instituto del café de Costa Rica.
- IICA: Instituto Interamericano de Cooperación para la Agricultura.
- MINAE: Ministerio del Ambiente y Energía.
- MODIS: Moderate Resolution Imaging Spectroradiometer.
- NDVI: Índice de vegetación de diferencia normalizada.
- ONU: Organización de las Naciones Unidas.
- ODS: Objetivos del desarrollo sostenible.
- SVEN: Modelo de transferencia de suelo, vegetación, energía, agua y CO₂.
- SENTINEL: Satélite del programa Copérnico.

Capítulo 1. Introducción

El café se produce en más de 50 países alrededor del mundo y es uno de los cultivos de mayor importancia socioeconómica en Costa Rica, además de estar estrechamente relacionada con su identidad cultural (Instituto del café de Costa Rica [ICAFFE], 2021). El cultivo se introdujo en América en 1720 y durante el siglo XVIII fue introducido al país. El café se desarrolló como un producto de exportación a partir de 1840, caracterizado por su alta calidad y reputación a nivel nacional e internacional (Alvarado y Rojas, 2007). El cultivo del café es considerado de importancia en la economía mundial, ya que se valora como un producto básico y uno de los productos más comercializados, con Brasil, Vietnam, Colombia e Indonesia como los principales productores a nivel mundial (ICAFFE, 2022). A nivel global se discute sobre las perspectivas de la producción cafetalera en el contexto del calentamiento global y la necesidad de generar información para afrontar los retos de la producción bajo condiciones de calentamiento e impactos de la variabilidad y el cambio climático.

El grano de café es la semilla de un arbusto tropical de hojas verdes, denominado cafeto. Este pertenece a la familia de las Rubiáceas y al género *Coffea*, las especies más conocidas son *Coffea Arábica L.*, *Canephora* y *Liberica*, y algunas variedades son Caturra, Catuaí, entre otras (Díaz, 2018; Ferreira et al., 2019). La floración es el comienzo de la fase reproductiva del cafeto (Urbaz et al., 2015), los botones florales aparecen generalmente en el tercer año del establecimiento del cultivo y alcanza su plenitud en el cuarto o quinto año, además la floración comprende varias etapas como la inducción, la diferenciación, el crecimiento y desarrollo, la latencia y la antesis o apertura floral (DaMatta et al., 2007; Peña et al., 2011; Urbaz et al., 2015). La planta de café presenta una floración fotoperiódica (días cortos) e hidro periódica (Peña et al., 2011). El fruto es de pulpa delgada, superficie lisa y brillante, constituido de tres partes: epicarpio o epidermis, el mesocarpio o pulpa y el endosperma o semilla (Alvarado y Rojas, 2007). Tiene cinco etapas de desarrollo como: división celular, fase de enlongación celular, crecimiento suspendido donde se alcanza el máximo tamaño del fruto y la tasa de crecimiento decrece, la fase de llenado del endospermo y la maduración donde ocurre el cambio de color (DaMatta et al., 2007).

El cultivo del café depende de condiciones ambientales determinadas, como la temperatura en superficie, la precipitación, el viento, la humedad relativa y factores físico-geográficos, como la altitud, para su adecuado desarrollo (Camargo, 2010; Bunn et al., 2015; Ovalle, 2018). Sin embargo, estas condiciones son afectadas significativamente como resultado del calentamiento global, con cambios en los patrones de precipitación y aumento de la temperatura que repercuten directamente al ciclo del cultivo (Ovalle, 2015). Algunos impactos directos proyectados para el cultivo del café resultado del calentamiento global se evidencian en la figura 1, entre los que destacan altas temperaturas, cambios en los patrones de precipitación como lluvias intensas o repentinas, así como condiciones de sequía, lo que puede afectar el suministro de agua y la disponibilidad de nutrientes para las plantas de café (Ovalle, 2015; DaMatta, 2018).

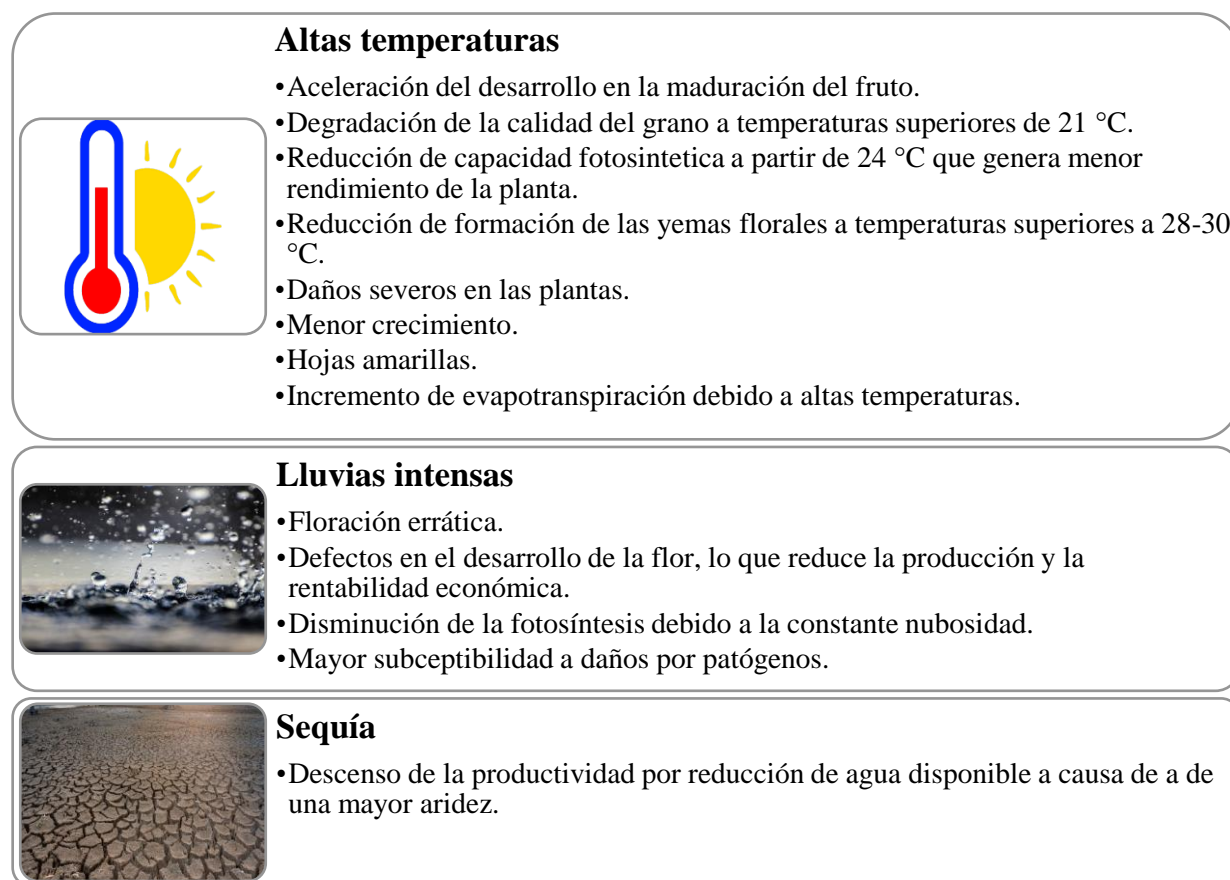


Figura 1. Impactos directos proyectados para el cultivo del café resultado de la variabilidad climática.

Fuentes: (Camargo, 2010; Hagggar y Schepp, 2015; Bunn et al., 2015; Ovalle, 2015; Byrareddy et al., 2020).

Las alteraciones en la temperatura y la precipitación también generan efectos como el aumento o aparición de enfermedades y plagas, que pueden afectar el rendimiento y distribución de los cultivos, cambios en los precios, producción y consumo (Wiebe et al., 2015; Blanc y Reilly, 2017). Los impactos proyectados se extienden a diferentes sectores y afectan el bienestar de las familias productoras (Centro Agronómico Tropical de Investigación y Enseñanza [CATIE], 2017; Imbach et al., 2018). Un ejemplo de estas afectaciones es el caso de las crisis de la roya (causado por el hongo *Hemileia vastratix*) en Centroamérica, que alcanzó su punto máximo entre los años 2012 y 2014. Esta crisis afectó gravemente los cultivos de café, impactando significativamente la producción al causar la disminución en rendimientos, pérdidas económicas y aumentos en los precios del café a nivel mundial (Piñeiro, 2015). Otras afectaciones que enfrentan los caficultores se relacionan con la complejidad del sistema climático y el actuar conjunto de la variabilidad climática, particularmente con el fenómeno de El Niño-Oscilación del Sur (ENOS) y el calentamiento global. Recientemente, la fase cálida (El Niño) de este modo de variabilidad climática ha generado desafíos adicionales como el desarrollo de periodos secos severos y prolongados, obligando a los agricultores a modificar los periodos de cosecha (Brenes, 2014). Los cambios en el comportamiento de este fenómeno representan un reto muy grande para el sector, ya que requiere de medidas de adaptación como una planificación cuidadosa y ajustes en el manejo de la siembra, poda, riego, entre otros.

Las variaciones de precipitación y temperatura relacionadas con el ENOS favorecen condiciones óptimas para el desarrollo de enfermedades y plagas, lo que aumenta la presión sobre los cultivos (Ovalle, 2015). En algunos casos, los agricultores se ven obligados a considerar la reubicación hacia zonas que previamente no eran adecuadas para el cultivo, como una estrategia de adaptación a los cambios en el clima y el ambiente (Imbach et al., 2018). Además se proyecta una reducción del área global apta para el cultivo del café en un 50% para el 2050, siendo mayor en latitudes y altitudes bajas (Bunn et al., 2015; Ovalle, 2018; Pappo et al., 2021) debido a los escenarios de calentamiento. En el caso de Costa Rica, se estima que variedades como el café arábica podría disminuir en un 1% de las áreas actuales (Imbach et al., 2018) y se proyecta una reducción de la idoneidad entre 73% a un 88% en las tierras aptas para el cultivo en América Latina, con mayores efectos proyectados en países como Nicaragua y Honduras (CATIE, 2017).

El cambio climático plantea nuevos desafíos para los productores de café, quienes deben integrar medidas de adaptación, como la implementación de prácticas de manejo del suelo y del agua más eficientes, la diversificación de cultivos, y la promoción de sistemas agroforestales que mejoren la resiliencia de los sistemas de producción de café frente a los impactos climáticos adversos (Carmargo, 2010; Hagggar y Schepp, 2015; Bunn et al., 2015; Ovalle, 2015; Byrareddy et al., 2020). Entre las principales preocupaciones del sector cafetalero ante los impactos de la variabilidad y el cambio climático destaca el uso del agua en el cultivo. Ya que variaciones en la disponibilidad del agua para el sistema es determinante para el desarrollo de la cosecha (Hagggar y Schepp, 2015; Byrareddy et al., 2020). La producción agrícola depende del acceso al agua y su disponibilidad, además es uno de los sectores más vulnerables a los riesgos asociados al clima (Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO], 2022). Por eso la gestión integrada del recurso hídrico en la agricultura, es importante para administrar y utilizar el agua de manera sostenible, desde aspectos sociales, económicos y ambientales. Particularmente en el caso de cultivos como el café, considerado commodity, que experimenta una rápida reducción del área sembrada (Fernández et al., 2020).

Como indican estudios de organismos internacionales como FAO (2022) e IAEA (2018) las mejoras en la gestión y acceso del recurso hídrico deben basarse en gestiones integradas; es decir, soluciones que engloben la gestión del suelo, plantas y los nutrientes. Son ejemplos de gestiones integradas la optimización de calendarios de riego, sistemas de riego más eficaces, mejorar la fertilidad del suelo, y conocer las necesidades de agua de los distintos cultivos en las diferentes etapas de crecimiento; así como las condiciones ambientales que los afecten.

Por lo tanto, un parámetro clave utilizado para investigar los sistemas del agua y los alimentos es el índice de eficiencia del uso del agua (EUA) (Elfarkh et al., 2023), que es un indicador importante en áreas con recursos hídricos esenciales. Este índice permite estimar un equivalente del valor económico de agua de riego, y es empleado como un prerrequisito para las políticas en la producción de alimentos (Elliott et al., 2014; Molina, 2014). Este también permite evaluar el funcionamiento del ecosistema en respuesta a condiciones ambientales (Boese et al., 2019).

Cuando se estudia la EUA se busca optimizar la utilización del recurso y minimizar su desperdicio. El sector agrícola consume aproximadamente el 70% de agua dulce disponible, asimismo se prevé que en 2050 las necesidades del agua para la agricultura aumenten más de 50% con el fin de satisfacer la demanda alimentaria, considerando que el recurso hídrico está disminuyendo por una mala gestión, cambio climático y uso indiscriminado (Organismo Internacional de Energía Atómica [IAEA], 2018; Leakey et al., 2019). Por lo que la estimación de la EUA es de importancia para mejorar la gestión del uso del recurso en este sector. Conocer la EUA, permite a productores y tomadores de decisiones, identificar ineficiencias en sus sistemas de riego para reducir el consumo total de agua en el cultivo, planificar sus calendarios de siembra, adaptarse a periodos de sequía para tomar medidas orientadas a preservar la humedad del suelo y garantizar el crecimiento del cultivo. En caso de lluvias intensas permite implementar prácticas de manejo para evitar inundaciones, minimizar la escorrentía, mejorar el manejo de las aguas pluviales e implementar estrategias para preservar los nutrientes del suelo (Alvarado y Rojas, 2007; Knauer et al., 2018 ; Leakey et al.;2019; Hoover et al., 2023; Fatichini et al., 2023).

Conocer datos sobre parámetros meteorológicos, permite una mejor planificación de los recursos, ya que los productores pueden anticipar mejor las necesidades hídricas y tomar decisiones informadas. Además, la gestión adecuada del agua puede reducir el estrés hídrico en los cultivos mejorando la salud del suelo (Alvarado y Rojas, 2007; Knauer et al., 2018; Leakey et al., 2019; Hoover et al., 2023; Fatichini et al., 2023) y, ante los cambios de patrones de la precipitación asociados con la variabilidad y el cambio climático es crucial contar con esta información para garantizar la sostenibilidad del cultivo (Hatfield y Dold, 2019).

El concepto de EUA fue introducido hace un siglo por Briggs y Shantz (1912) que mostraron la relación entre la productividad de las plantas y el uso del agua. Tiene diferentes definiciones y se estima de diferentes formas respecto a la disciplina científica desde la cual se realiza la estimación. Por lo que se puede decir que no existe una metodología única para determinar la EUA, lo que genera diferencias en escalas temporales y espaciales en las estimaciones (Molina, 2014). La EUA ha sido definida por Hatfield y Dold, (2019) como *“la medida de la cantidad producida por unidad de agua utilizada por*

una planta” o según Moreno et., al (2014) como “la relación existente entre la biomasa presente en el cultivo por unidad de agua utilizada por este en un determinado momento” (p.11). Mientras que Xie et al., (2016) definieron la EUA del ecosistema como la relación entre la ganancia de carbono (C) a través de la fotosíntesis y la pérdida de agua a través de la evapotranspiración (ET) a escala del ecosistema y a nivel de hoja. En ecología se define como la proporción de la productividad primaria neta y evapotranspiración (Guerrieri et al., 2019). Para esta investigación se utilizó este último enfoque ya que considera la modulación por la retroalimentación de agua, carbono y la energía entre el dosel y la atmósfera (Ponton et al., 2006; Chinchilla et al., 2021).

De acuerdo con Medrano et al., (2007), la EUA depende principalmente de dos tipos de factores: aquellos propios de la especie y variedad de la planta que tengan relación con la capacidad de optimización de los procesos de asimilación de carbono y de evapotranspiración del agua, y las características del ambiente en el que crece y se desarrolla la planta. Esta también depende de la escala en la que se encuentre, a nivel de la hoja, la planta, nivel del cultivo o del ecosistema (Fatichini et al., 2023). A nivel de escala foliar, la EUA se expresa como la relación entre el consumo de la asimilación neta de carbono (A_n) y la transpiración (ecuación 1) conocida como eficiencia instantánea (Medrano et al., 2007).

$$EUA = \frac{A_n}{T} \quad (1)$$

Otra métrica a escala foliar, es la EUA intrínseca, que se define como la relación entre la asimilación de CO₂ la y conductancia estomática (g_s) Knauer et al., 2018; Leakey et al., 2019; Hatfield y Dold, 2019).

$$EUA_i = \frac{A_n}{g_s} \frac{\frac{g_m}{g_s}}{\left(1 + \frac{g_m}{g_s}\right) * (C_a + C_c)} \quad (2)$$

Donde g_s es la conductancia estomática, g_m es la conductancia del mesófilo, C_a es la concentración de CO₂ en la atmósfera, C_c concentración de CO₂ en el sitio de carboxilación (Knauer et al., 2018; Leakey et al., 2019; Hatfield y Dold, 2019).

En la región hay pocos estudios que estimen la EUA, por ejemplo Van Kanten et al., (2005) analizó la EUA en un sistema agroforestal en condiciones bajo sol y sombra en Turrialba, utilizando métodos termoeléctricos y el cálculo de la transpiración como componente de la evapotranspiración. Y más recientemente, en el sitio de estudio de este proyecto de graduación, se realizó una investigación, donde se estimó el uso consuntivo del agua y la EUA mediante intercambio gaseoso a nivel de hoja, en lotes de pleno sol y sombra incipiente en el cultivo de café (Montero, 2022).

A nivel de cultivos y ecosistema, la EUA se estima de una manera aproximada, ya que según Medrano et al., (2007), en condiciones de campo es difícil conocer con exactitud la cantidad real de agua que ha consumido las plantas y su crecimiento en biomasa acumulada. Para obtener una medida de esta variable se pueden utilizar herramientas como lisímetros que son básculas situadas bajo tierra que determinan la masa de una parcela de terreno. Sin embargo, el costo y el hecho de que son funcionales con cultivos herbáceos homogéneos son limitaciones de esa metodología (Elfarkh et al., 2023). A nivel de cultivos de semillas o granos, la EUA se calcula mediante la relación entre la biomasa producida (kg) y el uso del agua (m³) (ecuación 3), durante toda la temporada de crecimiento y permite obtener información general con la que se logra el rendimiento (Moreno et al., 2014; Leahey et al., 2019).

$$EUA_{gr} = \frac{\text{Producción o Biomasa total}}{\text{Agua consumida}} \quad (3)$$

A nivel de ecosistema, se puede estimar con base en el calor latente observado (evapotranspiración en unidades de energía), mediante déficit de presión de vapor (DVP) y la productividad primaria bruta (PPB). La PPB y ET se pueden estimar o determinar a partir de la implementación de técnicas como la covarianza de torbellino y productos de teledetección que permiten escalar el cálculo del campo hasta escalas globales (Fatichini et al., 2023). La relación entre EUA y PPB se debe a la modulación por la retroalimentación de agua, carbono y energía entre el dosel y la atmósfera (Ponton et al., 2006 y Chinchilla et al., 2021). Por lo cual una forma de calcular la EUA a nivel de ecosistema es mediante esta relación (ecuación 4), ampliamente utilizada a escalas regionales (Elfarkh et al., 2023).

$$EUA_{eco} = \frac{PPB}{ET} \quad (4)$$

Donde PPB se define como “*la cantidad total de carbono asimilado por las plantas a través de la fotosíntesis dentro de un ecosistema*” (Elfarkh et al., 2023) y la ET se refiere a la evapotranspiración que se define como la “*cantidad de agua que evapora y transpira un ecosistema durante un año*” (Fossils, 2007).

Otras metodologías incluyen el uso de isótopos estables de carbono ($\delta^{13}\text{C}/^{12}\text{C}$) del CO_2 respirado por las plantas para estimar la EUA, con base a que son una herramienta útil a escala de ecosistema para estudiar la fotosíntesis y aclimatación de los ecosistemas al estrés ambiental (Ehleringer y Squeo, 2004; Seibt et al., 2008; Sánchez et al., 2017). La metodología observacional de mayor uso es la técnica de covarianza de torbellino, que permite realizar estimaciones directas robustas de los flujos de agua y carbono y las condiciones ambientales que acompañan el ecosistema (Ponton et al., 2006). Además de las técnicas isotópicas, la estimaciones de la EUA se han beneficiado de los avances en el uso de la teledetección, que permite el análisis a escalas regionales y globales en diferentes ecosistemas debido a que es posible realizar estudios relacionados a cobertura de la tierra, cuerpos de agua, vegetación; entre otros, (Ahmadi et al., 2019; Veneros et al., 2020). Aunque hay algunas desventajas asociadas a su uso como la validación en el sitio de estudio y problemas de resolución espacial (Wanyuan Cai et al., 2021), su uso ha permitido avanzar en el escalamiento de las estimaciones de la ET, PPB y EUA.

En esta investigación se hace uso de la técnica de covarianza de torbellino, que es uno de los métodos empíricos más utilizados para estimar de forma precisa los flujos de materia y energía entre la superficie y la atmósfera (Burba y Anderson, 2010) con la ventaja de la alta precisión debido a su alta frecuencia de medición (Burba, 2023).

En este caso, se busca determinar con mayor precisión la EUA mediante mediciones de la ET tomando ventaja de la escala micro-meteorológica como complemento a parámetros atmosféricos de suelo y vegetación y clave para el análisis de la EUA (Burba, 2023). Entre las ventajas de esta técnica es que ha permitido mediciones continuas y a largo plazo del flujo de agua y CO_2 en las últimas décadas y permite obtener datos de flujo de carbono y

agua en sitios específicos y luego calcular la EUA (Wanyuan Cai et al., 2021; Burba, 2023).

Entre los desafíos o desventajas de la técnica se pueden mencionar los altos costos del emplazamiento del equipo, complejidad técnica, mantenimiento de los sensores y mantenimiento del volumen de información que genera, además posibles errores aleatorios y sistemáticos que pueden generar subestimación o sobrestimación de los flujos a microescala (Wanyuan Cai et al., 2021; Elfarkh et al., 2023; Burba, 2023). La combinación de diferentes metodologías en la estimación de la EUA es común. Algunos métodos combinados incluyen el uso de modelos numéricos para estimar la EUA y productividad en cultivos. Por ejemplo se mencionan el modelo CropWat que permite simular el crecimiento de los cultivos herbáceos para mejorar la productividad del agua en condiciones de secano y regadío y es utilizado en diferentes condiciones agroecológicas en el mundo y el modelo Aqua Crop que simula la respuesta del rendimiento al agua de cultivos herbáceos (FAO, 2020).

Para la estimación de la EUA se puede hacer uso de información observada de PPB y ET, sin embargo, la determinación en campo de estos parámetros es costosa, por lo que se suele recurrir al uso de información satelital. Esta información es utilizada como entrada en modelos de superficie que finalmente brindan estimados para el cálculo de la EUA. No obstante, el uso de la información satelital está sujeto a la validación de los parámetros determinados en el sitio de estudio y la capacidad del modelo de superficie utilizado para reproducir los flujos de superficie. En este estudio es de interés determinar la capacidad del modelo de transferencia de suelo, vegetación, energía, agua y CO₂ (SVEN) (Wang et al., 2019) para estimar los flujos de superficie y EUA. El modelo SVEN simula la radiación del dosel, agua, flujos de carbono y dinámica de la vegetación. Este modelo deriva de la combinación de diferentes modelos como el laboratorio de propulsión a chorro de Priestley Taylor (PT JPL-ET), el modelo de teledetección remota y modelos de eficiencia de uso de luz (GPP), también el método de “restauración forzada” y un modelo de balance de agua para estimar la humedad del suelo y temperatura del suelo (Pateromichelaki, 2020; Wang et al., 2019). Entre los desafíos o desventajas, se encuentran la parametrización, calibración de las variables a escala local, posibles errores en la programación o modelación en las

simulaciones, así como el manejo de los datos faltantes y las dificultades derivadas de la información satelital utilizada para las estimaciones de los índices de vegetación.

La estimación de la EUA forma parte de la información crítica para la gestión del cultivo, especialmente bajo las condiciones de variabilidad y cambio climático. Debido a que los impactos sobre el cultivo de café dependen de las condiciones locales en cada sitio y su vulnerabilidad y estrategias empleadas como buenas prácticas agrícolas (Byrareddy et al., 2020; Pappo et al., 2021), es de interés contar con información a nivel de los lotes de la finca. Como resultado de estas condiciones locales, el desarrollo de investigaciones en las diferentes regiones cafetaleras es fundamental para entender el comportamiento del sitio y las amenazas que se enfrenta. De esta manera es posible contribuir con información pertinente para informar el desarrollo de estrategias de mitigación de impactos y adaptación al cambio climático.

Con esta premisa, la presente investigación se enmarca en los objetivos de desarrollo (ODS) de la Agenda de las Naciones Unidas para el Desarrollo Sostenible 2030, específicamente el ODS 16 Acción por el clima que busca medidas de mitigación y adaptación ante el cambio climático (Organización de las Naciones Unidas [ONU], 2020) y de manera transversal se vincula con el ODS 6 Agua limpia y saneamiento. La investigación se enfoca en la generación de información que permita contribuir con la reducción de la vulnerabilidad de los recursos hídricos a la variabilidad y el cambio climático. Los objetivos de la investigación se alinean con los planes nacionales de promover acciones eficaces de adaptación y mitigación, garantizar la seguridad hídrica mediante una gestión sostenible en beneficio de la sociedad y ecosistemas, y sobre todo desarrollar capacidades y fortalecer la investigación y conocimiento sobre el recurso hídrico (Ministerio del Ambiente y Energía [MINAE], 2009, 2013).

La investigación se desarrolló en el marco del proyecto “C0454 Flujos de Carbono y Eficiencia del Uso del Agua en agroecosistemas cafetaleros innovadores” de la Universidad de Costa Rica y tiene como objetivo “Cuantificar la eficiencia del uso del agua y su impacto en la productividad en una plantación de café en la finca La Hilda (provincia de Alajuela)”. El desarrollo de la investigación plantea la 1) implementación de una

metodología para la estimación de la eficiencia del uso del agua y la productividad en una plantación de café utilizando información derivada de la técnica de covarianza de torbellino, 2) la validación de la estimación de la eficiencia del uso del agua y la productividad obtenida a partir de estimaciones con el modelo SVEN y 3) la evaluación del impacto de la variabilidad interanual sobre la eficiencia en el uso del agua y la productividad.

Capítulo 2. Datos y métodos

En este capítulo, se describe la metodología que se utilizó en la investigación. Se presenta una descripción del sitio de estudio, los datos y técnicas utilizadas, incluyendo la técnica de covarianza de torbellino, la metodología para estimar la EUA, los cálculos del balance de energía y otros parámetros utilizados como datos de entrada en el Modelo SVEN como es el índice de vegetación de diferencia normalizada, la altura del dosel y la radiación de onda larga entrante. Además, se incluye una descripción del modelo SVEN, sus parámetros de entrada, evaluación y validación.

2.1 Sitio de estudio

El sitio de estudio se localiza en el sitio experimental en la finca “La Hilda” perteneciente al Grupo Santa Eduvigis, ubicada en San Pedro de Poás de Alajuela, Costa Rica ($10^{\circ}05'23''N$ $84^{\circ}14'01''W$) a una elevación de 1400 msnm. Se utilizaron datos en un lote de sol generados por medio de mediciones con la técnica de covarianza de torbellino como parte de los proyectos Flujos de Carbono y Eficiencia en el uso del agua en agroecosistemas cafetaleros innovadores (2020-2023) y Dinámica de la Captura de Carbono en agroecosistemas cafetaleros innovadores (2023-2024).

