

UNIVERSIDAD TECNOLÓGICA DE PANAMÁ

FACULTAD DE INGENIERÍA MECÁNICA

TRABAJO DE GRADUACIÓN PARA OPTAR POR EL TÍTULO DE MAESTRÍA EN
CIENCIAS DE LA INGENIERÍA MECÁNICA

**EVALUACIÓN DEL COMPORTAMIENTO DE LA AVICENNIA BICOLOR EN
MANGLAR PANAMEÑO: UN ESTUDIO NUMÉRICO**

PRESENTADO POR:

Jefferson Brooks

PROFESOR ASESOR:

Dra. Nathalia Tejedor

PROFESOR CO-ASESOR:

Dr. Miguel Chen Austin

Julio 2022

UNIVERSIDAD TECNOLÓGICA DE PANAMÁ

FACULTAD DE INGENIERÍA MECÁNICA

EVALUACIÓN DEL COMPORTAMIENTO DE LA AVICENNIA BICOLOR EN MANGLAR

PANAMEÑO: UN ESTUDIO NUMÉRICO

PRESENTADO POR:

Jefferson Brooks

Céd. 8-894-2118

Aprobado por: _____

Dra. Nathalia Tejedor F.

Profesora Asesora

Aprobado por: _____

Dr. Francisco López

Jurado Calificador

Aprobado por: _____

Dr. Reinhardt Pinzón

Jurado Calificador

Contenido

Dedicatoria.....	5
Agradecimientos	6
Lista de figuras.....	7
Lista de Tablas	8
Nomenclatura.....	9
Resumen.....	10
Abstract.....	11
Capítulo 1: Introducción	12
Concentración de CO ₂ en la Atmósfera.	12
Estado del Arte	14
Motivación	20
Justificación.....	21
Objetivo General	23
Objetivos Específicos.....	23
Planteamiento del Problema.....	24
Capítulo 2: Marco Teórico.....	25
Flujo de Agua en Árboles.....	25
Modelos Matemáticos Analizados	27
Torre de Medición de Flujos	31
Proceso de Tratamiento de los Datos Recolectados.....	35
Inteligencia Artificial y Aprendizaje Automático.....	35
Redes Neuronales Artificiales	38
Capítulo 3: Metodología	41
Dominios Propuestos y sus Interacciones	41
Estimación de los Flujos de Energía	45
Campaña de Medición y Acondicionamiento de Datos	46
Enfoque no Físico Basado en Datos.....	49
Enfoque Cuasi Físico Basado en Datos.....	51
Capítulo 4: Resultados	55
Análisis de Correlación.	56
Modelo de Caja Gris	59
Modelo de Caja Gris Simplificado.....	63
Modelo de Caja Negra.....	67

Capítulo 5: Discusión.....	79
Capítulo 6: Conclusiones	81
Modelo de Caja Gris	81
Modelo de Caja Negra.....	82
Trabajos Futuros.....	82
Referencias.....	84

Dedicatoria

A Dios por protegerme, guiarme y darme la sabiduría durante todo el camino.

A mis padres por su amor, consejos, valores y principios transmitidos para ser cada día una mejor persona, así como el sacrificio realizado para poder alcanzar esta meta.

A la Licda. Génesis Jiménez por todo el apoyo aportado, tanto profesional como personal.

Al MSc. Said Vargas por compartir sus conocimientos, consejos y experiencias durante este camino.

Al MSc. Antonio Jaén por todos los consejos y recomendaciones brindadas.

Agradecimientos

A la Secretaría Nacional de Ciencia, Tecnología e Investigación (SENACYT) y a la Facultad de Ingeniería Mecánica por permitirme realizar el programa de Maestría en Ciencias de la Ingeniería Mecánica.

A la Dra. Nathalia Tejedor y al Dr. Miguel Chen por todos los conocimientos y orientaciones impartidas durante el desarrollo de la investigación, aportando estratégicamente a mi crecimiento profesional como investigador.

A la Ing. Ana Karina Rivera H. por el empeño, sacrificio y contribuciones realizadas en esta investigación.

A los MScs. Brenda Tyril, Eric Parker, Miguel Moreno y Manuel Escala, por el apoyo y consejos brindados durante este recorrido.

A la Universidad Tecnológica OTEIMA, el Centro de Investigaciones Hidráulicas e Hidrotécnicas (CIHH), al Grupo de Investigación en Energética y Confort en Edificaciones Bioclimáticas (ECEB) y al Sistema Nacional de Investigación (SNI) por los recursos facilitados (capacitaciones, financiamientos, equipos, etc.).

Lista de figuras

Figura 1	<i>Concentración de CO₂ durante los últimos 1000 años.</i>	13
Figura 2	<i>Ubicación del área seleccionada para el estudio</i>	23
Figura 3	<i>Representación del flujo analizado por el método Covarianza de remolinos.</i>	32
Figura 4	<i>Proceso dentro de las cámaras de medición de gases.</i>	33
Figura 5	<i>Esquema de un modelo no lineal de una neurona</i>	39
Figura 6	<i>Intercambio de masa y energía a nivel de la hoja.</i>	41
Figura 7	<i>Interacción entre los dominios Suelo, Manglar y Atmósfera.</i>	43
Figura 8	<i>Perturbaciones encontradas en la base de datos sin filtro.</i>	47
Figura 9	<i>Impacto del proceso de suavizado en los datos utilizados.</i>	48
Figura 10	<i>Variabilidad del flujo de CO₂ en los meses de enero a junio de 2018.</i>	49
Figura 11	<i>Diagrama representativo del sistema.</i>	52
Figura 12	<i>Diagrama representativo simplificado del sistema.</i>	53
Figura 13	<i>Velocidad promedio registrada desde enero hasta junio del 2018.</i>	55
Figura 14	<i>Temperatura del aire promedio registrada desde enero hasta junio del 2018.</i>	55
Figura 15	<i>Humedad relativa promedio registrada desde enero hasta junio del 2018.</i>	56
Figura 16	<i>Análisis de correlación de las variables registradas en el área de estudio.</i>	58
Figura 17	<i>Potencial de agua en el aire durante los primeros seis meses del año 2018.</i>	59
Figura 18	<i>Calor latente registrado durante los primeros seis meses del año 2018.</i>	60
Figura 19	<i>Proceso realizado para el filtrado y suavizado de los datos.</i>	60
Figura 20	<i>Datos del calor latente luego de aplicar el primer filtro.</i>	61
Figura 21	<i>Validación del modelo propuesto para el día 28 de agosto de 2018.</i>	62
Figura 22	<i>Validación del modelo propuesto para el día 29 de agosto de 2018.</i>	63
Figura 23	<i>Comportamientos observados en los datos desde las 00:10 hasta las 23:50.</i>	64
Figura 24	<i>Validación del modelo simplificado para el día 11 de mayo de 2018.</i>	65
Figura 25	<i>Validación del modelo simplificado para el día 2 de junio de 2018.</i>	65
Figura 26	<i>Temperatura de aire registrada desde agosto del 2018 hasta noviembre del 2020.</i>	66
Figura 27	<i>Humedad relativa registrada desde agosto del 2018 hasta noviembre del 2020.</i>	66
Figura 28	<i>Validación del modelo simplificado para el día 10 de septiembre de 2018.</i>	67
Figura 29	<i>Validación del modelo de caja negra para el día 25 de enero (Parte 1).</i>	69
Figura 30	<i>Validación del modelo de caja negra para el día 25 de enero (Parte 2).</i>	70
Figura 31	<i>Validación del modelo de caja negra para el día 26 de febrero (Parte 1).</i>	71
Figura 32	<i>Validación del modelo de caja negra para el día 26 de febrero (Parte 2).</i>	72
Figura 33	<i>Validación del modelo de caja negra para el día 24 de mayo (Parte 1).</i>	74
Figura 34	<i>Validación del modelo de caja negra para el día 24 de mayo (Parte 2).</i>	75
Figura 35	<i>Validación del modelo de caja negra para el día 25 de septiembre (Parte 1).</i>	77
Figura 36	<i>Validación del modelo de caja negra para el día 25 de septiembre (Parte 2).</i>	78

Lista de Tablas

Tabla 1	<i>Ecuaciones alométricas para la determinación de la biomasa aérea.</i>	17
Tabla 2	<i>Sensores instalados en el área bajo análisis.</i>	33
Tabla 3	<i>Características encontradas en el primer grupo de datos de flujo de CO₂.</i>	49
Tabla 4	<i>Variables consideradas para el análisis de correlación.</i>	56
Tabla 5	<i>Correlaciones significativas observadas en la matriz resultante.</i>	58
Tabla 6	<i>Parámetros utilizados por el modelo</i>	61
Tabla 7	<i>Resultados de las iteraciones para el modelo simplificado.</i>	64
Tabla 8	<i>Configuración inicial de hiperparámetros para el modelo de caja negra.</i>	67
Tabla 9	<i>Hiperparámetros para el modelo aplicado al mes de enero 2018.</i>	68
Tabla 10	<i>Hiperparámetros para el modelo aplicado al mes de febrero 2018.</i>	73
Tabla 11	<i>Hiperparámetros para el modelo aplicado al mes de mayo 2018.</i>	73
Tabla 12	<i>Hiperparámetros para el modelo aplicado al mes de septiembre 2018.</i>	76

Nomenclatura

A	Asimilación neta de CO ₂	$\mu\text{mol m}^{-2}\text{s}^{-1}$
A_m	Asimilación neta en función del CO ₂	$\text{mg m}^{-2}\text{s}^{-1}$
C, C1, C2	Almacenamiento de agua	kg m^{-2}
C_i	Concentración de CO ₂ en el ambiente	
C_s	Concentración de CO ₂ en la cavidad estomática	
C_p	Calor específico del aire seco	$\text{J kg}^{-1}\text{K}^{-1}$
\bar{D}_i	Tensor de dispersión	
e'	Desviación en la presión de vapor	
F	Flujo interno de agua en el árbol	kg s^{-1}
FC	Flujo de CO ₂	$\text{mg m}^{-2}\text{s}^{-1}$
G	Flujo de calor en el suelo	W m^{-2}
g_{ha}	Conductancia en la capa límite para el calor y el vapor	$\text{mol m}^{-2}\text{s}^{-1}$
g_m	Conductancia mesofílica	mm s^{-1}
H	Flujo de calor sensible	W m^{-2}
IAF	Índice de área foliar	
\tilde{K}	Conductividad axial	$\text{kg s}^{-1}\text{MPa}^{-1}\text{m}$
K_i	Conductancia hidráulica	$\text{kg s}^{-1}\text{MPa}^{-1}$
LE	Flujo de calor latente	W m^{-2}
L, Lv	Calor latente de vaporización	J g^{-1}
PAR	Radiación fotosintética activa	$\mu\text{mol m}^{-2}\text{s}^{-1}$
R_d	Respiración de la hoja	$\text{mg m}^{-2}\text{s}^{-1}$
R_n	Radiación neta que recibe la plantación	W m^{-2}
T'	Desviación en la temperatura instantánea	m s^{-1}
u^*	Velocidad de fricción	m s^{-1}
V_w	Volumen molar parcial de agua	m^3/mol
w'	Desviación en la velocidad vertical del viento	m s^{-1}
ξ	Parámetro de estabilidad atmosférica	
ε	Eficiencia de uso cuántico inicial	$\text{mg CO}_2 [\text{J PAR}]^{-1}$
Γ	Punto de compensación de CO ₂	$\mu\text{mm mol}^{-1}$

Resumen

Los ecosistemas de manglar brindan múltiples beneficios dentro del sector social y económico, incluso mediante la fijación de CO₂ debido a las altas cifras de producción primaria neta que poseen. Considerando la significancia de estos ecosistemas, se buscaba incrementar los estudios para ayudar a evidenciar su importancia mediante la utilización de modelos matemáticos que permitan predecir los flujos de energía considerando la especie *Avicennia bicolor*, utilizando información disponible gracias a una torre de medición de flujos instalada en la Bahía de Panamá. Se procedió a realizar el tratamiento de los datos que se utilizaron dentro de los modelos, donde uno de ellos se basó en la analogía de la ley de Ohm, y el otro en predicción mediante la aplicación de redes neuronales. Se realizó una correlación entre las variables meteorológicas disponibles y los flujos de energía calculados mediante el método Eddy Covariance, donde se obtuvo correlaciones significativas entre el calor sensible con las ondas cortas de radiación ($R = 0.90$) y el flujo de calor en el suelo ($R = 0.80$). Se utilizó la analogía de la ley de Ohm para estimar el potencial de agua en el aire para dos días ($R = 0.37$ y $R = 0.43$), mientras que las redes neuronales lograron predecir el flujo de LE ($R^2 > 0.91$), H ($R^2 > 0.86$), FC ($R^2 > 0.88$) y el potencial del aire ($R^2 > 0.88$) de forma satisfactoria. El tratamiento previo de los datos en ambos modelos incrementó la efectividad de predicción, reduciendo a su vez la capacidad computacional requerida durante la ejecución de las iteraciones.

Palabras clave: bosques de manglar, covarianza de remolinos, medición de flujos de energía, modelo de caja gris, modelo de caja negra, redes neuronales artificiales.

Abstract

Mangrove ecosystems provide multiple benefits within the social and economic sector, including through the fixation of CO₂ due to the high figures of net primary production that they possess. Considering the significance of these ecosystems, the aim was to increase studies to help demonstrate their importance through the use of mathematical models that allow predicting energy flows considering the species *Avicennia bicolor*, using information available thanks to a flow measurement tower installed in the Bay of Panama. The treatment of the data that was used within the models was carried out, where one of them was based on the analogy of Ohm's law, and the other on prediction through the application of neural networks. A correlation was made between the available meteorological variables and the energy fluxes calculated using the Eddy Covariance method, where significant correlations were obtained between the sensible heat with the short waves of radiation ($R= 0.90$) and the heat flux in the ground ($R= 0.80$). The analogy of Ohm's law was used to estimate the water potential in the air for two days ($R= 0.37$ and $R= 0.43$), while the neural networks were able to predict the flow of LE ($R^2 > 0.91$), H ($R^2 > 0.86$), FC ($R^2 > 0.88$) and the potential of the air ($R^2 > 0.88$) in a satisfactory way. The previous treatment of the data in both models increased the prediction effectiveness, while reducing the computational capacity required during the execution of the iterations.

Keywords: mangrove forest, eddy covariance, energy flow measurement, gray box model, black box model, artificial neural networks.

Capítulo 1: Introducción

Concentración de CO₂ en la Atmósfera.

El incremento en las concentraciones de dióxido de carbono (CO₂) en la atmósfera ha despertado el interés de la comunidad científica por encontrar formas de contrarrestar su producción y acelerar el proceso de fijación, debido a que representa uno de los principales gases de efecto invernadero que estimula al incremento de la temperatura del planeta. Este incremento en la temperatura propicia el cambio climático y también ocasiona el derretimiento de zonas denominadas permafrost, las cuales almacenan grandes cantidades de CO₂ y metano que posteriormente son emitidos a la atmósfera (Castro, 2019).

El medio ambiente posee métodos bastante efectivos para la fijación de CO₂, dentro de los cuales se encuentran dos grandes reservorios: el mar y la biósfera, con la capacidad de almacenar hasta el 50% de las emisiones anuales (Siegenthaler & Sarmiento, 1993). Este incremento en la concentración del CO₂ en la atmósfera empezó a ser más evidente luego de comparar el comportamiento que existía antes y después de la época preindustrial (alrededor de los años 1800), debido a la utilización de combustibles fósiles y cambios en el uso del suelo (Figura 1) (Keeling et al., 1995).

La biósfera está caracterizada por la fijación de CO_2 mediante la vegetación, la cual utiliza el CO_2 para sus procesos físicos de crecimiento y mantenimiento, almacenando el carbono en su biomasa (Ray et al., 2011). En los árboles, el CO_2 es captado mediante el proceso de fotosíntesis necesario para crear la glucosa que será utilizada durante los procesos de regeneración y crecimiento, transportándose a través del floema para la distribución en toda la estructura de la planta (Mosquera-Sánchez et al., 1999).

Estado del Arte

Los árboles tienen la capacidad de adaptarse al medio en que se encuentran para poder sobrevivir, contribuyendo al ciclo global del carbón al fijarlo tanto en el suelo como en su estructura (Alongi, 2012; Sjögersten et al., 2014, 2021). Esta capacidad de fijación puede variar dependiendo de las condiciones del suelo en donde esté el árbol (contenido de agua, actividad microbiana, nutrientes, etc.), donde los manglares pueden fijar aproximadamente tres veces más carbono que los bosques tropicales por hectárea (Lefevre et al., 2017; Velázquez-Pérez et al., 2019), incrementando el interés por invertir en proyectos para aumentar la presencia de manglares en las costas (Alongi, 2014).

Las condiciones en las que se desarrollan los manglares no solo permiten la fijación de carbono, sino que también resulta ser una fuente de emisión de gases de efecto invernadero como el dióxido de carbono (CO_2), metano (CH_4) y óxido nitroso (N_2O) debido a la descomposición de las hojas, ramas y raíces disponibles en el suelo (Hoyos-Santillan et al., 2015, 2019; Mauricio Betancourt-Portela et al., 2013). Esta producción de gases puede estar relacionada con la presencia de oxígeno en la turba, donde la producción de CH_4 y CO_2 se incrementa notablemente en condiciones anóxicas (Hoyos-Santillan et al., 2016).

Múltiples análisis arbóreos se han estado realizando para entender sus procesos y la importancia que tiene cada parámetro en su desarrollo (Mazda & Wolanski, 2009), como es el caso de (Ishida et al., 1992) y (Edwards et al., 1986), quienes estructuraron modelos hidrológicos sobre el flujo de agua en árboles. (Colombo et al., 2007) presenta un estudio en Venezuela sobre dos especies de la familia *Calotropis*, *Procera* y *Gigantea*, que buscaba comprender y comparar sus características ecofisiológicas (estado del agua, intercambio de gases y anatomía foliar), mientras que (Carrasco, 2018) presentó un trabajo completo sobre el transporte de agua en plantas ubicadas en el norte de Argentina, por su parte, realizó un modelo dinámico para el flujo de agua en árboles de bosque tropical.

Los manglares desarrollaron la capacidad de adaptarse a los suelos poco firmes y saturados de las costas, donde se pueden encontrar una mezcla de salinidad y sedimentos debido al intercambio de agua entre el mar y las desembocaduras de los ríos (FAO, 2007). Algunas de las adaptaciones morfológicas consisten en el desarrollo de glándulas para expulsar el exceso de sal en su sistema hídrico, raíces capaces de mejorar el proceso de filtrado de la sal disuelta en el agua, raíces aéreas y abundantes que les permiten fijarse mejor al suelo blando de las costas, así como el desprendimiento de las semillas una vez esté madura y lista para establecerse en el suelo. Estas adaptaciones son características de ciertas especies de manglar (Rodríguez-Rodríguez et al., 2016; Uddin Farooqui & B. S. Dangi, 2017).

Debido a las características físicas como sus abundantes raíces y sus hojas, los manglares logran proteger las costas de fuertes vientos y oleajes, evitando inundaciones por la capacidad de absorción que poseen (FAO, 2007). En la investigación realizada por (Das & Crépin, 2013), se demostró mediante un modelo matemático que los manglares tienen una influencia en la atenuación de vientos ciclónicos, utilizando datos de un ciclón que azotó en 1999 las costas de la

región de Odisha en la India. El modelo logró predecir razonablemente los daños que se tendrían con la presencia de los manglares, los cuales eran mucho menores en comparación a lo ocurrido. Las características físicas de las zonas de manglar como la abundancia de raíces y suelos poco estables dificultan la presencia de humanos y de ciertos animales, beneficiando a especies marinas y terrestres (algunas en peligro de extinción) que pueden pasar sus etapas de crecimiento sin la presencia de sus principales depredadores (Domínguez & Martínez, 2019). También han sido fuente de recursos durante muchos años, tanto para satisfacer las necesidades de los pobladores, así como para la comercialización de productos, donde es posible encontrar zonas adaptadas para la producción de combustibles (leña y carbón), cría de especies marinas como peces, crustáceos y moluscos, construcción de botes y muchos otros productos (FAO, 2007; Jiménez, 1999). El manejo descontrolado de estas actividades afecta directamente la salud de estas zonas, modificando las concentraciones de nutrientes en el suelo, así como la reducción del caudal de agua que originalmente tenían las afluentes influyendo en la salinidad del suelo y por ende en las especies que se encontraban en esta región (Hoyos et al., 2013).

Dentro de los análisis más desarrollados en los bosques de manglar se encuentran las estimaciones de carbono fijado en su biomasa. Estos estudios realizan la estimación basada en ecuaciones alométricas las cuales utilizan mediciones físicas características de las especies, para obtener el valor del carbono fijado en la biomasa aérea (tronco, ramas y hojas) y subterránea (raíces). Dentro de las principales variables a determinar en estos estudios están el diámetro a la altura del pecho (DBH), la altura del árbol y la densidad de la madera (especie).

Algunos trabajos que utilizan ecuaciones alométricas se observan en la Tabla 1 (Brooks et al., 2021). Estos estudios fueron desarrollados en países como: Australia, Brasil, Colombia, Estados Unidos, India, Malasia, Nigeria, Qatar y Vietnam.

Tabla 1 Ecuaciones alométricas para la determinación de la biomasa aérea.