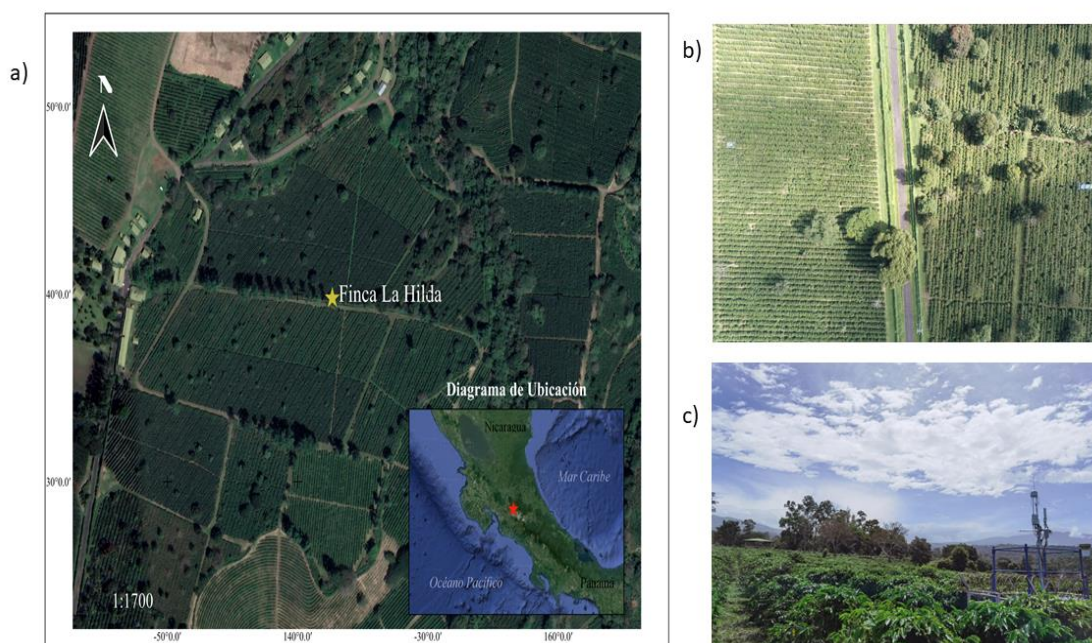


Figura 2. Sitio de estudio Finca la Hilda, San Pedro de Poás, Alajuela

Nota: a) Ubicación geográfica del sitio de estudio, Finca La Hilda San Pedro de Poás, Alajuela, Costa Rica, b) fotografía aérea de la Finca, c) fotografía de la torre de covarianza de torbellino

Fuente: Elaboración propia (2023) y fotografías tomadas por Guillén (2022).

El cantón de Poás de Alajuela se caracteriza por tener una extensión de 73.8 km², distribuidos en cinco distritos como San Rafael, Carrillos, Sabana Redonda, San Juan y San Pedro (14.64 km²), donde se encuentra la finca. La altitud promedio del cantón es entre 600 msnm a 2838 msnm en el Parque Nacional Volcán Poás. El sistema fluvial responde a la vertiente del Pacífico y la del Caribe, como la cuenca del río Tárcoles que es drenada por el río Poás, en el cual se unen el río Poasito, Prendas y su afluente Tacares y Mastate (Quesada, 2015; Barrantes y Quesada, 2016). El cantón se caracteriza por ubicarse alrededor de una serie de fuentes sísmicas y actividad volcánica como la comunidad de San Pedro que se localiza a 12 km al sur del cráter del Volcán Poás (Quesada, 2015). También se caracteriza por ser parte del régimen Pacífico de precipitación, el cual se ve modulado por fenómenos tanto a escala local como a escala regional (ZCIT) e intra-estacional (ENOS) (Montero, 2022).

La región donde se localiza La Hilda, tiene un clima estacional bien definido, con temporada seca entre (diciembre a abril) y lluvioso (mayo a noviembre). La precipitación media anual total es de 2.380 mm. El mes más seco para el periodo 2020-2021 fue enero (<15 mm) y el más lluvioso es octubre (> 500 mm). La temperatura media es de 20,4 ° C con pequeñas variaciones anuales. El antiguo uso del suelo de la finca, era el cultivo de caña de azúcar, y cuanta con más de 30 años con la actividad cafetalera. La investigación se desarrolló en el lote de sol “2016 Murillos” de 9.39 hectáreas (ha) que tiene café desde 1982. Sin embargo, se realizó una resiembra con la variedad Sarchimor T-5296 en 2016 (4830 plantas/hectárea). En esta región cafetalera, la madurez de grano se da en septiembre y el pico de cosecha en diciembre-enero y la antesis ocurre normalmente después de la entrada de época lluviosa (Alvarado y Rojas, 2007). De acuerdo con Montero (2022), que realizó una investigación en el sitio de estudio, encontró que para el 2021 en el lote a pleno sol, la transición fue homogénea de flores a frutos con pico de madurez en diciembre lo usual en la región. El manejo agronómico de la finca se caracteriza por manejo fitosanitario, fertilización y aplicación de enmiendas; así como control mecánico de malezas y las podas se realizan en el primer trimestre de cada año.

En cuanto a los rendimientos del lote de sol “2016 Murillos”, para el periodo de estudio, la cosecha fue de 85.63 fanegas/ha en 2020-2021 y de 32.77 fanegas/ha en 2021-2022.

Tabla 1. *Datos históricos de cosecha en fanegas por hectárea del lote de sol, finca La Hilda*

Cosecha	2019-2020	2020-2021	2021-2022	2022-2023
Fanegas/ha	6.48	85.63	32.77	72.44

Como se muestra en la tabla anterior, este comportamiento también se debe al concepto de bianualidad en el cultivo de café, es decir, un año con baja producción y otro con alta. Según el ICAFE (2020) para el periodo 2020 en el Valle Occidental, hubo un aumento en la cosecha resultado de una buena floración promovida por las lluvias oportunas en comparación con las últimas dos cosechas, a nivel país hubo un aumento del 12% respecto a la cosecha anterior 2019-2020. Sin embargo, en el 2020 y a mediados de 2021, hubo un aumento de lluvia favorecida por la fase La Niña del fenómeno ENOS, que generó enfermedades (antracnosis, chasparria, roya) y con ello debilitamiento de las plantas y por ende menor producción para la cosecha siguiente en varios sectores del país (ICAFE, 2022).

2.2. Datos y métodos

2.2.1. Datos e instrumentos

Los datos que se utilizaron en el estudio corresponden a las mediciones in situ obtenidas de una torre micrometeorológica emplazada en el lote de estudio (sol) en que se utiliza la técnica de covarianza de torbellino. Esta torre fue instalada en la finca La Hilda como parte del arreglo experimental del proyecto C0454 (Figura 1.c). La torre está instrumentada con un analizador tipo IRGAS (analizador infrarrojo de gas) de camino cerrado Li-7200RS (Li-Cor 2016, Lincoln Nebraska) que es un analizador de densidad de CO₂ y vapor de agua en el aire y un anemómetro sónico que mide el viento en tres dimensiones y un sistema Biomet completo (Pateromichelaki, 2020; Chinchilla; 2021).

Para los datos de entrada del modelo SVEN, se utilizó datos históricos con una frecuencia de media hora, obtenidas de una estación meteorológica básica Davis Vantage Pro2 Plus que estuvo instalada en la finca entre 2009 y 2022. Esta estación cuenta con un barómetro para medir la presión atmosférica, sensor para energía solar y radiación UV, un anemómetro para la velocidad y dirección del viento, sensores de temperatura, humedad relativa y punto de rocío y un sistema de cubo basculante para medir la precipitación (Pateromichelaki, 2020; Montero, 2022).

Para calcular el índice de vegetación normalizada (NDVI) se utilizó información disponible en la plataforma Sentinel Hub EO Browser y para la estimación de la radiación de onda larga entrante (LW_{in}) se utilizaron datos de fracción de nubes promediados en escala diaria de MODIS (Aqua) obtenidos mediante el sistema Giovanni desarrollado y mantenido por la NASA Centro de Servicios de Información y Datos de Ciencias de la Tierra Goddard (GES DISC).

A nivel de campo, se solicitó información general a la gerencia de la finca La Hilda, principalmente sobre el sitio de estudio, variedad del café, rendimientos, así como permisos para mediciones en campo de la altura del dosel de 10 plantas del lote de sol con apoyo de estudiantes de agronomía. Los datos se procesaron y analizaron utilizando diferentes paquetes y entornos como R Studio y Python en el entorno Visual Studio Code (VScode) y MATLAB R2023a (con licencia para estudiantes de la Universidad de Costa Rica).

2.2.2. Técnica de covarianza de torbellino

La técnica de covarianza torbellino o Eddy Covariance (EC), se usa para estimar de forma precisa los flujos de gases de efecto invernadero entre un ecosistema y la atmósfera (Burba y Anderson, 2010). Se emplea para determinar con mayor precisión la EUA mediante mediciones de la evapotranspiración, por lo que el uso de información en la escala-micrometeorológica es necesaria como complemento a parámetros atmosféricos de suelo y vegetación y clave para el análisis de la EUA (Burba, 2023). Las bases para el desarrollo de esta técnica datan de los trabajos de Sir Osborne Reynolds en 1855, y cuya aplicación experimental fue posible hasta 1926 debido a las limitaciones para obtener mediciones de alta frecuencia. Las primeras mediciones del flujo de CO_2 se realizaron en bosques, ecosistemas nativos, pastizales y humedales en los años 1960-1970 y actualmente esta técnica se emplea en más de 180 sitios en todo el mundo (Baldocchi, 2003; Burba, 2023).

La densidad de los gases es estimada a partir de la relación entre la radiación absorbida y un valor de referencia. El sistema mide directamente la radiación neta (R_n , en W/m^2) mediante el uso de un radiómetro neto. El procesamiento de los datos se realizó con los softwares EddyPro y Tovi (Li-Cor, Lincoln, Nebraska, USA). Con el método de promedio de Reynolds, la técnica de covarianza de torbellino estima los flujos de calor latente (LE,

en W/m^2) y sensible (H , en W/m^2), así como la evapotranspiración del sistema (ET , en mm) (Burba y Anderson, 2010; Burba 2023).

La implementación de esta técnica se basa en las mediciones de alta frecuencia, que permite capturar los movimientos turbulentos del aire, que permite determinar la diferencia neta de la energía y la materia que se mueve a través de la interfaz entre el dosel y la atmósfera (Baldocchi, 2003; Montero, 2022; Burba, 2023). Este se estima mediante análisis estadístico de la densidad del flujo vertical que esta dado por:

$$F = \overline{p_a w S} \quad (5)$$

Donde p_a es la densidad del aire, w es la velocidad vertical y S es la proporción de la mezcla que es la relación para entender como los flujos o remolinos transportan diferentes componentes gaseosos entre la superficie y la atmósfera, donde p_c se refiere a la concentración del gas en el flujo y p_a concentración del mismo gas en el aire:

$$S = \frac{p_c}{p_a} \quad (6)$$

Por lo tanto, el flujo (F) es igual al producto medio de la densidad del aire, la velocidad vertical del viento y la proporción de mezcla del trazador de interés. Aplicando la descomposición de Reynolds, que se define como un valor medio más un valor fluctuante (Baldocchi, 2003; Montero, 2022; Burba, 2023) se obtiene:

$$x = \bar{x} + x'$$

(7)

Asimismo, considerando la ecuación 5 que la desviación media respecto a la media es cero se obtiene:

$$F = \overline{p_a w S} + \overline{p_a' w' S'} + \overline{w_a' p_a' S'} + \overline{\bar{p}_a w'} + \overline{p_a' S' w'} \quad (8)$$

Para la técnica de covarianza de torbellino se supone que las fluctuaciones en la densidad del aire son insignificantes por lo que de la ecuación anterior se obtiene:

$$F = \overline{p_a} \overline{wS} + \overline{p_a} \overline{w' S'}$$

(9)

Otra suposición en la técnica es que, para terrenos horizontales homogéneos, el flujo vertical medio se considera insignificante por lo que el flujo turbulento se obtiene de la siguiente ecuación:

$$F \approx \overline{p_a} \overline{w' S'}$$

(10)

Se refiere a que es aproximadamente igual al producto de la densidad media del aire y la covarianza media entre las desviaciones instantáneas de la velocidad vertical del viento y la proporción de la mezcla. Además, se supone que las mediciones en la capa límite de interés el flujo es completamente turbulento (Balducchi, 2003; Montero, 2022; Burba, 2023).

Por lo tanto, se recomienda que la ubicación de la torre debe representar el área de interés para las direcciones predominantes del viento, adecuada ubicación de los sensores, en general la altura de la torre debe ser el doble de la altura del dosel (Burba, 2023). En cuanto a los parámetros de estudio como el flujo de calor sensible (H) y latente (LE) se pueden calcular mediante:

$$H = \overline{p} C_p \overline{w' T'} \quad (11)$$

El flujo de calor sensible H es igual a la densidad media del aire húmedo (ρ) multiplicado por la covarianza entre desviaciones en la velocidad vertical instantánea w y la temperatura T . Se logra la conversión a unidades de energía mediante el calor específico C_p (Moorhead et al., 2019; Burba, 2023). En caso del flujo de calor latente (ecuación 12) se conoce como flujo de vapor de agua en unidades de energía, ya que es usual que se exprese en términos de presión de vapor de la atmósfera (e), calor de vaporización latente (λ) y una relación de masas molares de agua y aire (Moorhead et al., 2019; Burba, 2023).

$$LE = \lambda \frac{M_w}{M_a} \overline{p w' e'} \quad (12)$$

La información obtenida mediante esta técnica se considera el valor real y se utilizó para evaluar la capacidad del modelo SVEN de reproducir las observaciones.

2.2.3. Balance de energía

Se estimó el balance de energía, ya que al implementarse la técnica de covarianza de torbellino, existen la posibilidad de sesgos y tendencias de sub o sobre estimación de los flujos turbulentos (Wilson et al., 2002; Foken, 2008; Yue et al., 2011; Raavshan et al., 2019), que pueden presentarse por problemas en los instrumentos, procesamiento de los datos, fuentes adicionales de energía no contabilizadas, la existencia de circulaciones secundarias de energía, entre otros factores (Mauder et al., 2020; Widmoser y Michel, 2021). Se realizó una evaluación del cierre del balance de energía, con el objetivo de garantizar la calidad de los datos utilizados (Capítulo 3). La evaluación se realizó con datos del periodo 2020 y 2021 con frecuencia de media hora obtenidos del sistema de covarianza de torbellino (EC), los datos se procesaron y analizaron utilizando Excel y R.

Para realizar el análisis del cierre del balance de energía se realizaron varios cálculos, primeramente, se implementó la ecuación de balance de energía (Kidston et al., 2010; Mauder et al., 2020 y Raavshan et al., 2019) indicada en la ecuación 29 utilizando las variables de la radiación neta (R_n) flujo de calor sensible (H), flujo de calor latente (LE) y flujo de calor del suelo (G). Se calculó además el residuo (A-H-LE).

Debido a la ocurrencia de advección, se analizó el ciclo diurno de los flujos de superficie e influencia de la advección en el desequilibrio del balance de energía desde el punto de vista del ciclo diurno (Figura 10). Partiendo de que el arreglo instrumental incluye otras estaciones meteorológicas en parcelas adyacentes al sitio de estudio, se procedió a estimar el término de advección para identificar su relación con el residuo mediante la ecuación de Mauder et., 2020 (ecuación 31), utilizando las variables de densidad del aire (Kg/m^3), C_p es la capacidad de calor del aire, presión constante, velocidad del viento (m/s^{-1}), Z_m la altura de la torre de sol (4.5 m) y ΔT la diferencia de la temperatura de los datos obtenidos de la torre EC y la estación meteorológica Davis ($^{\circ}C$), ΔX la distancia aproximada en línea recta entre la torre EC y la estación Davis Vantage Pro2 Plus (800 m). La advección se hizo en escala horaria, considerando los periodos diurno y nocturno para evaluar el comportamiento de la advección durante los periodos de mayor estabilidad de la capa

límite (Figura 11). El término advección también se analizó para diferentes condiciones de estabilidad atmosférica (estable, inestable y neutral) que se calculó mediante el parámetro de estabilidad (L).

El cierre del balance de energía superficial (EBC) se calculó mediante una regresión lineal ordinaria de los flujos turbulentos de energía de calor sensible y latente ($H+LE$) y la radiación neta menos el flujo del calor del suelo (R_n-G). Para este efecto se analizaron las pendientes de la regresión (OLR) en escala mensual durante el periodo de estudio.

Además, se analizó la influencia de las condiciones de estabilidad atmosférica utilizando el parámetro de estabilidad atmosférica adimensional ζ (ZL) siguiendo la metodología usada por Franseen et., al y Raavshan et al., 2019. Se usaron las variables de la altura de medición del anemómetro sónico (4.5 m) y L (m) la longitud de Obukhov (ecuación 33) obtenidas de los datos de la torre, y se clasificó en tres clases: a) estable= $\zeta \geq 0.1$, neutral ($-0.1 < \zeta < 0.1$) e inestable = ($\zeta \leq -0.1$). Por último, se hizo la comparación de la regresión del cierre de balance de energía bajo estas diferentes condiciones de estabilidad atmosférica.

2.2.3.1. Cálculo de evapotranspiración

La evapotranspiración (ET) desempeña un papel crucial en el ciclo del hidrológico, ya que controla cómo la humedad se mueve hacia la atmósfera y afecta aspectos clave de los ecosistemas terrestres, como la escorrentía, la humedad del suelo y el crecimiento de las plantas (Risco, 2015). Este flujo es la combinación de dos procesos separados por los que el agua se pierde a través de la superficie del suelo, evaporación y transpiración (Rodríguez et al., 2012; FAO, 2022). La ET depende de variables climáticas como radiación solar, temperatura del aire, la humedad atmosférica y la velocidad del viento; factores de cultivo como el tipo, variedad, etapa de desarrollo, así como el manejo y condiciones ambientales como salinidad o baja fertilización del suelo, densidad del cultivo, cubierta del suelo, entre otros (FAO, 2022). Es importante tener claro las diferencias en la estimación de este parámetro, ya que las formulaciones utilizadas comúnmente hacen referencia a variables que son en realidad diferentes: la evapotranspiración del cultivo de referencia (ET_0) que depende únicamente de parámetros ambientales, la evapotranspiración del cultivo bajo condiciones estándar (ET_c) que se refiere a la evapotranspiración de cualquier cultivo cuando se encuentra exento de enfermedades, buena fertilización, la evapotranspiración del

cultivo bajo condiciones no estándar (ET_{caj}) que se refiere a la ET de cultivos que crecen bajo condiciones ambientales y de manejo diferentes de las condiciones estándar y la evapotranspiración real (FAO, 2022). En la siguiente tabla se detallan las definiciones y maneras de estimar las variables indicadas anteriormente.

Tabla 2. *Tipos de evapotranspiración*

Tipos	Definición	Fórmula
Evapotranspiración real (ET)	Es la cantidad de agua que realmente evapora y transpira un cultivo bajo condiciones específicas de manejo, disponibilidad de agua, tipo de suelo, y otros factores que afectan al cultivo (salinidad, fertilización, etc.).	Ecuación 13
Evapotranspiración de referencia (ET_0)	Es la cantidad de agua que evapora y transpira de una superficie de referencia bajo condiciones específicas de clima (temperatura, viento, radiación solar y humedad relativa). Es un valor utilizado como referencia para estimar la ET de los cultivos ajustado con un coeficiente de cultivo K_c	Se estima mediante diferentes métodos como: FAO Penman- Monteith (ecuación 14) Hargreaves (ecuación 17) Blaney-Criddle (ecuación 18)

Fuente: (FAO, 2022)

En el caso de esta investigación se utilizaron las metodologías de FAO-Penman- Monteith, Hargreaves y Blaney y Criddle, para estimar la evapotranspiración de referencia (ET_0) de acuerdo con la disponibilidad de datos meteorológicos obtenidos de la estación Davis Vantage Pro2 Plus. Se utilizó el coeficiente del cultivo (k_c) para obtener el valor de ET para comparar con el resultado de la ET estimada mediante la técnica de covarianza de torbellino usando la formulación:

$$ET = K_c * ET_0 \quad (13)$$

El valor de K_c utilizado es el obtenido en el estudio de Montero (2022), en el lote de sol “2016 Murillos”, donde obtuvo un K_c de 0.62 en época lluviosa y un K_c de 0.36 en época seca, que fueron resultados similares a otros estudios (Gutierrez y Meinzer, 1994).

El método de Penman- Monteith (PM) es uno de los más completos y precisos para estimar la ET_0 y utiliza datos meteorológicos como la radiación neta, la temperatura del

aire, la velocidad del viento, la humedad relativa y la presión atmosférica. Parte de sus ventajas es que se usa en el mundo sin calibraciones locales y es un modelo muy utilizado por diferentes ramas (Rodríguez et al., 2012; FAO, 2022). Este dado por la siguiente ecuación:

$$ET_0 = \frac{0.408\Delta (Rn-G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34u_2)} \quad (14)$$

Donde:

- R_n : radiación neta.
- G : flujo de calor del suelo.
- $(e_s - e_a)$ representa el déficit de presión de vapor del aire (kPa), que es un indicador preciso de la capacidad evaporación real del aire, donde e_s corresponde a la presión a vapor de saturación (presión a la cual un líquido y su vapor coexisten en equilibrio en una temperatura dada) y e_a presión real de vapor (presión de vapor ejercida por el agua en el aire). Para obtener estos datos se necesitaron información de temperatura máxima, mínima, media y humedad relativa media.
- γ es la constante psicrométrica (kPa °C⁻¹) que es $0.665 \times 10^{-3} * (\text{Presión atmosférica})$.
- T es temperatura del aire en °C.
- Δ es la pendiente de la curva de presión de vapor de saturación (kPa °C⁻¹) que se requirió información de temperatura media del aire.
- u es la velocidad del viento a 2 m de altura (m s⁻¹).

Para la estimación de este método se utilizaron los parámetros de radiación neta (W/m²) estimada, temperatura del aire máxima, mínima y media (°C), velocidad del viento (m s⁻¹) y humedad relativa (%) en escalas diaria y mensual. La radiación neta se puede derivar de parámetros climáticos como radiación solar y horas de sol, temperatura del aire y presión de vapor. Esta se estimó a partir del método dado por la FAO con base en la información de radiación solar obtenida de una estación meteorológica, y se emplea especialmente para regiones determinadas, tamaño de la región pequeña, pocas diferencias de relieve entre

otras (Richard et al., 1998). En este caso, se calcula la radiación de onda larga (RL) y después la radiación neta (R_n). La RL se obtiene mediante la ley de Stefan-Boltzmann:

$$RL = \epsilon \sigma T^4 \quad (15)$$

Donde ϵ es la emisividad de la superficie (asumida como 0.97) para superficies terrestres, σ es la constante de Stefan-Boltzmann ($5.67 \times 10^{-8} \text{ W /m}^2 \text{ K}^{-4}$) y T es la temperatura media del aire. Seguidamente se calcula R_n mediante:

$$R_n: RL - RS \quad (16)$$

Para la estimación mediante el método de Hargreaves (HG), se utilizó la formulación original de Hargreaves para la estimación de la radiación solar y la ecuación de Hargreaves y Samani donde estima la ET_0 mediante datos de temperatura mínima (t_{min}) y máxima (t_{max}). La expresión general es:

$$ET_0 = 0.0023(t_{med} + 17.78) RS (t_{max} - t_{min})^{0.5} \quad (17)$$

T_{med} es la temperatura media y RS a la radiación solar incidente (Risco, 2015), toda la información disponible de la estación meteorológica Davis Vantage Pro2 Plus. Por otro lado, el método de Blaney-Cridde utiliza la temperatura del aire y varía de acuerdo con la latitud aproximada del sitio de estudio.

$$ET_0 = \frac{I_i}{I} * (45.72 * t_{min} + 812.8) \quad (18)$$

I_i , es la insolación incidente en el día en horas y I número total de horas de luz del día, t_{min} la temperatura mínima. Los resultados obtenidos de la estimación de la ET del cultivo utilizando los resultados de la evapotranspiración de referencia y el coeficiente de cultivo estos tres métodos se compararon con el ET determinada a partir de la torre micrometeorológica con el método de covarianza de torbellino y se analizó la desviación entre las estimaciones con respecto a la observación de campo.

En el caso de la estimación de la ET utilizando la información del modelo SVEN, se utilizó la formulación a partir de la variable LE mediante la relación:

$$ET = \frac{LE \times \Delta t}{\lambda} \quad (19)$$

Donde λ es el calor latente de vaporización, que es la cantidad de energía necesaria para evaporar un kilogramo de agua y Δt es el tiempo sobre el cual se promedia o integra el flujo de calor latente (normalmente en segundos por día, es decir, 86400 segundos) (Versini et al., 2024).

2.2.4. Índice de vegetación de diferencia normalizada

Para la generación de la información necesaria como entrada para el modelo SVEN, se calculó el índice de vegetación de diferencia normalizada que es muy utilizado para determinar la cobertura vegetal y es derivado de la respuesta de vegetación con relación el espectro electromagnético (Olivares et al., 2019).

$$NDVI = \frac{IRc-R}{IRc+R} \quad (20)$$

Donde IRc representa la banda infrarrojo cercano y R a la banda roja.

Los valores de este índice son reflejo de la relación de una banda roja y una banda en el infrarrojo cercano IRc; es decir, la vegetación en la banda roja se ve influenciada por la cantidad de clorofilas, mientras que la IRc por el contenido de agua (Olivares et al., 2019). Estas dos bandas son usadas por que captan la mayor cantidad de información relativa a la vegetación (Arévalo, 2021). Los valores del NDVI oscilan entre -1 y 1, donde valores negativos corresponden a nubes, agua y nieve, valores negativos cercanos a cero representa suelo desnudo o rocas, los valores positivos menores cercanos a 0 se interpreta como suelos desnudos o cuerpos de agua, y valores mayores se relacionan con un equivalente a la cobertura vegetal (Olivares et al., 2019; Arévalo, 2021). Este índice se puede obtener mediante sistemas de información geográfica (SIG) mediante diferentes fuentes de datos, generadas mediante análisis de imágenes generadas por sensores remotos (Arévalo, 2021).

Por eso para el cálculo del índice de vegetación de diferencia normalizada (NDVI) se utilizó información de la plataforma de uso gratuito Sentinel Hub EO Brower. Se utilizó información del sensor MODIS (Espectrorradiómetro de Imágenes de Resolución Moderada), que cuenta con 36 bandas espectrales de las cuales 7 son utilizadas para el monitoreo de cobertura terrestre, con una resolución espacial de 250 y 500 m, este está a bordo de dos satélites (Terra y Aqua) que han permitido obtener información diaria desde el año 2009-2022 (Figura 3) (García-Mora y Mas, 2011).