Autor	Ecuación		Especies	T (°C)	PM (mm y ⁻¹)
(Mohd Zaki et al., 2016)	$AGB = \exp[-1.803 - 0.976 \cdot E + 0.967 \cdot \ln(\rho_e) + 2.673 \cdot \ln(DBH) - 0.0299 \cdot [\ln(DBH)^2]]$	(1)	L.t.t.s.	22.9 -27.7	2178
(da Motta Portillo et al., 2017)	$AGB = 0.251 \cdot \rho_e \cdot DBH^{2.46}$	(2)	L.r. R.m. A.s.		1320
(Vinh et al., 2019)	$AGB = 0.38363 \cdot DBH^{2.2348}$	(3)	R.a.	27	1800
(Simpson et al., 2019)	$\ln(AGB) = 1.63 \cdot \ln(D_0) + 1.3545 \cdot \ln(H) - 2.8853$	(4)	L.r. A.g. R.m.	21 - 29	
(Chatting et al., 2020)	$\log(AGB) = 2.14 \cdot \log(CD) + 0.20$ $CD = 0.3831 \cdot DBH + 0.6863$	(5)	A.m.		54
(Kelleway et al., 2016)	$AGB = \frac{h \cdot [0.214 \cdot (DBH \cdot \pi) - 0.113]^2}{10}$	(6)	A.m.		1084
(Clough et al., 1997)	$Log(AGB) = A + (B \cdot Log(DBH))$	(7)	R.s. A.m.	35	1750
	$V = \frac{h}{6} \cdot (A_{ba} + 4 \cdot A_m + A_t)$	(8)			
(Prasanna et al., 2017)	$L_{db} = \sum_{j=1}^i n_j \cdot Lw_j \cdot N_j$	(9)	A.m.	28 - 34.2	
	$B_{db} = \sum_{j=1}^i n_j \cdot bw_j$	(10)			

Donde L.T.T.S. (árboles tropicales de tierras bajas), L.r. (*Laguncularia racemosa*), R.a. (*Rhizophora apiculata*), A.g. (*Avicennia germinans*), R.m. (*Rhizophora mangle*), A.s. (*Avicennia schaueriana*), A.m. (*Avicennia marina*), R.s. (*Rhizophora stylosa*) y PM (precipitación media anual). Adaptado de “A Critical Review on Mathematical Descriptions to Study Flux Processes and Environmental-Related Interactions of Mangroves” (p. 5), por J. Brooks, 2021, Sustainability, 13 (12).

Jiménez analizó un bosque seco tropical de Costa Rica, caracterizado por la presencia de la especie de manglar *Avicennia Bicolor*, con el objetivo de contabilizar la población e identificar la influencia que tenía las condiciones climáticas del área (salinidad, disponibilidad de agua, etc.) en el crecimiento y mortalidad de la especie (Jiménez, 1990; Jiménez & Sauter, 1991).

(Guzmán et al., 2005) realizaron un levantamiento de información sobre las zonas de manglar, arrecifes y pastos marinos en Bocas del Toro, Panamá, para lograr disponer de información sobre el estado en que se encontraban estas áreas debido a la contaminación, deforestación e intervención del ser humano. Para los arrecifes de coral se encontraron 63 especies de esponjas y 92 de corales. En los pastos marinos se presentaron cuatro especies de algas marinas (*Thalassia testudinum*, *Syringodium filiforme*, *Halodule beaudettei* y *Halophila decipiens*), mientras que la población de manglar dominante correspondió a la *Rhizophora mangle*, presentando mediciones en la altura, área basal, biomasa total, entre otros. Para (Lovelock et al., 2005), la abundancia de la especie *Rhizophora mangle* se debe a que la capacidad para sobrevivir a suelos inundados es mayor en comparación a la *Avicennia germinans*, condición ambiental que pudo haber sido consecuencia de la actividad tectónica. La estimación de biomasa para los bosques analizados en Bocas del Toro fue de 8-194 Mg ha⁻¹.

(McGowan et al., 2010) obtuvieron información en islas del Archipiélago de Las Perlas, contabilizando los árboles de manglar, considerando la especie, altura y diámetro a la altura del pecho. En Isla del Rey se analizaron dos ubicaciones donde predominaron la *Laguncularia racemosa* y la *Pelliciera rhizophorae*, mientras que en la Isla San José predominó la *Rhizophora mangle*.

Mediciones en diferentes puntos del río Coco Solo en la provincia de Colón fueron desarrolladas con el objetivo de conocer en impacto que podían tener las zonas de manglar en cuanto a la

amortiguación en la calidad del agua debido a las actividades humanas. Nutrientes como el amoníaco, nitrato, fosfato y nitrito tenían un valor mucho más alto en las áreas perturbadas por el humano, pero se iban reduciendo a medida que recorrían las áreas de manglar, lo que indica que poseen la capacidad de mejorar o estabilizar las condiciones del agua que será descargada al océano (Lin & Dushoff, 2004).

Otro estudio para la determinación de contaminantes (metales pesados) fue desarrollado en la bahía de Punta Mala (*Laguncularia racemosa*), donde se obtuvieron concentraciones de manganeso, cobre, zinc, níquel, plomo, hierro, cromo y cadmio, comparándolos con valores de países de la región como Colombia, Brasil, Costa Rica, así como Australia y Hong Kong. Se recolectaron muestras del suelo de forma aleatoria y también hojas de los árboles que se encontraban dentro de la parcela de análisis las cuales fueron limpiadas y secadas al igual que las muestras de sedimentos, para luego enviarlas a Reino Unido para el correspondiente análisis. El metal más abundante según los resultados en los sedimentos fue el hierro (9827 ppm) seguido por el manganeso (295 ppm), valores para el hierro relativamente altos en comparación a dos zonas en Costa Rica (3225 ppm y 6118 ppm), pero bajos si se comparan con la Ciénaga Grande en Colombia (15593 ppm). Para las hojas se obtuvo mediciones para el zinc, cobre y plomo, comparándose con datos de cuatro puntos de Australia, obteniendo para el zinc 35.80 ppm vs 35.50 ppm, cobre 3.70 ppm vs 24.80 ppm y para el plomo 6.20 ppm vs 3.90 ppm (Defew et al., 2005).

La zona de la bahía de Punta Mala también fue objeto de estudio para el cambio en extensión del bosque entre los años 1980 al 2002 mediante la utilización de imágenes aéreas y el Sistema de Información Geográfica (GIS, por sus siglas en inglés). Se logra observar la reducción del

bosque debido a la construcción de sistemas de tratamiento de agua y carreteras (Benfield et al., 2005).

Dependiendo de la información que se disponga sobre un proceso, es posible modelarlo mediante el desarrollo de ecuaciones diferenciales en modelos de Caja Blanca, Caja Gris y Caja Negra. Cuando se habla de modelos de Caja Blanca consisten en la relación de todas las variables conocidas y relevantes, con resultados en ecuaciones diferenciales algebraicas o en variables de estado (Cardona et al., 2020). Los modelos de Caja Gris están conformados por modelos de Caja Blanca que poseen cierto nivel de complejidad, así como partes de modelos de Caja Negra por lo cual podría recibir diferentes clasificaciones dependiendo de la complejidad del fenómeno analizado (Ljung, 2010). Resulta ser muy utilizado para el desarrollo de modelos no lineales, con trabajos aplicados en el área de acondicionamientos de espacios (Afram & Janabi-Sharifi, 2015; Berthou et al., 2014; Brastein et al., 2018; Reynders et al., 2014), procesos dentro de plantas industriales (García-González & González-Santos, 2020), etc. En los modelos de caja negra se realiza una representación matemática que no toma en cuenta los procesos desarrollados, se basan normalmente en mediciones realizadas (modelos totalmente empíricos) presentadas mediante ecuaciones de regresión (Stella & Warner, 2018). No es necesario el conocer las relaciones entre las variables que conforman el objeto de estudio, en comparación a los modelos de caja blanca, lo que resulta en una ecuación mucho más simple al trabajar con modelos de caja negra.

Motivación

La estimación de la cantidad de CO₂ fijada en los bosques de manglar, así como la tasa de transpiración, son valores que a menudo se obtienen de forma general mediante la instalación de costosas torres de medición las cuales requieren de mucha inversión de tiempo y recursos para su

respectivo mantenimiento debido a las condiciones en las que deben ser instaladas. Estos valores captados pertenecen al bosque en general, no es posible conocer la contribución de cada especie existente al valor final por lo que se pierde información evitando profundizar más en cuanto a las condiciones del propio bosque.

Desarrollando un modelo matemático permitiría estimar la contribución de la especie en cuanto a las variables deseadas, sin la necesidad de instalar sofisticadas torres de flujo en el área de estudio. Se reducen las variables que deben ser medidas en campo y al mismo tiempo se protege más al personal de estar mucho tiempo expuesto a los riesgos presentes en estas zonas. Con esto, se realiza una contribución a la comunidad científica enfocada en el estudio de las zonas de manglar en cualquier parte del mundo.

Una vez se encuentre validado el modelo, será posible el realizar las respectivas estimaciones utilizando las variables climáticas del área de estudio, así como algunas variables de las especies de árboles existentes, brindando información complementaria a los estudios de flujos de energía en los bosques de manglar.

Justificación

El estado del arte realizado muestra que actualmente se encuentran múltiples trabajos enfocados a la retención del carbono en las plantas, realizando estimaciones basadas principalmente en ecuaciones alométricas utilizando mediciones físicas para estimar el carbono en la biomasa, pero pocos analizan puntualmente en intercambio de gases que existe mediante la realización de la fotosíntesis. Analizar dicho intercambio puede indicarte la cantidad de CO₂ que el árbol podría estar retirando de la atmósfera durante un periodo de tiempo, así como el vapor de agua generado por sus procesos biológicos. Estas estimaciones encontradas mediante la realización de

simulaciones pueden ser verificadas individualmente mediante equipos que determinan las tasas de intercambio de gases en una hoja.

Se selecciona a la especie de manglar *Avicennia bicolor* por ser una de las especies presentes en el área de estudio, además de estar clasificada como especie vulnerable/amenazada en la lista roja de la UICN en los manglares panameños incluyendo a al mangle Piñuelo (*Pelliciera rhizophorae*) (Duke, 2010).

Conociendo el comportamiento de esta especie, se tendría como trabajo a futuro, determinar el impacto que tendría el reforestar las costas que se han visto afectadas drásticamente con el paso del tiempo debido a la mala planificación de obras comerciales, poniendo en peligro a muchas especies en peligro de extinción, así como la vida marina, influyendo a mediano y largo plazo en la economía del país (FAO, 2007). El comprender el comportamiento de los árboles de manglar permite cada vez más el conocer la importancia que tienen, promoviendo la formulación y ejecución de nuevos proyectos gubernamentales para la protección y valoración de estas áreas a nivel nacional e internacional como reservorios naturales de CO₂.

La generación del modelo con sus respectivos resultados puede también beneficiar a los proyectos FID2016-30 y FIED2021-18, financiados por la Secretaría Nacional de Ciencias Tecnología e Innovación (SENACYT), que se encuentra realizando estudios en manglares ubicados en la bahía de Panamá, específicamente en las coordenadas geográficas 9°00'51.82" N 79°27'10.60" W (Figura 2), gracias a la existencia de una torre de medición de gases que posee sensores capaces de detectar la concentración de dióxido de carbono, vapor de agua, temperatura, entre otras variables climáticas (González et al., 2020).

Figura 2 *Ubicación del área seleccionada para el estudio*



Con la ayuda del Centro de Investigaciones Hidráulicas e Hidrotécnicas (CIHH) se tuvo acceso a las áreas en donde se desarrolla el proyecto FID2016-30 en la bahía de Panamá para la recolección de la información necesaria para el desarrollo del modelo de la especie de manglar *Avicennia bicolor*.

Objetivo General

- Desarrollar un modelo matemático que permita estudiar el comportamiento de la especie de manglar *Avicennia bicolor* para estimar flujos de energía.

Objetivos Específicos

- Revisar el estado del arte sobre modelos matemáticos aplicados en árboles.
- Determinar las variables que influyen en el comportamiento de los manglares.
- Analizar la data disponible sobre las variables más influyentes en los manglares.
- Realizar un modelo matemático que permita estimar los flujos de CO₂ y/o vapor de agua de la especie de manglar *Avicennia bicolor*.

Planteamiento del Problema

Los estudios existentes poseen mayor enfoque en las estimaciones de retención de carbono en las diferentes estructuras de los árboles, dejando a un lado la determinación de la rata de captación del CO₂ mediante el desarrollo de los procesos biológicos del árbol.

Cambiar el enfoque de “cuánto carbono logró fijar” a “cuánto carbono fijará en un periodo de tiempo” resulta ser mucho más beneficioso para la realización de proyectos a mediano y largo plazo, debido a que es posible realizar una estimación de cuántos árboles deben ser necesarios en una zona para lograr fijar una cantidad específica de CO₂ en un plazo de tiempo estipulado. Dicho cambio de enfoque permite ver con claridad la importancia que representan estas zonas respecto a las altas concentraciones de CO₂ en la atmósfera.

La confiabilidad de las mediciones recolectadas por la torre de flujo dependerá mucho de las condiciones del terreno (altura de los árboles, homogeneidad de la especie, pendiente del terreno inferior al 3%), estas condiciones no siempre se cumplen por lo que se opta por realizar modificaciones al momento de instalar los sensores para aumentar la veracidad de las mediciones (Serrano-Ortiz P, 2006). Si las estimaciones se realizan tomando en cuenta la cantidad de especies, se elimina el margen de error producido por las condiciones del terreno.

Se desarrolla una búsqueda de las ecuaciones y variables más influyentes en los procesos biológicos de la planta, junto con el uso de ecuaciones fundamentales. Para la realización del modelo de Caja Gris se procede a transformar las ecuaciones diferenciales ordinarias en variables de estado para ser introducidas en un código desarrollado en el software Matlab, utilizando valores iniciales y finales basados en data presente en la literatura, así como mediciones obtenidas por la torre de flujo.

Capítulo 2: Marco Teórico

Flujo de Agua en Árboles

La estructura de los árboles está desarrollada para absorber agua y nutrientes desde el suelo mediante sus raíces, hasta las hojas. Los conductos encargados de dicha distribución son el xilema y el floema, transportando el agua y los nutrientes desde el suelo a las raíces, y luego la sabia elaborada desde las hojas al resto del árbol respectivamente (Hölttä et al., 2006; Stroock et al., 2014). Dentro de estos sistemas es posible encontrar variables como los potenciales hídricos, resistencias, conductividad hidráulica, contenido de agua, entre otros.

El flujo de agua dentro del árbol comúnmente se explica mediante la Teoría de la Cohesión-Tensión, donde el agua es transportada desde el suelo hacia las hojas debido a la diferencia de potencial de agua existente entre la raíz y el aire que interactúa con las hojas (Edwards et al., 1986; Juárez, 2009; J. S. Sperry et al., 1998). Se utiliza el Potencial hídrico o el Potencial de agua (ψ) para expresar la capacidad de movimiento de las moléculas de agua (energía libre) dentro de un sistema, expresado en unidades de presión. Esta diferencia de presión podría tener valores de -50 MPa en el aire y -0.05 MPa en las raíces (Juárez, 2009; Stroock et al., 2014).

La interacción entre el agua dentro del árbol y el aire en el exterior ocurre gracias al proceso de transpiración, donde se pierde el agua en forma de vapor cuando ocurre la fotosíntesis en las hojas (Edwards et al., 1986). Durante el proceso de fotosíntesis, se obtiene CO_2 de la atmósfera y agua del árbol para generar la glucosa que será utilizada en el proceso de respiración, en donde se genera la enzima ATP utilizada para el crecimiento y mantenimiento de la estructura, como se presenta en las siguientes ecuaciones químicas (Gómez et al., 2001; Jones, 2013; Mosquera-Sánchez et al., 1999):

Fotosíntesis:



Respiración:



Dentro de los procesos que participan en el intercambio de masa y energía se encuentran la fotosíntesis, respiración y transpiración del árbol. Como se definió anteriormente, la transpiración se encuentra ligada con la fotosíntesis para encontrar el ajuste necesario para obtener CO_2 sin comprometer el sistema hídrico de la planta, generando la glucosa que participará dentro de la respiración celular. Las hojas respiran todo el día, pero a medida que empieza a disminuir la radiación, el oxígeno generado por la fotosíntesis empieza a ser consumido por el proceso de respiración. Debido a este comportamiento, es común el despreciar el consumo de oxígeno durante el día y enfocarse solamente en la fotosíntesis, para luego considerar la respiración de la planta durante la noche (Vogel, 2018).

Dependiendo de las condiciones en las que se encuentre la planta, necesitará regular la capacidad de transpiración para mantener agua necesaria para sus procesos, y al mismo tiempo proteger su sistema hidráulico, evitando el estrés hídrico (J. Sperry, 2000). Cuando no existe suficiente agua en el sistema hídrico, ya sea por falta en las raíces o un exceso de transpiración, se pueden crear burbujas en los conductos ocasionando cavitación o embolia, afectando el potencial hídrico del xilema y amenazando la supervivencia de la planta (Stroock et al., 2014). Para evitar problemas de ausencia de agua, las plantas reducen su conductancia estomática, cerrando los estomas, sacrificando el potencial fotosintético pero evitando daños en sus células (J. S. Sperry et al., 1998).

Para representar el sistema suelo-planta-atmósfera, se ha aplicado la analogía de la Ley de Ohm, considerando los potenciales hídricos disponibles a lo largo de la estructura, así como las resistencias que pueden influir en el transporte de agua (Tyree & Ewers, 1991). Dicha analogía

no es recomendada por (Kumagai, 2001) quien sostiene que el método se aleja demasiado de la realidad al suponer estado estacionario, así como un valor constante para las resistencias que presenta el flujo internamente.

Para efectos prácticos, en campo se utilizan equipos que miden la evapotranspiración de la plantación, lo cual consiste en la unificación de la transpiración generada por el árbol y la evaporación de agua desde el suelo (FAO, 2011).

Modelos Matemáticos Analizados

(Früh & Kurth, 1999) estructuraron un problema de valor límite inicial discreto, mezclando conceptos sobre el flujo de Darcy, almacenamiento de agua y pérdidas de conductividad en la red hidráulica debido a ciertas deficiencias encontradas en los trabajos de (Tyree & Sperry, 1988) como la ausencia de almacenamiento de agua, o (Tyree & Ewers, 1991) que no calcula pérdidas de conductividad durante el transporte de agua.

Para la determinación del potencial de agua (Ψ) utilizaron la Ecuación 13:

$$\Psi = P + \rho_{H_2O} g z \quad (13)$$

Donde P es la presión hidrostática (Pa), ρ_{H_2O} es la densidad del agua, g la aceleración gravitacional y z la altura sobre el nivel de referencia. Relacionaron el gradiente del potencial hídrico y el caudal mediante la ley de Darcy debido a que el xilema puede ser representado como un medio poroso (Fiscus et al., 1983; Stroock et al., 2014):

$$F = \hat{K} \frac{\partial \Psi}{\partial x} \quad (14)$$

Donde \hat{K} es la conductividad hidráulica por longitud (conductividad axial) ($kg s^{-1} MPa^{-1} m$).

Para cuantificar la capacidad del organismo de almacenar o liberar agua, se asumen cambios isotérmicos en el potencial de agua, obteniendo la capacitancia hidráulica ($kg dm^{-3} MPa^{-1}$) definida por:

$$c(P) = \frac{\partial \theta}{\partial \Psi} \quad (15)$$

Donde θ es el contenido de agua. El autor asume que, dentro de los segmentos del eje, la capacitancia y la conductividad axial son homogéneas. Aplicando la conservación de masa en la ecuación unidimensional se obtiene la Ecuación 16:

$$\frac{\partial f}{\partial x} = \frac{\partial \theta}{\partial t} \quad (16)$$

Donde f es la densidad del flujo y solo es aplicable para secciones que permanezcan constantes. Introduciendo la Ecuación 14 y la Ecuación 15 en la Ecuación 16, y añadiendo un término para la transpiración, se obtiene:

$$\frac{\partial f}{\partial x} \left[K(x, P) \frac{\partial \Psi}{\partial x} \right] = c(x, P) \frac{\partial \Psi}{\partial t} + E(t) l(x) \quad (17)$$

Donde K es la conductancia hidráulica, $E(t)$ la densidad del flujo de transpiración y $l(x)$ el área foliar local.

También se encuentra el trabajo desarrollado por (Richter et al., 2013) enfocado en determinar la capacidad que tenían los árboles de manglar en la captación de contaminantes metálicos y orgánicos presentes en las afluentes, utilizando como variables de estado para su modelo el potencial hídrico, concentración de contaminantes, raíces, xilema, núcleo y dosel. Estas ecuaciones generales se presentan a continuación:

$$C_i(\psi_i) \frac{\partial \psi_i}{\partial t} = \nabla \cdot K_i(\psi_i) \nabla(\psi_i - z) \quad (18)$$

$$\frac{\partial(\theta_i c_{li})}{\partial t} = \nabla \cdot (\bar{D}_i \nabla c_{li} - \vec{q}_i c_{li}) - k_{des,i} (K_{di} c_{li} - c_{si}) \quad (19)$$

$$\frac{\partial}{\partial t} c_{si} = k_{des,i} (K_{di} c_{li} - c_{si}) \quad (20)$$

Donde la Ecuación 18 es utilizada para el transporte de agua, la Ecuación 19 para la presencia de contaminantes, siendo complementada con la Ecuación 20. Dentro de las variables utilizadas se encuentra el potencial de agua (ψ_i), la función capacitiva (C_i), el contenido de agua (θ_i), concentración de sólidos y líquidos (c_{si} , c_{li} respectivamente), conductancia hidráulica (K_i), tensor de dispersión (\bar{D}_i), velocidad de Darcy (\vec{q}_i), coeficiente de partición ($K_{d,i}$) y una constante de velocidad para la desorción ($K_{des,i}$).

(Kumagai, 2001) utilizó un modelo que combinaba un modelo de conductancia estomática con el concepto de mecánica de fluidos para el transporte y almacenamiento de agua, utilizando ecuaciones de difusividad no estacionaria basadas en el flujo volumétrico, desfase de tiempo entre corriente de transpiración y absorción, así como el gradiente de presión (Ecuación 21).

$$\left[\int_z^{z+\Delta z} S_p(z) dz \right] C_p \frac{\partial \psi_p}{\partial t} = \frac{\partial q}{\partial z} \Delta z - Q(z) \quad (21)$$

Donde z es la altura desde la superficie de agua (m), t el tiempo (s), ψ_p el potencial de agua (m), $S_p(z)$ el área de sección transversal del tallo a la altura z (m^2), C_p la capacitancia (m^{-1}), q el flujo ($m^3 s^{-1}$) y $Q(z)$ flujo de sabia ($m^3 s^{-1}$).

(Jara-Rojas et al., 2009) presenta un modelo en donde relaciona la conductancia estomática de la hoja con la captación de CO_2 mediante la asimilación neta de CO_2 durante la fotosíntesis (Modelo $A_n - g_s$). Mostró que existen dos modelos que intentan predecir la captura de CO_2 mediante la conductancia estomática, pero que al final resultan poco fiables debido a la variabilidad física que existe en los estomas.

El modelo $A_n - g_s$ determinaba la conductancia estomática de la hoja mediante la Ecuación 22:

$$g_s = \frac{1.6 A}{C_s - C_i} \quad (22)$$

Donde A es la asimilación neta de CO_2 , C_s la concentración de CO_2 en el ambiente y C_i la concentración de CO_2 en la cavidad estomática, generada al utilizar la Ecuación 23:

$$C_i = f_0 \left(1 - \frac{D_s}{D_{max}}\right) C_s + \left(1 - f_0 \left(1 - \frac{D_s}{D_{max}}\right)\right) \Gamma \quad (23)$$

$$D_s = q * (T_s) - q_s \quad (24)$$

Donde f_0 es un factor acoplado cuando $D_s = 0$ (g/kg), D_s es el déficit de humedad específica entre la cavidad subestomática y la atmósfera. D_{max} es el valor máximo de humedad específica en saturación, q_s es la humedad específica de la atmósfera cerca de las hojas, mientras que $q * (T_s)$ es la humedad específica en saturación a la temperatura de la hoja T_s (°C). Γ es el punto de compensación de CO_2 ($\mu mm \text{ mol}^{-1}$).

La asimilación neta ($\mu mol \text{ m}^{-2} \text{ s}^{-1}$) mostrada en la ecuación 22 es estimada en el estudio mediante la Ecuación 25:

$$A = ((A_m + R_d) \left[1 - e^{\frac{-\varepsilon I_a F_c}{A_m + R_d}}\right] - R_d) F_{co2} \quad (25)$$

Donde A_m es la asimilación neta en función del CO_2 ($mg \text{ m}^{-2} \text{ s}^{-1}$), R_d es la respiración de la hoja ($mg \text{ m}^{-2} \text{ s}^{-1}$), I_a la radiación fotosintética activa (PAR) que alcanza a la hoja ($\mu mol \text{ m}^{-2} \text{ s}^{-1}$), ε es la eficiencia de uso cuántico inicial ($mg \text{ CO}_2 [J \text{ PAR}]^{-1}$), F_c es un factor de conversión entre el PAR y su asociación con la energía: $F_c = 0.22 J \text{ PAR } \mu mol^{-1}$ de acuerdo con la relación de 1 mol de fotones $\equiv 0.22 MJ \text{ PAR}$. F_{co2} es una conversión entre la unidad de masa y unidad molar de CO_2 ($22.727 \mu mol \text{ CO}_2 [g \text{ CO}_2]^{-1}$).

La asimilación neta en función del CO_2 se determina mediante la Ecuación 26:

$$A_m = A_{m \text{ max}} \left[1 - e^{\frac{-0.001 g_m (C_i - \Gamma) \Phi_{co2}}{A_{m \text{ max}}}}\right] \quad (26)$$

Donde $A_{m \text{ max}}$ es la asimilación neta máxima de CO_2 , g_m es la conductancia mesoflílica ($mm \text{ s}^{-1}$) y Φ_{co2} es un factor de conversión ($\Phi_{co2} = 1.799 mg \text{ CO}_2 \text{ m}^{-3} \text{ a } 25^\circ C \text{ y } 1 \text{ Atm}$).

La respiración de la hoja (R_d) y la eficiencia de uso cuántico inicial (ε) se determinan mediante la Ecuación 27 y la Ecuación 28 respectivamente:

$$R_d = A_m/9 \quad (27)$$

$$\varepsilon = \varepsilon_0 \frac{C_i - \Gamma}{C_i + 2\Gamma} \quad (28)$$

Donde ε_0 es el valor máximo de ε .

El trabajo realizado por (Jara-Rojas et al., 2009) utiliza muchos datos de otra investigación realizada por (Jacobs et al., 1996). La estructura principal de estas ecuaciones también fue utilizada por (Barr et al., 2009), con algunas modificaciones como se muestra en la Ecuación 29:

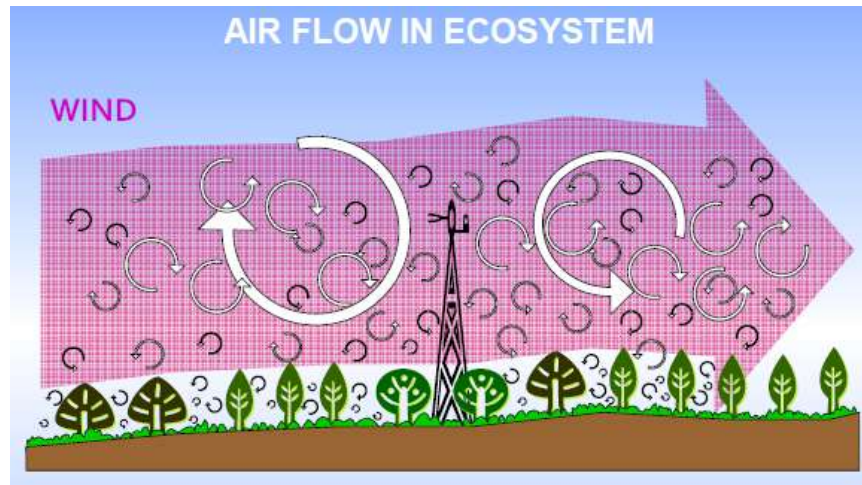
$$A_N = \frac{\alpha PAR}{1 + \left(\frac{\alpha}{A_m + R_d}\right) PAR} - R_d \quad (29)$$

Donde α es la eficiencia cuántica aparente relacionada con el aprovechamiento de la radiación.

Torre de Medición de Flujos

Las torres de medición de flujo de gases son utilizadas en campos abiertos, con la capacidad de registrar el intercambio de gases y/o energía entre la atmósfera y las parcelas a las que tiene alcance. El viento proveniente del exterior de la plantación recorre la zona bajo análisis (Footprint), mezclando sus condiciones gaseosas con las de la plantación (Figura 3), para luego ingresar a los diferentes equipos instalados en la torre que se encargarán de registrar las variaciones (Bayona & Romero, 2015; Burba & Anderson, 2008).

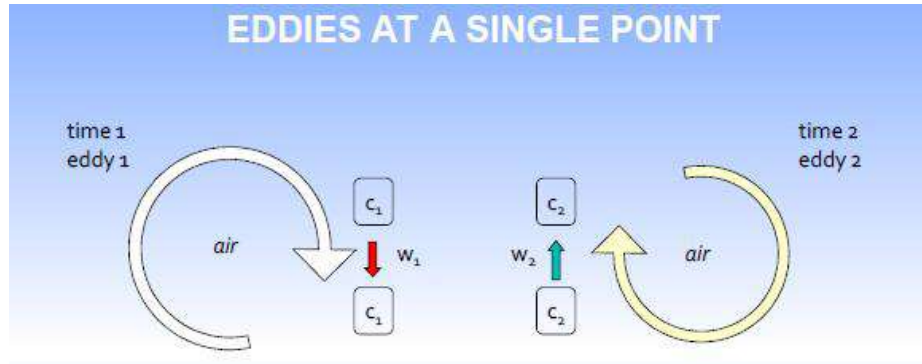
Figura 3 *Representación del flujo analizado por el método Covarianza de remolinos.*



Nota. Adaptado de A Brief Practical Guide to Eddy Covariance Flux Measurements (p. 16), por G. Burba and D. Anderson, 2008, LI-COR, Inc.

El concepto básico de covarianza de remolinos consiste en la suposición de que el desplazamiento horizontal del viento posee múltiples remolinos, los cuales aumentan al momento en que el viento tiene contacto con las plantaciones, turbulencia que aumenta o propicia el intercambio entre las condiciones del bosque y la atmósfera. Esta perturbación genera movimientos en diferentes direcciones, pero la utilizada para determinar el intercambio de gases recae sobre la componente vertical del viento. La componente vertical es analizada por cámaras que poseen los equipos instalados en la torre, realizando conteos sobre la cantidad de moléculas que suben y bajan dentro de estas cámaras (Figura 4), permitiendo visualizar durante un periodo de tiempo si la plantación funciona como un receptor o emisor de los gases analizados (Burba & Anderson, 2008; Jones, 2013).

Figura 4 *Proceso dentro de las cámaras de medición de gases.*



Nota. Adaptado de A Brief Practical Guide to Eddy Covariance Flux Measurements (p. 17), por G. Burba and D. Anderson, 2008, LI-COR, Inc.

Dentro de los equipos que comúnmente son instalados se encuentran: sensores de temperatura, viento, radiación, vapor de agua, CO₂, entre otros, procurando el monitoreo frecuente por parte del equipo técnico para asegurar un adecuado funcionamiento de estos sensores, así como la estructura principal de la torre (Bayona & Romero, 2015). Los sensores instalados en la torre de flujo y en el área de análisis se muestran en la Tabla 2.

Tabla 2 *Sensores instalados en el área bajo análisis.*

Sensor	Modelo
Monitor de viento	Young Model 05103V
Anemómetro Ultrasónico	Young Model 86106
Humedad del aire	Young Model 41382VC
Temperatura del aire	BetaTherm 100L6A1IA
Temperatura del suelo	Campbell HFP01SC-L
Flujo de Calor del suelo	Kipp & Zonen CNR 4
Radiómetro	LI-7500DS
Analizador de gas de ruta abierta CO ₂ /H ₂ O	LI-7200RS
Analizador de CO ₂ /H ₂ O Cerrado	

Las torres de medición de flujo de gases son utilizadas tanto para el ámbito investigativo, como para el monitoreo de plantaciones privadas (Marín et al., 2017; Ortiz et al., 2019; Zermeño-

González et al., 2010), con el objetivo de preservar la calidad de sus cultivos gracias al conocimiento que se tiene sobre las condiciones del área, indicándoles el momento y cantidad específica de riego para mejorar la eficiencia del proceso.

El movimiento del flujo vertical está fundamentado en la Ecuación 30:

$$F \approx \overline{\rho_a w' s'} \quad (30)$$

Donde $\overline{\rho_a}$ representa la densidad media del aire, $\overline{w' s'}$ la multiplicación de la covarianza media entre las desviaciones en la velocidad del viento vertical instantánea y la relación de mezcla.

Los equipos instalados suelen utilizar las siguientes ecuaciones (Burba & Anderson, 2008):

Flujo de calor sensible (H):

$$H = \rho_a C_p \overline{w' T'} \quad (31)$$

Donde se involucra al calor específico C_p para la conversión a energía, y la covarianza media de la desviación de la temperatura del viento vertical instantáneo T' .

Flujo de CO₂ (F_c):

$$F_c = \overline{w' \rho_c'} \quad (32)$$

Flujo de Calor Latente (LE) (Launiainen et al., 2005):

$$LE = L \rho_a \overline{w' e'} \quad (33)$$

Donde L es el calor latente de vaporización y e' la desviación en la presión de vapor.

Al momento de la instalación de una torre de flujo, es necesario conocer las dimensiones del Footprint deseado, para así determinar la posición y altura de la torre de flujo dentro de la zona de estudio. La homogeneidad del ecosistema y la altura de los árboles serán factores que deberán considerarse para determinar la altura de los diferentes sensores que serán instalados (Serrano-Ortiz P, 2006).

Proceso de Tratamiento de los Datos Recolectados.

La torre de flujo puede determinar la producción primaria bruta de gases del bosque, así como la respiración del ecosistema siempre y cuando posea los sensores necesarios. Una vez que se posee una base de datos de un tiempo especificado, se extrae la información para su respectivo procesamiento aplicando los siguientes pasos (CARBORED-II, 2010):

- a) Descomposición de multiresolución, o análisis de Ogive, para examinar la sensibilidad de la covarianza a la longitud del periodo en que se promedian los datos.
- b) Análisis de relleno de periodos con huecos de datos; análisis de los datos en busca de espacios en donde no se haya tenido registro de información por errores humanos o instrumentales.
- c) Cálculo del balance de carbono.
- d) Descomposición del balance neto de carbono del ecosistema en sus componentes principales, la productividad primaria bruta y la respiración del ecosistema.

Inteligencia Artificial y Aprendizaje Automático.

La inteligencia artificial hace referencia a la capacidad de una máquina de imitar las habilidades cognitivas del ser humano, siendo actualmente un campo muy amplio y con aplicaciones muy vastas (El Naqa & Murphy, 2015). Dentro de los subcampos de la inteligencia artificial está el aprendizaje automático, donde los algoritmos desarrollados adquieren conocimiento de un conjunto de datos, extrayendo patrones utilizados en el análisis predictivo con base al aprendizaje realizado (Columbia Engineering, n.d.; Goodfellow et al., 2016). Formalmente, el aprendizaje puede ser de la siguiente manera: Un programa se dice que aprende de cierta experiencia “E” con respecto a un conjunto de tareas “T” y una medida de desempeño “P”, si su desempeño en las tareas “T”, medido por “P”, mejora con la experiencia “E”. A continuación, se

describen los componentes principales que intervienen en el aprendizaje (Goodfellow et al., 2016):

- La tarea “T”: La tarea, predicción o inferencia que se quiere realizar con el aprendizaje automático, puede ser una clasificación, traducción, regresión, detección de anomalías, entre otros.
- La medida de desempeño “P”: es utilizada para evaluar la habilidad de un algoritmo de aprendizaje automático de realizar la tarea T. Para una tarea de clasificación, la medida de desempeño es la precisión, o la proporción de los ejemplos para los cuales el modelo genera la salida correcta.
- La experiencia “E”: se refiere al conjunto de datos, o el compendio de ejemplos. Según el tipo de experiencia que tenga el algoritmo de aprendizaje automático, este se caracteriza de dos maneras:
 - Aprendizaje no supervisado: el conjunto de datos que sirve de experiencia no está etiquetado. El algoritmo aprende las propiedades útiles de este conjunto de datos.
 - Aprendizaje supervisado: el conjunto de datos que sirve de experiencia contiene pares objetos, donde una componente son las entradas o características y a estas se les asocia su correspondiente valor deseado.

El aprendizaje se realiza con un conjunto de datos llamado conjunto de entrenamiento, donde se busca minimizar el error entre la salida predicha por el modelo y salida real, según lo indicado por el conjunto de datos de entrenamiento. Esto es en esencia un problema de optimización. Sin embargo, el objetivo del aprendizaje automático es que el desempeño del modelo sea bueno en un conjunto de datos nuevo, distinto al de entrenamiento denominado conjunto de prueba. Un

modelo capaz de desempeñarse de forma aceptable en un conjunto de datos de prueba se dice que es capaz de generalizar.

Relacionado a la capacidad de generalización de un modelo, existen dos desafíos esenciales en el aprendizaje automático: el *underfitting* y el *overfitting*. El *underfitting* ocurre cuando un modelo no es capaz de lograr un error lo suficientemente bajo en el conjunto de entrenamiento. El *overfitting* ocurre cuando la diferencia entre el error en el conjunto de entrenamiento y el error en el conjunto de prueba es muy alta. Cuando existe *underfitting* el modelo no es capaz de replicar el comportamiento del conjunto de entrenamiento, apuntando a que la hipótesis no tiene la suficiente capacidad para describir el sistema. Cuando existe *overfitting*, el modelo memoriza los ejemplos del conjunto de entrenamiento en vez de aprender la relación que existe entre las dos variables (Bashir et al., 2020).

Más allá de los parámetros que corresponden a la estructura paramétrica del modelo, en los algoritmos de aprendizaje automático a su vez se definen hiperparámetros, aquellos parámetros cuyo valor se utiliza para controlar el proceso de aprendizaje y determinan el valor de los parámetros del modelo (los pesos y el sesgo de la red neuronal) (Villalobos-Arias et al., 2021). Algunos hiperparámetros comunes son la división de datos de entrenamiento-validación-prueba, la tasa de aprendizaje del algoritmo de optimización, el algoritmo de optimización, la función de activación, la cantidad de capas escondidas, la cantidad de neuronas en la capa escondida, cantidad de iteraciones y épocas, tamaño de lote, entre otros.

Típicamente los hiperparámetros no son optimizados mediante el conjunto de datos de entrenamiento, aunque es posible utilizar algún procedimiento de aprendizaje para determinar los valores óptimos de los hiperparámetros de un algoritmo de aprendizaje automático. Para seleccionar los valores óptimos de los hiperparámetros se utiliza un tercer conjunto de datos,

denominado el conjunto de validación. Este conjunto puede ser tomado como un subconjunto del conjunto de datos de entrenamiento. Entonces, el conjunto de entrenamiento se utiliza para optimizar los parámetros y el error de generalización se determina probando el modelo con el conjunto de validación, ya sea durante o después del entrenamiento. El desempeño en el conjunto de validación mide qué tan buenos son los valores de los hiperparámetros y permite actualizarlos de forma acorde. Una vez se hayan optimizado los parámetros, el desempeño final del modelo se mide en el conjunto de prueba (Goodfellow et al., 2016).

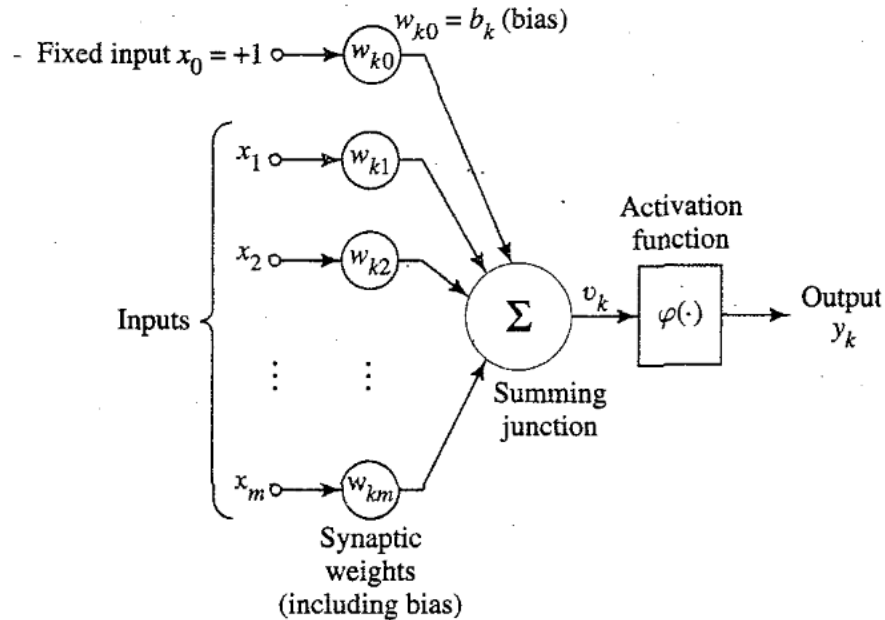
Redes Neuronales Artificiales

Dentro de los métodos de aprendizaje automático figuran las redes neuronales artificiales, modelos inspirados por el comportamiento del cerebro humano que consiste en un conjunto de unidades de procesamiento (neuronas) interconectadas. Las interconexiones tienen distintos pesos utilizados para almacenar el conocimiento adquirido a través de algún proceso de aprendizaje. Entre los métodos de aprendizaje utilizados en el entrenamiento de redes neuronales están descenso de gradiente, Levenberg - Marquardt, etc. En esta investigación, la arquitectura de red utilizada es el perceptrón multicapa, también denominada Feedforward, consiste en múltiples capas en donde las conexiones entre unidades no forman un ciclo. El objetivo de la red neuronal es aproximar una función como la dada por la Ecuación 34. La función, dada por los parámetros θ determinados como óptimos durante el entrenamiento, procesa las entradas x , para obtener la salida y (Goodfellow et al., 2016; Haykin, 1999).

$$y = f(x; \theta) \tag{34}$$

La neurona es la unidad de procesamiento fundamental para la operación de una red neuronal. El diagrama de bloques de la Figura 5 muestra el modelo no lineal de una neurona.