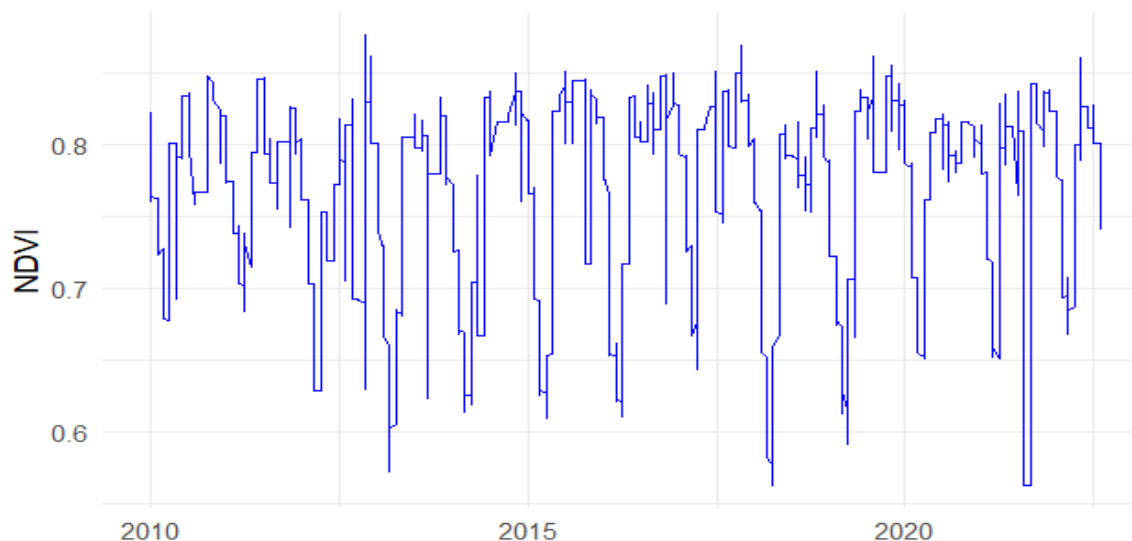


Figura 3. Índice de vegetación de diferencia normalizada, en finca La Hilda, 2010-2022

Nota: Datos de NDVI obtenidos del sensor MODIS, plataforma Geovanni de la NASA.

2.2.5. Cálculo de la altura del dosel

Un parámetro de entrada del modelo SVEN, es la altura del dosel (h_{rough}). En este caso al no tener inicialmente mediciones directas sobre una muestra significativa de las plantas en el periodo de estudio, se calculó de dos formas. Primero se utilizaron de referencia los valores utilizados por, Pateromichelaki (2020) que correspondía a una altura inicial del sistema de 0.40 metros. Es importante mencionar, que el cultivo en el 2016 tuvo una resiembra con la variedad Sarchimor T-5296 (4830 plantas/ha). Debido a que en este estudio abarca 2021 y se necesitaban datos 2022 para actualizar la información se contó con la ayuda de estudiantes de agronomía que realizaron un muestreo en campo en 10 plantas en el lote de sol (Tabla 3). No obstante, se tomó la altura máxima habilitada en el modelo de 1.68 metros.

Tabla 3. *Altura del dosel de plantas de café en el lote de sol, 2022*

Número de planta	Altura del dosel en metros
Planta 1	2.26
Planta 2	2.6
Planta 3	2.07
Planta 4	1.84
Planta 5	2.39
Planta 6	2.08
Planta 7	2.02
Planta 8	2.16
Planta 9	2.38
Planta 10	2.5
Promedio	2.23

2.2.6. Radiación de onda larga entrante

Otro de los parámetros de entrada, es la radiación de onda larga entrante (LW_{in}), que se define como la energía radiante que proviene del espacio exterior y que tiene longitudes de onda más largas en comparación con otras formas de radiación electromagnética. Este tipo de radiación incluye principalmente la radiación infrarroja, que tiene longitudes de onda más largas que la luz visible (An et al.;2017). Para el cálculo de esta variable se utilizaron datos de la estación meteorológica Davis Vantage Pro2 Plus para el periodo 2010-2022. Se estimó a partir de la emisividad del aire, utilizando el método propuesto por An et al.; (2017). No obstante, este método se consideró limitado al no reproducir razonablemente los valores esperados y se consideraba poco adecuado debido a que en la zona hay nubosidad importante y este modelo no considera esta información. Por lo que se procedió a utilizar el método propuesto por Konzelmann et al., (1994).

El método propuesto por An et al.;(2017), utiliza la temperatura del aire y del suelo, y calcula la emisividad del aire mediante :

$$\varepsilon = 0.7 + 5.95 * 10^{-4} e_a \exp \frac{1500}{T_a + 273.1}$$

(21)

Mientras que el método para calcular la emisividad del aire planteado por Kolzeman utiliza datos meteorológicos como temperatura del aire (Kelvin) y punto de rocío de la

temperatura (T_{dew}) además parámetros satelitales como la fracción de nubosidad (n) (Konzelmann et al., 1994; Juszak y Pellicciotti, 2013).

La siguiente ecuación muestra la emisividad del aire en condiciones de cielo despejado, donde e_a es la presión de vapor de agua (en Pa) y T_a es la temperatura del aire (Kelvin).

$$\varepsilon_{cs} = 0.23 + 0.484 * \left(\frac{e_a}{T_a}\right)^{\frac{1}{8}}$$

(22)

La presión de vapor de aire e_a , se calcula mediante la ecuación dada por la FAO (2009), con valores de T_{dew} (en °C).

$$e_a = e^0(T_{dew}) = 0.6108 * \exp\left[\frac{17.17 * T_{dew}}{T_{dew} + 273.3}\right]$$

(23)

Para la estimación de la fracción de nubes (n , serie temporal) se utilizaron datos promediados en escala diaria de MODIS (Aqua) obtenidos mediante el sistema Giovanni desarrollado y mantenido por la NASA Centro de Servicios de Información y Datos de Ciencias de la Tierra Goddard (GES DISC). En la figura 4, se puede observar la comparación entre los métodos de An et al. (2017) y Konzelmann et al. (1994) para el cálculo de LW_{in} . En el gráfico de dispersión a la izquierda, el coeficiente de determinación ($R^2 = 0.18$) indica una relación débil entre los valores obtenidos por ambos métodos, lo cual sugiere que existen discrepancias significativas en sus estimaciones. Esto puede atribuirse a diferencias en las formulaciones y en las variables consideradas en cada método.

El gráfico de series de tiempo muestra cómo ambos métodos se comportan a lo largo de los años. Se observa que el método de Konzelmann et al. (1994), presenta una mayor variabilidad en las estimaciones diarias de LW_{in} . En contraste, el método de An et al. (2017), parece subestimar o suavizar ciertos picos y mínimos que sí son capturados por Konzelmann. Esta variabilidad es importante en estudios de clima y de balance de energía, ya que permite un seguimiento más detallado de las fluctuaciones en las condiciones ambientales.




Figura 4. Comparación de métodos de cálculo de radiación de onda larga entrante (LW_{in}), en la finca La Hilda, 2010-2022.

La elección de Konzelmann et al. (1994) como método de referencia para el estudio, se debe a su capacidad para capturar la variabilidad diaria de LW_{in} de forma más precisa y detallada en el sitio de estudio, La Hilda, entre 2010 y 2022. Este método ha sido ampliamente utilizado y validado en contextos similares y se adapta mejor a las necesidades de este análisis, al proporcionar estimaciones que reflejan con mayor exactitud las condiciones observadas en campo

Por lo tanto, para el cálculo del método de Kozelmann, en la figura 5, se muestra la serie de tiempo de la fracción de nubes del periodo 2010 hasta agosto 2022. Los valores bajos se presentaron en enero y febrero que se puede atribuir a la estación seca, donde hay poca precipitación lo que resulta en cielos más despejados y una menor cobertura de nubes, mientras que junio y julio en algunos años, mostraron valores más altos debido a la transición a la estación lluviosa. Esto se atribuye a la zona de convergencia intertropical que provoca un aumento en la humedad y la formación de nubes.

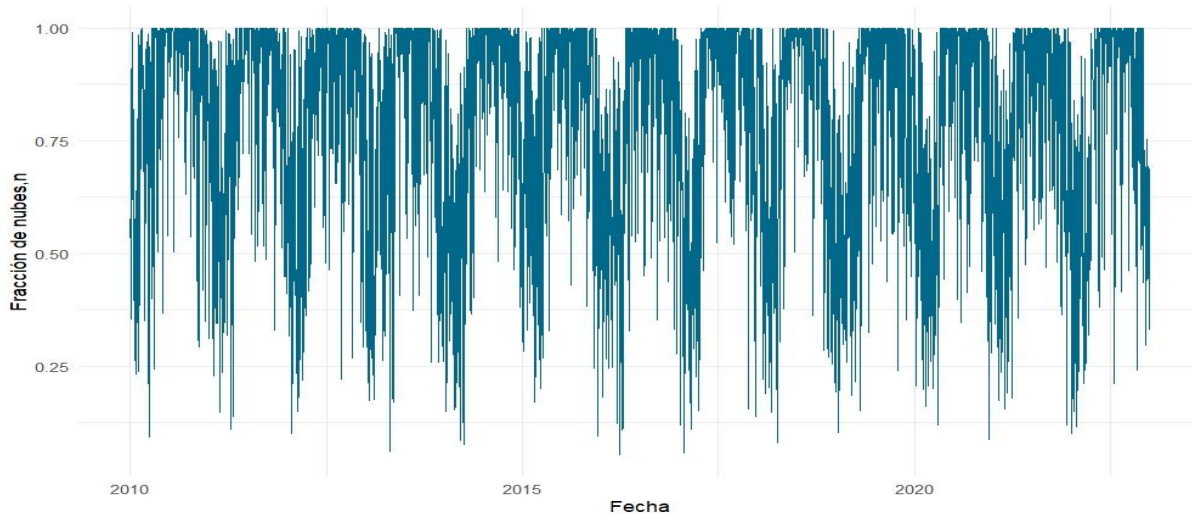


Figura 5. Fracción de nubes diaria, del periodo 2010-2022, Finca La Hilda

Nota: La fracción de nubes, es la proporción del área de un píxel satelital (o una región específica), que está cubierta por nubes. El rango de valores va de 0 a 1, donde 0 significa que no hay nubes y 1 que está totalmente cubierta de nubes.

La emisividad del aire en condiciones de nubosidad se calculó mediante la ecuación de Konzelman, donde $a=2$ y $b= 0.952$ y n es la fracción de nubes.

$$\varepsilon_a = \varepsilon_{cs} * (1 - n^a) + b * n^a \quad (24)$$

La radiación de onda larga entrante (LW_{in}) se derivó utilizando la ecuación 15 de Stefan-Boltzmann donde se emplea la temperatura del aire (Kelvin) y σ la constante de Stefan-Boltzmann ($5.67*10^{-8} \text{ W/m}^2 \text{ K}^{-4}$). En la siguiente figura se puede observar el comportamiento de este parámetro.




Figura 6. Radiación de onda larga entrante (LW_{in}) diarios en W/m^2 , en la finca La Hilda, 2010-2022.

Durante la estación seca, especialmente en los meses de enero a marzo en todo el periodo, los valores de LW_{in} fueron cercanos a los 200 W/m^2 . Esto se debe a la menor nubosidad y humedad relativa, lo que resulta en menos emisión de radiación térmica por parte de la atmósfera hacia la superficie. En contraste, durante la estación lluviosa, que va de mayo a noviembre, los valores de LW_{in} aumentaron alcanzando hasta 400 W/m^2 , esto se debe a la alta nubosidad y mayor humedad, que elevan la emisión de radiación térmica desde las nubes y el vapor de agua en la atmósfera.

2.2.7. Estimación de la eficiencia del uso del agua

Los estudios de la eficiencia del uso del agua (EUA), son importantes para comprender como el cambio climático afecta a los ecosistemas, ya que esta es la relación entre la ganancia de carbono (C) a través de la fotosíntesis y la pérdida de agua a través de la evapotranspiración (ET) a diferentes escalas. Harder et al., (2023) señalan que para determinar el futuro probable del agua agrícola a medida que cambia el clima, los cultivos y las técnicas agrícolas, es necesario comprender la relación dinámica entre el crecimiento de los cultivos y el uso del agua.

La EUA está relacionada con la productividad primaria bruta (PPB) que está modulada por la retroalimentación de agua, carbono y energía entre el dosel y la atmósfera (Ponton et al., 2006 y Chinchilla et al., 2021). Por eso para esta investigación se utilizó un enfoque basado en la PPB y la evapotranspiración con la EUA definido como la relación entre PPB y ET (ecuación 4).

Como observaciones de campo, se utilizó información derivada de la técnica de covarianza de torbellino, con datos cada media hora del periodo 2020 y 2021 de la productividad primaria bruta (PPB) y la evapotranspiración (ET) para estimar la EUA (Capítulo 4). Debido a que la información derivada de la técnica de covarianza está dada en unidades de $\text{gCO}_2/\text{KgH}_2\text{O}$, se realizó una conversión de la PPB de $\mu\text{mol m}_2 \text{ s}^{-1}$ a $\text{gcm}^2/\text{día}/\text{hora}/\text{mensual}$ y la ET en mm a KgH_2O (Tang et al., 2015; Liu et al., 2017; Peddinti et al., 2020; Chinchilla et al., 2021).

La EUA, está controlada principalmente por factores ambientales, (Jiang et al., 2022), controles fisiológicos y fenológicos, que varían según las zonas climáticas y los ecosistemas (Siles 2020; Jiang et al., 2022). Por lo anterior, también se analizó el comportamiento de la EUA con variables meteorológicas disponibles como la temperatura del aire, humedad relativa, la velocidad del viento, flujo del calor del suelo, contenido de agua, presión atmosférica y precipitación

2.2.8. Descripción del modelo SVEN

El modelo de transferencia de suelo, vegetación, energía, agua y CO₂ (SVEN) integra los procesos en superficie mediante un esquema simplificado (Figura 7). Este simula la radiación del dosel, agua, flujos de carbono y dinámica de la vegetación. Se deriva de la combinación de diferentes modelos como el laboratorio de propulsión a chorro de Priestley Taylor (PT JPL-ET), el modelo de teledetección remota y modelos de eficiencia de uso de luz (GPP), también el método de “restauración forzada” y un modelo de balance de agua para estimar la humedad del suelo, temperatura del suelo (Pateromichelaki, 2020; Wang et al., 2019). La estructura del modelo está integrada por tres módulos con submódulos y salidas cada uno, entre ellos el módulo de balance de energía superficial, el módulo de balance de agua y el de flujos de CO₂ (Figura 8). Por otro lado, la descripción de cada módulo y sus ecuaciones se detallan en los anexos, ya que como se explicó anteriormente es un modelo compuesto por varios modelos o métodos.




Figura 7. Descripción general de los procesos de la superficie terrestre simulados por el modelo SVEN.

Nota: SW_{in} : radiación de onda corta entrante, SW_{out} : radiación de onda corta saliente, LW_{in} : entrada de radiación de onda larga, LW_{out} : radiación de onda larga saliente, R_n : radiación neta, G : flujos de calor del suelo, T_s : temperatura superficial, T_d : temperatura del suelo profundo, H : flujos de calor sensible, P : precipitación, λE : flujos de calor latente λE_i : flujos de calor latente del agua recibida, λE_c : flujos de calor latente de transpiración, λE_s : flujos de calor latente de evaporación del suelo, CWS : almacenamiento de agua del dosel, SWS : almacenamiento de agua del suelo, Q_{inf} : infiltración, Q_{per} : percolación, R : escorrentía superficial, GPP : productividad primaria bruta) Adaptado de Wang et al., (2019).

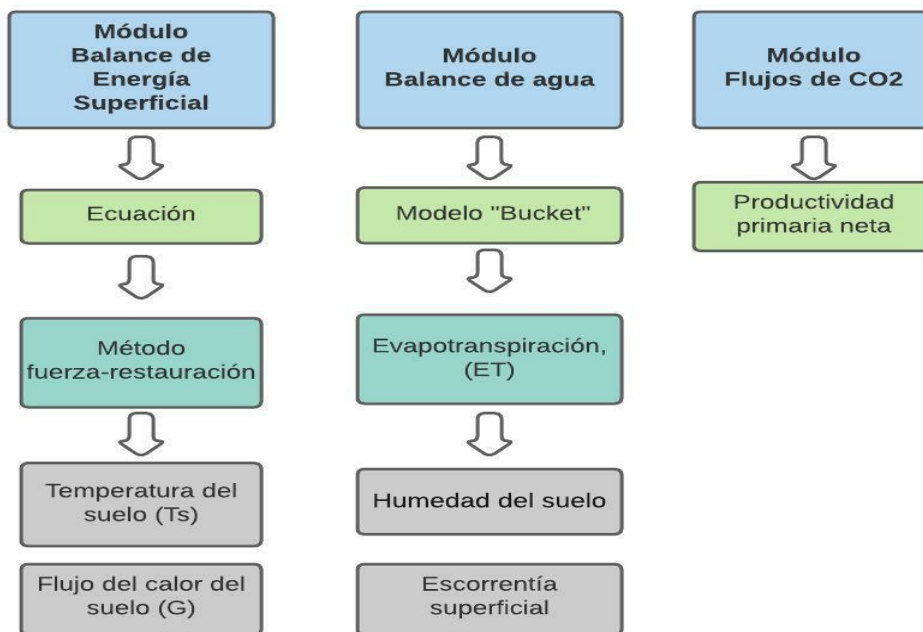


Figura 8. Módulos y submódulos del modelo SVEN.

Nota: La figura muestra la estructura del modelo SVEN, en color celeste se indica los módulos, en color verde los submódulos y en color gris las salidas. Fuente: Adaptado de Pateromichelaki, (2020).

2.2.8.1. Parámetros del modelo

Los datos de entrada del modelo SVEN incluyen principalmente, datos meteorológicos como precipitación, temperatura, velocidad del viento, humedad relativa. Algunas condiciones iniciales utilizadas en estudios como el de Wang et al., (2019) incluyen almacenamiento inicial de agua del suelo SW_{in} , temperatura superficial inicial del suelo T_{s0} y temperatura inicial del suelo profundo T_{d0} , que se obtienen de simulaciones spin-up (Tabla 4). De acuerdo con Wang et al., (2019) el modelo SVEN utiliza 6 parámetros relacionados a las propiedades físicas del suelo para la transferencia e infiltración de calor, que se obtienen mediante búsqueda de la textura del suelo, parámetros de biomasa o estudios similares, mediciones de campo, teledetección. Además, otros parámetros necesarios son dados por los métodos y modelos explicados anteriormente en los diferentes módulos, como θ_r , θ_s , LUE_{max} y T_0 , entre otros (Tabla 5).

Tabla 4. Descripción de condiciones iniciales y datos de entrada del modelo SVEN

Descripción de la variable	Sigla	Unidad	Fuente
Condiciones iniciales:			
Almacenamiento inicial de agua en el suelo	SW _{in}		Simulaciones spin-up ¹
Almacenamiento de agua inicial del dosel	CSW		Simulaciones spin-up ¹
Temperatura superficial inicial del suelo	T _{so}		Simulaciones spin-up ¹
Temperatura inicial del suelo profundo	T _{d0}		Simulaciones spin-up ¹
Datos de entrada:			
Radiación de onda corta entrante	SW _{in}	W/m ²	Datos meteorológicos
Radiación de onda larga entrante	LW _{in}	W/m ²	Estimación a partir de información satelital (Plataforma Geovanni-NASA)
Temperatura del aire	T _α	°C	Datos meteorológicos
Humedad relativa	RH	%	Datos meteorológicos
Velocidad del viento	WS	m/s	Datos meteorológicos
Presión atmosférica	Ps	kPa	Datos meteorológicos
Precipitación	P	Mm	Datos meteorológicos
Índice de vegetación de diferencia normalizada	NDVI	-	MODIS (Plataforma Sentinel Hub EO Browser)
Altura del dosel	h _{rough}	M	Literatura: Pateromichelaki,(2020) Datos de campo (Tabla 3)

Fuente: Adaptado de (Wang et al.,2019 y Pateromichelaki, 2020).

Nota: ¹ Una simulación spin-up se refiere a un periodo inicial en el que un modelo computacional se ejecuta hasta que alcance un estado estable antes de realizar observaciones o experimentos, es muy utilizado en modelos de climatología donde la estabilidad del modelo es crucial para obtener resultados confiables en simulaciones numéricas (López et al., 2018).

Para esta investigación como se muestra en la Tabla anterior, los datos de entrada se obtuvieron de la estación meteorológica Davis Vantage Pro2 Plus, ubicada en el sitio de estudio, con información del 2010-2021. Específicamente se utilizaron las variables de radiación total, temperatura, humedad relativa, velocidad del viento, presión atmosférica y precipitación y la información del NDVI se obtuvo a partir de la información satelital.

Tabla 5. *Parámetros del modelo SVEN según literatura*

Parámetros	Descripción	Unidad	Rango	Referencia
C_{sat}	Coficiente térmico para la saturación del suelo del modelo fuerza restauración (force-restore)	$10^{-6} \text{ K} \cdot \text{m}^2 \cdot \text{J}^{-1}$	[3,15]	Noilhan y Planton (1989)
B	Pendiente de la curva de retención del coeficiente térmico del modelo fuerza restauración (force-restore)	[-]	[4.05,11.4]	Noilhan y Planton (1989)
C_{veg}	Coficiente térmico de la superficie vegetal	$10^{-6} \text{ K} \cdot \text{m}^2 \cdot \text{J}^{-1}$	[1,10]	Calvet et al, (1998)
SWS_{max}	Almacenamiento máximo de agua en el suelo	M	[0,1]	Boegh et al (2009)
K_s	Tasa de infiltración por la saturación del suelo	$\text{mm} \cdot \text{h}^{-1}$	[0.001,25]	Dettman et al. (2014)
N	Parámetro de ajuste del modelo de Mualem Model	/	[1,3]	Dettman et al (2014)
θ_r	Humedad volumétrica residual	$\text{m}^3 \cdot \text{m}^{-3}$	[0.034,0.100]	Carsel y Parrish (1998)
Θ_s	Humedad volumétrica saturada	$\text{m}^3 \cdot \text{m}^{-3}$	[0.36,0.46]	Kufa y Burkhardt (2013)
A	Métodos empíricos de ET potencial	[-]		Fisher et al. (2008)
k_{Par}	Coficiente de extinción de PAR	[-]		Charbonnier (2013)
k_{Rn}	Coficiente de extinción de radiación	[-]		Fisher et al. (2008)
T_o	Temperatura óptima del crecimiento de la planta	[-]		Krishnan (2017)
LUE_{max}	Máxima eficiencia en el uso de la luz	$\text{G C m}^{-2} \text{ MJ}^{-1}$	[0,5]	Zhou et al., (2015)

Fuente: Adaptado de (Wang et al.,2019 y Pateromichelaki, 2020)

Las salidas del modelo corresponden a la información de los flujos de calor latente de agua recibida, de transpiración, y de evaporación del suelo, también flujos de calor sensible (H), flujos de calor del suelo (G) y productividad primaria bruta, como se resume en la figura 9.

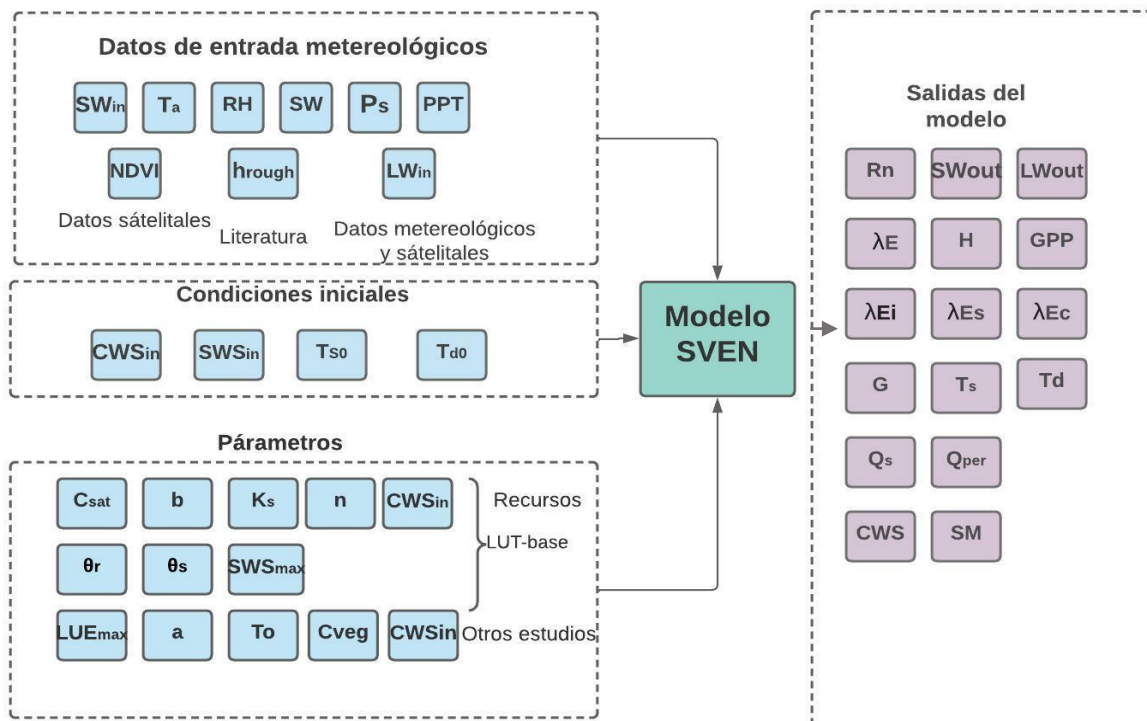


Figura 9. Datos de entrada, condiciones iniciales, parámetros y salidas del Modelo SVEN.

Nota: en la figura se muestra en color celeste todos los datos de entrada, condiciones iniciales y parámetros que se detallan en las Tablas 4 y 5, en color morado se indica las salidas o resultados del modelo SVEN que son R_n : radiación neta, SW_{out} : radiación de onda corta saliente, LW_{out} : radiación de onda larga saliente, λE : flujos de calor latente, H : flujos de calor sensible, GPP : productividad primaria bruta, λE_i : flujos de calor latente del agua recibida, λE_c : flujos de calor latente de transpiración, λE_s : flujos calor latente de evaporación del suelo, G : Flujos de calor del suelo, T_s : temperatura superficial, T_d : temperatura del suelo profundo, Q_s : infiltración, Q_{per} : percolación CWS : almacenamiento de agua del dosel, SM : radiación de onda). Adaptado de Pateromichelaki (2020)

2.2.8.2. Evaluación y validación del modelo

Para la simulación del modelo SVEN, los datos de entrada se obtuvieron de la estación meteorológica Davis Vantage Pro2 Plus, a escala de media hora (Tabla 4), además el modelo cuenta con parámetros ya calibrados en sus diferentes subrutinas (Tabla 5), esta información se simuló a través del software MATLAB R2023a, con licencia de la Universidad de Costa Rica. Para evaluar la capacidad del modelo para representar el comportamiento de los valores observados en campo se realizó un análisis de los datos observados (torre de covarianza de torbellino) con los datos simulados (estación meteorológica Davis Vantage Pro2 Plus) obtenidos del Modelo SVEN, mediante gráficas comparativas y de dispersión, modelo de regresión lineal para cada variable: temperatura

del suelo (T_{suelo}), radiación neta (R_n), flujo de calor latente (LE), flujo de calor sensible (H), la productividad primaria bruta (PPB) y se estimó la ET a partir de LE, mediante lenguajes de programación como R y Python.

La eficiencia del modelo se cuantificó mediante métricas estadísticas como correlación de Pearson, coeficiente de determinación R^2 , RMSE (Error de raíz cuadrática media) y MAE (Error absoluto medio).

El coeficiente de correlación de Pearson o coeficiente de correlación lineal, mide la fuerza o grado de asociación entre dos variables cuantitativas, es decir es una media geométrica entre las pendientes de los modelos de regresión lineal simple (Restrepo y González , 2007).

$$p = \frac{\text{Cov}(X,Y)}{\sqrt{\text{Var}(X)*\text{Var}(Y)}} \quad (25)$$

Este coeficiente varía entre -1 a 1, donde 1 indica una correlación positiva perfecta, es decir; a medida que una variable aumenta, la otra aumenta proporcionalmente, un valor de -1 indica una correlación negativa perfecta, es decir; a medida que una variable aumenta la otra disminuye proporcionalmente, y un valor de 0, indica la ausencia de correlación lineal entre las dos variables simple (Restrepo y González , 2007).

El coeficiente de determinación R^2 o bondad de ajuste, evalúa la fuerza de la relación lineal entre dos variables; es decir; las diferencias de unas variables pueden ser explicadas por la segunda (Restrepo y González, 2007).

$$R^2 = \frac{\sum_{i=1}^N (OBS_i - \overline{OBS}) * (SIM_i - \overline{SIM})^2}{\sum_{i=1}^N (OBS_i - \overline{OBS})^2 * \sum_{i=1}^N (SIM_i - \overline{SIM})^2} \quad (26)$$

El coeficiente tiene un valor entre 0-1, un valor de 1 o cercano, significa un buen ajuste del modelo a los datos observados, mientras que un valor de 0 o cercano a 0, significa que el modelo sugiere que el modelo no es útil para predecir o explicar la variable dependiente en función de las variables independientes.

El error cuadrático medio (RMSE) mide la diferencia promedio entre las predicciones del modelo y los valores reales en la misma escala que la variable dependiente:

$$RMSE = \sqrt{\frac{1}{N} * \sum_{i=1}^N (OBS_i - SIM_i)^2} \quad (27)$$

Cuanto menor sea el RMSE, mayor será la precisión del modelo en la predicción de los valores observados y se expresa en las mismas unidades que la variable.

El error absoluto medio (MAE) es la media de las diferencias absolutas entre los valores predichos y los valores observados, al igual que el RMSE a menor sea su valor mejor precisión y se expresa en las mismas unidades que la variable (Kim y Kim, 2016).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (28)$$

Donde n es el número total de observaciones, y_i el valor observado, \hat{y}_i es el valor predicho.

En resumen, un modelo excelente tendrá RMSE y MAE bajos, un R^2 cercano a 1, y una alta correlación de Pearson. Un modelo bueno mostrará errores algo mayores, pero aún aceptables y un R^2 moderadamente alto. Si estas métricas son intermedias, el modelo es moderado, mientras que valores altos de error y un R^2 bajo indicarían que el modelo es poco preciso.

2.2.9. Reconstrucción histórica

En este estudio, se propuso realizar una reconstrucción histórica, para el período 2010-2022. Esta reconstrucción se visualizó mediante gráficos de series de tiempo, lo que permitió analizar las variaciones y tendencias de la RN, LE, ET, PPB, H, T_suelo en ese período. Esta aproximación es crucial para comprender cómo ha cambiado la disponibilidad de agua en la región, aportando datos fundamentales para la planificación hídrica y la adaptación a posibles cambios climáticos futuros. Asimismo, conocer la variabilidad interanual e identificar los fenómenos del Niño y la Niña en ese periodo.

Capítulo 3. Balance de energía en superficie

La técnica de covarianza de torbellino es uno de los métodos más robustos para estudiar el intercambio de flujos turbulentos entre la superficie terrestre y la atmósfera, ya que permite estudiar y evaluar el ciclo del agua, el crecimiento de las plantas y flujos de carbono, así como mejorar modelos climáticos y regionales (Foken, 2008; Raavshan et al., 2019). Diversos estudios han mostrado que la energía disponible medida (radiación neta entrante menos el flujo del calor del suelo) es generalmente mayor que la suma de los flujos de intercambio (flujo de calor latente y sensible). Sin embargo, estos flujos son muchas veces capturados de forma incompleta, lo que genera sesgos como subestimaciones de la energía disponible (Raavshan et al., 2019; Mauder et al., 2020; Widmoser y Michel, 2021).

Cuando el balance de energía no cierra se dice que hay desequilibrio energético, esto es uno de los principales desafíos en la evaluación e interpretación de los datos de flujo de la técnica de covarianza de torbellino (Wilson et al., 2002; Foken, 2008; Yue et al., 2011; Raavshan et al., 2019). Algunos estudios hacen referencia a subestimaciones cercanas entre 20% y 30% de la energía disponible, estos sesgos pueden presentarse por problemas con los instrumentos, errores en el procesamiento de los datos, la presencia de fuentes adicionales de energía no contabilizadas, la existencia de circulaciones secundarias de energía, entre otros factores (Mauder et al., 2020; Widmoser y Michel, 2021).

Es conocido que las estimaciones de flujos de superficie en los trópicos son un reto y en el caso de regiones con lluvia abundante las mediciones son afectadas por la intensidad de la lluvia. Aunque en este trabajo se hace uso de un sistema de covarianza de flujo de paso cerrado, esto no excluye la posibilidad de sesgos, por lo que se realiza en primera instancia una evaluación del cierre del balance de energía, con el objetivo de garantizar la calidad del dato. En el caso de esta investigación, se estimó el balance de energía a partir de la ecuación de balance, siguiendo Kidston et al., 2010; Raavshan et al., 2019 y Mauder et al., 2020 y utilizando la información obtenida de las mediciones realizadas con el sistema de EC:

$$R_n = H + LE + G + \text{Imb} \quad (29)$$

Donde R_n es la radiación neta, H es el flujo de calor sensible, LE el flujo de calor latente, G el flujo del calor del suelo y Imb es el desequilibrio energético conocido como desbalance o residuo. Para la evaluación del cierre de balance energético (EBC) se hizo uso de la regresión lineal ordinaria de los flujos turbulentos ($H+LE$) frente a la energía disponible (R_n-G). Posteriormente se calculó la relación de balance de energía (EBR) según Raavshan et al., 2019:

$$EBR = \frac{H+LE}{R_n-G} \quad (30)$$

Y finalmente se comparó el desequilibrio energético o residuo de acuerdo con Mauder et al., 2020 es:

$$A-H-LE \quad (31)$$

Donde A corresponde a la energía disponible, es decir; (R_n-G)

3.1. Ciclo diurno de los flujos de superficie e influencia de la advección en el desequilibrio del balance de energía:

La información del balance de energía en superficie es fundamental para el estudio de la interacción entre la superficie y la atmósfera. El cierre de este balance es uno de los principales problemas, que ha sido estudiado desde hace varias décadas, debido a que se conoce que las mediciones de EC presentan una tendencia a subestimar los flujos turbulentos de calor (Wilson et al., 2002; Foken, 2008; Yue et al., 2011; Raavshan et al., 2019). El ciclo diurno del balance de energía y sus componentes, se muestran en la figura 10. Durante el día los flujos de energía son positivos, y sus valores máximos se observan cerca del mediodía (11:00 am y 12:00 md) con un valor máximo de 490 W/m^2 , y la H con 196 W/m^2 y el sensible LE con 200 W/m^2 , siguiendo el comportamiento del calentamiento de la superficie. De acuerdo con Mauder et al., (2020), en estas condiciones de la R_n , la evapotranspiración es baja y la mayor parte del día se utiliza para transferir calor a la atmósfera mediante energía latente H y otra parte se transporta al suelo (G). Durante la noche y horas del día tempranas, los flujos de energía son negativos, la radiación neta presenta valores por debajo de 40 W/m^2 , para H valores por debajo de 25 W/m^2 y valores pequeños por debajo de 10 W/m^2 de energía sensible LE , el comportamiento del flujo de calor del suelo y del residuo es similar.

La radiación neta promedio mensual es mayor en los meses de diciembre a mayo, con valores entre 600 y 800 W/m² principalmente en el mes de marzo, correspondiente a la estación seca. En los meses entre junio y noviembre, los valores máximos se mantuvieron entre un rango de 300 a 500 W/m², correspondiente a la estación lluviosa. El flujo de calor latente en los meses de estación seca fue mayor al calor sensible, mientras que en los meses de estación lluviosa los flujos de calor sensible son mayores en el periodo de estudio.




Figura 10. Ciclo diario en finca La Hilda de Poás, Alajuela periodo 2020-2021.

Nota: Ciclo diario en Finca la Hilda en Poás de Alajuela, Costa Rica del periodo 2020-2021 con valores acumulados diarios por hora de datos de cada 30 minutos W/m². La línea negra muestra la radiación neta, la línea azul el flujo de calor del suelo, la línea de color café el flujo de calor latente, la línea verde el flujo de calor sensible, la línea roja el desequilibrio energético y la línea amarilla la advección.

Partiendo de que el arreglo instrumental incluye otras estaciones meteorológicas en parcelas adyacentes al sitio de estudio, se procede a estimar el término de advección para identificar su relación con el residuo. La advección se estima a partir Mauder et al.,(2020) de:

$$A = \rho C_p Z_m U \left(\frac{\Delta T}{\Delta X} \right) \quad (32)$$

Donde p es la densidad del aire (Kg/m^3), C_p es la capacidad de calor del aire a presión constante, U es la velocidad del viento (m/s^{-1}), Z_m es la altura de la torre de sol (4.5 m), ΔT es la diferencia de la temperatura de los datos obtenidos de la torre EC y la estación meteorológica Davis ($^{\circ}\text{C}$), ΔX es la distancia aproximada en línea recta entre la torre EC y la estación meteorológica Davis (800 m).

Como se muestra en la figura 10, la advección fue cercana a cero, esto significa que hay menos entradas anómalas en el sistema, lo cual garantiza una mejor calidad de los datos. Esta relación también se puede observar en la figura 11 y tabla 6, donde se evidencia que los valores de la pendiente tienden a cero y esto es debido a la advección. Además, las condiciones de advección cambian según las condiciones del día. Durante el periodo de estudio, el desequilibrio energético fue negativo durante el día y positivo durante la noche. El calentamiento diferencial cambia, es decir en el día es positivo y en la noche negativo, la advección es inversa al calentamiento diferencial.




Figura 11. Advección y parámetro de estabilidad 2020-2021.

Nota: La advección fue estimada a partir de la ecuación 32 y las condiciones atmosféricas mediante la estimación del parámetro de estabilidad de la ecuación 33, mediante los datos de la torre covarianza de torbellino.

De acuerdo con la figura anterior, que la relación de advección con el parámetro de estabilidad (ecuación 33), se presentan valores positivos en condiciones atmosféricas estables, negativos en inestables y cercanos a cero en condiciones neutrales. Es decir, el

sistema está en condiciones de reconocer que cuando hay condiciones de inestabilidad hay una anomalía negativa en la advección.

3.2. Cierre del balance de energía superficial

Es de importancia garantizar la calidad de la información, y por esto es de interés proveer una medida cuantitativa de la calidad del dato, en el caso de la información derivada de EC se evalúa el cierre del balance (EBC). La figura 12, muestra la media mensual del cierre de balance de energía, determinado por regresión lineal ordinaria durante el periodo 2020-2021 de flujos turbulentos de energía sensible y latente ($H+LE$) y la radiación neta menos el flujo del calor del suelo (R_n-G). Se hace la indicación que en el caso ideal de un balance cerrado, el valor de la pendiente de la regresión lineal ordinaria (OLR) es igual a 1 (Wilson et al., 2002; Yue et al., 2011; Raavshan et al., 2019). Para el periodo y sitio de estudio, los resultados muestran que la pendiente tiene valores que varían entre 0.3 y 0.9, con pendientes altas de 0.8 a 0.9 asociado a la mayor variabilidad de la estación seca (diciembre-abril), mientras que en la estación lluviosa presentó pendientes de 0.7. con lo que se considera una calidad razonable de la información.




Figura 12. Cierre de balance de energía agregado mensual (EBC) para el periodo 2020-2021.

Nota: obtenido por regresión lineal ordinaria de flujos turbulentos ($LE+H$) contra flujos de energía (R_n-G) con datos de cada media hora, para el periodo 2020-2021.

El mes de enero es el que muestra los valores más bajos para la pendiente, lo que es indicativo de errores en el sistema que generan esta diferencia. El mes de enero es el

periodo más frío y se observa en el sitio una cantidad importante de deposición de rocío, por lo que hay presencia de agua no contabilizada en el sistema que es observada por el sistema como flujo de agua positivo. El mes de diciembre es el que el que mostró el valor más alto para la pendiente 1. Este mes fue uno de los periodos más secos, y refleja valores promedio altos de ET (5mm/mensual). Los meses de febrero y marzo también mostraron pendientes y valores de ET altos de 4.4mm/mensual, lo que significa que existe una menor disponibilidad de agua en la superficie del suelo y por lo tanto la ET aumenta, ya que el agua disponible se evapora rápidamente.

Los meses de abril a agosto mostraron una leve disminución con valores similares de pendientes entre 0.6-0.7, estos se identifican por ser la primera temporada de lluvias en el país. El mes de agosto tuvo un comportamiento similar a los meses de estación lluviosa, sin embargo, este fue el mes con el valor de ET más bajo con un promedio de 2 mm/mensual, lo que significa que en el sistema había mucha disponibilidad de agua en la superficie del suelo, esto debido al mes de julio que fue el más lluvioso del periodo.

El mes de setiembre, fue uno de los meses más lluviosos en el periodo, con una precipitación promedio de 400 a 500 mm/mes, sin embargo, este al igual que julio, presentó un valor de ET alto de 4 mm/mensual, lo que significa que en el sistema todavía hay presencia de agua no contabilizada.

Los meses de octubre y noviembre, también fueron los meses más lluviosos del periodo. Estos mostraron un comportamiento similar con pendientes de 0.7, y un bajo valor de ET promedio de 3 mm/mensual, por la alta disponibilidad de agua en la superficie del suelo, ante la estación lluviosa.

Es importante mencionar que el cierre de balance de energía puede verse como un problema de escala, porque cada flujo es representativo de un área, y el cierre se ha realizado en función de las áreas con huellas de flujos turbulentos (Masseroni, 2012; 2014), también como efectos de mezcla de flujos, es decir, cambios directos en la velocidad de fricción que cambia con la estabilidad atmosférica y la hora del día (Wilson et al., 2002; Masseroni, 2014), así como los efectos de la heterogeneidad de la superficie y la estacionalidad en la influencia del crecimiento de la cobertura vegetal en el cierre del balance de energía (Masseroni, 2014). Como se puede observar de los resultados, la

influencia de la estacionalidad influye mucho en el crecimiento de la vegetación, como es el cultivo del café, donde su crecimiento vegetativo en la zona occidental de Costa Rica (ICAFFE, 2021), se da desde marzo a octubre (crecimiento en altura y formación del bandolas).

En la época seca como febrero, marzo se da principalmente la inducción de desarrollo de las yemas y en el periodo de transición abril se da la formación de botones florales y floración, donde la ET es alta. En época lluviosa de julio a octubre se da el llenado de los frutos, donde el ET es menor, ya que, las plantas obtienen el agua de las raíces, en lugar de depender de la evaporación de la superficie del suelo y ya en los meses más secos como diciembre-febrero se da la maduración de la cosecha, donde la ET es alta por la mayor disponibilidad de agua en el sistema (ICAFFE, 2021).

3.3. Influencia de las condiciones de estabilidad atmosférica

En esta sección se evalúan los términos de cierre y residuo del balance de energía (EBC y EBR) en función de la estabilidad atmosférica. Para este propósito se utilizó el parámetro de estabilidad atmosférica adimensional ζ (ZL), estimado a partir de los datos de EC. De acuerdo con (Franssen et al., 2010; Raavshan et al., 2019) el parámetro de estabilidad se puede obtener a partir de la ecuación:

$$\zeta = Z_m/L \quad (33)$$

Donde Z_m es la altura de medición del anemómetro sónico (4.5 m) y L (m) la longitud de Obukhov, la estabilidad se clasificó en tres clases: a) estable= $\zeta \geq 0.1$, neutral ($-0.1 < \zeta < 0.1$) e inestable = ($\zeta \leq -0.1$). Los resultados se muestran en la Tabla 6, se identifica que en el periodo de estudio las condiciones neutrales fueron dominantes, del conjunto de datos, el 25% fueron condiciones estables, el 19% condiciones inestables y el 56% condiciones neutrales.

Las condiciones de estabilidad inciden sobre el cierre del balance, se obtiene como resultado que durante las condiciones estables el balance muestra el mejor cierre (pendiente de 0.819), seguido por las condiciones neutrales (pendiente 0.718) mientras que el cierre presenta más problemas para los casos de condiciones inestables (0.627). Este resultado es de importancia, ya que las condiciones inestables se ven muy afectadas por los efectos de la

advección, por lo que es esperable que bajo condiciones de inestabilidad el efecto de la advección presente mayor afectación sobre el balance.

Tabla 6. Cierre de balance energético (EMC) obtenido de regresión lineal ordinaria, bajo diferentes condiciones de estabilidad atmosférica y EBR promedio durante 2020-2021.

Condición de estabilidad	Parámetro	Unidad	Valor EBC
Estable	Pendiente	W/m ²	0.819
	R ²		0.781
	N°datos		144
	EBR		0.36
Neutral	Pendiente	W/m ²	0.718
	R ²		0.765
	N°datos		328
	EBR		0.52
Inestable	Pendiente	W/m ²	0.627
	R ²		0.723
	N°datos		113
	EBR		0.63

La condición de estabilidad en la finca La Hilda durante el periodo 2020-2021, mostró un comportamiento determinado por la estacionalidad. Los meses con dominancia de condiciones estables con datos acumulados diarios, fueron de diciembre a abril, principalmente el mes de diciembre, correspondiente a la estación seca, mientras que las condiciones inestables se presentaron en la estación lluviosa, principalmente los meses de mayo y octubre en que se observan los eventos de precipitación intensa en cada uno de los periodos de lluvia. Las condiciones neutrales fueron similares durante todos los meses.

3.4. Evapotranspiración

La ET es un proceso que desempeña un papel crucial en el balance de energía de los ecosistemas, como combinación de la evaporación del agua desde la superficie terrestre y la transpiración de las plantas (Rodríguez et al., 2012). Esta representa un flujo significativo de energía en forma de calor latente, el cual es transferido desde la superficie hacia la atmósfera (Versini et al., 2024).

Por eso, en estudios de balance energético, una estimación precisa de la ET es importante para conocer el comportamiento de los flujos energéticos, ya que cualquier discrepancia en

su cuantificación puede conducir a errores en la evaluación de otros componentes críticos, como el flujo de calor sensible o el almacenamiento de energía en el suelo.

Por eso, además de la ET real obtenida de la torre EC, se estimó la ET_0 mediante otros métodos como FAO-Penman-Monteith (PM), Hargreaves (H) y Blaney-Criddle (BC) mediante datos meteorológicos de la estación meteorológica Davis Vantage Pro2 Plus. La comparación entre estos métodos permite evaluar las diferencias entre las condiciones teóricas de referencia y las condiciones reales en campo.

En la figura 13, se puede observar el cálculo de la ET estimada y ET real para el periodo 2010-2022. El método de BC, muestra los valores más altos, con un promedio general de 62.39 mm/mes. Esto se debe a su tendencia a sobreestimar la ET estimada en comparación con los otros métodos, especialmente en los meses de enero, marzo y mayo en todo el periodo. Estos meses coinciden con períodos donde las condiciones climáticas probablemente favorecen una alta demanda evaporativa, como en el verano o en estaciones con mayor radiación solar.

Por otro lado, el método H, presenta un promedio general intermedio de 11.52 mm/mes, con sus valores más altos en los meses de febrero, marzo y abril. Sin embargo, este método muestra una notable disminución en los siguientes meses, lo que indica una mayor sensibilidad a ciertos factores climáticos que podrían estar relacionados con la variación estacional de temperatura.

El método PM, conocido por ser uno de los más precisos y confiables para estimar la evapotranspiración (Rodríguez et al., 2012), muestra valores más altos en los meses de mayo a agosto y los más bajos en los meses enero y marzo. Esto indica que el método es menos susceptible a fluctuaciones extremas y se ajusta de manera más precisa a las condiciones climáticas observadas en esos períodos.




Figura 13. Comparación de la evapotranspiración (mm/mensual) estimada mediante tres métodos durante el periodo 2010-2022 de datos de la estación meteorológica Davis Vantage Pro2 Plus.

Nota: el primer gráfico de color celeste es la ET estimada por el FAO Penman-Monteith, el segundo de color gris por el método Hargreaves y el último naranja por Blaney- Criddle.

En comparación con la técnica de covarianza de torbellino (EC) durante el período 2020 y 2021, se observaron diferencias notables en el desempeño de los modelos a escala diaria y mensual. Al comparar las estimaciones de ET obtenida por medio de la técnica de covarianza de torbellino, el método H mostró un R^2 negativo a escala diaria de -1.13 mm/día y un RMSE de 3.69, mientras que escala mensual, su desempeño mejoró ligeramente, con un R^2 de 0.0074, un RMSE de 1.27 mm/mensual. El método BC, por otro lado, presentó un R^2 de -0.39 a escala diaria y mejoró en 0.040 a escala mensual, pero con una diferencia notable en el RMSE: 2.38 con datos diarios y 1.25 mensual, lo que indica que, aunque es relativamente preciso en términos de RMSE, su capacidad de predicción lineal es limitada. El método PM mostró un R^2 de -2.34, un RMSE de 3.69 con datos diarios. Al pasar a la escala mensual, el RMSE mejoró a 1.21, y el R^2 en 0.1047, reflejando un desempeño más estable.




Figura 14. Comparación de los métodos de cálculo de ET estimada y ET con el de la técnica de covarianza de torbellino (EC) en el periodo de estudio 2020-2021 a escala mensual.

Los resultados obtenidos muestran que ninguno de los tres métodos evaluados se acercó con precisión a los valores de evapotranspiración real en campo mediante la técnica de covarianza de torbellino. Esto muestra que los métodos empíricos presentan limitaciones cuando se aplican a las condiciones específicas del estudio, posiblemente debido a la simplificación de los factores climáticos que influyen en la evapotranspiración. Por otro lado, la técnica de EC, es ampliamente reconocida en la literatura científica como un método más robusto y preciso para medir los flujos de masa y energía entre la superficie terrestre y la atmósfera, ya que permite la medición directa de la evapotranspiración basada en la turbulencia del aire sobre la superficie, capturando de manera más fiel la dinámica real del ecosistema (Baldocchi, 2003; Foken, 2008; Burba, 2023).

Capítulo 4. Estimación de la eficiencia del uso del agua

La producción de café es una actividad agrícola de gran importancia socioeconómica en el país. En toda su cadena de valor, este cultivo presenta una alta demanda de recursos hídricos, por lo cual es necesario comprender y evaluar la eficiencia del uso del agua. Este conocimiento es esencial para garantizar la viabilidad económica de los productores, y abordar desafíos relacionados con la variabilidad climática y sus efectos en el cultivo, para así promover prácticas agrícolas sostenibles. Para esta investigación, se estimó la EUA a nivel de ecosistema con la metodología relacionada con la productividad primaria bruta (PPB) ya que esta modulada por la retroalimentación de agua, carbono y energía entre el dosel y la atmósfera (Ponton et al., 2006; Chinchilla et al., 2021), utilizando la ecuación 4, mediante datos obtenidos de la técnica de covarianza de torbellino, utilizando datos de evapotranspiración (ET) y de productividad primaria bruta (PPB) cada media hora generando datos acumulados mensuales del periodo de estudio 2020 y 2021.

Es importante mencionar que en diversas investigaciones indican que la EUA, está controlada principalmente por factores como tipo de suelo, tipo de cultivo y las prácticas de manejo (Mbava et al., 2020) así como factores ambientales, por ejemplo, disponibilidad o contenido de agua, concentración de CO₂ atmosférico (Jiang et al., 2022), controles fisiológicos y fenológicos como la conductancia estomática e índice de área foliar, sin embargo, estos varían según las zonas climáticas y los ecosistemas (Siles, 2020; Jiang et al., 2022). Los factores meteorológicos que usualmente se analizan es la temperatura del aire, humedad relativa, la velocidad del viento, flujo del calor del suelo, contenido de agua, presión atmosférica y precipitación (Siles 2020; Jiang et al., 2022).

La temperatura, es uno de los factores climáticos de mayor impacto en la fisiología del café, siendo la temperatura óptima de 18° a 21°C, la cual está relacionada con la altitud donde el rango óptimo para la producción de café en Costa Rica es de 500 a 1700 msnm (ICAFE, 2020 ; Siles, 2020).

En el caso de la finca La Hilda, la altitud promedio del cantón esta entre 600 msnm a 2838 msnm (Quesada, 2015; Barrantes y Quesada, 2016), estando en el rango óptimo para la producción de café, mientras que la temperatura promedio osciló entre 14 °C a 23 °C en los

años 2020 y 2021, en caso de las temperaturas diarias oscilaron con un mínimo de 13.4 °C y un máximo de 31 °C especialmente en época seca (Figura 15). Las altas temperaturas por encima de 21°C pueden generar una aceleración del desarrollo en la maduración del fruto y por lo tanto una disminución en la calidad del grano (Bunn et al., 2015), temperaturas a partir de 24 °C genera menor rendimiento de la planta (Camargo, 2010), y entre 28 a 30 °C genera reducción de formación de yemas florales y daños en las plantas como menor crecimiento y hojas amarillas (Haggar y Schepp, 2015; Ovalle, 2018).

La radiación neta en condiciones de pleno sol para el periodo 2020 se mantuvo con un promedio de 113.77 W/m² y 2021 de 108 W/m². Los valores máximos se evidenciaron en la época seca, siendo el mes con mayor radiación neta marzo (200 W/m²), y valor mínimo se dio en el mes de agosto, los valores disminuyeron en la época lluviosa con valores entre 90-100 W/m². La humedad relativa, se comportó similar en ambos años con un promedio diario de 80%, con mayor humedad en época lluviosa entre 84-90%, mientras que en la época seca los valores fueron de 60% (Figura 15). Porcentajes superiores a 85% propicia el ataque de enfermedades fungosas en el cultivo del café (ICAFE, 2020a). El comportamiento de estos 3 factores ambientales muestra que, en época lluviosa, existe mayor humedad y nubosidad, reduciendo la radiación neta y disminuyendo la temperatura, en ambos años.

Otro factor que incide en la producción de café es el viento, ya que puede inducir a la desecación, daños mecánicos del tejido vegetal, incidencia de enfermedades (ICAFE, 2020). En La Hilda, para el 2020 la velocidad del viento tuvo un promedio diario de 1.34 m/s y de 1.16 m/s en 2021, los valores máximos mensuales se dieron de enero a abril y luego disminuyó en época lluviosa con promedios de 0.70-0.80 m/s.