Figura 5 Esquema de un modelo no lineal de una neurona



Nota. Adaptado de Neural Networks: A Comprehensive Foundation (p. 35), por Simon Haykin, 1999, Prentice Hall.

Los elementos principales de la neurona son (Haykin, 1999):

- Las sinapsis o conexiones, cada una caracterizada por un peso. Cada entrada x_j de una neurona k está multiplicada por un peso w_{kj} . Los pesos son parámetros optimizados por el algoritmo de aprendizaje automático.
- El punto suma, el cual realiza la adición de las señales de entrada multiplicadas por sus pesos.
- La función de activación, la cual puede ser lineal o no lineal, y es utilizada para controlar la salida de la neurona.
- Sesgo, parámetro utilizado para desplazar la función de activación.

La operación matemática realizada por la neurona se resume en la Ecuación 35 y la Ecuación 36.

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (35)$$

$$y_k = \varphi (v_k) \quad (36)$$

La interconexión de las neuronas forma lo que se denomina una red (red neuronal), donde pueden ser organizadas en forma de capas. Si en una capa i se aproxima una función $f(i)$, entonces, para una red con tres capas, la salida de la red neuronal estará dada por la estructura en cadena (Goodfellow et al., 2016):

$$y = f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x))) \quad (37)$$


La longitud de esta cadena es lo que determina la profundidad de la red neuronal.

Capítulo 3: Metodología

Dominios Propuestos y sus Interacciones

Seleccionando la hoja como un dominio por analizar, se observa una serie de intercambios energéticos-gaseosos entre el interior del árbol y la atmósfera (Figura 6). Si lo que se busca es conocer la participación que tiene el árbol en el medio, entonces se empieza a analizar los procesos biológicos que generan entradas y salidas del sistema.

Figura 6 Intercambio de masa y energía a nivel de la hoja.



Para analizar el intercambio energético entre las plantaciones y la atmósfera, se ha propuesto el uso de la Ecuación 38 (FAO, 2011; Jones, 2013):

$$R_n - G - \lambda ET - H = 0 \quad (38)$$

Donde R_n representa la radiación neta que recibe la plantación, G el flujo de calor en el suelo, λET el calor latente y H el calor sensible, todos expresados en términos de energía ($MJ m^{-2} día^{-1}$). El término de calor latente puede ser expresado en términos del contenido de humedad relativa del medio, mientras que el calor sensible puede ser representado mediante la ecuación básica de transferencia de calor por convección:

$$H = h_c A (T_{ex} - T_s) \quad (39)$$

Con el coeficiente de transferencia de calor (h_c), área de transferencia de calor (A) y la diferencia de temperatura entre el exterior y la superficie (T_{ex}, T_s). No obstante, es posible determinar el calor sensible mediante el índice de área foliar (IAF) y las condiciones del medio circundante (Ecuación 40): densidad (ρ_{af}), calor específico (C_{pa}), coeficiente de transferencia general (C_f), velocidad del viento cerca del follaje (W_{af}) y la diferencia de temperatura entre la hoja (T_{hoja}) y el aire dentro del follaje (T_{af}) (Ávila Hernandez, 2019; Tovar Jiménez, 2018).

$$H = (1.1 \text{ IAF } \rho_{af} C_{pa} C_f W_{af}) (T_{af} - T_{hoja}) \quad (40)$$

Determinando las variables ρ_{af} , C_f , W_{af} y T_{af} mediante la Ecuación 41, Ecuación 42, Ecuación 43, Ecuación 44 y la Ecuación 45 respectivamente:

$$\rho_{af} = \frac{\rho_a + \rho_f}{2} \quad (41)$$

$$C_f = 0.01 \left(1 + \frac{0.3 (m/s)}{W_{af}(m/s)} \right) \quad (42)$$

$$\sigma_f = 0.9 - 0.7^{-0.75 \text{ IAF}} \quad (43)$$

$$W_{af} = 0.83 \sigma_f W \sqrt{C_{hn}^f} + (1 - \sigma_f) W \quad (44)$$

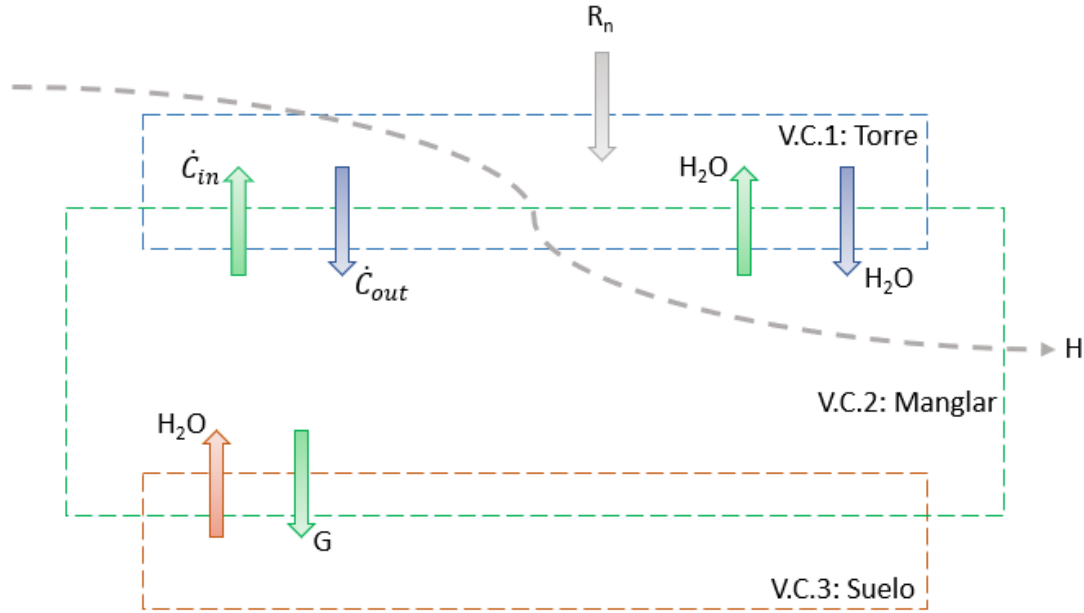
$$T_{af} = (1 - \sigma_f) T_a + \sigma_f (0.3 T_a + 0.6 T_f + 0.1 T_g) \quad (45)$$

Ecuaciones que involucran la densidad del aire a la temperatura ambiente y a la temperatura de la hoja (ρ_a, ρ_f), la velocidad del viento W , función que involucra el tipo de vegetación (σ_f), coeficiente de transferencia masiva C_{hn}^f y las temperaturas del aire, de la hoja y el suelo T_a , T_f y T_g respectivamente.

Ampliando el dominio de análisis, se encuentran tres secciones que pueden brindar información: suelo, árboles y atmósfera (torre de flujo) como se muestra en la Figura 7. De esta forma es posible comprender e identificar los diferentes intercambios que existen en el área de

investigación, desde la contribución de agua en el suelo hasta el intercambio de gases entre las hojas y el viento en contacto con la atmósfera.

Figura 7 *Interacción entre los dominios Suelo, Manglar y Atmósfera.*



Basado en la literatura, se conoce que el flujo de carbono medido por la torre está relacionado con la concentración del CO₂ en el ambiente (Ecuación 46), que incluiría un factor de corrección desconocido hasta el momento.

$$F_c = \alpha_1 C_r \quad (46)$$

Por lo que el cambio respecto al tiempo de esa concentración de CO₂ estaría representada por el intercambio que exista entre el manglar (V.C.2) y la atmósfera (V.C.1), junto con factores de corrección como se observa en la Ecuación 47:

$$\alpha_2 \frac{dC_r}{dt} = \alpha_3 \dot{C}_{in} - \alpha_4 \dot{C}_{out} \quad (47)$$

Donde \dot{C}_{in} estaría representando la respiración del bosque, mientras que \dot{C}_{out} el proceso de fotosíntesis tomando como punto de referencia la parte superior de la torre. Para el caso de la presencia de agua, se puede visualizar en la Figura 7 el recorrido desde el suelo hasta la

atmósfera mediante los procesos de evaporación y transpiración. Para conocer el almacenamiento de agua realizado por el manglar $\left(\frac{dm_{H_2O}}{dt}\Big|_{V.C.2}\right)$ se aplica conservación de masa, obteniendo:

$$\frac{dm_{H_2O}}{dt}\Big|_{V.C.2} = \dot{m}_{H_2O}\Big|_{V.C.3} - \dot{m}_{H_2O}\Big|_T - \dot{m}_{H_2O}\Big|_R \quad (48)$$

Donde $\dot{m}_{H_2O}\Big|_{V.C.3}$ es el flujo de agua que entra al árbol desde el suelo, $\dot{m}_{H_2O}\Big|_T$ y $\dot{m}_{H_2O}\Big|_R$ son los flujos de agua que participan en los procesos de transpiración y respiración respectivamente.

Para la determinación de la conductancia en la capa límite para el calor y el vapor (copa del árbol-atmósfera, g_{ha} mol/m²s) se utilizó la Ecuación 49 propuesta por (Campbell & Norman, 1977), donde se utilizan datos de campo como la velocidad de fricción (u^*), calor sensible (H), temperatura (T) y densidad molar del aire ($\hat{\rho}$).

$$g_{ha} = \frac{0.4^2 \hat{\rho} u(z)}{\left[\ln\left(\frac{z-d}{z_m}\right) + \Psi_M \right] \left[\ln\left(\frac{z-d}{z_H}\right) + \Psi_H \right]} \quad (49)$$

Donde:

$$u(z) = \frac{u^*}{0.4} \left[\ln\left(\frac{z-d}{z_m}\right) + \Psi_M \right] \quad (50)$$

$$\Psi_H = -2 \ln \left[\frac{1 + (1 - 16\xi)^{1/2}}{2} \right], \Psi_M = 0.6\Psi_H \quad (51)$$

$$\Psi_M = \Psi_H = 6 \ln(1 + \xi) \quad (52)$$

$$\xi = -\frac{0.4 g z H}{\hat{\rho} c_p T u^{*3}} \quad (53)$$

Donde z es la altura a la que se mide la temperatura (m), d un valor de desplazo de distancia (m), z_H el parámetro de rugosidad de la superficie, z_m un parámetro de longitud de rugosidad de impulso. Para la determinación de las variables antes mencionadas se utilizaron las siguientes

relaciones: $d = 0.77h$, $z_m = 0.13h$ y $z_H = 0.2 z_m$, donde h representa la altura del cultivo. La Ecuación 52 es utilizada cuando el flujo es estable ($\xi < 0$), mientras que para flujos inestables se utiliza la Ecuación 51.

La densidad molar del aire también fue determinada utilizando la Ecuación 54 y los datos obtenidos en campo:

$$\hat{\rho} = \frac{P}{RT} \quad (54)$$

El potencial de agua en el aire (Ψ_{air}) puede ser determinado mediante la Ecuación 55 (Jones, 2013):

$$\Psi_{air} = \frac{RT}{V_w} \ln(RH) \quad (55)$$

Donde V_w represental el volumen molar parcial de agua ($18.05 \times 10^{-6} \text{ m}^3/\text{mol}$) y RH la humedad relativa.

Estimación de los Flujos de Energía

El método EC se enfoca en analizar flujos turbulentos, lo que implica un análisis estadístico de las variables registradas (velocidad vertical del viento, concentración del gas analizado, etc.), mediante la descomposición de Reynolds, donde la variable consta de un valor medio y uno fluctuante (Burba & Anderson, 2008; Reverter, 2008):

$$x = \bar{x} + x' \quad (56)$$

La multiplicación de las variables utilizando la estructura de la Ecuación 56, promediando para utilizar datos destacados, se llega a una ecuación compuesta por un término de transporte medio y el otro la covarianza existente:

$$\overline{xy} = \bar{x} \bar{y} + \overline{x'y'} \quad (57)$$

La Ecuación 57 será despejada para encontrar el término de covarianza que es utilizado en las ecuaciones de flujos de energía, los otros términos son generados por las mediciones de los sensores instalados (anemómetro sónico, analizador de gas infrarrojo).

La columna de datos referente a una variable se secciona en tiempos definidos para determinar la covarianza de los datos, proceso realizado mediante la estructuración del código en el software MATLAB, incluyendo algunas constantes necesarias para el cálculo de los flujos de energía:

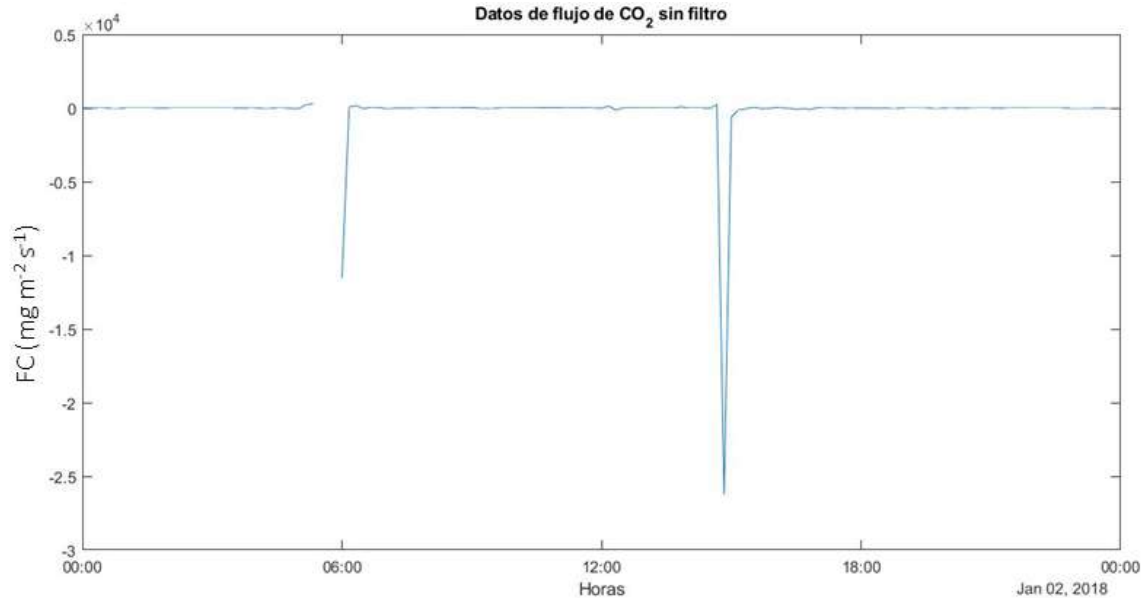
$\rho = 1.22 \text{ kg/m}^3$ (densidad del aire calculada), $E_p = 0.62$ (relación del peso molecular del vapor de agua y el aire seco), $R_d = 287 \text{ J/kg K}$ (constante del gas ideal para el aire seco), $R_v = 461 \text{ J/kg K}$ (constante del gas ideal para el vapor de agua), $C_p = 1004.67 \text{ J/kg K}$ (calor específico del aire seco a 27°C) y $L_v = 2500 \text{ J/g}$ (calor latente de vaporización).

Para más detalles referirse al proyecto FID16-30, disponible en <http://manglar-carbono.utp.ac.pa>.

Campaña de Medición y Acondicionamiento de Datos

Obteniendo la base de datos de las diferentes variables registradas en el área de estudio, se procedió a importar la información al software MATLAB para el respectivo tratamiento. La presencia de datos que se encontraban muy diferentes del resto (valores atípicos), son comúnmente observados en los registros de información que provienen de sensores instalados en campo debido a que están expuestos a las inclemencias del tiempo y a los animales que fácilmente podrían desconfigurar el equipo. Tomando en cuenta la presencia de los datos atípicos, es posible aplicar ciertas funciones que permitan modificar estos valores por otros más acordes al grupo, mejorando considerablemente la interpretación de los gráficos generados. En la Figura 8 se puede observar la presencia de valores atípicos y discontinuidades que surgen cuando el sensor se desconecta o presenta algún desperfecto físico.

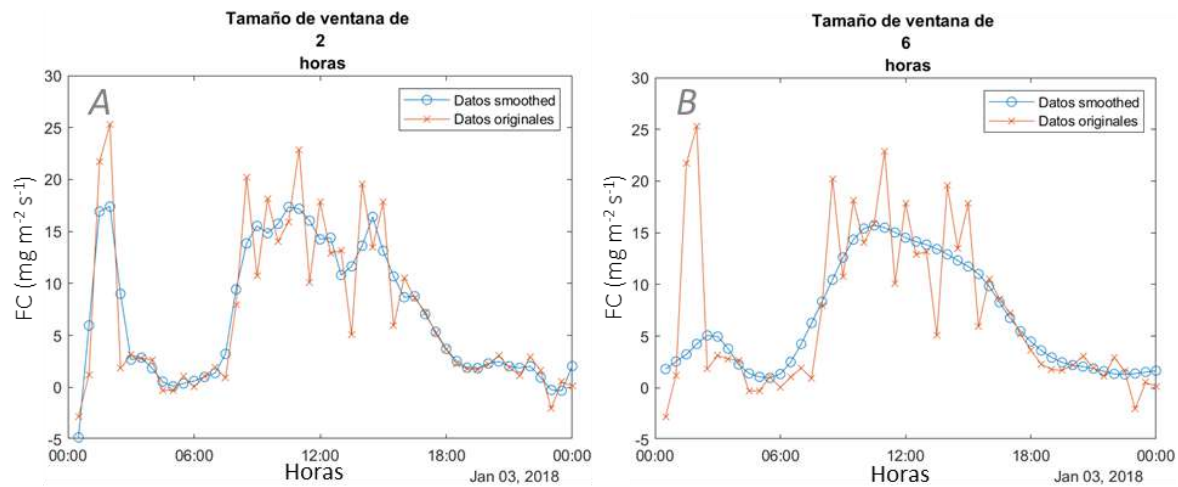
Figura 8 *Perturbaciones encontradas en la base de datos sin filtro.*



Estas alteraciones en las mediciones dificultan el proceso de interpretación, de modo que, dependiendo de la naturaleza de los datos, así como la confiabilidad que necesite el estudio, será necesario procesar los datos mediante funciones que acondicionen su comportamiento, como, por ejemplo, *Smoothdata* y *Filloutiers*, que suavizan y eliminan valores atípicos, respectivamente, aplicables mediante el software MATLAB.

Las funciones antes mencionadas deben ser verificadas detenidamente al momento de aplicarlas para evitar el exceso de filtro en los datos disponibles. En la Figura 9a y la Figura 9b se observan las comparaciones entre los datos una vez pasan por funciones de filtrado de ruido, donde la figura 9a utilizó una cantidad de referencia para el filtrado (ventana) más pequeña en comparación a la figura 9b, lo que le permitió mantener un comportamiento similar a los datos originales.

Figura 9 *Impacto del proceso de suavizado en los datos utilizados.*



Nota. A. Suavizado de datos utilizando datos de referencia cada 2 horas (ventana de datos). B. Suavizado de datos utilizando datos de referencia cada 6 horas.

Los datos como la Humedad Relativa (HR), Temperatura del aire, Calor latente (LE) y Flujo de CO₂ (FC) y la velocidad del viento con sus respectivas componentes, fueron analizados en busca de valores atípicos para su respectivo procesamiento en caso de ser necesario.

Para el análisis y predicción de los flujos de energía en el caso de estudio, se propone utilizar dos enfoques basados en los datos de medición, presentados a continuación: enfoque no físico y enfoque cuasi físico. El primero busca recrear el comportamiento de los datos aprendiendo de los mismos sin necesidad de entender los fenómenos físicos involucrados (modelo de caja negra), el último busca recrear el comportamiento de los datos asumiendo la confiabilidad de estos, incluyendo parte de los fenómenos físicos involucrados conocidos previamente (modelo de caja gris).

Enfoque no Físico Basado en Datos

Se opta por escoger un mes en particular en el cual fueron recolectados los datos debido a la alta variabilidad de los datos de diferentes meses. Esto se ilustra en la Figura 10, donde se muestran los diagramas de caja para los datos de los meses de enero a junio de 2018. En la Tabla 3 se resumen otras métricas estadísticas de interés para describir la variabilidad de los datos.

Figura 10 Variabilidad del flujo de CO_2 en los meses de enero a junio de 2018.

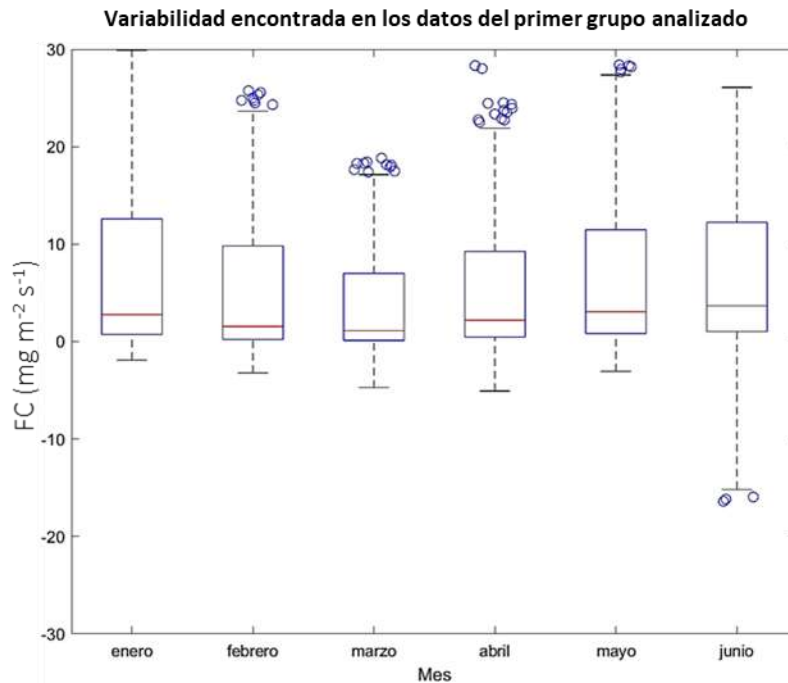


Tabla 3 Características encontradas en el primer grupo de datos de flujo de CO_2 .

Mes	Promedio	Desv. Estándar	Varianza	Mínimo	Máximo	Rango
Enero	6.54	7.11	50.52	-1.90	29.87	31.77
Febrero	5.11	6.20	38.40	-3.22	25.74	28.96
Marzo	3.57	4.46	19.89	-4.71	18.83	23.54
Abril	5.08	6.09	37.10	-5.08	33.27	38.34
Mayo	6.38	6.85	46.96	-3.05	28.39	31.44
Junio	6.51	7.10	50.43	-16.39	26.08	42.47

Se utiliza el *Experiment Manager* de MATLAB, aplicación que permite crear experimentos de aprendizaje automático para entrenar redes neuronales sujetas a distintas condiciones iniciales e hiperparámetros. De esta manera, es posible comparar los resultados para determinar los hiperparámetros óptimos. El *Experiment Manager* realiza un barrido sobre las distintas configuraciones de hiperparámetros y determina sus valores óptimos de acuerdo con el criterio de desempeño, que sería el RMSE de la salida del conjunto de prueba. A continuación, se describen los hiperparámetros considerados para realizar los experimentos:

- Cantidad de días de entrenamiento (*training_days*): debido a la variabilidad que puede existir en los datos que están basados en las condiciones climáticas, se estableció un rango de entrenamiento que va entre 1 y 15 días, donde el software determina la cantidad de días necesarios para el mejor desempeño del modelo.
- Cantidad de capas escondidas (*hidden_layers_over_1*): según (Maren et al., 1990) utilizar de una a dos capas escondidas podría ser suficiente para obtener un modelo significativo, mientras que para (Goodfellow et al., 2016) la estructura de la red depende directamente de los datos. Para esta investigación, el utilizar menos de tres capas no generaba buenos resultados, y cuando se utilizaban más de nueve capas, el modelo solo tomaba mucho más tiempo procesando. La cantidad de capas escondidas varía entre 2 y 9.
- Cantidad de neuronas en la capa escondida (*hiddenUnits*): la cantidad de neuronas se varía entre 10 y 100.
- Tamaño de lote (*miniBatchSize*): el tamaño de lote se refiere a la cantidad de muestras consideradas antes de actualizar los pesos y sesgo de la red neuronal. Un conjunto de entrenamiento puede ser dividido en un lote (si se considera todo el conjunto de

entrenamiento en cada actualización) o en más de un lote (si el conjunto de entrenamiento se divide en varios subconjuntos de muestras). El tamaño de lote se varía entre 16 y 128.

- Tasa de aprendizaje (myInitialLearnRate): la tasa de aprendizaje controla el ajuste de los parámetros del modelo respecto al valor de la función de pérdida. Entre menor sea la tasa de aprendizaje, el grado de ajuste de los parámetros es menor en la dirección del gradiente mínimo. Entre mayor sea la tasa de aprendizaje, serán más abruptos los ajustes en los parámetros, lo cual puede provocar que el modelo no alcance el mínimo global. Se determina la tasa de aprendizaje óptima variándola entre 1×10^{-4} y 1×10^{-2} . (*Design and Run Experiments to Train and Compare Deep Learning Networks - MATLAB - MathWorks América Latina*, n.d.).
- Entradas consideradas: en todas las redes neuronales se consideran cinco entradas fijas, velocidad del viento en sus tres componentes, absorción de CO_2 y absorción de H_2O . Adicionalmente se le asignaron las variables registradas en la parte alta de la torre: Velocidad promedio del viento (WS_ms_top_Avg), promedio de la dirección del viento (WindDir_D1_WVT), temperatura del aire (temp10_Avg) y la humedad relativa (RH10_Avg), para que el software pueda utilizar la configuración que más le beneficia a la variable estimada por el modelo.
- Variables estimadas por el modelo (salidas): durante los meses donde se realicen las validaciones, el modelo estará estimando variables como el Potencial de agua en el aire (PotAir), flujo de CO_2 (FC), flujo de calor sensible (H) y flujo de calor latente (LE).

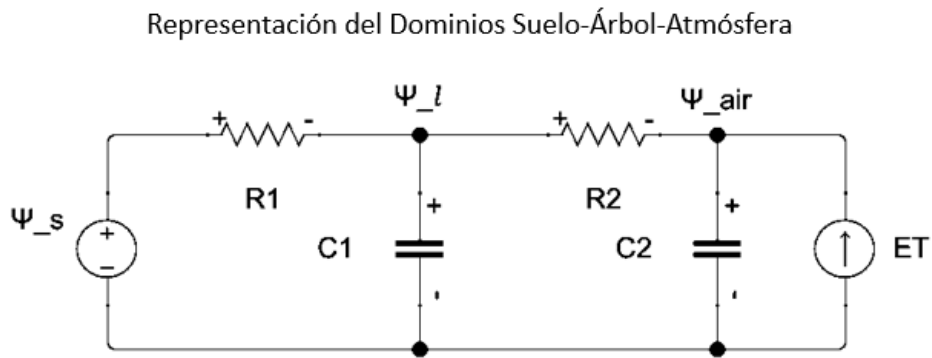
Enfoque Cuasi Físico Basado en Datos

Para el modelo de caja gris se propuso a utilización de la analogía eléctrica (i.e., Ley de Ohm) para crear un enlace entre los dominios propuestos (el suelo, los árboles y la atmósfera),

considerando un modelo de estado no estacionario (dependiente del tiempo) mostrado en la Figura 11; el mismo es basado en (Campbell, 1985; Tyree & Ewers, 1991). Este modelo, basado en conocimiento previo, muestra las interacciones entre los diferentes parámetros internos y externos de interés involucrados en el comportamiento de los flujos presentados dentro de un árbol. Las resistencias R representan la imposición al flujo dentro del árbol, las capacitancias representan el almacenamiento de agua y las fuentes de voltaje y corriente representan entradas conocidas del sistema (potenciales hídricos).

Para estudiar las interacciones entre los dominios propuestos, se consideran los siguientes parámetros: el almacenamiento de agua tanto en el árbol como en la atmósfera (C_1 y C_2 respectivamente), los potenciales de agua en el suelo, hojas y atmósfera (Ψ_s , Ψ_l y Ψ_{air} respectivamente), así como las resistencias al flujo que pueden presentarse dentro del árbol (R_1) y en la frontera entre el dosel del bosque y la atmósfera (R_2). Luego de tener su representación lineal usando la analogía eléctrica, esta se traduce en ecuaciones diferenciales ordinarias de primer orden o ecuaciones algebraicas. Estas, en conjunto con las entradas y salidas ya conocidas de los datos, apoyan al proceso de estimación a través de un método de optimización, en donde los parámetros mencionados son identificados y retenidos bajo criterios de convergencia.

Figura 11 Diagrama representativo del sistema.



La representación mostrada en el esquema de la Figura 11, permite obtener los dos balances de

flujo, uno para el árbol (Ecuación 56) y otro para el aire (Ecuación 57):

$$\frac{\Psi_s - \Psi_l}{R_1} = \frac{\Psi_l - \Psi_{air}}{R_2} + C_1 \frac{d\Psi_l}{dt} \quad (56)$$

$$\frac{\Psi_l - \Psi_{air}}{R_2} + ET = C_2 \frac{d\Psi_{air}}{dt} \quad (57)$$

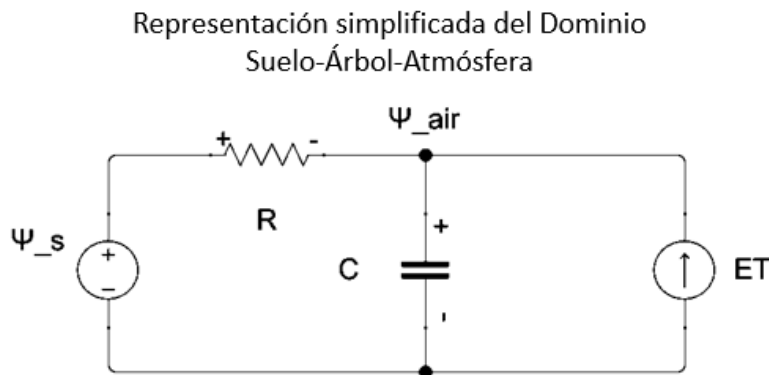
en donde ET representa la evapotranspiración.

Debido a la ausencia de información respecto al potencial del agua en el suelo para la *Avicennia bicolor*, se propone la determinación basada en la proporción que debe existir entre el potencial del suelo, las hojas y la atmósfera. Lo que implica que $\Psi_s = A * \Psi_{air}$, siendo A un valor estimado por el modelo, por lo que se obtiene la siguiente representación en Espacio de Estado:

$$\begin{bmatrix} \frac{d\Psi_l}{dt} \\ \frac{d\Psi_{air}}{dt} \end{bmatrix} = \begin{bmatrix} -\frac{1}{C_1} \left(\frac{1}{R_1} + \frac{1}{R_2} \right) & \frac{1}{C_1} \left(A + \frac{1}{R_2} \right) \\ \frac{1}{C_1 R_2} & -\frac{1}{C_1 R_2} \end{bmatrix} \begin{bmatrix} \Psi_l \\ \Psi_{air} \end{bmatrix} + \begin{bmatrix} 1 \\ \frac{1}{C_1} \end{bmatrix} [ET] \quad (58)$$

Buscando obtener la representación más acertada al fenómeno analizado, se realizó un diagrama simplificado (Figura 12) en donde solo se considera el almacenamiento de agua en el dominio correspondiente a los árboles (C), y se desprecia la conductancia de la capa límite.

Figura 12 Diagrama representativo simplificado del sistema.



El diagrama simplificado genera la Ecuación (59):

$$\frac{\Psi_s - \Psi_{air}}{R} = C \frac{d\Psi_{air}}{dt} \quad (59)$$

Cuya representación en Espacio de Estado sería:

$$\left[\frac{d\Psi_{air}}{dt} \right] = \left[\frac{1}{CR} (G - 1) \right] [\Psi_{air}] + \left[\frac{1}{C_1} \right] [ET] \quad (60)$$

Una vez se obtiene la representación de Espacio de Estado del sistema deseado, se procede a utilizar el Software MATLAB para identificar el valor de los diferentes parámetros que componen al modelo. Se utiliza la función “*idgrey*” para ingresar la matriz, y luego la función “*greyest*” para la solución utilizando el método de mínimos cuadrados para minimizar el error entre las variables estimadas y las obtenidas en campo.

Capítulo 4: Resultados

Utilizando los datos registrados por la torre de medición, es posible conocer el comportamiento de variables como la velocidad del viento (Figura 13), temperatura del aire (Figura 14) y la humedad relativa (Figura 15) durante el mes de enero hasta junio de 2018.

Figura 13 *Velocidad promedio registrada desde enero hasta junio del 2018.*

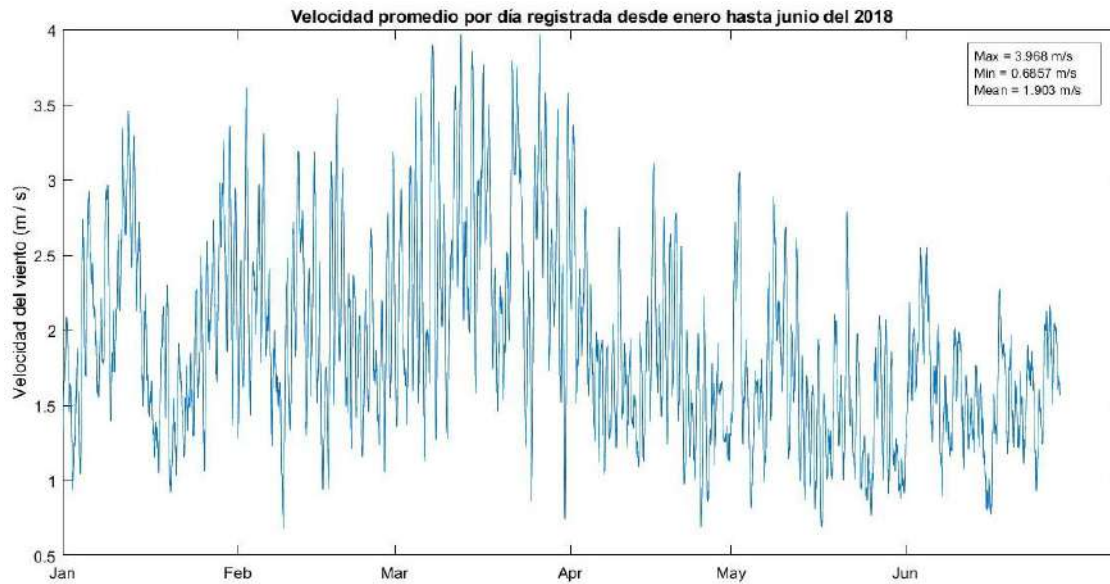


Figura 14 *Temperatura del aire promedio registrada desde enero hasta junio del 2018.*

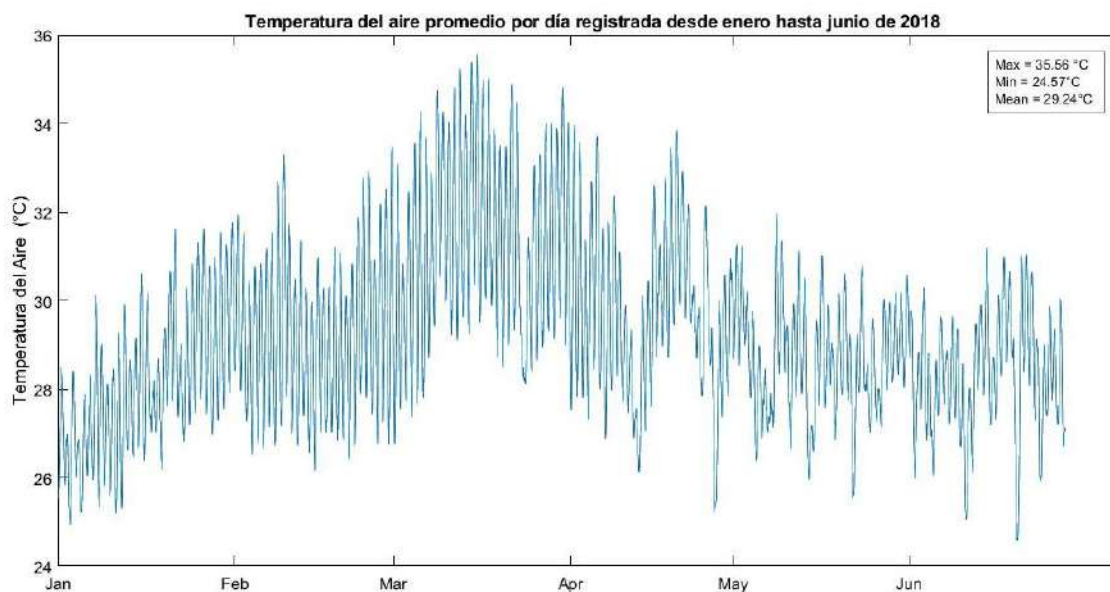
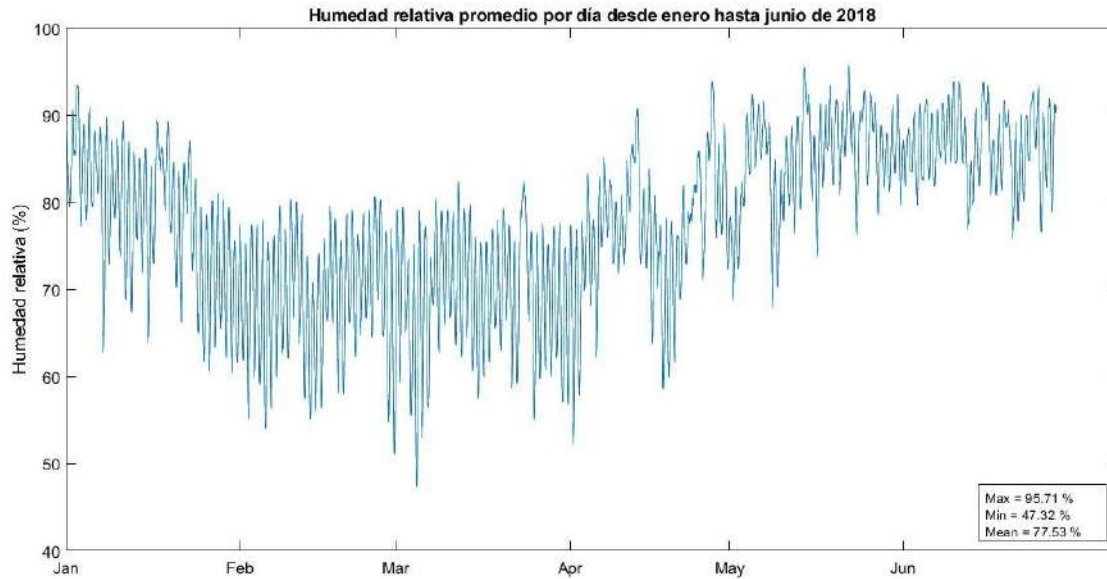


Figura 15 *Humedad relativa promedio registrada desde enero hasta junio del 2018.*



Análisis de Correlación.

Se implementó un análisis de correlación de Pearson para conocer la relación que existía entre las variables que estaban siendo medidas (Tabla 4) y los flujos de energía obtenidos mediante el desarrollo de las respectivas ecuaciones. El coeficiente de correlación R permite identificar las variables que pueden afectar en mayor medida los flujos de energía calculados.

Tabla 4 *Variables consideradas para el análisis de correlación.*

Variable	Unidades	Descripción
FC	mg/m ² s	Flujo de CO ₂
H	W/m ²	Flujo de Calor Sensible
LE	W/m ²	Flujo de Calor Latente
Sigma_w		Desviación estándar de la velocidad vertical
ustar	m/s	Velocidad de fricción
Tau	N/m ²	Cantidad de Movimiento
CO ₂ Absorptance		Valor bruto de absorptancia del CO ₂
H ₂ O Absorptance		Valor bruto de absorptancia del H ₂ O
CO ₂	mmol/m ³	Registro de CO ₂ en unidades molares


Variable	Unidades	Descripción
H ₂ O	mmol/m ³	Registro de H ₂ O en unidades molares
Aux 1 - U	m/s	Velocidad horizontal del viento en la dirección U (Norte)
Aux 2 - V	m/s	Velocidad horizontal del viento en la dirección V (90° contrarreloj de U)
Aux 3 - W	m/s	Velocidad vertical del viento
Aux 4 - Ts	K	Temperatura sónica
WS_ms_top	m/s	Promedio de velocidad del viento a 30.3m
Wind_Dir_D1	Grados	Promedio de la dirección del viento
RH1_Avg	%	Humedad relativa a 2.6 m
RH10_Avg	%	Humedad relativa a 30.3 m
BP_hPa	hPa	Presión Barométrica
CM3_Up	W/m ²	Onda corta de radiación solar entrante
CM3_Dn	W/m ²	Onda corta de radiación solar reflejada
CNR4TK	K	Temperatura promedio del aire
CG3_Up_co	W/m ²	Radiación descendente de onda larga, valor absoluto
CG3_Dn_co	W/m ²	Radiación ascendente de onda larga, valor absoluto
Shf_Avg1	W/m ²	Flujo de calor en el suelo, punto 1
Shf_Avg2	W/m ²	Flujo de calor en el suelo, punto 2

Se seleccionó un periodo de tiempo que no tuviese interrupciones en las mediciones, utilizando los datos medidos cada diez minutos, desde el primero de enero a las 00:10, hasta el doce de enero a las 23:50, utilizando un total de 1727 mediciones. Mediante la función “*cor()*” y “*corplot()*” del Software RStudio, se determina la matriz de correlación y se grafican los resultados para su respectivo análisis. Las correlaciones significativas se muestran en la Tabla 5, mientras que el gráfico de la matriz resultante se observa en la Figura 13.

Tabla 5 Correlaciones significativas observadas en la matriz resultante.

	H	Shf_avg1	Shf_avg2	Sigma_w	ustar
CM3_up	0.90	0.73	0.86		
CM3_dn	0.89	0.71	0.84		
CNR4TK	0.74	0.89	0.92		
Shf_avg2	0.80				
CG3_dn	0.73	0.91	0.91		
Ws_ms_top				0.75	0.74

Figura 16 Análisis de correlación de las variables registradas en el área de estudio.