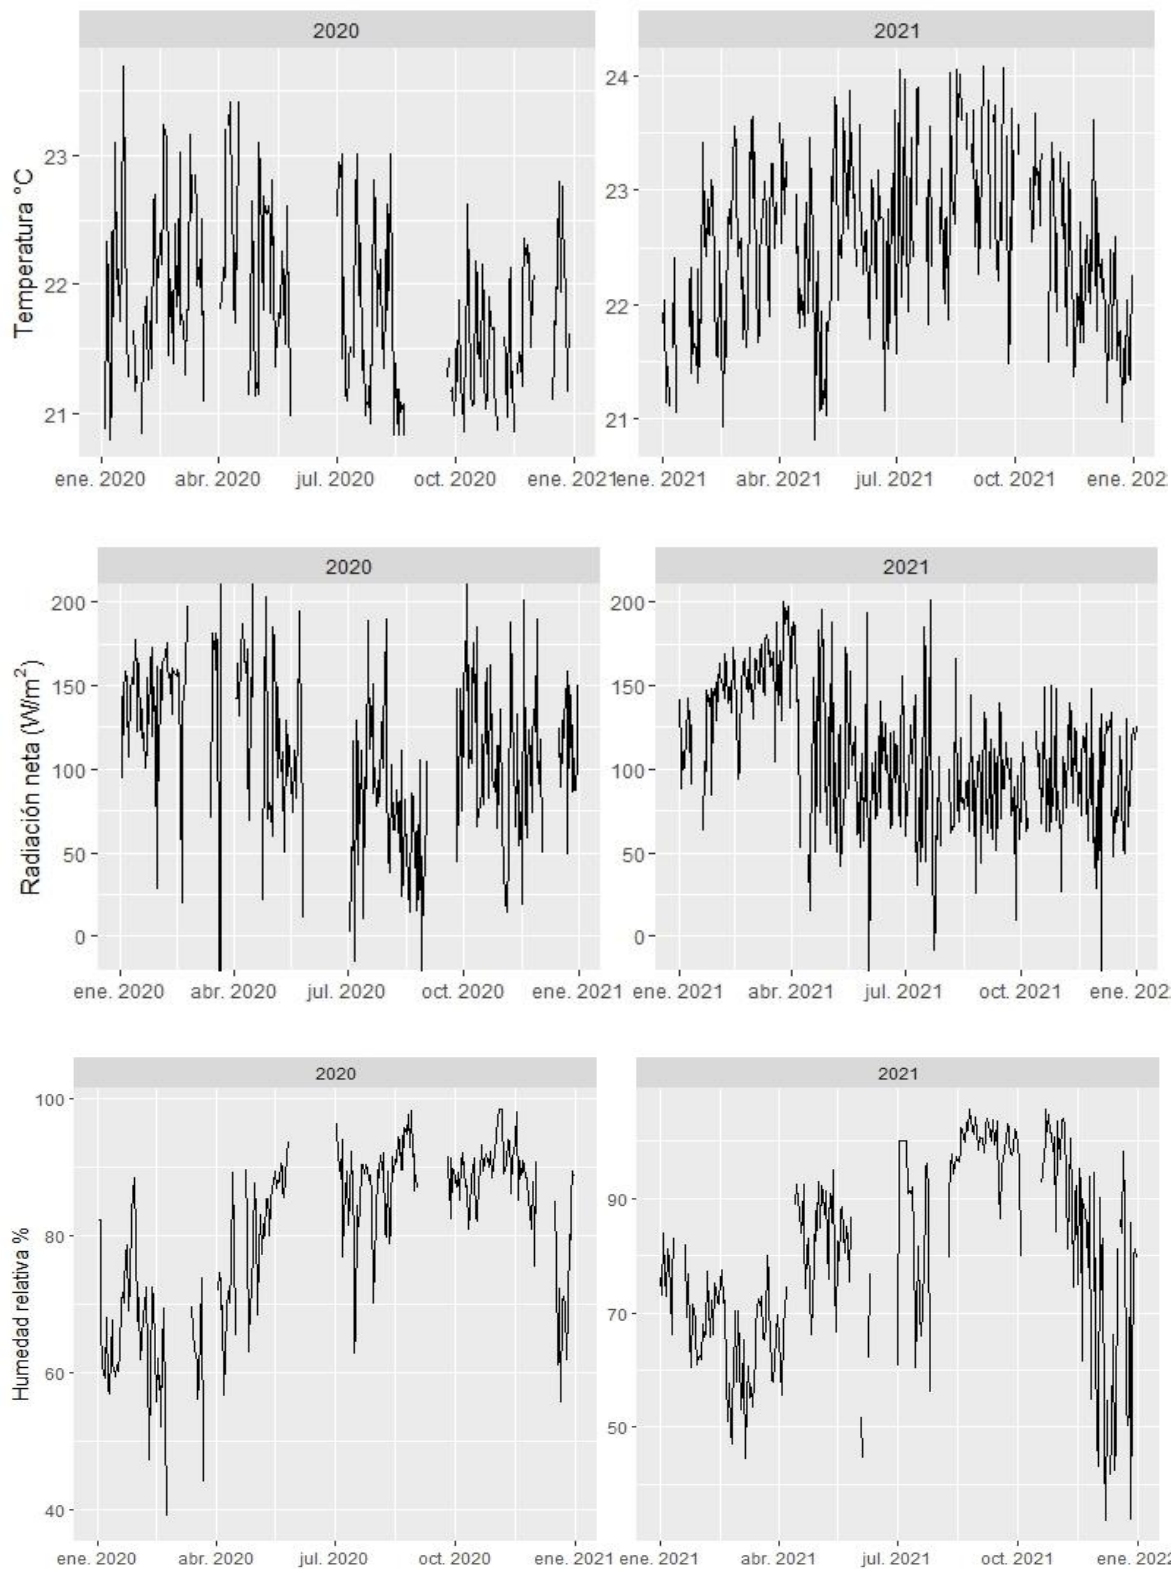


Figura 15. Temperatura del aire diaria en °C, radiación neta diaria en % y humedad relativa diaria en % para el año 2020 y 2021 en la finca La Hilda.

La precipitación en La Hilda presenta estaciones secas y lluviosas bien definidas, con una precipitación anual de aproximadamente 2300 mm. La temporada seca va de diciembre a abril y la temporada de lluvias va de mayo a noviembre, con una disminución en la precipitación entre julio y agosto que según Montero (2022) se debe a la influencia de la sequía de medio verano o “veranillo” que es una reducción de las precipitaciones entre la primera y segunda etapa de la temporada de lluvias, dado que el sitio está influenciado por el régimen de precipitaciones del Pacífico. Para el periodo de estudio, el mes más seco fue enero (< 10 mm/mes) mientras que la precipitación máxima se presentó en los meses de septiembre y octubre (> 400 mm/mes). En 2020, se puede observar que hubo fuertes lluvias en mayo, donde se presentaron dos ondas tropicales, con superávits en el valle central de hasta 50 y 70%, en noviembre se presentaron dos ciclones tropicales intensos conocidos como el huracán ETA y IOTA que provocaron temporales importantes con superávits de 300% en el valle central y se registró condiciones muy húmedas y alta nubosidad así como vientos predominantes (Chinchilla et al., 2020). En La Hilda se identificó para noviembre 90% de humedad relativa y vientos de 0.85 m/s.




Figura 16. *Precipitación mensual del 2020 y 2021, en la finca La Hilda.*

4.1. Eficiencia del uso del agua

La EUA de la finca la Hilda para los años 2020 y 2021 varió entre 0 a 50 gCO₂/kgH₂O con valores más altos durante la estación lluviosa, principalmente en el mes de noviembre y agosto 2020, julio 2021 y valores más bajos en la estación seca como el mes de enero.




Figura 17. Ciclo anual de la eficiencia del uso del agua en la finca La Hilda, 2020-2021.

Nota: Estimación de la eficiencia del uso del agua, con datos de productividad primaria bruta (PPB) en (gCO₂/kgH₂O) y Evapotranspiración (ET) en (mm/día), con datos cada media hora obtenidos de la técnica de covarianza de torbellino de los años 2020 y 2021.

La estación seca presentó valores de EUA entre 0 a 20 gCO₂/kgH₂O, donde se caracterizó por tener poca precipitación, temperaturas de hasta 23 °C, y a su vez radiación neta de 130-230 W/m², con una velocidad del viento de hasta más de 2 m/s, siendo el mes de enero 2021, el que presentó una menor EUA. Los meses de diciembre, febrero, marzo y abril, presentaron un comportamiento similar en ambos años, con un EUA entre 12 a 20 gCO₂/kgH₂O. Estos meses se caracterizaron por tener poca precipitación, altas temperaturas y alta radiación neta con un promedio de 145 W/m² alcanzando en marzo 2020 un valor máximo de 216 W/m², la humedad relativa promedio fue de 68% y con velocidad del viento de 2 m/s. De acuerdo con el estudio realizado por Montero (2022), en el 2021 en el lote bajo sol predominó el desarrollo de las yemas florales, a mediados de

abril inició la antesis y la transición de floración a la etapa de llenado de fruto. El mes de mayo, presentó valores de 10 y 20 $\text{gCO}_2/\text{kgH}_2\text{O}$, siendo más alto en el año 2021, cabe destacar que este mes, se caracterizó por presentar altas precipitaciones de 269 mm y 367 mm en 2020, por lo tanto, alta humedad relativa de más de 80 %, ya que como se indicó anteriormente hubo un superávit de lluvias. Para junio, la información disponible fue del año 2021, donde la EUA fue de 22 $\text{gCO}_2/\text{kgH}_2\text{O}$, que según el estudio de Montero (2022), para este mes se alcanzó la frecuencia máxima del llenado del fruto. Asimismo, este mes se caracterizó por tener una alta precipitación de 312 mm, con humedad relativa del 70% y muy pocos vientos de baja velocidad.

El mes de julio, fue el segundo mes con un valor alto de EUA 41.24 $\text{gCO}_2/\text{kgH}_2\text{O}$ en 2021, influenciado por las lluvias intensas de hasta 368 mm y una alta humedad relativa de 85%. Caso contrario fue el mes de agosto, que tuvo una EUA mayor en 2020, de 40 $\text{gCO}_2/\text{kgH}_2\text{O}$, donde la precipitación fue alta en ambos años, con una humedad de hasta 90% y poco viento, asimismo para el año 2021, en este mes inició el periodo de maduración (Montero, 2022). Para septiembre la información disponible fue el 2021, donde se obtuvo una EUA de 27 $\text{gCO}_2/\text{kgH}_2\text{O}$, siendo uno de los meses más lluviosos para ese año con un valor máximo de 525.7 mm y por lo tanto una alta humedad de más de 90%.

El mes de octubre mostró un comportamiento similar en ambos años, con un EUA de 28 $\text{gCO}_2/\text{kgH}_2\text{O}$ y siendo uno de los meses más lluviosos con 410 y 324 mm respectivamente, con humedad superior a 90%. En el caso de noviembre, para el año 2020 fue el mes con el valor más alto de EUA 48.10 $\text{gCO}_2/\text{kgH}_2\text{O}$, relacionado con la alta precipitación (247 mm) y alta humedad de 87%. Según Xiao et al., (2013) y Montero (2022), la EUA está relacionada con la precipitación y aumenta en función de la productividad del ecosistema, es decir; una alta precipitación estimula un aumento de la EUA; por el contrario, las condiciones secas pueden provocar una disminución y que a una mayor PPB se obtiene una mayor EUA. Esta relación se evidencia en las figuras 16 y 17, y en lo explicado anteriormente, donde la variabilidad intraestacional de la EUA estuvo influenciada por eventos de lluvias intensas, donde los meses más húmedos como julio, octubre y noviembre tuvieron altos valores de EUA de entre 20 a 50 $\text{gCO}_2/\text{kgH}_2\text{O}$, mientras que los meses más secos tuvieron valores más bajos de EUA.

En cuanto al ciclo anual de la productividad primaria bruta (PPB) mostró altos valores en la temporada de lluvias entre 113 a 130 $\text{gcm}^2/\text{mensual}$ en 2021 y entre 50 y 95 $\text{gcm}^2/\text{mensual}$ en 2020, la cual coincide con la fase más activa de crecimiento y almacenamiento de la cosecha de frutas en desarrollo (Montero, 2022). Los meses con mayor PPB también fueron los meses más húmedos como julio, octubre y noviembre con valores promedio de 2-4 $\text{gcm}^2/\text{mensual}$, especialmente en el año 2021. Algunas investigaciones han encontrado que elevadas precipitaciones y alta humedad son responsables de cosechas dispersas y bajos rendimientos (Silles, 2020), y por lo tanto, reducción de calidad de los granos de café y aumentos en costos de cosecha (DaMatta et al., 2007; Bunn et al., 2015). En el caso de la finca La Hilda, este comportamiento se evidenció en los bajos rendimientos en la primera cosecha 2019-2020 con apenas 6.48 fanegas/ha y luego tuvo una mejora en la cosecha de 2020-2021.

Este comportamiento también se debe al concepto de bianualidad en el cultivo de café, es decir, un año con baja producción y otro con alta. Según el ICAFE (2020) para el periodo 2020 en el valle occidental, hubo un aumento en la cosecha gracias a la buena floración promovida por las lluvias oportunas en comparación con las últimas dos cosechas, a nivel país hubo un aumento del 12% respecto a la cosecha anterior 19-20. Sin embargo, en el 2020 y a mediados de 2021, hubo una gran cantidad de lluvia favorecida por el fenómeno de la niña lo que generó enfermedades (antracnosis, chasparria, roya) y con ello debilitamiento de las plantas y por ende menor producción para la cosecha siguiente (ICAFE,2022).

4.1.1. Eficiencia del uso del agua observada y simulada

Al realizar la comparación los valores observados analizados anteriormente de la EC, con valores simulados obtenidos del modelo SVEN, con datos de entrada de la estación meteorológica Davis Vantage Pro2 Plus. Los resultados obtenidos indican una correlación negativa moderada (-0.394) entre la EUA simulada y la observada, lo que sugiere que el modelo de simulación no captura adecuadamente los patrones reales de la EUA. Además, el alto MAE 389.77 $\text{gCO}_2/\text{kgH}_2\text{O}$ sugiere una significativa discrepancia promedio entre las predicciones y los valores observados. Esta discrepancia está relacionada con una sobreestimación en las variables simuladas, específicamente en la ET y la PPB (Capítulo

5). En particular, la presencia de valores atípicos en estas variables simuladas podría estar distorsionando las estimaciones del modelo, dificultando la alineación con los datos observacionales. Estos valores atípicos pueden resultar en un sesgo en las predicciones, haciendo que la simulación subestime o sobrestime la EUA en ciertos periodos.

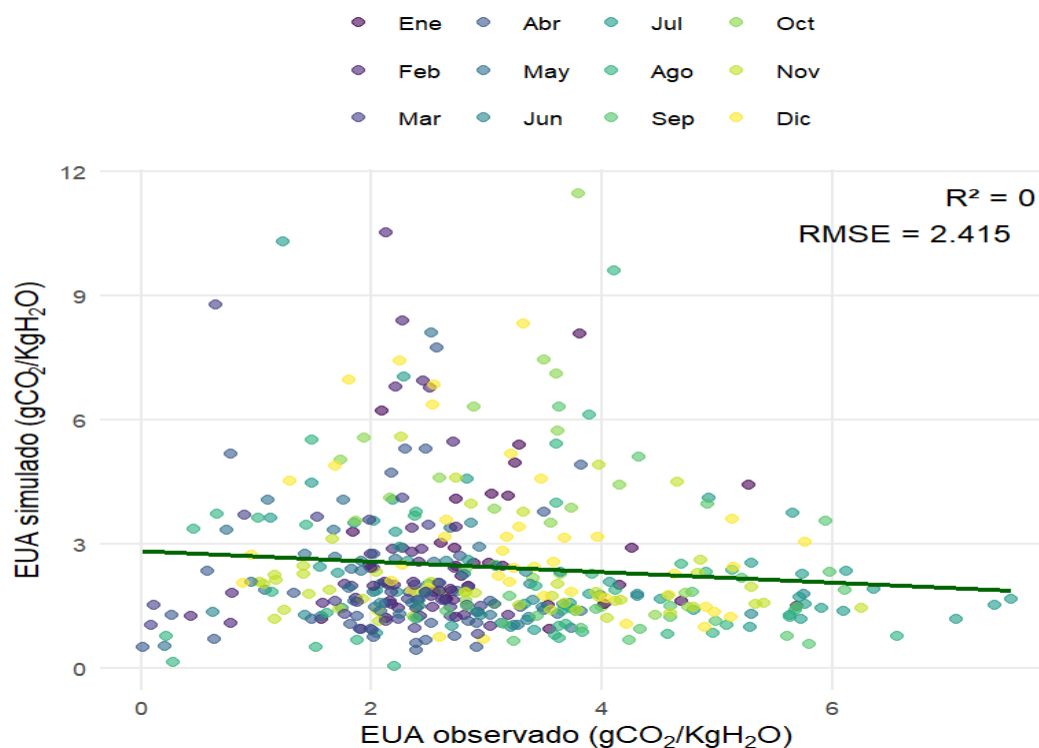


Figura 18. Comportamiento de EUA observada y simulada por el Modelo SVEN, periodo 2020-2021 a escala mensual.

Nota: La EUA observada se refiere a los datos de la torre de covarianza de torbellino, y lo simulados de la estimación de la EUA calculada mediante ET y PPB simulados por el Modelo SVEN.

Como se muestra en la figura anterior, el R^2 de 0.0094, indica que el modelo explica solo el 0.94% de la variabilidad observada en los datos. Este bajo valor sugiere que el modelo utilizado no captura adecuadamente los factores que influyen en la EUA, lo que podría deberse a la falta de variables clave o a simplificaciones en la simulación. El RMSE, que mide la magnitud promedio del error entre los valores observados y simulados, es de 452 unidades. Este valor relativamente alto indica que las predicciones del modelo tienden a desviarse significativamente de los valores reales, lo que sugiere que las predicciones no son lo suficientemente precisas. En conjunto, estos resultados sugieren la necesidad de

mejorar el modelo, posiblemente incorporando más variables o ajustando los parámetros para lograr una mejor concordancia entre los valores observados y simulados de la EUA.

Asimismo, este comportamiento se mostró en todos los meses, los valores de R^2 son generalmente bajos, lo que indica una débil correlación entre los datos simulados y observados. Además, los valores de RMSE varían entre meses, con errores más altos en los meses lluviosos como julio y agosto (RMSE de 3.263 y 2.806, respectivamente), reflejando posibles limitaciones en el modelo para capturar las dinámicas del uso del agua durante la temporada de mayor precipitación. Esta discrepancia resalta la necesidad de ajustar o calibrar el modelo para mejorar su desempeño, especialmente en los meses de mayor variabilidad climática (Figura 19).




Figura 19. Comportamiento de EUA observada y simulada por el Modelo SVEN, por mes del periodo 2020-2021.

Por lo tanto, es necesario revisar el modelo de simulación y considerar la implementación de técnicas para identificar y corregir valores atípicos, así como ajustar los parámetros del

modelo para reducir la sobreestimación, o subestimación y mejorar la precisión en la estimación de la EUA. Este enfoque permitirá una mejor comprensión de la dinámica del uso del agua en las plantaciones de café y contribuirá a la optimización de los recursos hídricos en el cultivo.

Capítulo 5: Evaluación del Modelo SVEN

Las variables utilizadas para la evaluación del modelo (Tabla 4 y 5) fueron analizadas en escalas de cada media hora. Los resultados (temperatura del suelo, radiación neta, flujo de calor latente, flujo de calor sensible y la productividad primaria neta), se contrastaron en escala media hora y diaria comparados con los datos observados de la torre de covarianza de torbellino. Las métricas estadísticas de desempeño, para evaluar la calidad y precisión en ambas escalas se observan en la Tabla 7. En todas las variables se identificó un mejor desempeño del modelo a escala diaria, y por año en el 2021.

En la frecuencia de media hora, el modelo mostró un desempeño bajo en las variables ET y LE donde la correlación fue mayor, y tanto el RMSE como el MAE fueron relativamente bajos, lo que indica que el modelo no logró predecir estas variables con una precisión aceptable. Por otro lado, las variables Tsuelo, RN, H y PPB presentaron un desempeño deficiente. En particular, la variable H mostró un rendimiento muy pobre, con una correlación casi inexistente, un RMSE elevado, un R^2 prácticamente nulo, y un MAE considerablemente alto, lo que indica que el modelo fue casi incapaz de predecir esta variable con precisión.

Estos resultados sugieren que, aunque el modelo tiene cierta capacidad para reproducir la estacionalidad de las variables como ET y LE, muestra serias limitaciones en su capacidad predictiva para variables como H, PPB, Tsuelo y RN, donde no logra explicar la variabilidad de los datos y comete errores porcentuales elevados. A escala diaria el desempeño de la Tsuelo mejoró ligeramente, pero sigue siendo una capacidad de reproducción baja. Para variables como LE, PPB, RN y H, SVEN tuvo un menor desempeño comparado a escala media hora, obteniendo correlaciones y R^2 negativos o muy bajas, RMSE moderado o alto y MAPE muy elevados. Esta disminución en el rendimiento entre escalas se debe a que, al promediar los datos a diario, se pierde información importante sobre las fluctuaciones que ocurren en intervalos más cortos. Además, los errores en las predicciones tienden a acumularse y volverse más evidentes en la escala diaria.

Tabla 7. Desempeño del modelo SVEN a diferentes escalas de tiempo, 2020-2021.

Escala de tiempo	Métricas estadísticas de desempeño	Variables					
		Tsuelo	RN	LE	H	PPB	ET
		<i>K</i>	W/m^2	W/m^2	W/m^2	g/cm^2d^{-1}	<i>Mm</i>
Media hora	N	24 110	24 126	24 731	24 682	24 565	24 731
	Correlación de Pearson	0.24	0.23	0.27	0.02	0.1872416	0.27
	RMSE	4.05	291.66	157.35	134.22	10.89257	0.16
	R ²	0.06	0.05	0.07	0.00045	0.0350594	0.08
	MAE	2.96	196.64	114.55	84.02	5.96	0.11
Diaria	N	577	577	593	593	588	593
	Correlación de Pearson	0.48	-0.08	-0.02	0.03	-0.12	-0.02
	RMSE	2.33	101.83	48.68	47.04	3.84	0.07
	R ²	0.48	-0.08	-0.02	0.03	-0.12	-0.02
	MAE	1.43	78.40	37.42	35.47	2.93	0.06

Nota: En la primera columna se observa la escala de tiempo (escala media hora y diaria), en la segunda las métricas estadísticas para evaluar el desempeño del modelo, en esta se observa: N, número de datos, RMSE el error cuadrático medio, R² coeficiente de determinación y MAE error absoluto medio y seguidamente su resultado por cada variable analizada. Un modelo es “Aceptable” cuando presenta R² > 0.6, correlación alta (> 0.7), RMSE y MAE bajos, “Moderado”: R² entre 0.3 y 0.6, correlación moderada (0.5-0.7), RMSE y MAE intermedios y deficiente R² < 0.3, correlación baja (< 0.5), RMSE y MAE altos.

5.1. Validación de cada variable

El análisis de las estadísticas del modelo en frecuencia de media hora mostró un desempeño variado en la predicción de las diferentes variables, como se muestra en la Tabla 7 y Figura 20, se evidencia que el modelo puede ser útil en la predicción de ET y LE, es moderado para PPB y su capacidad para predecir variables como H y RN es limitada o deficiente. Estas limitaciones de acuerdo con Pateromichelaki (2020) podrían estar relacionadas con la mayor variabilidad de los parámetros durante el ciclo diurno, que no se refleja de manera tan evidente en escalas temporales más amplias, como la diaria, asimismo es posible que algunos valores atípicos dentro de los conjuntos de datos utilizados para la validación hayan afectado negativamente el desempeño del modelo, especialmente en el caso de H, el cuál durante el análisis a pesar de quitar valores simulados muy extremos, se debe realizar una clasificación más rigurosa de los datos

residuales, lo podría ayudar a aclarar el impacto de estos valores atípicos en la eficiencia del modelo a diferentes escalas temporales.

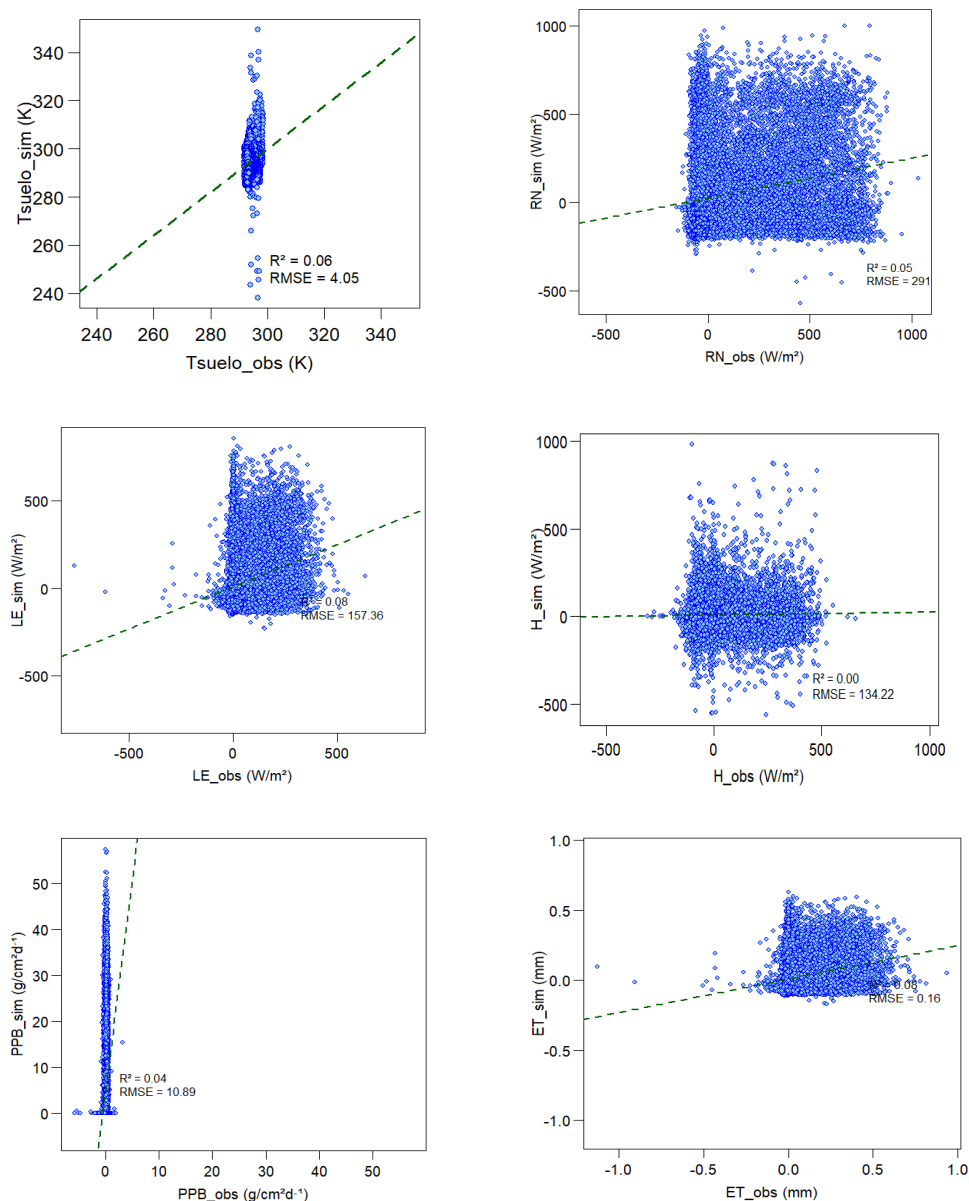


Figura 20. Diagramas de dispersión de datos observados y simulados, del periodo 2020-2021 a escala media hora de las variables temperatura del suelo, radiación neta, flujo de calor latente y sensible, productividad primaria bruta y evapotranspiración.

En el caso de la temperatura del suelo (Tsuelo), a escala media hora, el modelo muestra una correlación débil con los datos observados con una correlación de Pearson de 0.24 y un bajo R^2 de 0.06, lo que indica que el modelo no logra capturar adecuadamente las

variaciones en intervalos cortos de tiempo. Además, los errores de predicción son relativamente altos, con un RMSE de 4.05 y un MAE de 2.96. En contraste, a escala diaria, el modelo muestra un mejor desempeño, con una correlación de Pearson de 0.48 y un R^2 de 0.48, lo que sugiere que el modelo es mucho más efectivo para capturar las tendencias diarias de la temperatura del suelo. Los errores de predicción también disminuyen considerablemente a esta escala, con un RMSE de 2.33 y un MAE de 1.43. Estos resultados indican que el modelo predice de manera más precisa la temperatura del suelo cuando se considera a escala diaria en comparación con la escala media hora.




Figura 21. Comparación de datos observados y simulados de la temperatura del suelo (Kelvin), del periodo 2020-2021 a escala diaria.

En la figura 21, se evidencia para ambos años una subestimación en los meses como diciembre, enero, febrero, mientras que meses de abril a julio una sobreestimación. Asimismo, durante el año 2021, el modelo mostró un mejor desempeño en la predicción diaria en comparación con 2020. La correlación aumentó de 0.45 a 0.56, y el coeficiente de determinación (R^2) mejoró de 0.20 a 0.32, lo que indica una mayor precisión y capacidad explicativa. Además, los errores disminuyeron considerablemente, con un RMSE reducido de 3.31 a 0.96 y un MAE de 2.23 a 0.77, lo que refleja una mayor exactitud en las predicciones del modelo para 2021.

El análisis de la radiación neta muestra un bajo desempeño del modelo en ambas escalas temporales. A escala media hora, la correlación de Pearson es de 0.23 y el R^2 es de 0.05, indicando una débil relación entre las predicciones y los valores observados, con un RMSE de 291.66 y un MAE de 196.64. A escala diaria, el desempeño empeora con una correlación negativa de -0.08 y un R^2 de -0.08, lo que sugiere que el modelo no solo es impreciso, sino que también introduce un sesgo significativo, con un RMSE de 101.83 y un MAE de 78.40. Estos resultados indican que el modelo tiene dificultades para capturar adecuadamente las variaciones de la radiación neta en ambas escalas.




Figura 22. Comparación de datos observados y simulados de la radiación neta (W/m^2), del periodo 2020-2021 a escala diaria.

Al comparar los resultados del modelo entre los años 2020 y 2021, se observa una mejora en el desempeño en 2021, aunque sigue siendo limitado. En 2020, la correlación fue negativa (-0.18), indicando una relación inversa entre las predicciones y los valores observados, con un R^2 de 0.03, lo que sugiere que el modelo apenas capturó la variabilidad de los datos. El RMSE fue de 130.36 y el MAE de 102.55, reflejando errores significativos.

En 2021, la correlación mejoró a 0.11 y aunque el R^2 fue ligeramente menor (0.01), los errores disminuyeron considerablemente, con un RMSE de 71.85 y un MAE de 58.98. Estos resultados indican que el modelo tuvo un mejor ajuste en 2021, reduciendo los errores, aunque aún muestra limitaciones en la precisión de la radiación neta. Esto se puede observar en la figura anterior, donde se evidencia principalmente subestimación de los

valores en casi todos los meses, exceptuando una leve sobreestimación en mayo y septiembre en 2020 y octubre 2021.

En el caso de flujo de calor latente, presentó un mejor rendimiento a escala media hora que diaria. A escala media hora, el modelo presenta una correlación de Pearson de 0.27 y un R^2 de 0.07, indicando una relación débil entre las predicciones y los valores observados, con un RMSE de 157.35 y un MAE de 114.55. Sin embargo, a escala diaria, el rendimiento del modelo empeora significativamente, con una correlación negativa de -0.02, un R^2 de -0.02, y una reducción en los errores (RMSE de 48.68 y MAE de 37.42), lo que sugiere un ajuste deficiente y la presencia de sesgo en las predicciones diarias.




Figura 23. Comparación de datos observados y simulados de flujo de calor latente (W/m^2), del periodo 2020-2021 a escala diaria.

Este comportamiento se evidencia en la comparación anual diaria, donde ambos años presentaron correlaciones negativas (-0.12 y -0.086), un R^2 de 0.02 disminuyendo en 2021 a 0.01, errores significados RMSE de 57.03 y 40.80 respectivamente y MAE de 44.99 y 31.36 mostrando un sesgo y ajuste insuficiente. Esto según Calvo et al., (2018), a escala diaria puede deberse a errores en promediación, dinámicas diarias no capturadas, como efectos acumulativos de radiación solar, evapotranspiración y otros factores que influyen en el flujo de calor latente. Además, en la figura 22, al igual que RN, se puede observar que existe subestimación en la mayoría de los meses, con sobrestimación principalmente en meses lluviosos, por ejemplo 2021 de mayo a julio, y octubre.

La variable de flujo de calor sensible es una de las variables que al igual que RN, el desempeño de modelo es poco preciso para ambas escalas temporales. A escala de media hora, la correlación de Pearson es prácticamente nula (0.02), y el R^2 es extremadamente bajo (0.00045), lo que indica que el modelo casi no captura la relación entre las predicciones y los valores observados. Los errores también son elevados, con un RMSE de 134.22 y un MAE de 84.02. A escala diaria, aunque la correlación de Pearson mejora ligeramente a 0.03 y el R^2 sube a 0.03, estos valores siguen siendo muy bajos, lo que refleja una débil capacidad del modelo para explicar la variabilidad en los datos observados. Sin embargo, los errores se reducen, con un RMSE de 47.04 y un MAE de 35.47, lo que sugiere que, aunque el modelo sigue siendo ineficaz, las predicciones diarias son un poco más precisas en términos absolutos en comparación con las predicciones a escala de media hora. Además, como se observa en la siguiente figura en ambos años hubo una subestimación de la variable en todos los meses.




Figura 24. Comparación de datos observados y simulados de flujo de calor sensible (W/m^2), del periodo 2020-2021 a escala diaria.

La comparación a escala diaria entre los años muestra una mejora en 2021. En 2020, la correlación fue negativa (-0.09) y el R^2 muy bajo (0.009), con errores significativos (RMSE de 50.73 y MAE de 36.46). En 2021, la correlación mejoró a 0.16 y el R^2 a 0.026, con menores errores (RMSE de 41.67 y MAE de 32.53), indicando un desempeño algo mejor del modelo en 2021.

El análisis de PPB muestra un bajo desempeño del modelo en ambas escalas. A escala de media hora, la correlación de Pearson es baja (0.187), con un R^2 de 0.04, indicando una relación débil entre las predicciones y los valores observados, y errores moderados (RMSE de 10.89 y MAE de 5.96). A escala diaria, el desempeño empeora, con una correlación negativa (-0.12) y un R^2 de -0.12, lo que sugiere un ajuste deficiente y la presencia de sesgo, acompañado de menores errores absolutos (RMSE de 3.84 y MAE de 2.93).




Figura 25 .Comparación de datos observados y simulados de productividad primaria neta ($G \text{ cm}^2/\text{día}$), del periodo 2020-2021 a escala diaria.

Los resultados anuales, muestran una correlación de Pearson negativa en ambos años, (-0.07 y -0.22), indicando una relación inversa entre las variables observadas y simuladas que se intensifica en el tiempo. El R^2 de 2020 es extremadamente bajo (0.005), lo que aumenta ligeramente en 2021 a 0.05, pero aún señala una explicación muy limitada de la variabilidad de los datos por parte del modelo. El RMSE muestra una mejora, disminuyendo de 4.08 en 2020 a 3.40 en 2021, y el MAE es similar en ambos años de 2.86 y 2.84 respectivamente.

Para esta variable a comparación de las demás presenta sobreestimación en la mayoría de los meses, en el periodo, solo algunas subestimaciones en agosto 2021, y se observa acercamiento de valores observados y simulados en julio y diciembre 2021.

La ET que fue una variable estimada a partir del resultado de LE, mostró, por lo tanto, resultados similares, mostrando un mejor desempeño a escala media hora, que tuvo una correlación de Pearson moderada de 0.27 y un R^2 de 0.08, lo que indica una relación débil pero existente entre las predicciones y los valores observados, con un RMSE de 0.16 y un

MAE de 0.11. Sin embargo, a escala diaria, el rendimiento del modelo disminuye con una correlación negativa de -0.02 y un R^2 de -0.02, sugiriendo un ajuste deficiente y un sesgo en las predicciones, aunque los errores absolutos son menores (RMSE de 0.07 y MAE de 0.06).

Esta relación sugiere que el modelo tiene dificultades para capturar las dinámicas diarias de procesos estrechamente relacionados como la evapotranspiración y el flujo de calor latente, posiblemente debido a cómo promedia los efectos de los factores climáticos y del suelo a lo largo del día. La mejora en la escala de media hora podría indicar que el modelo es más sensible a variaciones rápidas, pero pierde precisión al promediar estas variaciones en una escala diaria.




Figura 26 .Comparación de datos observados y simulados de evapotranspiración (mm), del periodo 2020-2021 a escala diaria.

A escala diaria mostró una ligera mejora en 2021, con un RMSE de 0.06 y un MAE de 0.05, frente a un RMSE de 0.08 y un MAE de 0.07 en 2020. Sin embargo, la correlación siguió siendo negativa en ambos años (-0.09 en 2021 y -0.13 en 2020), similar al comportamiento observado en el flujo de calor latente (LE). Esto indica que el modelo continúa teniendo dificultades para capturar las dinámicas diarias de ET y LE, con un sesgo persistente y una baja capacidad explicativa. Además, se puede observar mismo comportamiento de subestimación y sobreestimación en meses como octubre.

Capítulo 6. Reconstrucción histórica

En este capítulo se realizó una reconstrucción histórica de datos climáticos a partir de las simulaciones obtenidas mediante el modelo SVEN, no obstante, se indica que, con base en el resultado mostrado anteriormente, en su forma actual el modelo lo representa bien la variabilidad de los parámetros necesarios para estimar la EUA. Este enfoque se basa en el uso de modelos climáticos avanzados, como SVEN, para simular las condiciones atmosféricas en un periodo específico, en este caso, de 2010 a 2022. A través de estas simulaciones, es posible obtener estimaciones detalladas de variables clave como LE, H, RN, PPB y la ET.

6.1. Análisis de tendencia

Las variables simuladas durante el período 2010-2022 revelan patrones estacionales y fluctuaciones interanuales que reflejan las condiciones climáticas de la zona de estudio.

En general, como se muestra en la figura 27, todas las variables mostraron un comportamiento estacional marcado, con picos durante el verano, cuando las condiciones climáticas favorecen una mayor radiación solar, y valores más bajos durante el invierno, asociado con la mayor cobertura nubosa y las lluvias. La radiación neta, por ejemplo, alcanzó sus valores máximos durante la época seca, mientras que en la época lluviosa mostró una disminución significativa, probablemente debido a la mayor nubosidad y precipitación.

La LE y la ET, que están directamente relacionadas con los procesos de evapotranspiración, también mostraron tendencias similares, con valores más altos en los meses secos cuando la demanda atmosférica de vapor de agua es mayor, y valores reducidos durante la época lluviosa. La PPB mostró una variabilidad menos pronunciada, pero mantuvo una tendencia ligeramente ascendente en los períodos de mayor radiación, reflejando el aumento en la productividad primaria durante esos momentos. El H y la Tsuelo también siguieron un patrón estacional, elevadas durante el verano, lo que a su vez contribuye a una mayor producción de calor sensible (H). Estos comportamientos destacan la fuerte interrelación entre la radiación solar, la temperatura del suelo y los flujos de calor en el ecosistema.

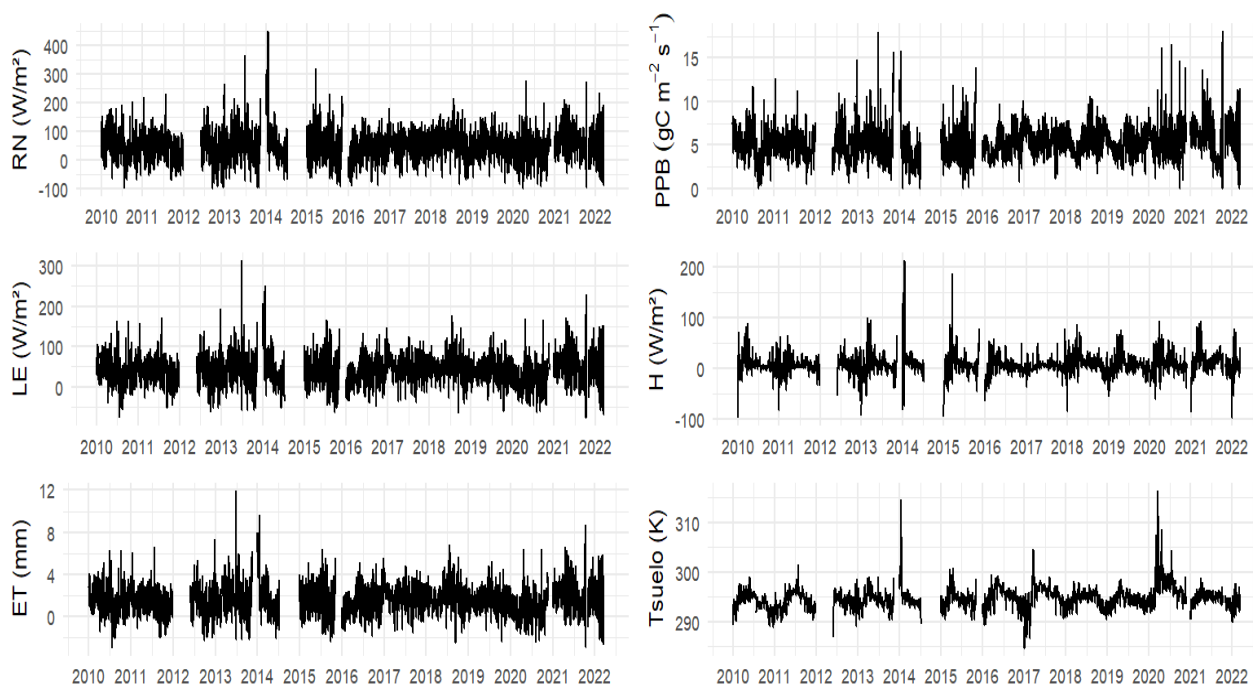


Figura 27. Reconstrucción histórica de las variables simuladas radiación neta, flujo de calor latente, evapotranspiración, productividad primaria bruta, flujo de calor sensible y temperatura del suelo, durante el periodo 2010-2022.

Nota: Análisis con datos a escala diaria desde 2010-2022 obtenidos de la simulación con el modelo SVEN.

Asimismo, a continuación, se explica el análisis por cada variable:

La RN como se muestra en la figura 27 y 28, durante la temporada seca, alcanzó sus valores más altos, impulsada por la menor cobertura nubosa y la mayor insolación, principalmente en los meses de marzo a junio, con promedios de hasta 64 W/m^2 , mientras que en la temporada lluviosa (mayo-noviembre) disminuye debido a la mayor nubosidad y las frecuentes lluvias, que limitan la radiación solar incidente, por ejemplo, noviembre con promedios de 33 W/m^2 .

Durante el periodo 2010-2022, la media anual fue de aproximadamente 51.21 W/m^2 , con una desviación estándar de 11.00 W/m^2 . El coeficiente de variación (CV) fue del 21.48%, lo que indica una variabilidad interanual moderada, es decir; aunque hubo fluctuaciones en

los valores anuales de estas no fueron extremadamente pronunciadas, manteniéndose dentro de un rango relativamente consistente a lo largo de los años.




Figura 28. Comportamiento de la radiación neta (RN) simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.

Nota: Los años 2012, 2014 se tenía información de pocos meses, por lo que simulo los meses correspondientes.

Es importante mencionar, que la RN es crucial para las plantaciones de café a pleno sol, ya que afecta directamente la fotosíntesis, el crecimiento y la salud de las plantas (DaMatta et al., 2007). Durante los meses secos, una alta RN puede mejorar la producción de café al aumentar la fotosíntesis, pero también puede causar estrés hídrico si no hay suficiente agua disponible y en la temporada lluviosa, la menor RN debido a la nubosidad reduce el riesgo de estrés térmico, pero también puede limitar el crecimiento (DaMatta et al., 2007; Ovalle, 2015 y 2018). Por lo tanto, manejar adecuadamente la radiación neta, posiblemente con prácticas como el uso de sombra parcial es esencial para optimizar el rendimiento y la calidad del café (Ovalle, 2015).

Con respecto a LE y ET, son parámetros están estrechamente vinculados a los procesos de evaporación y transpiración en las plantas y su entorno, y su comportamiento estacional

ofrece información valiosa para la gestión agrícola (Fossils, 2007; FAO, 2022; Elfarkh et al., 2023).




Figura 29. Comportamiento de la LE simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.

Nota: Los años 2012, 2014 se tenía información de pocos meses, por lo que simulo los meses correspondientes.

Durante la temporada lluviosa (mayo a julio), tanto ET como LE alcanzan sus valores más altos (Figura 24, 29 y 30). Esto se debe a la mayor disponibilidad de agua y a las condiciones climáticas favorables, que promueven una mayor transpiración en las plantas de café y, por ende, un mayor uso de energía en forma LE (DaMatta y Ramalho, 2006). El aumento en ET en este periodo refleja un ciclo activo de agua, donde las plantas utilizan eficientemente el agua disponible para sus procesos fisiológicos, asegurando el crecimiento y el desarrollo de los frutos (DaMatta y Ramalho, 2006; DaMatta et al., 2007).

Ambos parámetros presentan un CV del 21.31% a nivel anual, lo que indica una alta fluctuación de un año a otro. Esto refleja cómo las condiciones climáticas y la disponibilidad de agua afectan estos procesos en una plantación de café.

Mensualmente, tanto LE como ET muestran una variabilidad moderada con un CV del 15.75%, lo que sugiere que, aunque hay cambios a lo largo del año, estos no son tan pronunciados como los cambios interanuales.




Figura 30. Comportamiento de ET simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.

Nota: Los años 2012, 2014 se tenía información de pocos meses, por lo que simulo los meses correspondientes.

En resumen, ET y LE muestran patrones estacionales similares, con ambos indicadores subiendo en la temporada lluviosa y bajando en la temporada seca. Este comportamiento es crucial para la planificación y manejo de una plantación de café, ya que permite ajustar prácticas como el riego y la conservación del agua, asegurando así un cultivo más sostenible y productivo. El H (Figura 27 y 31) muestra una alta variabilidad interanual durante el periodo 2010-2022, con un CV de 43.90%, una desviación estándar de 3.87 W/m² y una media anual de 8.82 W/m² es decir, muestra fluctuaciones significativas en los valores de H de un año a otro, reflejando cambios en las condiciones atmosféricas y el intercambio de calor entre la superficie y la atmósfera en la plantación de café., siendo inestable.




Figura 31. Comportamiento de H simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.

Nota: Los años 2012, 2014 se tenía información de pocos meses, por lo que simulo los meses correspondientes.

El H es crucial para la gestión de plantaciones de café a pleno sol, ya que indica la cantidad de calor transferido entre la superficie del suelo y la atmósfera (DaMatta y Ramalho, 2006). Durante los meses más cálidos (mayo a julio), H tiene un valor promedio de 10.40 W/m^2 , sugiriendo que el calor es liberado hacia el aire, lo que puede aumentar la temperatura alrededor de las plantas y potencialmente causar estrés térmico. En contraste, en enero, H muestra un valor negativo de -0.27 W/m^2 , lo que indica que el suelo absorbe calor del aire, contribuyendo a enfriar las plantas en momentos de temperaturas más bajas. Este conocimiento permite a los agricultores ajustar prácticas como la sombra parcial o el riego para mitigar el estrés térmico y optimizar las condiciones de crecimiento del café.

La PPB muestra un incremento a lo largo de los años, con un pico en 2021 ($6.17 \text{ gC/m}^2/\text{día}$), reflejando una mayor productividad de las plantas durante ese año (Figura 27 y 32). Los valores más altos se concentran en los meses de diciembre y enero, lo que podría estar relacionado con condiciones climáticas favorables para la fotosíntesis, como la luz solar y la temperatura. En contraste, los meses de marzo, abril, mayo presentan los valores

más bajos. La baja variabilidad interanual (CV de 8.06%) indica que, aunque hay fluctuaciones, la productividad se mantiene relativamente estable a lo largo de los años.




Figura 32. Comportamiento de la PPB simulada por el Modelo SVEN del periodo 2010-2022 a escala mensual.

Nota: Los años 2012, 2014 se tenía información de pocos meses, por lo que simulo los meses correspondientes.

En resumen, esta reconstrucción histórica y conocer la relación entre estas variables es crucial para optimizar la producción agrícola. La RN es la fuente de energía que impulsa LE, H, y PPB, determinando cómo se distribuye esa energía en el sistema suelo-planta-atmósfera (DaMatta y Ramalho, 2006; DaMatta et al., 2007). Un mayor LE favorece la evapotranspiración, vital para el crecimiento de las plantas, mientras que un mayor H indica más calor en el ambiente, lo que puede aumentar el estrés térmico (Ovalle, 2018). La PPB, que mide la cantidad de carbono fijado por las plantas a través de la fotosíntesis, depende directamente de la disponibilidad de RN y de las condiciones térmicas y hídricas reguladas por LE y H. Comprender cómo interactúan estos flujos es esencial para gestionar el agua y la energía de manera eficiente en los cultivos como el café, maximizando la productividad y minimizando los impactos negativos del estrés ambiental.

6.2. Análisis de tendencia la EUA simulada

La EUA simulada mostró una variabilidad significativa entre 2010 y 2022. Los valores medios anuales oscilaron entre 290.65 en 2018 y 460.64 $\text{gCO}_2/\text{kgH}_2\text{O}$ en 2020, con el CV indicando mayor fluctuación en 2013 (19.67%) y menor en 2020 (6.44%). Estos resultados sugieren que las simulaciones son relativamente estables en algunos años, pero han experimentado grandes variaciones en otros, probablemente debido a cambios en las condiciones climáticas como las variables de entrada (LW_{in} , SW_{in} , RN, RH, entre otros).




Figura 33. Comportamiento de la EUA simulada por el Modelo SVEN del periodo 2010-2022 a escala diaria.

Nota: Este se calculó mediante los resultados simulados de ET (mm) y PPB ($\text{gC}/\text{m}^2/\text{día}$), y se realizó la conversión a $\text{gCO}_2/\text{kgH}_2\text{O}$ ya que los valores observados están en esa unidad.

A nivel mensual los valores más altos de EUA se registraron en noviembre (442.26 $\text{gCO}_2/\text{kgH}_2\text{O}$) y septiembre (439.66 $\text{gCO}_2/\text{kgH}_2\text{O}$), posiblemente debido a condiciones climáticas favorables que mejoraron la eficiencia fotosintética. Abril también mostró una alta EUA (392.96 $\text{gCO}_2/\text{kgH}_2\text{O}$), asociada probablemente al inicio de la temporada lluviosa. Por otro lado, julio (309.69 $\text{gCO}_2/\text{kgH}_2\text{O}$) y febrero (319.31 $\text{gCO}_2/\text{kgH}_2\text{O}$) presentaron la menor EUA, lo que sugiere una mayor demanda de agua y menor eficiencia durante estos meses. La variabilidad fue mayor en abril, indicando fluctuaciones en las condiciones que la afectaron.

En cuanto a la relación de la EUA con las variables anteriormente analizadas, se puede observar que en los periodos donde fue la RN fue alta y constante (noviembre y septiembre) se observó una mayor EUA, esto sugiere que la energía solar disponible fue utilizada eficientemente para fijar carbono, incrementando la productividad, sin un aumento desproporcionado en la evapotranspiración (ET).

La LE en los meses donde fue elevado, como julio, la EUA tendió a ser más baja. Esto indica que gran parte de la energía estaba siendo utilizada para la transpiración, reduciendo la cantidad de agua disponible para la fotosíntesis efectiva. Los altos valores de H pueden indicar que las plantas estuvieron expuestas a condiciones más cálidas y secas, lo que puede haber causado un estrés térmico y, en consecuencia, una reducción en la EUA. Este tipo de condiciones pueden haber sido más evidentes en los meses con menor EUA, como julio. En periodos donde ET fue alta pero no acompañada de un aumento proporcional en la PPB, como en febrero, la EUA fue menor. Esto sugiere que el agua disponible no fue utilizada de manera óptima para la producción de biomasa.

En meses donde la PPB fue alta y las condiciones climáticas (RN, LE, H) fueron favorables, como en noviembre y abril, la EUA también fue alta. Esto demuestra que cuando las plantas pueden maximizar la fotosíntesis sin un aumento significativo en la pérdida de agua, la eficiencia en el uso del agua se incrementa. En resumen, los resultados anteriores de las variables climáticas y de energía muestran que la EUA es un equilibrio delicado entre la disponibilidad de energía (RN), las pérdidas de agua (LE y ET), y la capacidad de las plantas para fijar carbono (PPB). Períodos con alta radiación neta y menor estrés térmico permitieron que la PPB se maximizara, resultando en una alta EUA. En contraste, cuando las pérdidas de agua fueron elevadas sin un aumento correspondiente en la PPB, la EUA disminuyó. Este análisis subraya la importancia de manejar adecuadamente tanto los recursos hídricos como la energía disponible para optimizar la productividad en plantaciones de café.

Conclusiones

En el capítulo 3, los resultados muestran que, aunque el cierre del balance de energía es razonablemente bueno, especialmente en condiciones atmosféricas estables y neutrales, este tiene dificultades con el periodo de época seca y bajas temperaturas. La pendiente de la regresión lineal entre los flujos turbulentos y la energía disponible varió entre 0.3 y 0.9, lo que indica que, en ciertos meses, el cierre del balance fue insuficiente, sugiriendo la presencia de agua no contabilizados o errores en las mediciones. En este caso de acuerdo con las observaciones en sitio se determina que la deposición de rocío es una fuente de agua importante para la superficie del dosel, por lo que es una variable que debería tomarse en cuenta para el cierre.