Las variables correlacionadas obtenían valores cercanos a 0 ($p < 0.001$) y mayores a 0.7 para el coeficiente de correlación de Spearman. A pesar de que se obtienen 26 variables en el área de estudio, solamente 10 están correlacionadas, pero ninguna de estas logra explicar el flujo de CO_2 .

Modelo de Caja Gris

Se seleccionó la base de datos con mayor disponibilidad de información, la cual correspondía a los meses de enero a junio del año 2018 (25 420 mediciones). Los datos más recientes (2019-2022) presentaban muchas irregularidades en los datos debido a la desinstalación de algunos sensores por daños y/o mantenimientos realizados en la torre de flujo.

Para el modelo de Caja gris se utilizó como variable de entrada el calor latente (LE) registrado por la torre. El potencial de agua en el aire no mostró valores atípicos durante el periodo seleccionado (Figura 17), mientras que LE sí presentó perturbaciones (Figura 18) por lo que fue necesario aplicar filtros para reducir el ruido en los datos.

Figura 17 *Potencial de agua en el aire durante los primeros seis meses del año 2018.*

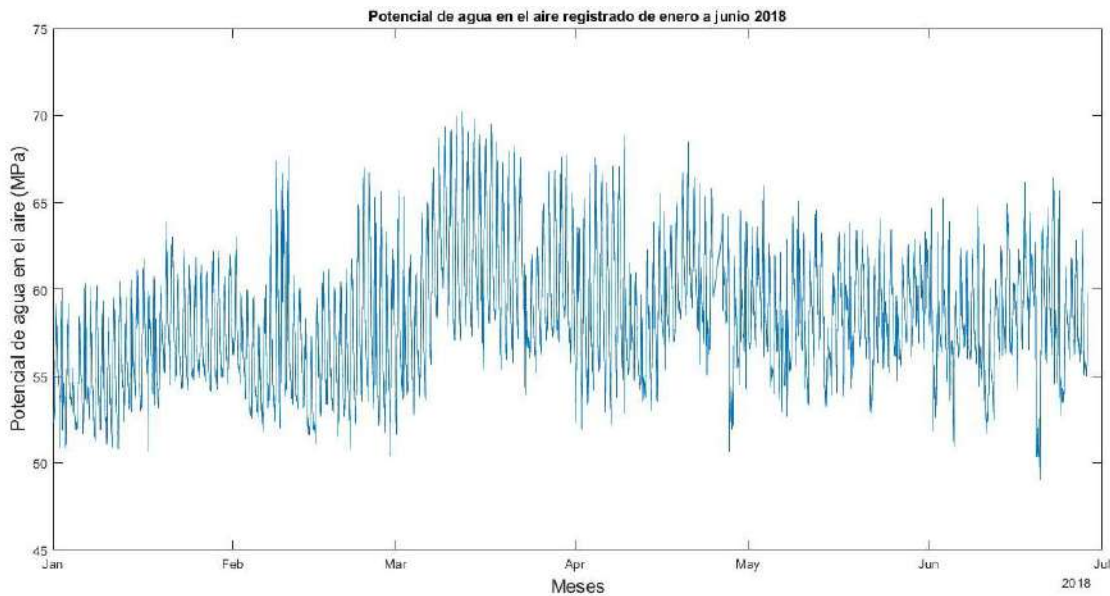
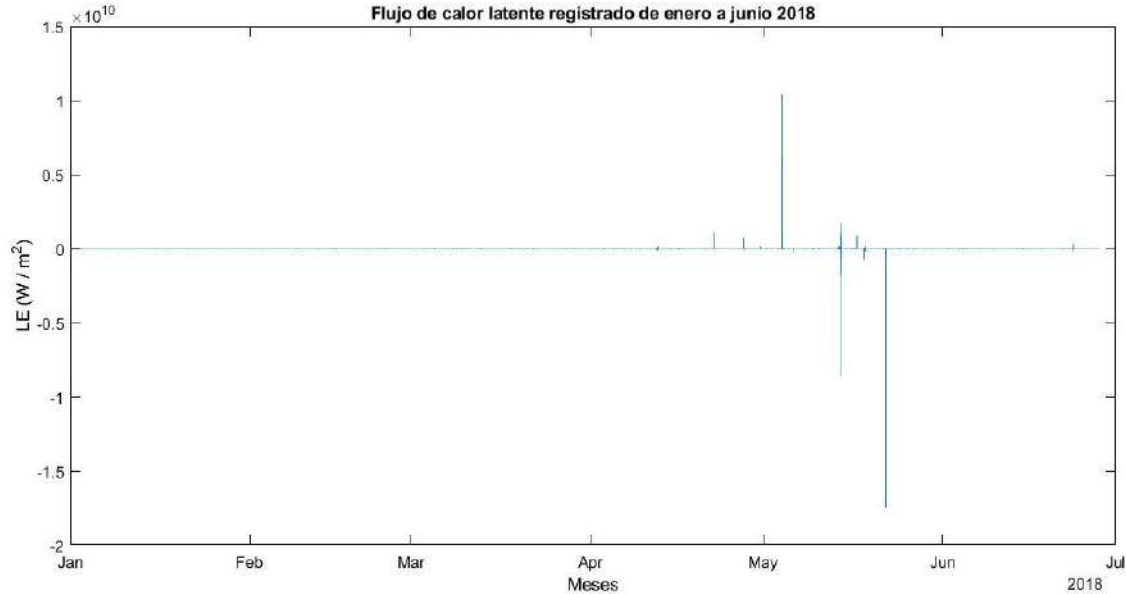


Figura 18 Calor latente registrado durante los primeros seis meses del año 2018.



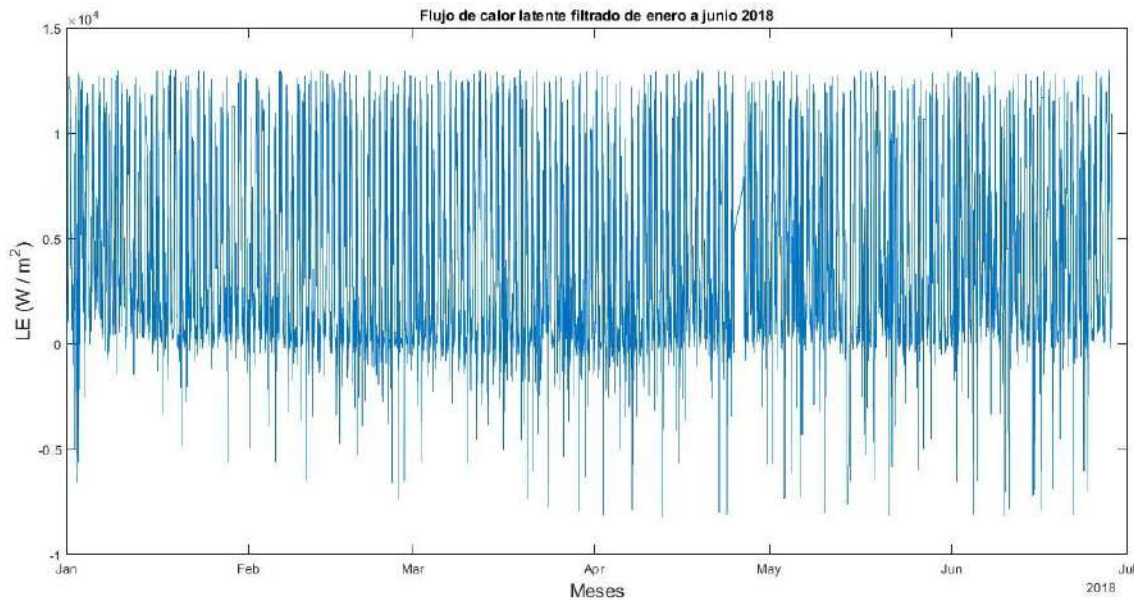
La Figura 19 muestra un esquema del proceso realizado para el filtrado y suavizado de los datos.

Figura 19 Proceso realizado para el filtrado y suavizado de los datos.



Aplicando el primer filtro (*filloutliers*, 'next') se eliminan los valores atípicos que corresponden a las mediciones que se encuentren fuera de las tres desviaciones estándar respecto a la media. Estos valores atípicos serán reemplazados por el valor siguiente según la configuración utilizada en la codificación ('next'). La utilización del segundo filtro (*Smoothdata*) permite suavisar los datos como se mostró en la Figura 8a, para luego aplicar nuevamente el filtro *filloutliers* para unificar los datos. El resultado se muestra en la Figura 20.

Figura 20 Datos del calor latente luego de aplicar el primer filtro.



El proceso de filtrado y suavizado de los valores de calor latente registrados fue necesario debido a que durante el entrenamiento el modelo buscará predecir los datos, y si existe demasiada variabilidad se necesitará una alta capacidad computacional para las iteraciones, además, de que se tendrían valores muy altos en error final de predicción.

Se realizó una corrida del modelo utilizando los datos filtrados del calor latente y el potencial de agua en el aire, la cual duró 12 días de procesamiento en una computadora con procesador Intel Core i7-9700F CPU @ 3.00 GHz, con 64 GB de RAM. Se realizaron 21 288 iteraciones para obtener un valor de error de estimación (VEE) de 27.57%. Los parámetros utilizados y los estimados por el modelo se encuentran en la Tabla 6.

Tabla 6 Parámetros utilizados por el modelo

Parámetros	Iniciales	Estimados por el modelo
C1	72.4145	-2.410×10^{-5}
C2	2.4255×10^4	1.690×10^5
R1	5.0338×10^5	5.019×10^5
R2	134.783	-4.491×10^7
G	0.2160	1.679×10^8

El valor inicial de los parámetros fue un producto entre el valor propuesto encontrado en la literatura y un número aleatorio entre 0 y 1 (Parámetro * rand()). El único parámetro que tenía un valor calculado fue R2, donde se utilizó la Ecuación 49 referente a la conductancia en la capa límite. Considerando los resultados obtenidos para u^* y H, se obtiene un g_{ha} de $3.47 \text{ mol/m}^2\text{s}$ o $6.25 \times 10^{-2} \text{ kg/m}^2\text{s}$ donde R2 sería $16 \text{ m}^2\text{s/kg}$. Para los demás parámetros se multiplicó aleatoriamente un valor, buscando un valor más bajo de VEE para iniciar las iteraciones. Utilizando el valor físico de R2 no se tenía un desarrollo del modelo por lo que también se multiplicó por 10 para incrementar su magnitud. El valor inicial de los parámetros puede variar, pero el modelo debería converger a los mismos valores finales.

Se realiza una validación del modelo utilizando los días 28 y 29 de agosto de 2018, mostrados en las Figuras 21 y 22, donde se observa una mala adaptación al comportamiento real que obtuvo el valor del Potencial de agua en el aire en esos días.

Figura 21 Validación del modelo propuesto para el día 28 de agosto de 2018.

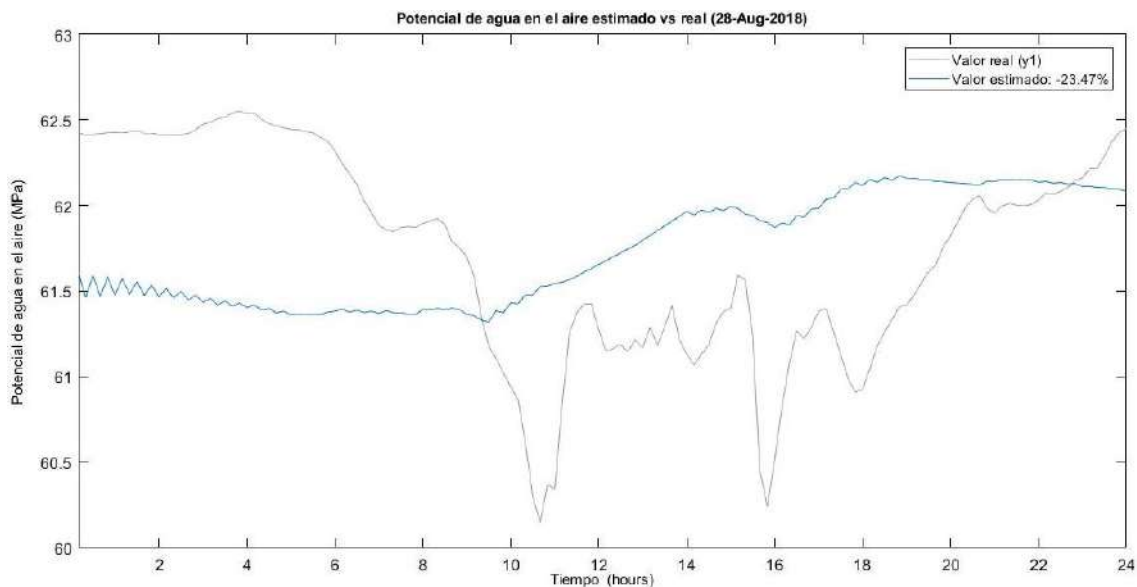
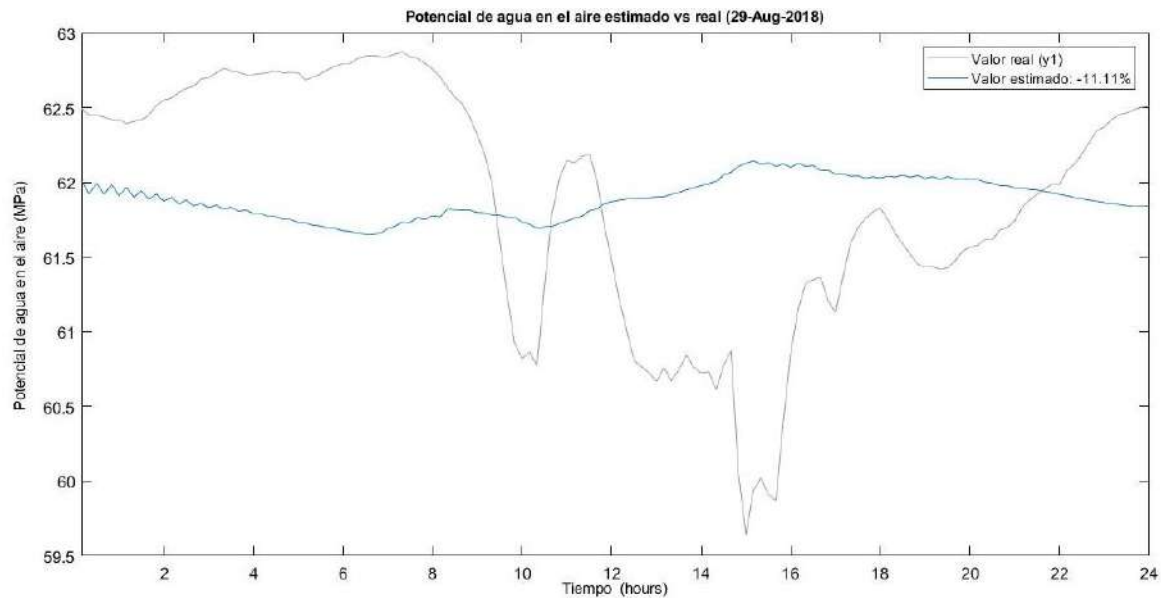


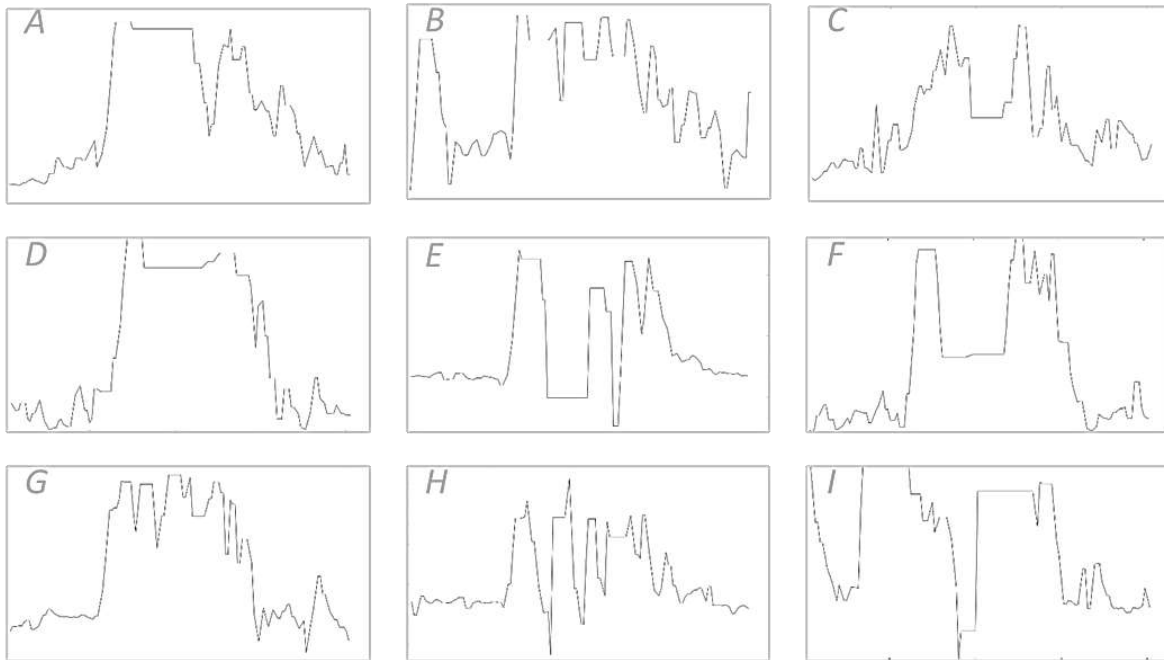
Figura 22 Validación del modelo propuesto para el día 29 de agosto de 2018.



Modelo de Caja Gris Simplificado

Al aplicar los datos filtrados del calor latente en el modelo simplificado, se obtenía un VEE mayor a 300% por lo que se procedió a agrupar los días que tenían un comportamiento parecido. Para agrupar los días en diferentes grupos, se procedió a graficar cada día desde el 01-ene-2018 (00:10:00) hasta 28-jun-2018 (08:20:00), finalizando con 9 comportamientos diarios ilustrados en la Figura 23.

Figura 23 Comportamientos observados en los datos desde las 00:10 hasta las 23:50.



Entrenando el modelo utilizando el Grupo G, se encontró un VEE de 13.46%, luego de 4774 iteraciones en 10 horas de procesamiento. Este grupo estaba compuesto por 16 días, seleccionando dos días para validación. Los resultados de la corrida realizada se muestra en la Tabla 7.

Tabla 7 Resultados de las iteraciones para el modelo simplificado.

Parámetros	Iniciales	Estimados por el modelo
C	2.2501×10^4	8.8027×10^4
R	6.1451×10^5	4.8222×10^4
G	0.1112	4.2418×10^9

Utilizando los parámetros estimados por el modelo, se procede a realizar la validación utilizando el día 11 de mayo (Figura 24) y el 2 de junio (Figura 25).

Figura 24 Validación del modelo simplificado para el día 11 de mayo de 2018.

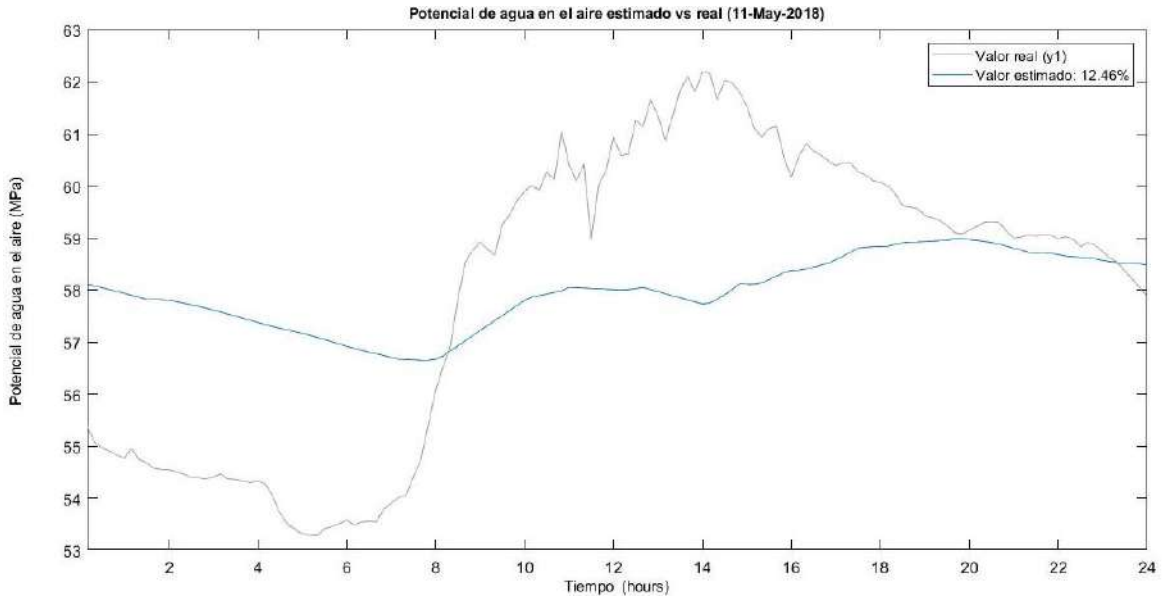
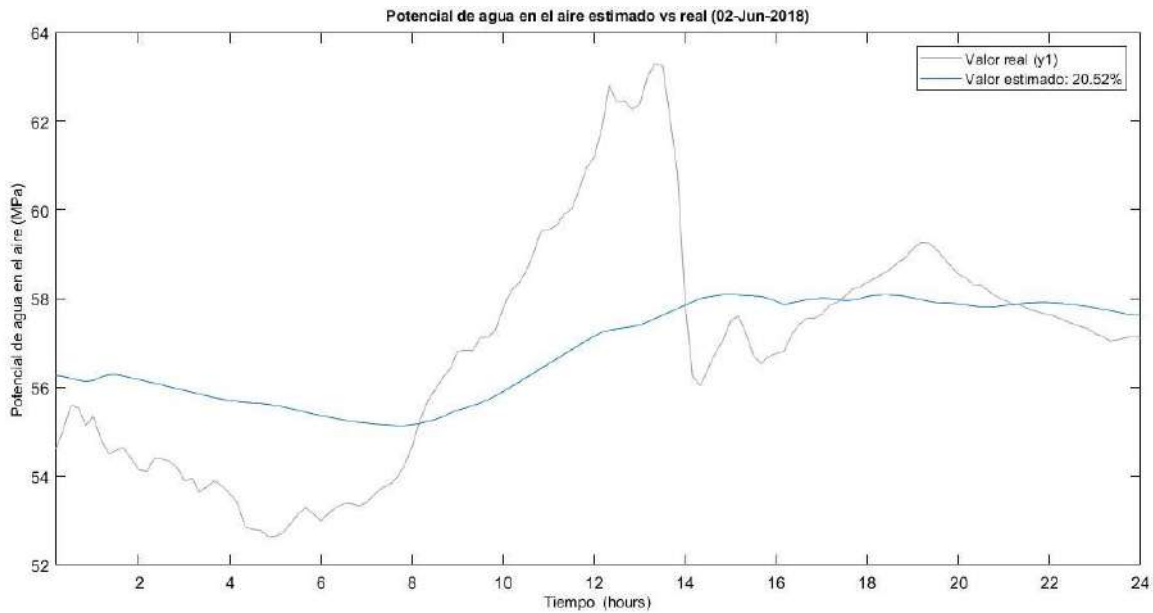


Figura 25 Validación del modelo simplificado para el día 2 de junio de 2018.



Los resultados obtenidos en validación del 11 de mayo muestran un coeficiente R^2 de 0.37, mientras que para el 2 de junio se obtuvo un coeficiente R^2 de 0.43, generando mejores valores en comparación a los obtenidos en el modelo con dos resistencias y dos capacitancias, pero aún mantiene una muy baja capacidad de predicción.

Se analizó otro grupo de datos disponibles desde agosto de 2018 hasta noviembre de 2020, referentes a la temperatura del aire a 30.3m (Figura 26) y la humedad relativa (Figura 27) pero, debido a la variabilidad de los datos, solo fue posible utilizar una sección correspondiente al 28 de agosto hasta 26 de septiembre de 2018 (2 160 mediciones), denominado Grupo A1.

Figura 26 *Temperatura de aire registrada desde agosto del 2018 hasta noviembre del 2020.*

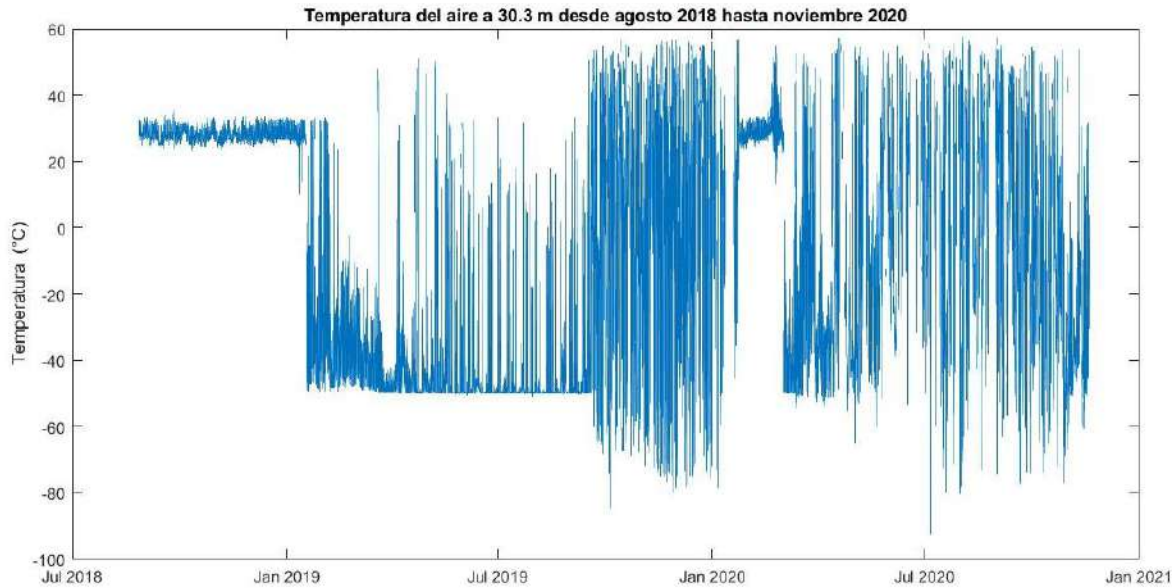
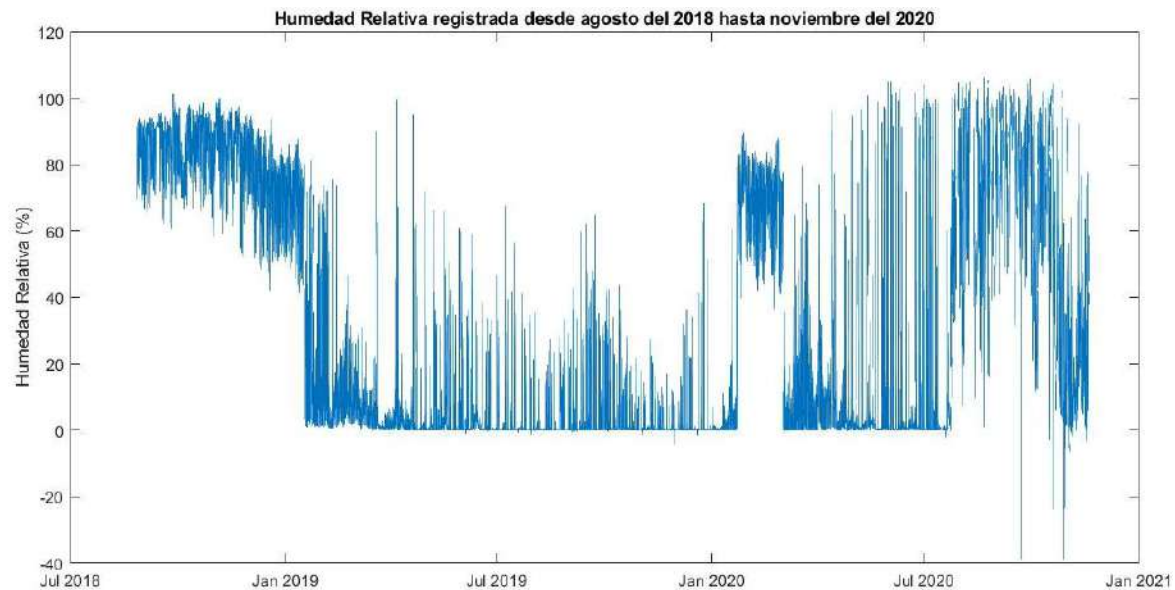
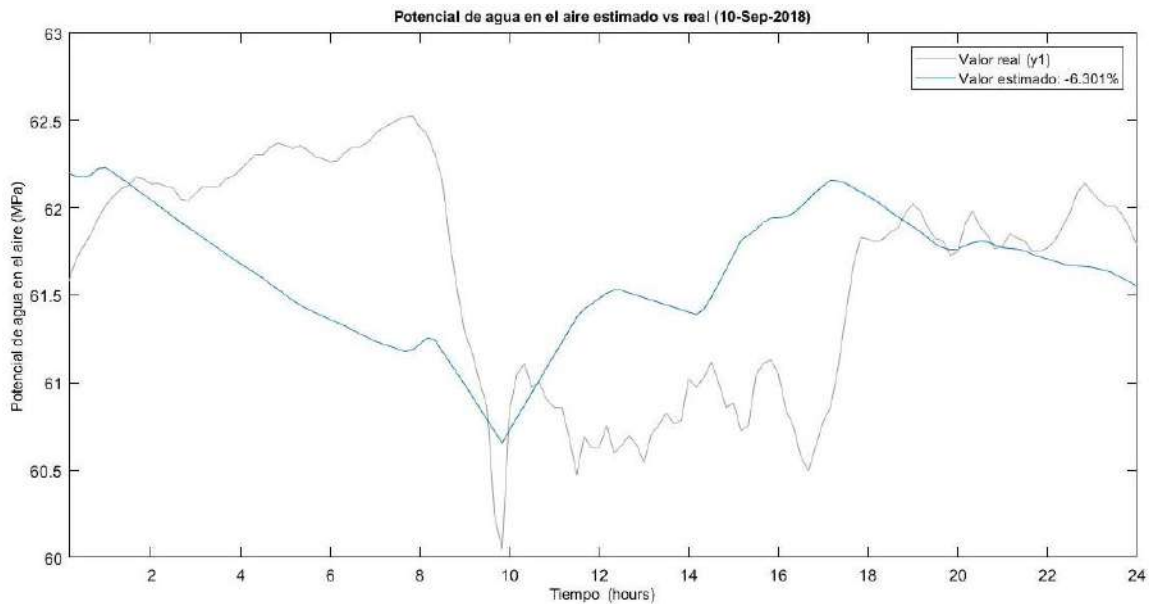


Figura 27 *Humedad relativa registrada desde agosto del 2018 hasta noviembre del 2020.*



Utilizando el subgrupo disponible para el entrenamiento del modelo, se obtuvo un VEE de 43.93% (el más bajo utilizando el Grupo A1), utilizando el día 10 de septiembre para su respectiva validación (Figura 28).

Figura 28 Validación del modelo simplificado para el día 10 de septiembre de 2018.



Modelo de Caja Negra.

Se utiliza la misma base de datos que en el modelo de caja gris, los datos de enero a junio de 2018, utilizando los 15 primeros días del mes seleccionado para el entrenamiento del modelo, mientras que los días restantes del mes pueden ser utilizados para su respectiva validación. La configuración inicial de los hiperparámetros del modelo se muestran en la Tabla 8.

Tabla 8 Configuración inicial de hiperparámetros para el modelo de caja negra.

Hiperparámetros	Rango
My Initial Learn Rate	$[1 \times 10^{-4}, 1 \times 10^{-2}]$
Mini Batch Size	[16, 128]
Jan/Feb training days	[1, 15]
Hidden layers over	[1, 8]
Hidden Units	[10, 100]

El primer mes seleccionado fue enero de 2018, utilizando el día 25 para validar la efectividad de

los hiperparámetros estimados por el modelo (Tabla 9).

Tabla 9 *Hiperparámetros para el modelo aplicado al mes de enero 2018.*

Hiperparámetro	LE	FC	H	PotAir
My Initial Learn Rate	0.0094	0.0033	0.0048	0.0100
MiniBatchSize	106	110	71	47
Jan trainingdays	15	8	12	14
Hidden layers over	3	3	9	7
Hidden Units	84	61	94	13
RMSE prueba ^a .	3715.37	1.62	0.42	0.96
Variables adicionales utilizadas	WS_ms_top_Avg WinDir_D1_WVT temp10_Avg	WS_ms_top_Avg WinDir_D1_WVT RH10_Avg	WS_ms_top_Avg WinDir_D1_WVT	temp10_Avg RH10_Avg

^a LE (W/m^2), FC (mg/m^2s), H (W/m^2) y PotAir (MPa).

Las comparaciones de flujos de energía estimados y calculados se muestran en la Figura 29 y Figura 30.

Figura 29 Validación del modelo de caja negra para el día 25 de enero (Parte 1).

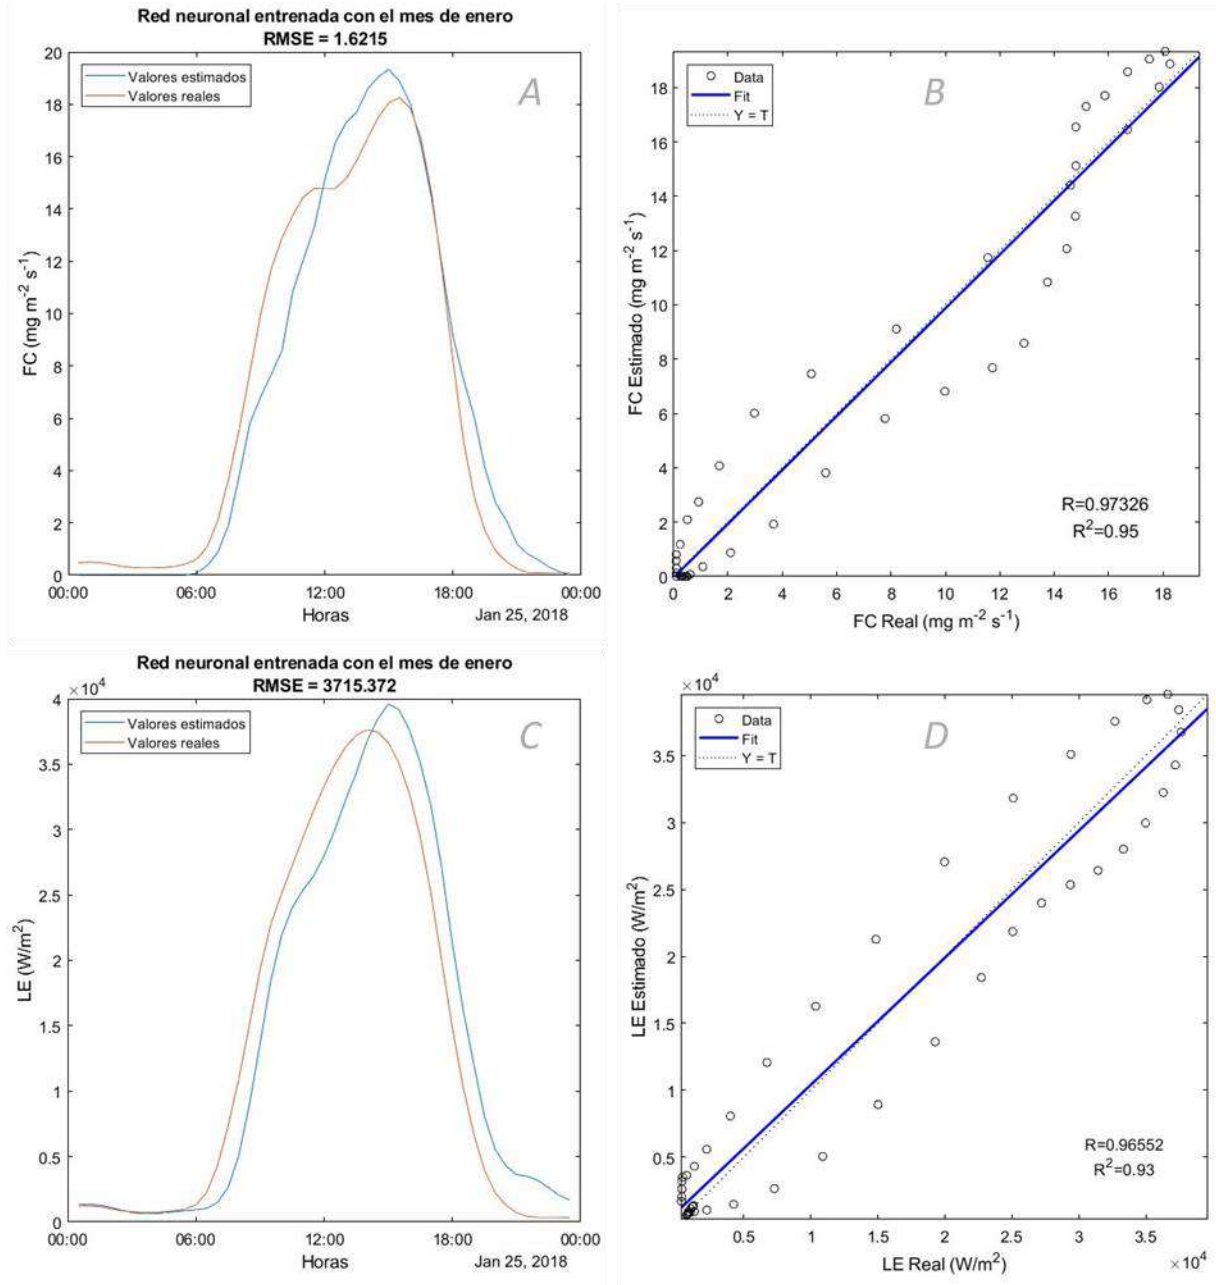
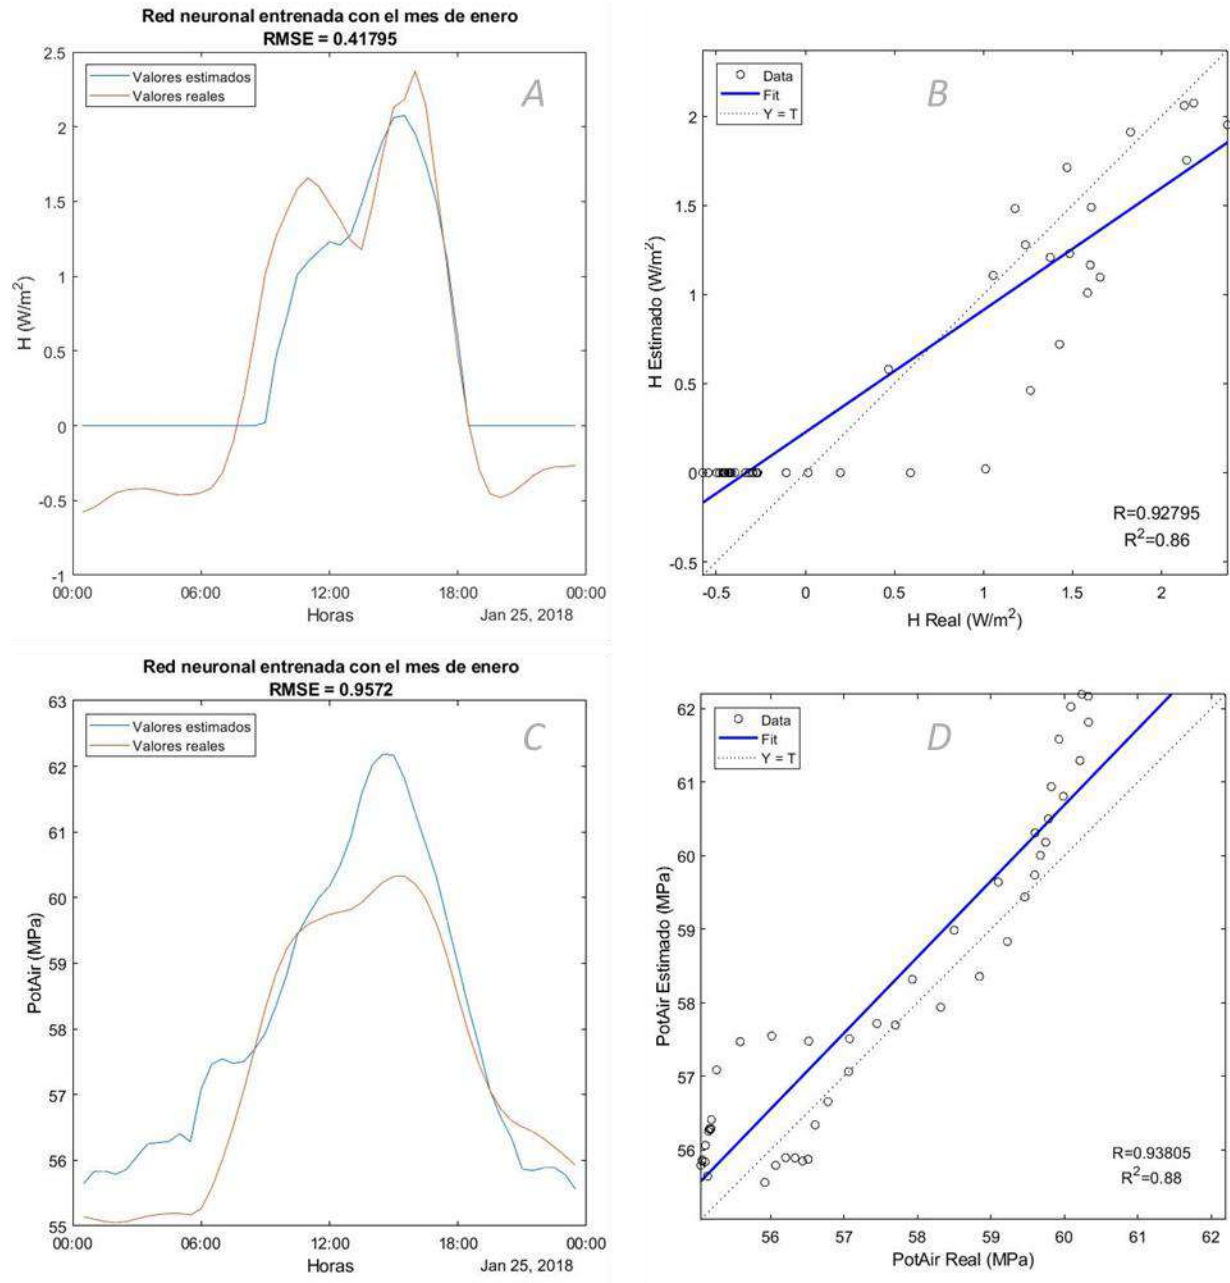


Figura 30 Validación del modelo de caja negra para el día 25 de enero (Parte 2).