La estacionalidad tuvo un impacto significativo en el EBC ya que, durante la estación seca, se observó un mejor cierre del balance, mientras que, en la estación lluviosa, los valores de la pendiente fueron más bajos, lo que sugiere mayores desafíos en la medición y balanceo de los flujos de energía durante periodos con alta disponibilidad de agua. Este comportamiento se vio en las condiciones de estabilidad atmosférica que jugaron un papel crucial, ya que mejores resultados se obtuvieron bajo condiciones estables, mientras que las condiciones inestables presentaron mayores dificultades para lograr un balance adecuado, debido a la influencia de la advección y otros procesos submesoescala. A pesar de los desafíos observados, la metodología utilizada permitió obtener datos con una calidad aceptable, aunque es evidente que las condiciones ambientales y la precisión de los instrumentos son factores críticos que deben ser continuamente evaluados y mejorados para garantizar un cierre de balance más preciso.

En este capítulo también se compararon tres métodos empíricos (FAO-Penman Monteith, Hargreaves, y Blaney-Criddle) para la estimación de la evapotranspiración (ET) con los valores obtenidos mediante la técnica covarianza de torbellino. Los resultados revelaron que ninguno de los métodos empíricos logró replicar con precisión los valores de ET observados por EC, indicando que los métodos simplificados subestiman o no capturan adecuadamente la complejidad del proceso de ET en las condiciones específicas del sitio de estudio. Esto resalta la robustez de la técnica de EC que, al medir directamente la turbulencia del aire, ofrece una representación más precisa de los flujos de masa y energía

entre la superficie terrestre y la atmósfera, capturando de manera más fiel la dinámica real del ecosistema.

Por otro lado, el capítulo 4, se centró en analizar la metodología de covarianza de torbellino, en cuanto a la estimación de la EUA con datos obtenidos de ET y PPB de esta técnica, seguidamente se comparó con la obtenida del modelo SVEN, durante el periodo de estudio 2020-2021 en esta se identificó que, durante los años 2020 y 2021, la EUA en la finca La Hilda mostró una variabilidad significativa, con valores más altos durante la temporada lluviosa y más bajos durante la temporada seca. Esta variabilidad está directamente relacionada con los cambios en la precipitación, la humedad relativa y la radiación neta. Los meses con mayores precipitaciones y humedad, como julio, octubre y noviembre, presentaron los valores más altos de EUA, lo que sugiere que una mayor disponibilidad de agua contribuye a una mayor productividad en términos de CO₂ fijado por unidad de agua.

Las condiciones ambientales, particularmente la temperatura y la humedad, juegan un papel crucial en la productividad del café y en la eficiencia del uso del agua. Las altas temperaturas y la radiación neta durante la temporada seca reducen la EUA, mientras que las altas precipitaciones y la elevada humedad durante la temporada de lluvias aumentan la eficiencia en el uso del agua.

El modelo de simulación SVEN mostró limitaciones en su capacidad para predecir la EUA observada, con un R² de 0.0094, lo que indica que solo el 0.94% de la variabilidad observada en los datos fue explicada por el modelo. Esto debido a la subestimación en ET y PPB generada por la mala representación de los componentes de la radiación estimados por medio de información satelital.

El modelo SVEN, no estima adecuadamente el flujo de calor latente (LE), existe un error el modelo de superficie de PT-JPL, donde se está heredando el sesgo que se tiene en la radiación neta, LAI, generando datos negativos de LE. Debido a la limitación del modelo SVEN para representar adecuadamente la EUA, no se estimó el rendimiento para evitar propagación de errores y una interpretación incorrecta de los resultados.

El capítulo 5 se centró en la aplicación del modelo para la transferencia de energía entre el suelo, la vegetación y la atmósfera (SVEN). Los resultados mostraron que el modelo tuvo un desempeño moderado en la predicción de la ET y LE, especialmente a escala de media hora, donde se lograron correlaciones aceptables y errores relativamente bajos. Sin embargo, el modelo fue deficiente para predecir la RN y H, Tsuelo y la PPB, mostrando correlaciones bajas y altos errores, particularmente en la escala diaria. Aunque hubo mejoras en el desempeño del modelo en 2021 en comparación con 2020, las limitaciones en la precisión de las predicciones para RN y H se evidenciaron en ambos años.

Sin embargo, una ventaja de este modelo como indica Pateromichelaki, (2020), es que requiere pocos datos de entrada, utilizando observaciones meteorológicas estándar y datos satelitales. Esto lo hace ideal para su aplicación en la agricultura de pequeña a mediana escala y en países en desarrollo, donde el acceso a tecnologías avanzadas es limitado. Además, muchos parámetros se pueden extraer de la literatura y tablas existentes, y en ausencia de datos específicos, como LW_{in} , NDVI se pueden usar datos satelitales. Por lo que se puede considerar realizar un proceso de calibración del modelo para evaluar si estos cambios en el modelo pueden mejorar su rendimiento.

Asimismo, el modelo SVEN es una herramienta valiosa para la planificación en plantaciones de café, como finca La Hilda, ya que permite un monitoreo preciso de variables clave como las analizadas en el estudio que podría facilitar la optimización del riego, que es crucial para inducir la floración en períodos específicos, y ayuda a gestionar el estrés hídrico en un contexto de cambio climático (Pateromichelaki, 2020), al proporcionar estimaciones en tiempo real. Además, el SVEN mejora la eficiencia en la gestión del agua y apoya decisiones informadas para maximizar el rendimiento y la sostenibilidad en la producción de café.

Seguidamente en el capítulo 6 con el fin de “evaluar el impacto de la variabilidad interanual sobre la eficiencia en el uso del agua y la productividad” se utilizó las simulaciones obtenidas del Modelo SVEN del periodo 2010-2022 para realizar una reconstrucción histórica de las variables RN, LE, H, ET, PPB y calcular la EUA. De este análisis de tendencia se identificó que la EUA en las plantaciones de café mostró una variabilidad interanual significativa entre 2010 y 2022. Años como 2013 y 2022

presentaron mayor fluctuación, lo que refleja la sensibilidad de la EUA a cambios en las condiciones climáticas y en la gestión agrícola.

La EUA está fuertemente influenciada por la radiación neta (RN), el flujo de calor latente (LE), el flujo de calor sensible (H), y la evapotranspiración (ET). En años y meses con alta RN y baja ET, la EUA fue más alta, indicando una mayor eficiencia en la utilización del agua disponible para la producción de biomasa. En contraste, en periodos donde LE y ET fueron elevados sin un aumento proporcional en la productividad primaria bruta (PPB), la EUA disminuyó.

La estacionalidad juega un papel crucial en la variabilidad mensual de la EUA. Los meses de transición, como noviembre y septiembre, mostraron los valores más altos de EUA, posiblemente debido a condiciones climáticas más equilibradas que favorecen la fotosíntesis sin un exceso de pérdida de agua. En contraste, meses como julio y febrero, con condiciones más extremas, presentaron menor EUA, reflejando un uso menos eficiente del agua en esas condiciones.

Por lo tanto, los resultados subrayan la importancia de una gestión adecuada tanto de los recursos hídricos como de la energía solar disponible. Maximizar la productividad en condiciones de alta RN y optimizar el uso del agua en periodos de alta ET son clave para mantener una alta EUA y, por ende, una mayor productividad sostenible en las plantaciones de café.

Recomendaciones

Con respecto al balance de energía, se logró un cierre razonable en algunas condiciones, el estudio revela la necesidad de ajustes metodológicos y un mayor control de las variables ambientales para mejorar la precisión y fiabilidad de los resultados.

Por otro lado, dada la superioridad demostrada de la técnica de covarianza de torbellino en la medición de la ET, se recomienda su uso preferencial en estudios donde se requiere alta precisión en la evaluación de los flujos energéticos. Sin embargo, para aplicaciones donde la técnica de covarianza de torbellino no sea factible, se sugiere utilizar el método FAO-Penman Monteith, que, aunque aún presenta limitaciones, mostró un mejor desempeño en comparación con los otros métodos empíricos. Además, se recomienda realizar ajustes o calibraciones específicas de los métodos empíricos según las condiciones locales para mejorar su precisión en futuras investigaciones.

Para mejorar el desempeño del modelo SVEN en futuras investigaciones, y obtener una mejor precisión en la predicción de la EUA se recomienda considerar los siguientes ajustes y mejoras basados en las dificultades encontradas durante este estudio:

Ajuste de parámetros específicos: Se observó que el parámetro h_{rough} estaba limitado a una altura del dosel de 1.68 metros, por lo que este límite debe ajustarse. Es crucial revisar y ajustar este parámetro para que pueda adaptarse mejor a las características específicas del terreno y la vegetación, lo que podría mejorar la precisión del modelo.

Se requiere utilizar estimaciones más precisas de LAI y R_n para corregir el sesgo en el modelo y el uso de radiómetros con las 4 componentes para generar validación de la estimación satelital de R_n .

En la revisión y ajuste de métodos para el cálculo de variables como LW_{in} se destaca que durante la investigación, se encontraron dificultades con el método inicial seleccionado para modelar la variable de entrada LW_{in} . Originalmente, se utilizó el enfoque propuesto por An et al. (2017), que estimaba la emisividad del aire utilizando la temperatura del aire y del suelo. Sin embargo, este método no proporcionó resultados óptimos, lo que llevó a su reemplazo por el método de Konzelmann et al. (1994). Este segundo enfoque utiliza datos meteorológicos como la temperatura del aire en kelvin y el punto de rocío (T_{dew}),

además de parámetros satelitales como la fracción de nubosidad, ofreciendo una mayor precisión en las estimaciones. Se recomienda considerar estos factores al seleccionar métodos para el cálculo de variables críticas, asegurando que los datos y parámetros utilizados sean los más adecuados para las condiciones específicas del estudio.

Uso de fuentes de datos satelitales: En este estudio se utilizó el sensor MODIS para obtener datos de NDVI debido a su disponibilidad desde 2010, lo que permitió un análisis a largo plazo. Sin embargo, para futuros estudios, se podría realizar una comparación con los datos de SENTINEL-2. Esta comparación podría ayudar a evaluar las diferencias en la precisión y resolución entre ambos sensores, proporcionando una mejor comprensión de cómo se comporta el modelo SVEN en diferentes escenarios y resoluciones. Al hacer esta comparación, se podrían identificar las ventajas y limitaciones de cada sensor, lo que permitiría optimizar el uso de los datos satelitales en función de los objetivos específicos del estudio y mejorar la calidad de las predicciones del modelo.

Se recomienda ampliar el periodo utilizado para la validación para evaluar la capacidad del modelo, en una versión mejorada, de la variación interanual de ET y realizar la calibración de los parámetros de suelo en el modelo con base en observaciones del sitio de estudio.

En cuanto a temas técnicos como el manejo de caché y datos incompletos, se encontró durante el uso del modelo SVEN en MATLAB, problemas relacionados con el manejo de caché, que impedían una correcta actualización de los datos y afectaban la precisión del modelado. Para evitar estos problemas, se recomienda limpiar regularmente el caché del programa y revisar el flujo de datos para asegurar que los cambios en los parámetros y datos de entrada se reflejen adecuadamente en las simulaciones. Esto mejorará la precisión del modelo y garantizará que se manejen correctamente los datos incompletos o faltantes.

Con respecto, a la reconstrucción histórica de variables o parámetros a través de simulaciones con el modelo SVEN se recomienda:

Manejo de valores atípicos: Si bien se observó cierta estabilidad en el periodo analizado en las diferentes variables, se realizó análisis exhaustivos en cuanto a que en ciertas variables como PPB, ET mostraban valores muy altos, que se descartaron para no generar ruido al

análisis, ya que el Modelo SVEN sobreestima o subestima como se muestra en el capítulo 5 algunas variables.

Con la información obtenida de la reconstrucción histórica a nivel de manejo en la finca la Hilda se recomienda el desarrollo de planes de manejo para los diferentes períodos estacionales, maximizando la EUA durante los meses de alta RN y minimizando las pérdidas de agua durante los meses más calurosos, por ejemplo, ajustar la fertilización, el riego y otras prácticas agrícolas de acuerdo con las condiciones climáticas previstas.

Se recomienda aumentar investigaciones adicionales que analicen la relación entre la EUA y otros factores ambientales o prácticas agrícolas no abordadas en este estudio, como el tipo de suelo, la variedad de café, y la densidad de plantación, para identificar nuevas oportunidades de optimización.

IX. Bibliografía

- Alvarado Soto, M., & Rojas Cubero, G. (2007). *El cultivo y beneficiado del café* (1994.a ed.). Universidad Estatal a Distancia.
- Ahmadi, B., Ahmadalipour, A., Tootle, G., y Moradkhani, H. (2019). Remote Sensing of Water Use Efficiency and Terrestrial Drought Recovery across the Contiguous United States. *Remote Sensing*, 11(6), Article 6. <https://doi.org/10.3390/rs11060731>
- An, N., Hemmati, S., y Cui, Y.-J. (2017). Assessment of the methods for determining net radiation at different time-scales of meteorological variables. *Journal of Rock Mechanics and Geotechnical Engineering*, 9(2), 239-246. <https://doi.org/10.1016/j.jrmge.2016.10.004>
- Arévalo, D. F. G. (s. f.). *Cálculo del índice de vegetación de diferencia normalizada - ndvi usando la plataforma google earth engine para los años 2019 y 2020 de la vereda la florida en el municipio de puerto.*
- Baldocchi, D. 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>
- Barrantes-Castillo, G., & Quesada-Román, A. (2016). *Cartografía de afectación por amenazas naturales en el cantón de Poás, Costa Rica*. Recuperado de <https://www.revistas.una.ac.cr/index.php/geografica/article>
- Blanc, E., y Reilly, J. (2017). Approaches to Assessing Climate Change Impacts on Agriculture: An Overview of the Debate. *Review of Environmental Economics and Policy*, 11(2), 247-257. <https://doi.org/10.1093/reep/rex011>

- Boese, S., Jung, M., Carvalhais, N., Teuling, A. J., y Reichstein, M. (2019). Carbon–water flux coupling under progressive drought. *Biogeosciences*, *16*(13), 2557-2572. <https://doi.org/10.5194/bg-16-2557-2019>
- Bunn, C., Läderach, P., Ovalle Rivera, O., y Kirschke, D. (2015). A bitter cup: Climate change profile of global production of Arabica and Robusta coffee. *Climatic Change*, *129*(1), 89-101. <https://doi.org/10.1007/s10584-014-1306-x>
- Burba. (2023). *Eddy Covariance Method for scientific, regulatory and comercial applications*. LI-COR, Biosciences, Lincoln, Nebraska
- Burba, G., & Anderson, D. (2010). *A brief practical guide to eddy covariance flux measurements: Principles and workflow examples for scientific and industrial applications*.
- Byrareddy, V., Kouadio, L., Kath, J., Mushtaq, S., Rafiei, V., Scobie, M., y Stone, R. (2020). Win-win: Improved irrigation management saves water and increases yield for robusta coffee farms in Vietnam. *Agricultural Water Management*, *241*, 106350. <https://doi.org/10.1016/j.agwat.2020.106350>
- Brenes Carlos. (2014). *El fenómeno del Niño en el sector agropecuario: Conocerlo para adaptarse mejor*. Consejo Agropecuario Centroamericano.
- Calvo-Valverde, L.-A., Acuña-Alpízar, N. J., Calvo-Valverde, L.-A., y Acuña-Alpízar, N. J. (2018). Aplicación de métodos agregados en la detección de puntos atípicos en series de tiempo meteorológicas. *Revista Tecnología en Marcha*, *31*(1), 98-109. <https://doi.org/10.18845/tm.v31i1.3500>
- Camargo, M. B. P. de. (2010). The impact of climatic variability and climate change on arabic coffee crop in Brazil. *Bragantia*, *69*, 239-247. <https://doi.org/10.1590/S0006-87052010000100030>

- Chinchilla, C., Durán, A., Muñoz, M., y Gutierrez, M. (2021). Quantifying the Annual Cycle of Water Use Efficiency, Energy and CO₂ Fluxes Using Micrometeorological and Physiological Techniques for a Coffee Field in Costa Rica. *Forests*, 12, 889. <https://doi.org/10.3390/f12070889>
- Chinchilla, G., Morera, R., & Navarro, J. A. (2020). *Boletín meteorológico mensual, 2020*. Instituto Meteorológico Nacional.
- CATIE. (2017). *Impactos del cambio climático en la agricultura de Centroamérica, estrategias de mitigación y adaptación*. Recuperado de <https://repositorio.catie.ac.cr/handle/11554/9476>
- DaMatta, F. M., y Ramalho, J. D. C. (2006). Impacts of drought and temperature stress on coffee physiology and production: A review. *Brazilian Journal of Plant Physiology*, 18, 55-81. <https://doi.org/10.1590/S1677-04202006000100006>
- DaMatta, F. M., Ronchi, C. P., Maestri, M., y Barros, R. S. (2007). Ecophysiology of coffee growth and production. *Brazilian Journal of Plant Physiology*, 19, 485-510. <https://doi.org/10.1590/S1677-04202007000400014>
- Díaz Arango, F. O. M. G. (2018). *Café. Un recorrido de la semilla a la taza*. <http://www.digitaliapublishing.com/a/60640/cafe.-un-recorrido-de-la-semilla-a-la-taza>
- Ehleringer, J. R., y Squeo Porcile, F. A. (2004). *Isotopos estables: una herramienta comun para la ecofisiologia vegetal y animal*. ediciones universitarias universidad catolica de valparaiso. <http://repositorio.conicyt.cl/handle/10533/165587>
- Elfarkh, J., Johansen, K., El Hajj, M. M., Almashharawi, S. K., y McCabe, M. F. (2023). Evapotranspiration, gross primary productivity and water use efficiency over a

- high-density olive orchard using ground and satellite based data. *Agricultural Water Management*, 287, 108423. <https://doi.org/10.1016/j.agwat.2023.108423>
- Elliott, J., Deryng, D., Müller, C., Friler, K., Konzmann, M., Gerten, D., Glotter, M., Flörke, M., Wada, Y., Mejer, N., Eisner, S., Fekete, B. M., Folbert, C., Foster, I., Gosling, S. N., Hadeland, I., Jabárov, N., Ludwig, F., Masaki, Y., ... Wisser, D. (2014). Constraints and potentials of future irrigation water availability on agricultural production under climate change. *Proceedings of the National Academy of Sciences*, 111(9), 3239-3244. <https://doi.org/10.1073/pnas.1222474110>
- FAO.(2009).*TheEToCalculator.ReferenceManual*.https://www.fao.org/fileadmin/user_upload/faowater/docs/ReferenceManualETo.pdf
- FAO. (2020). *Respuesta del rendimiento de los cultivos al agua*. 530.
- FAO. (2022a). *Evapotranspiración del Cultivo.Guías para la determinación de los requerimientos de agua de los cultivos*. Estudio FAO Riego y Drenaje 56.
- FAO. (2022b). *Gestión Integrada de los recursos hídricos en favor de la seguridad alimentaria y resiliencia al cambio climático* (171).
- Fatichini, S., Paschalis, A., & Bonedeti, S. (2023). *Water use efficiency: A review of spatial and temporal variability*. Recuperado de <https://www.researchgate.net/requests/r120004999>
- Fernández Cortés, Y., Sotto Rodríguez, K. D., & Vargas Marín, L. A. (2020). *Impactos ambientales de la producción del café, y el aprovechamiento sustentable de los residuos generados*. *Revista de la Facultad de Ciencias Básicas*, 16(1), 93-107. Recuperado de http://www.scielo.org.co/scielo.php?script=sci_abstract&pid=S1909-04552020000100093&lng=en&nrm=iso&tlng=es
- Ferreira, T., Shuler, J., Guimarães, R., y Farah, A. (2019). *CHAPTER 1 Introduction to Coffee Plant and Genetics*. 1-25. <https://doi.org/10.1039/9781782622437-00001>

Foken, T. (2008). *Energy balance closure using eddy covariance above two different land surfaces and implications for CO₂ flux measurements*. Recuperado de https://www.researchgate.net/publication/225556534_Energy_Balance_Closure_Using_Eddy_Covariance_Above_Two_Different_Land_Surfaces_and_Implications_for_CO2_Flux_Measurements

Fossils, T. (2007). *Evapotranspiration—An overview*. ScienceDirect Topics. Recuperado de <https://www-sciencedirect-com.ezproxy.sibdi.ucr.ac.cr/topics/earth-and-planetary-sciences/evapotranspiration>

Franssen, H. J. H., Stöckli, R., Lehner, I., Rotenberg, E., y Seneviratne, S. I. (2010). Energy balance closure of eddy-covariance data: A multisite analysis for European FLUXNET stations. *Agricultural and Forest Meteorology*, 150(12), 1553-1567. <https://doi.org/10.1016/j.agrformet.2010.08.005>

García-Mora, T. J., y Mas, J.-F. (2011). Evaluación de imágenes del sensor MODIS para la cartografía de la cobertura del suelo en una región altamente diversa de México. *Boletín de la Sociedad Geológica Mexicana*, 63(1), 83-94.

Guerrieri, R., Belmecheri, S., Ollinger, S. V., Asbjornsen, H., Jennings, K., Xiao, J., Stocker, B. D., Martin, M., Hollinger, D. Y., Bracho-Garrillo, R., Clark, K., Dore, S., Kolb, T., Munger, J. W., Novick, K., y Richardson, A. D. (2019). Disentangling the role of photosynthesis and stomatal conductance on rising forest water-use efficiency. *Proceedings of the National Academy of Sciences*, 116(34), 16909-16914. <https://doi.org/10.1073/pnas.1905912116>

Gutiérrez, M. V., Meinzer, F. C., & Grantz, D. A. (1994). Regulation of transpiration in coffee hedgerows: covariation of environmental variables and apparent responses of stomata to wind and humidity. In *Plant, Cell & Environment* (Vol. 17, Issue 12, pp. 1305–1313). <https://doi.org/10.1111/j.1365-3040.1994.tb00532.x>

Haggar, J., y Schepp, K. (2015). *Coffee and Climate Change*. 55.

- Harder, P., Helgason, W. D., Johnson, B., y Pomeroy, J. W. (2023). Crop water use efficiency from eddy covariance methods in cold water-limited regions. *Agricultural and Forest Meteorology*, 341, 109657. <https://doi.org/10.1016/j.agrformet.2023.109657>
- Hatfield, J. L., y Dold, C. (2019). Water-Use Efficiency: Advances and Challenges in a Changing Climate. *Frontiers in Plant Science*, 10. <https://www.frontiersin.org/articles/10.3389/fpls.2019.00103>
- Hoover, D. L., Abendroth, L. J., Browning, D. M., Saha, A., Snyder, K., Wagle, P., Witthaus, L., Baffaut, C., Biederman, J. A., Bosch, D. D., Bracho, R., Busch, D., Clark, P., Ellsworth, P., Fay, P. A., Flerchinger, G., Kearney, S., Levers, L., Saliendra, N., ... Scott, R. L. (2023). Indicators of water use efficiency across diverse agroecosystems and spatiotemporal scales. *Science of The Total Environment*, 864, 160992. <https://doi.org/10.1016/j.scitotenv.2022.160992>
- IAEA. (2018). *Gestión del agua con fines agrícolas* [Text]. IAEA. <https://www.iaea.org/es/temas/gestion-del-agua-con-fines-agricolas>
- ICAFFE. (2020a). *Guía técnica para el cultivo del café*.
- ICAFFE. (2020b). *Informe sobre la actividad cafetalera 2020*.
- ICAFFE. (2021). *Informe actividad cafetalera 2021*.
- ICAFFE. (2022). *Informes de la actividad cafetalera*. Recuperado de <https://www.icafe.cr/sector-cafetalero/informacion-de-mercado/informes-de-la-actividad-cafetalera/>
- Imbach, P., Chou, S. C., Lyra, A., Rodrigues, D., Rodriguez, D., Latinovic, D., Siqueira, G., Silva, A., Garofolo, L., y Georgiou, S. (2018). Future climate change scenarios

- in Central America at high spatial resolution. *PLOS ONE*, 13(4), e0193570.
<https://doi.org/10.1371/journal.pone.0193570>
- Jiang, Lu Zhao, Chuan Liang, y Xiaotao Hu. (2022). *Leaf- and ecosystem-scale water use efficiency and their controlling factors of a kiwifruit orchard in the humid region of Southwest China.*
- Juszak, I., y Pellicciotti, F. (2013). A comparison of parameterizations of incoming longwave radiation over melting glaciers: Model robustness and seasonal variability. *Journal of Geophysical Research: Atmospheres*, 118(8), 3066-3084.
<https://doi.org/10.1002/jgrd.50277>
- Kim, S., y Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32, 669-679.
<https://doi.org/10.1016/j.ijforecast.2015.12.003>
- Kidston, J., Brümmer, C., Black, T. A., Morgenstern, K., Nesic, Z., McCaughey, J. H., & Barr, A. G. (2010). *Energy balance closure using eddy covariance above two different land surfaces and implications for CO2 flux measurements.* *Boundary-Layer Meteorology*, 136(2), 139-157. <https://doi.org/10.1007/s10546-010-9507-y>
- Knauer, J., Zaehle, S., Medlyn, B. E., Reichstein, M., Williams, C. A., Migliavacca, M., De Kauwe, M. G., Werner, C., Keitel, C., Kolari, P., Limousin, J.-M., y Linderson, M.-L. (2018). Towards physiologically meaningful water-use efficiency estimates from eddy covariance data. *Global Change Biology*, 24(2), 694-710.
<https://doi.org/10.1111/gcb.13893>
- Konzelmann, T., van de Wal, R. S. W., Greuell, W., Bintanja, R., Henneken, E. A. C., y Abe-Ouchi, A. (1994). Parameterization of global and longwave incoming radiation

- for the Greenland Ice Sheet. *Global and Planetary Change*, 9, 143-164.
[https://doi.org/10.1016/0921-8181\(94\)90013-2](https://doi.org/10.1016/0921-8181(94)90013-2)
- Leakey, A. D. B., Ferguson, J. N., Pignon, C. P., Wu, A., Jin, Z., Hammer, G. L., y Lobell, D. B. (2019). Water Use Efficiency as a Constraint and Target for Improving the Resilience and Productivity of C3 and C4 Crops. *Annual Review of Plant Biology*, 70(1), 781-808. <https://doi.org/10.1146/annurev-arplant-042817-040305>
- Liu, X., Chen, X., Li, R., Long, F., Zhang, L., Zhang, Q., y Li, J. (2017). Water-use efficiency of an old-growth forest in lower subtropical China. *Scientific Reports*, 7(1), Article 1. <https://doi.org/10.1038/srep42761>
- López Romero, J. M., Gómez Navarro, J. J., Palacios Peña, L., Lorente Plazas, R., Jiménez Guerrero, P., Montávez Gómez, J. P., y Jerez, S. (2018). *¿Cuánto tiempo de spin-up es realmente necesario para simulaciones climáticas regionales?* Asociación Española de Climatología. <https://repositorio.aemet.es/handle/20.500.11765/9977>
- Masseroni. (2014). *Limitations and improvements of the energy balance closure with reference to experimental data measured over a maize field | Atmósfera*. <https://www.elsevier.es/en-revista-atmosfera-76-articulo-limitations-improvements-energy-balance-closure-S0187623614700335>
- Masseroni, D., Ravazzani, G., Corbari, C., y Mancini, M. (2012). Turbulence integral length and footprint dimension with reference to experimental data measured over maize cultivation in Po Valley, Italy. *Atmósfera*, 25(2), 183-198.
- Mauder, M., Foken, T., y Cuxart, J. (2020). Surface-Energy-Balance Closure over Land: A Review. *Boundary-Layer Meteorology*, 177(2-3), 395-426.
<https://doi.org/10.1007/s10546-020-00529-6>

- Mbava, N., Mutema, M., Zengeni, R., Shimelis, H., y Chaplot, V. (2020). Factors affecting crop water use efficiency: A worldwide meta-analysis. *Agricultural Water Management*, 228, 105878. <https://doi.org/10.1016/j.agwat.2019.105878>
- Medrano, H., Bota, J., Llompart, J., Flexas, J., Ribas-Carbo, M., y Gulias, J. (2007). Eficiencia en el uso del agua por las plantas. *Investigaciones Geográficas*, 43. <https://doi.org/10.14198/INGEO2007.43.04>
- MINAE. (2009). *Política Hídrica Nacional*. <https://da.go.cr/politicas/>
- MINAE. (2013). *Agenda del agua*.
- Moorhead, J. E., Marek, G. W., Gowda, P. H., Lin, X., Colaizzi, P. D., Evett, S. R., y Kutikoff, S. (2019). Evaluation of Evapotranspiration from Eddy Covariance Using Large Weighing Lysimeters. *Agronomy*, 9(2), Article 2. <https://doi.org/10.3390/agronomy9020099>
- Montero Marín, F. (2022). *Estimación del uso del agua de plantas de café (Coffea arabica L.) cultivadas al sol y a la sombra*. Universidad de Costa Rica.
- Montero Acuña, R. (2022). *Impact of rainfall on the diurnal cycle of surface fluxes in a coffee plantation*.
- Molina, F. A. (2014). *Estimación de la eficiencia del uso del agua (EUA) y Kdpv para plantas jóvenes de Jatropha Curcas L.* Tesis ingeniero agrónomo--Universidad de Chile
- Moreno, R., Rojano-Aguilar, A., y López-Cruz, I. L. (2014). *La eficiencia en el uso del agua en la agricultura controlada*. 7.
- Olivares, B. O., López-Beltrán, M. A., Olivares, B. O., y López-Beltrán, M. A. (2019). Índice de Vegetación de Diferencia Normalizada aplicado al territorio indígena agrícola de Kashaama, Venezuela. *Cuadernos de Investigación UNED*, 11(2), 112-121. <https://doi.org/10.22458/urj.v11i2.2299>

- ONU. (2020). - *Indicadores de los ODS*. <https://unstats.un.org/sdgs/report/2020/>
- Ovalle Rivera, O. (2018). *Impacto del cambio climático sobre la aptitud del cultivo de café en Costa Rica* [Report]. International Center for Tropical Agriculture. <https://cgspace.cgiar.org/handle/10568/92853>
- Ovalle Rivera, O. C. (2015). *Impacto del cambio climático en la productividad del café (Coffea arabica) bajo sistemas agroforestales en Costa Rica y Nicaragua*. <https://repositorio.catie.ac.cr/handle/11554/7204>
- Pateromichelaki, I. M. (2020). *Modelling of interactions within the soil-vegetation-atmosphere continuum in a coffee plantation in Costa Rica*.
- Pappo, E., Wilson, C., y Flory, S. L. (2021). Hybrid coffee cultivars may enhance agroecosystem resilience to climate change. *AoB PLANTS*, 13(2), plab010. <https://doi.org/10.1093/aobpla/plab010>
- Peddinti, S. R., Kambhammettu, B. V. N. P., Rodda, S. R., Thumaty, K. C., y Suradhaniwar, S. (2020). Dynamics of Ecosystem Water Use Efficiency in Citrus Orchards of Central India Using Eddy Covariance and Landsat Measurements. *Ecosystems*, 23(3), 511-528. <https://doi.org/10.1007/s10021-019-00416-3>
- Peña Quiñones, A. J., Ramírez Builes, V. H., Jaramillo Robledo, A., Rendón Sáenz, J. R., y Arcila Pulgarín, J. (2011). EFFECTS OF DAYLENGTH AND SOIL HUMIDITY ON THE FLOWERING OF COFFEE COFFEA ARABICA L. IN COLOMBIA. *Revista Facultad Nacional de Agronomía Medellín*, 64(1), 5745-5754.
- Piñeiro, V., Morley, S., & Elverdin, P. (2015). *Los efectos de la roya en las economías centroamericanas*. Recuperado de <https://ebrary.ifpri.org/utils/getfile/collection/p15738coll2/id/129390/filename/129601.pdf>

Ponton, S., Flanagan, L. B., Alstad, K. P., Johnson, B. G., Morgenstern, K., Kljun, N., Black, T. A., y Barr, A. G. (2006). Comparison of ecosystem water-use efficiency among Douglas-fir forest, aspen forest and grassland using eddy covariance and carbon isotope techniques. *Global Change Biology*, 12(2), 294-310. <https://doi.org/10.1111/j.1365-2486.2005.01103.x>

Quesada Jiménez, K. (2015). *Caracterización del territorio Central Occidental (Alajuela-Grecia-Poás-Valverde Vega)*.

Raavshan Eshonkulov, Arne Poyda, Joachin Ingwersen, Hans Dieter Wizemann, Tobías Weber, Petrea Hogy, Alim Pulatov, y Thilo Streck. (2019). *Evaluating multi-year, multi-site data on the energy balance closure of eddy-covariance flux measurements at cropland sites in southwestern Germany*. <https://doi.org/10.5194/bg-16-521-2019>

Restrepo B, L. F., y González L, J. (2007). De Pearson a Spearman. *Revista Colombiana de Ciencias Pecuarias*, 20(2), 183-192.

Risco Eber Sence. (2015). *Generación de una base de datos de evapotranspiración grillada y de alta resolución a nivel nacional (1981-2014)*. Ministerio de Ambiente, Perú.

Richard Allen, Luis Pereira, Dirk Raes, y Martin Smith. (1998). *Evapotranspiración de cultivos—Directrices para calcular las necesidades de agua de los cultivos— Documento de riego y drenaje de la FAO 56*. <https://www.fao.org/3/x0490e/x0490e00.htm#Contents>

Rodríguez, S., Arteaga, R., Sargeman, D., & Cervantes, R. (2012). *Evapotranspiración de referencia estimada con FAO-Penman-Monteith, Priestley-Taylor, Hargreaves y RNA*.

- Sánchez-Murillo, R., Esquivel-Hernández, G., Sáenz-Rosales, O., Piedra-Marín, G., Fonseca-Sánchez, A., Madrigal-Solís, H., Ulloa-Chaverri, F., Rojas-Jiménez, L. D., y Vargas-Viquez, J. A. (2017). Isotopic composition in precipitation and groundwater in the northern mountainous region of the Central Valley of Costa Rica. *Isotopes in Environmental and Health Studies*, 53(1), 1-17. <https://doi.org/10.1080/10256016.2016.1193503>
- Seibt, U., Rajabi, A., Griffiths, H., y Berry, J. A. (2008). Carbon isotopes and water use efficiency: Sense and sensitivity. *Oecologia*, 155(3), 441. <https://doi.org/10.1007/s00442-007-0932-7>
- Siles Gutiérrez, P. (s. f.). *Hydrological processes (water use and balance) in a coffee (Coffea arabica L.) monoculture and a coffee plantation shaded by Inga densiflora in Costa Rica*. [2020].
- Tang, X., Ding, Z., Li, H., Li, X., Luo, J., Xie, J., y Chen, D. (2015). Characterizing ecosystem water-use efficiency of croplands with eddy covariance measurements and MODIS products. *Ecological Engineering*, 85, 212-217. <https://doi.org/10.1016/j.ecoleng.2015.09.078>
- Van Kanten, R., Schroth, G., Beer, J., y Jiménez, F. (2005). Fine-root dynamics of coffee in association with two shade trees in Costa Rica. *Agroforestry Systems*, 63(3), 247-261. <https://doi.org/10.1007/s10457-005-4163-9>
- Urbaz, M., Silva-Acuña, R., Méndez Natera, J. R., y Mundarain Padilla, S. (2015). Fenología de la floración del cafeto var. Catuaí Rojo en el municipio Caripe del estado Monagas, Venezuela. *Idesia (Arica)*, 33(1), 59-67. <https://doi.org/10.4067/S0718-34292015000100007>

- Veneros, J., García, L., Morales, E., Gómez, V., Torres, M., López-Morales, F., Veneros, J., García, L., Morales, E., Gómez, V., Torres, M., y López-Morales, F. (2020). Aplicación de sensores remotos para el análisis de cobertura vegetal y cuerpos de agua. *Idesia (Arica)*, 38(4), 99-107. <https://doi.org/10.4067/S0718-34292020000400099>
- Versini, P.-A., Castellanos-Díaz, L. A., Ramier, D., y Tchiguirinskaia, I. (2024). Evapotranspiration evaluation using three different protocols on a large green roof in the greater Paris area. *Earth System Science Data*, 16(5), 2351-2366. <https://doi.org/10.5194/essd-16-2351-2024>
- Wang, Monica García, Andreas Ibrom, y Peter Bauer. (2019). *Temporal interpolation of land surface fluxes derived from remote sensing—Results with an Unmanned Aerial System*.
- Wanyuan Cai, Sana Ullah, y Lei Yan and Yi Lin. (2021). *Remote Sensing of Ecosystem Water Use Efficiency: A Review of Direct and Indirect Estimation Methods*.
- Widmoser, P., y Michel, D. (2021). Partial energy balance closure of eddy covariance evaporation measurements using concurrent lysimeter observations over grassland. *Hydrology and Earth System Sciences*, 25(3), 1151-1163. <https://doi.org/10.5194/hess-25-1151-2021>
- Wiebe, K., Lotze-Campen, H., Sands, R., Tabeau, A., Mensbrugge, D. van der, Biewald, A., Bodirsky, B., Islam, S., Kavallari, A., Mason-D’Croz, D., Müller, C., Popp, A., Robertson, R., Robinson, S., Meijl, H. van, y Willenbockel, D. (2015). Climate change impacts on agriculture in 2050 under a range of plausible socioeconomic and emissions scenarios. *Environmental Research Letters*, 10(8), 085010. <https://doi.org/10.1088/1748-9326/10/8/085010>

- 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., ... Verma, S. (2002). Energy balance closure at FLUXNET sites. *Agricultural and Forest Meteorology*, 113(1), 223-243. [https://doi.org/10.1016/S0168-1923\(02\)00109-0](https://doi.org/10.1016/S0168-1923(02)00109-0)
- Xiao, J., Sun, G., Chen, J., Chen, H., Chen, S., Dong, G., Gao, S., Guo, H., Guo, J., Han, S., Kato, T., Li, Y., Lin, G., Lu, W., Ma, M., McNulty, S., Shao, C., Wang, X., Xie, X., ... Zhou, J. (2013). Carbon fluxes, evapotranspiration, and water use efficiency of terrestrial ecosystems in China. *Agricultural and Forest Meteorology*, 182-183, 76-90. <https://doi.org/10.1016/j.agrformet.2013.08.007>
- Xie, J., Chen, J., Sun, G., Zha, T., Yang, B., Chu, H., Liu, J., Wan, S., Zhou, C., Ma, H., Bourque, C. P.-A., Shao, C., John, R., y Ouyang, Z. (2016). Ten-year variability in ecosystem water use efficiency in an oak-dominated temperate forest under a warming climate. *Agricultural and Forest Meteorology*, 218-219, 209-217. <https://doi.org/10.1016/j.agrformet.2015.12.059>
- Yue, P., Zhang, Q., Niu, S., Cheng, H., y Wang, X. (2011). Effects of the soil heat flux estimates on surface energy balance closure over a semi-arid grassland. *Acta Meteorologica Sinica*, 25(6), 774-782. <https://doi.org/10.1007/s13351-011-0608-4>

X. Anexos

a) Módulo de balance de energía superficial:

El módulo de balance de energía superficial incorpora las ecuaciones de balance de energía de superficie con el método de fuerza-restauración (force restore) para estimar la temperatura de la superficie del suelo y los flujos de calor (Wang et al., 2019).

$$R_n = SW_{in} - SW_{out} + LW_{in} - LW_{out} = (1 - ALB) SW_{in} + (1 - \varepsilon) LW_{in} - \varepsilon \sigma T_s^4 \quad (34)$$

Donde SW_{in} es la radiación de onda corta, SW_{out} es la de onda corta saliente, LW_{in} la de onda larga entrante, LW_{out} es la salida la radiación de onda larga, σ es la constante de Stefan-Boltzmann ($5.670367 \cdot 10^{-8} \text{ W m}^{-2}$), T_s la temperatura de superficie (Tabla 3). El albedo ALB está dado por la ecuación 34 y ecuación 35 basado en el índice de vegetación de razón simple (SR). La emisividad de la superficie se da por la ecuación 36 basada en la relación empírica con NDVI (Wang et al., 2019 y Pateromichelaki, 2020).

$$ALB = 0.28 - 0.14 \exp(-6.08/SR^2) \quad (35)$$

$$SR = (1 + NDVI) / (1 - NDVI) \quad (36)$$

$$\varepsilon = \{0.986 \cdot 1.0094 + 0.047 \ln \ln(NDVI)\} \cdot 0.91, (NDVI) > 0.608, (0.131 < NDVI < 0.608), (NDVI < 0.131) \quad (37)$$

En cuanto a la radiación neta que llega a la superficie, se disipa como flujos de calor sensible, latente en el suelo (ecuación 43), calculando el cambio de calor de almacenamiento $\frac{dS}{dt} (W/m^2)$ que se calcula mediante el modelo PT-JPL (módulo del balance de agua), los flujos de calor sensible, H, se calculan a través del gradiente de temperatura entre el aire y la superficie (ecuación 42) y los flujos del calor del suelo, G, que se calcula por el método fuerza-restauración.

$$\frac{dS}{dt} = SW_{in} - SW_{out} + LW_{in} - LW_{out} - H - \lambda E - G \quad (38)$$

Los diferentes componentes de este modelo fuerza-restauración se observan en la ecuación 40, que describe el efecto regulador de la temperatura del suelo profundo en la asimilación del calor que llega a la superficie del suelo. Además, como la temperatura de la capa

profunda T_d , generalmente fluctúa menos en comparación con la temperatura de la superficie del suelo T_s , por lo cual se crea un gradiente de temperatura ($T_s - T_d$).

El gradiente de temperatura del suelo y el forzamiento de la atmósfera a través de la suma de flujos de calor ($R_n - E - H$) actúan en la interfaz de la atmósfera y suelo, lo que determina la temperatura superficial resultante (Wang et al., 2019).

$$\frac{dT_s}{dt} = C_T(R_n - \lambda E - H) - C_d(T_s - T_d) \quad (39)$$

$$\frac{dT_d}{dt} = \omega(T_s - T_d) \quad (40)$$

$$\frac{1}{C_T} = \frac{1-f_c}{c_{sat} \left(\frac{SWS_{max}}{SWS} \right)^{\frac{b}{2 \ln 10}}} + \frac{f_c}{c_{veg}} \quad (41)$$

$$C_d = 2\pi\omega \quad (42)$$

En las ecuaciones, C_T se refiere al coeficiente térmico de restauración de fuerza para la transferencia de calor superficial ($K \cdot m^2 \cdot J^{-1}$), el parámetro ω es la frecuencia de oscilación $1/24$ (h^{-1}) y C_d es la periodicidad diurna en ω (h^{-1}). C_{sat} es el coeficiente térmico de fuerza-restauración para el suelo ($K \cdot m^2 \cdot J^{-1}$), C_{veg} es el coeficiente para la vegetación, b es la pendiente de la curva de retención del coeficiente térmico de fuerza-restauración y f_c es la cobertura fraccional de vegetación y se asume que es igual a f_{IPAR} (fracción fotosintéticamente y radiación activa interceptada por el dosel). SWS_{max} es el almacenamiento máximo de agua en el suelo (m^3) y SWS es el almacenamiento real de agua en el suelo (Wang et al., 2019).

Como se mencionó anteriormente en la ecuación 41, se determina el flujo de calor sensible (W/m^2) basado en el gradiente de temperatura entre la superficie del suelo y el aire, ρ es la densidad del aire (kg/m^3), C_p es la capacidad calorífica específica del aire ($J / kg^1 / K^1$) y r_a es la resistencia aerodinámica para transferencia de calor (s/m^1). La disipación de energía como el flujo de calor sensible es determinado por la resistencia aerodinámica de la velocidad del viento horizontal por la estructura del dosel (Wang et al., 2019).

La ecuación 43 menciona esta resistencia aerodinámica al transporte turbulento en condiciones neutras r_{AN} . Donde h_c es la altura del dosel (m), d es la altura del desplazamiento cero (m), z es la altura de referencia de velocidad (m), y Z_{0m} es la longitud de rugosidad aerodinámica para el impulso (m) z_{oh} es la rugosidad aerodinámica para la transferencia de calor (m), u es la velocidad del viento horizontal y altura de referencia (m/s) kB^{-1} tiene en cuenta la diferencia entre las temperaturas aerodinámicas y radiométricas y este modelo tiene un valor constante de 2.3. k que es la constante van Karman (0.4).

$$H = \rho \cdot C_p (T_s - T_a) / r_a \quad (43)$$

$$r_{aN} = \frac{\ln \ln \frac{z-d}{z_{0m}} \ln \ln \frac{z-d}{z_{oh}}}{k^2 u} \quad (44)$$

$$d = 0.67 h_c \quad (45)$$

$$2z_{0m} = 0.1 h_c \quad (46)$$

$$z_{0m} = 0.1 h_c \quad (47)$$

$$z_0 h = \frac{z_{0m}}{\exp \exp kB^{-1}} \quad (48)$$

La resistencia aerodinámica se corrige por la estabilidad atmosférica como se muestra en la Ecuación 48, ψ_m es el factor de corrección de estabilidad para la cantidad de movimiento, ψ_h es la estabilidad del factor de corrección del flujo de calor sensible. Para condiciones inestables (gradiente de temperatura negativa), los factores de corrección de estabilidad son menores que 1.0 y la corrección reduce la resistencia y mejora la turbulencia, mientras que para condiciones estables son superiores a 1.0 y la corrección aumenta la resistencia y suprime la turbulencia (Wang et al., 2019)

$$r_a = r_{aN} \cdot \psi_m \cdot \psi_h \quad (49)$$

Para condiciones inestables ($RiB \leq 0$), aplica:

$$\psi_h = \psi_m = (1 - 15 RiB)^{-1/2} \quad (50)$$

Para condiciones estables ($0 \leq RiB < 0.2$), aplica:

$$\psi_h = \psi_m = (1 - 5 RiB)^{-1} \quad (51)$$

$$R_{iB} = \frac{\left(\frac{g}{T_s}\right) \cdot \partial T_s / \partial z}{\left(\frac{\partial u}{\partial z}\right)^2} \quad (52)$$

R_{iB} es el número de Richardson, g es la aceleración gravitacional.

b) Módulo de balance de agua:

El módulo de balance de agua está combinando el Laboratorio de propulsión a chorro ET de Priestley-Taylor (PT-JPL ET) con un modelo simple “Bucket” que representa la columna de suelo superior, para derivar ET, componentes del agua del suelo y escorrentía superficial. El modelo PT-JPL hace uso de la ecuación de Priestley-Taylor para derivar la evapotranspiración potencial y variables ecofisiológicas que se utilizan para estimar la evapotranspiración real. Las ecuaciones 55, 56 y 57 se utilizan para derivar los componentes de ET, a saber, la evaporación del agua interceptada (E_i), la transpiración de las plantas (E_c) y el agua del suelo evaporación (E_s) (Wang et al., 2019).

$$E_i = \lambda E_i + \lambda E_c + \lambda E_s \quad (53)$$

$$\lambda E_i = f_{wet} \cdot \alpha \cdot \Delta / (\Delta + \gamma) \cdot R_{nc} \quad (54)$$

$$\lambda E_c = (1 - f_{wet}) \cdot f_g \cdot f_M \cdot f_{T_a} \cdot \alpha \cdot \Delta / (\Delta + \gamma) R_{nc} \quad (55)$$

$$\lambda E_s = f_{sM} \cdot \alpha \cdot \Delta / (\Delta + \gamma) (R_{n5} - G) \quad (56)$$

En las ecuaciones anteriores, λET es el flujo de calor latente de la evapotranspiración total (W/m^2), λE_i es el flujo de calor latente de evaporación del agua interceptada (W/m^2), λE_c es el flujo de calor latente de transpiración (W/m^2), y λE_s es el flujo de calor latente de evaporación del agua del suelo (W/m^2).

Los flujos están restringidos por condiciones ambientales limitantes que son expresados en las ecuaciones a través de una serie de factores que varían entre 0 y 1 e indican la reducción relativa de la evapotranspiración potencial (Pateromichelaki, 2020; Wang et al., 2019).

El factor f_{wet} indica la humedad relativa de la superficie y se utiliza para dividir la evaporación del agua interceptada y transpiración de la planta. La fracción de dosel transpirante activo se expresa a través de f_g , es decir, la fracción del dosel verde, mientras que f_M expresa la restricción de humedad de la planta y viene dada por la ecuación 57. El factor f_{Ta} es la restricción de temperatura de la planta e indica la limitación de temperatura de la fotosíntesis. Finalmente, f_{SM} es la restricción de humedad del suelo (Wang et al., 2019).

Δ es la pendiente de la curva de presión de vapor de saturación versus temperatura y es la constante psicrométrica. El parámetro α es la relación entre la evapotranspiración potencial y evapotranspiración potencial de equilibrio y tiene un valor empírico sugerido de 1,26 en el modelo PT-JPL. G representa el flujo de calor del suelo y R_{nc} y R_{ns} el dosel de red y flujos de radiación neta del suelo respectivamente.

$$f_{sm} = \theta_e \quad (57)$$

La ecuación 57, se utiliza para derivar f_{wet} de CWS , que es el almacenamiento real de agua del dosel (mm) y CWS_{max} , es el almacenamiento máximo de agua del dosel (mm). La cantidad máxima posible de agua interceptada, CWS_{max} , se calcula como $0,2 \text{ LAI kg/m}^2$.

$$f_{wet} = \frac{CWS}{CWS_{max}} \quad (58)$$

La ecuación 59 de pronóstico se utiliza para estimar CWS , donde f_c es la vegetación fraccionada cubierta, se supone que es igual a f_{IPAR} . Además, la precipitación P y evaporación del agua interceptada E_i se dan en m/s^1 .

$$\frac{dCWS}{dt} = f_c \cdot P - E_i \quad (59)$$

En la ecuación 60, da la efectividad de la precipitación P_e , como la diferencia entre la precipitación y el cambio en el almacenamiento del dosel.

$$P_e = P + I - dCWS \quad (60)$$

Posteriormente, se aplica el modelo "bucket" con el fin de estimar los balances hídricos dentro de la columna de referencia del suelo superficial. Esencialmente, se aplica un simple balance hídrico para determinar las tasas de infiltración Q_{inf} y percolación Q_{per} , así como el escurrimiento superficial R . Si bien el suelo no está saturado (mientras que el almacenamiento de agua del suelo, SWS , está por debajo de su máximo valor, $SWS_{m\acute{a}x}$), la tasa de infiltración es igual a la precipitación efectiva.

$$Q_{inf} = P_e \quad (61)$$

$$\frac{dSWS}{dt} = Q_{inf} - E_C - E_S - Q_{per} \quad (62)$$

Por otro lado, después de que se excede la capacidad máxima del suelo, SWS es igual a $SWS_{m\acute{a}x}$ y se produce runo superficial, como se describe en las siguientes ecuaciones:

$$Q_{inf} - E_C - E_S - Q_{per} \quad (63)$$

$$R = P_e - Q_{inf} \quad (64)$$

Para calcular la percolación del agua a través del suelo, se utiliza el modelo de Mualem que calcula la conductividad hidráulica de suelos insaturados, asumiendo un gradiente hidráulico vertical uniforme, como se describe en la siguiente ecuación (Pateromichelaki, 2020).

$$Q_{per} = K_s \cdot \sqrt{\theta_e} \cdot \left(1 - \left(1 - \theta_e^{\left(\frac{1}{1-\frac{1}{n}} \right)^{\left(1-\frac{1}{n} \right)}} \right)^2 \right) \quad (65)$$

$$\theta_e = \frac{\theta - \theta_r}{\theta_s - \theta_r} \quad (66)$$

$$\theta = \frac{SWS}{SWS_{maz}} \theta_s \quad (67)$$

Donde K_s es la conductividad hidráulica saturada (m/s^1), n es un parámetro de ajuste que depende en el tamaño de los poros, θ es la humedad volumétrica del suelo (m^3/m^3), θ_e es

la humedad del suelo efectiva (m^3/m^3), θ_s es la humedad saturada del suelo (m^3/m^3), y θ_r es el residuo de la humedad del suelo (m^3/m^3) (Pateromichelaki, 2020).

c) Módulo de Flujos de CO₂

El tercer módulo se emplea para estimar la productividad primaria neta (PPN) mediante un modelo de eficiencia en el uso de luz (LUE). Las restricciones ambientales y eco fisiológicas para la transpiración del dosel del modelo PT-JPL se aplican para estimar las tasas de asimilación de carbono. Como se en la ecuación 68. La PPN se calcula tomando en cuenta las restricciones que se emplean para derivar la transpiración de la planta (Módulo balance de agua) y una restricción adicional que se refiere al dosel fotosintéticamente activo (Wang et al., 2018).

$$PPN = LUE_{max} \cdot PAR_c \cdot f_g \cdot f_M \cdot f_{T\alpha} \cdot f_{vPD} \quad (68)$$

Donde LUE_{max} es el valor máximo del modelo de eficiencia en el uso de luz, PAR_c es la radiación fotosintética activa interceptado por el dosel y se deriva de la ley de Beer Lambert, f_g es la fracción del dosel verde, f_M es la restricción de humedad de la planta, f_{Ta} es la restricción debido a la temperatura del aire y f_{vPD} es la restricción por déficit de la presión de vapor que representa el ajuste de la apertura estomática debido al déficit de saturación de agua atmosférica.

$$f_g = \frac{f_{APAR}}{f_{IPAR}} \quad (69)$$

$$f_M = \frac{f_{APAR}}{\max(f_{APAR})} \quad (70)$$

f_{APAR} es la fracción de PAR absorbida por la cubierta de vegetación y f_{IPAR} es la fracción de PAR interceptada por la cubierta vegetal

$$f_{Ta} = 1.1814 \cdot [1 + e^{0.3(-T_0 - 10 + T_\alpha)}]^{-1} \cdot [1 + e^{0.2(T_0 - 10 + T_\alpha)}]^{-1} \quad (71)$$

T_{∞} es la temperatura del aire y T_0 es la temperatura óptima del crecimiento de la planta. En estudios como el de Pateromichelaki, (2020) lo calculó en el modelo SVEN como $PAR \cdot f_{APAR} \cdot T_{\infty} / VPD$ y la temperatura óptima para café la calculo mediante literatura obteniendo un valor de 19.5 °C.

$$f_{VPD} = \frac{1}{1 - \frac{VPD}{D_0}} \quad (72)$$

D_0 es el coeficiente empírico para VDP y es igual a 15hPa.