La Figura 31 y la Figura 32 muestran la validación del modelo utilizando el día 26 de febrero, seleccionando los primeros 15 días del mes para entrenamiento, cuyos hiperparámetros resultantes se muestran en la Tabla 10.

Figura 31 Validación del modelo de caja negra para el día 26 de febrero (Parte 1).

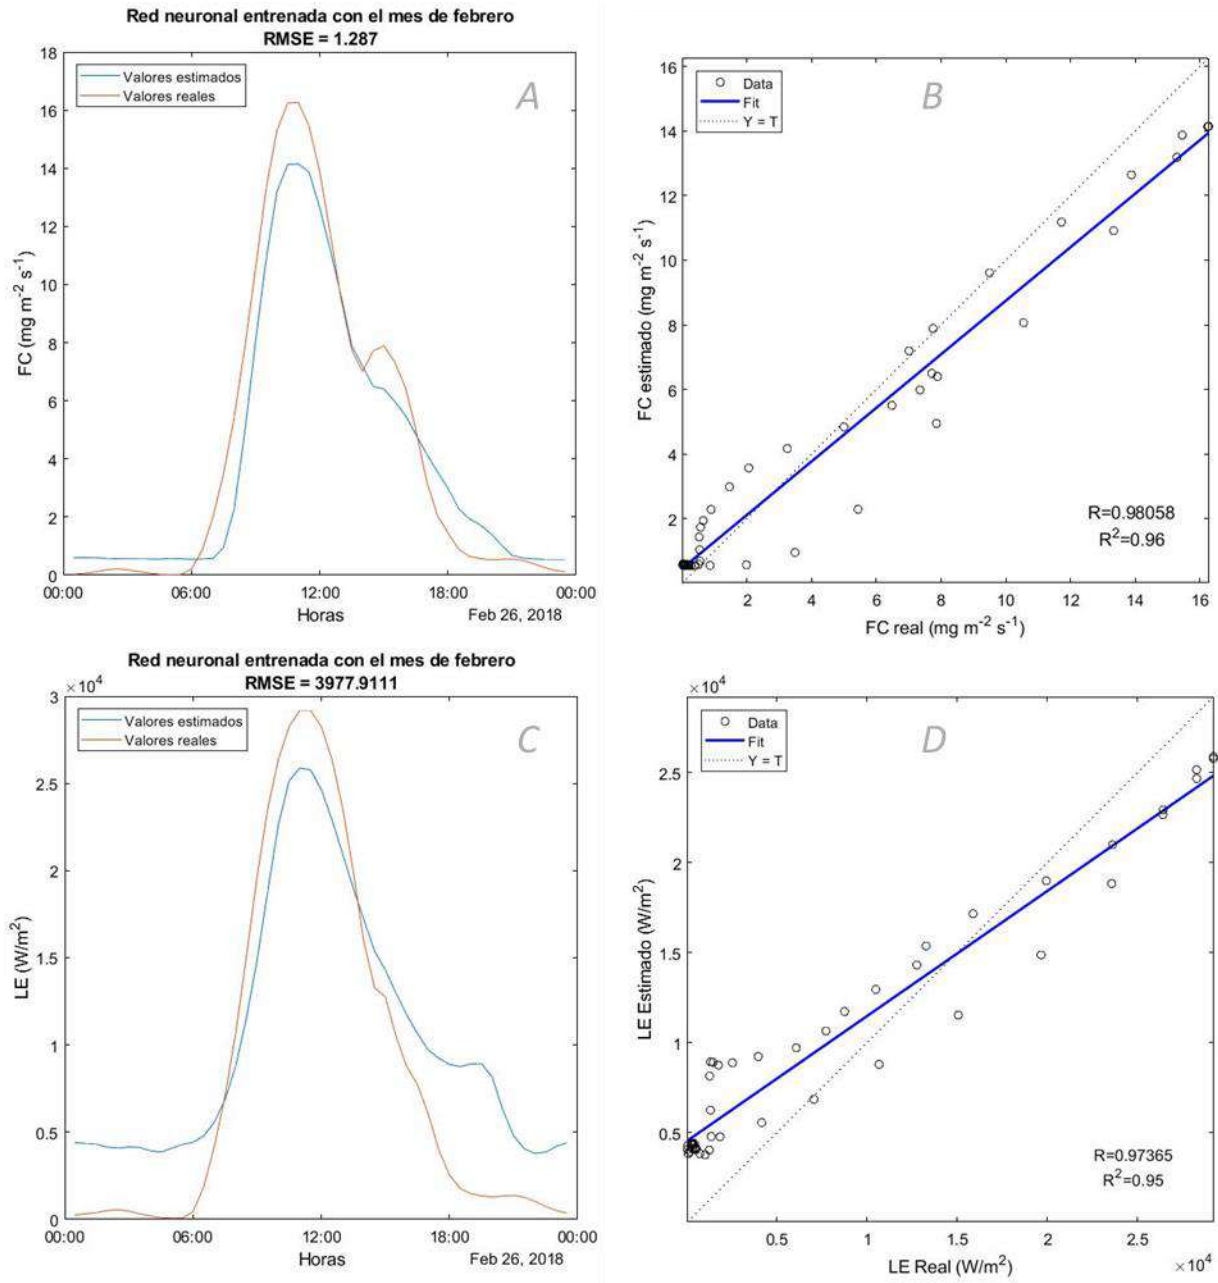


Figura 32 Validación del modelo de caja negra para el día 26 de febrero (Parte 2).




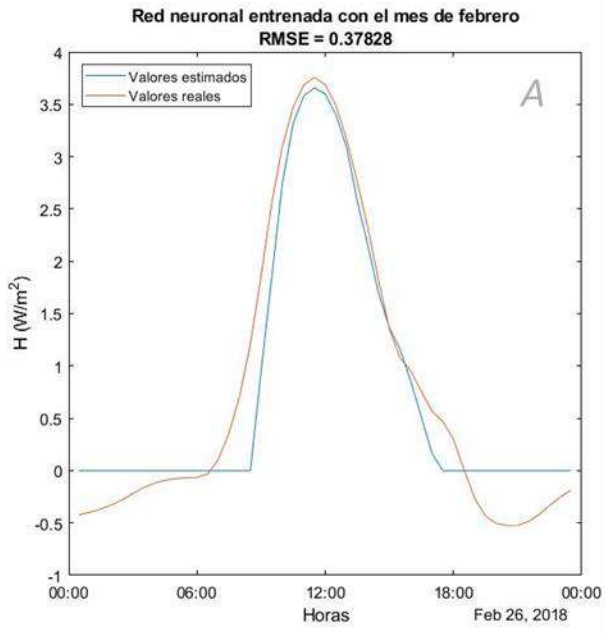


Tabla 10 *Hiperparámetros para el modelo aplicado al mes de febrero 2018.*

Hiperparámetro	LE	FC	H	PotAir
My Initial Learn Rate	0.0068	0.0049	0.0024	0.0092
Mini Batch Size	113	118	101	80
Feb training days	15	15	10	15
Hidden layers over	9	7	6	9
Hidden Units	30	11	75	91
RMSE prueba	3977.91	1.29	0.38	0.87
Variables adicionales utilizadas	WS_ms_top_Avg WinDir_D1_WVT RH10_Avg	WS_ms_top_Avg WinDir_D1_WVT RH10_Avg	WS_ms_top_Avg WinDir_D1_WVT temp10_Avg RH10_Avg	WS_ms_top_Avg temp10_Avg

^a LE (W/m²), FC (mg/m²s), H (W/m²) y PotAir (MPa).

Se utilizaron los meses de mayo y septiembre para el entrenamiento cuyos hiperparámetros resultantes se encuentran en la Tabla 11 y la Tabla 12 respectivamente. Para validar ambos meses se utilizaron los días 24 de mayo (Figura 33 y Figura 34) y 25 de septiembre (Figura 35 y Figura 36).

Tabla 11 *Hiperparámetros para el modelo aplicado al mes de mayo 2018.*

Hiperparámetro	LE	FC	H	PotAir
My Initial Learn Rate	0.0042	0.0033	0.0008	0.0083
Mini Batch Size	39	40	78	41
May training days	15	14	9	14
Hidden layers over	3	2	5	9
Hidden Units	93	99	100	46
RMSE prueba	2073.29	1.91	0.14	0.46
Variables adicionales utilizadas	WinDir_D1_WVT RH10_Avg	WS_ms_top_Avg	RH10_Avg	WS_ms_top_Avg temp10_Avg RH10_Avg

^a LE (W/m²), FC (mg/m²s), H (W/m²) y PotAir (MPa).

Figura 33 Validación del modelo de caja negra para el día 24 de mayo (Parte 1).


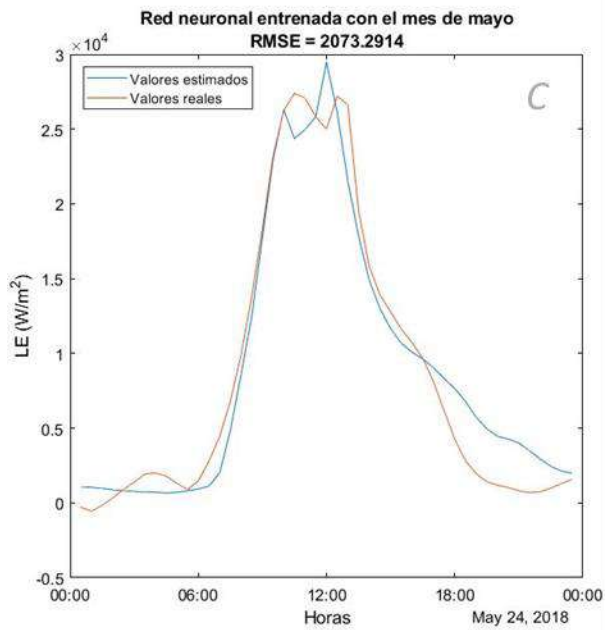




Figura 34 Validación del modelo de caja negra para el día 24 de mayo (Parte 2).

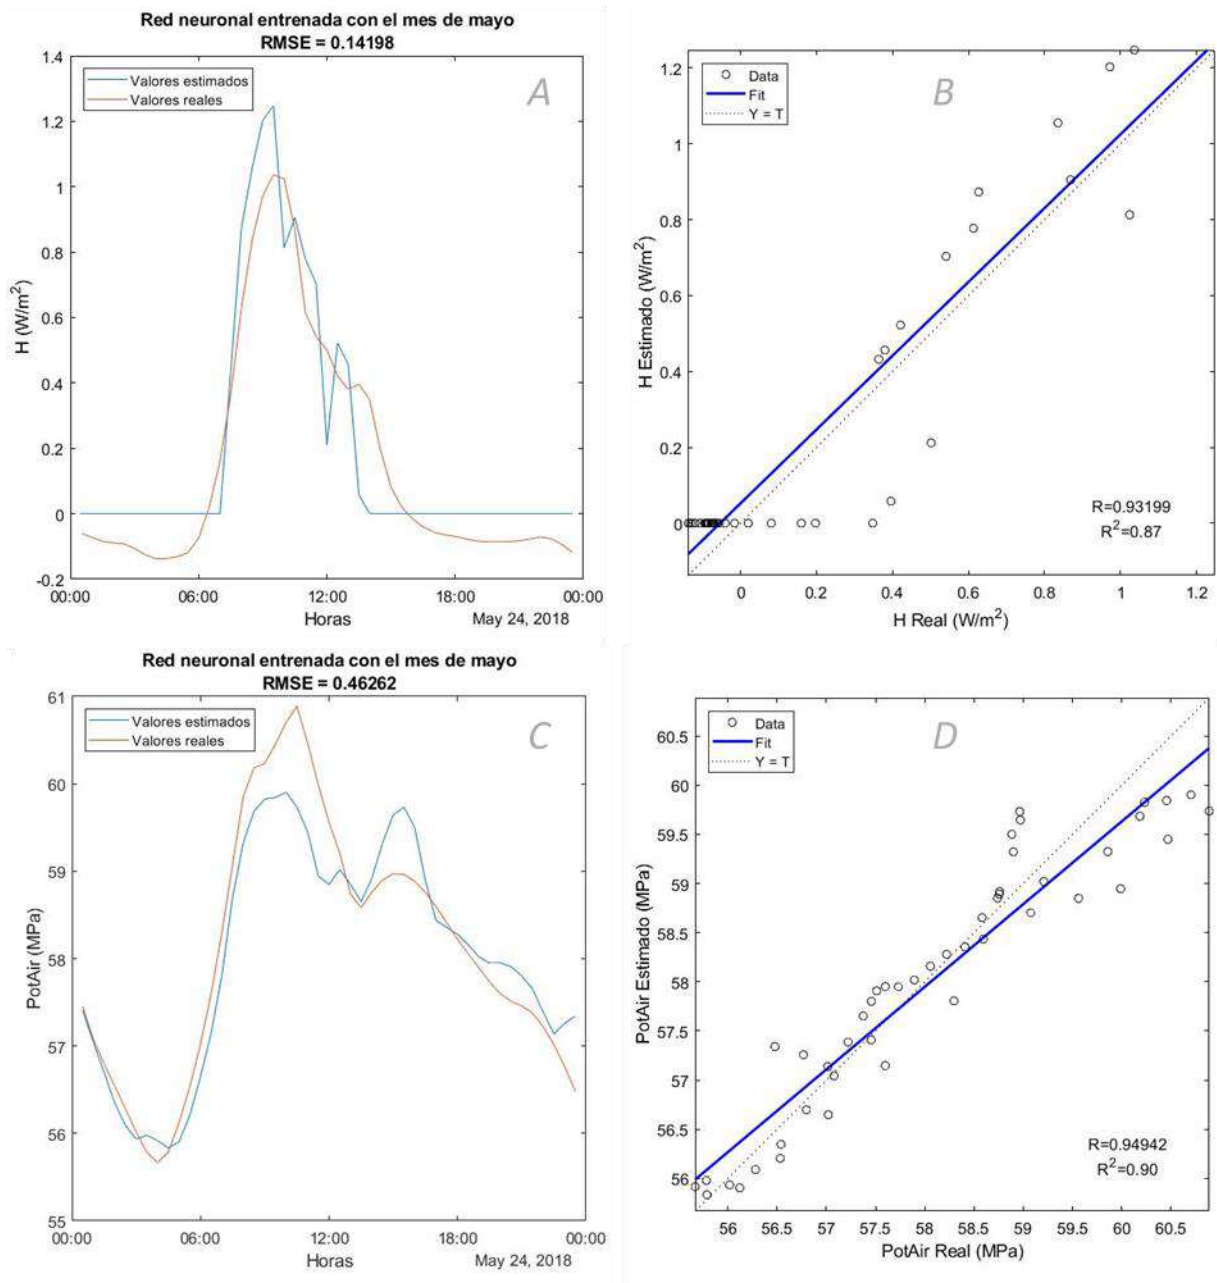


Tabla 12 *Hiperparámetros para el modelo aplicado al mes de septiembre 2018.*

Hiperparámetro	LE	FC	H	PotAir
My Initial Learn Rate	0.0008	0.0098	0.0098	0.0100
Mini Batch Size	27	31	20	38
Sep training days	4	10	6	15
Hidden layers over	8	8	6	9
Hidden Units	10	99	10	40
RMSE prueba	2968.40	1.95	0.44	0.56
Variables adicionales utilizadas	WS_ms_top_Avg WinDir_D1_WVT temp10_Avg RH10_Avg	RH10_Avg	Ninguna	WS_ms_top_Avg WinDir_D1_WVT temp10_Avg RH10_Avg

^a LE (W/m²), FC (mg/m²s), H (W/m²) y PotAir (MPa).

Figura 35 Validación del modelo de caja negra para el día 25 de septiembre (Parte 1).

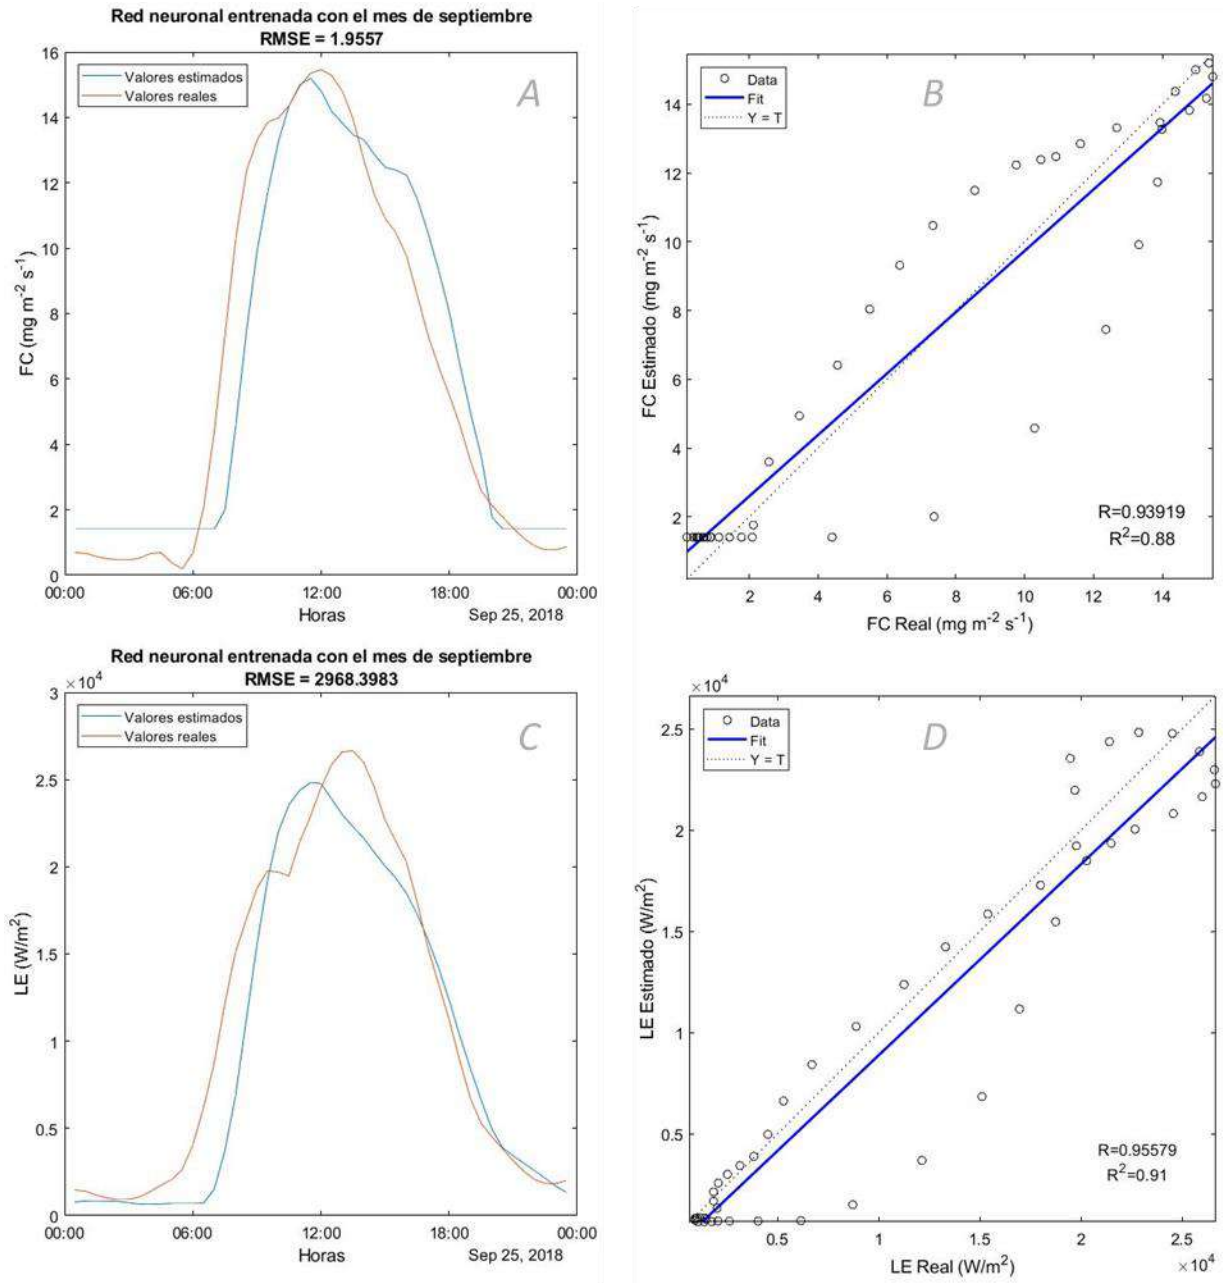
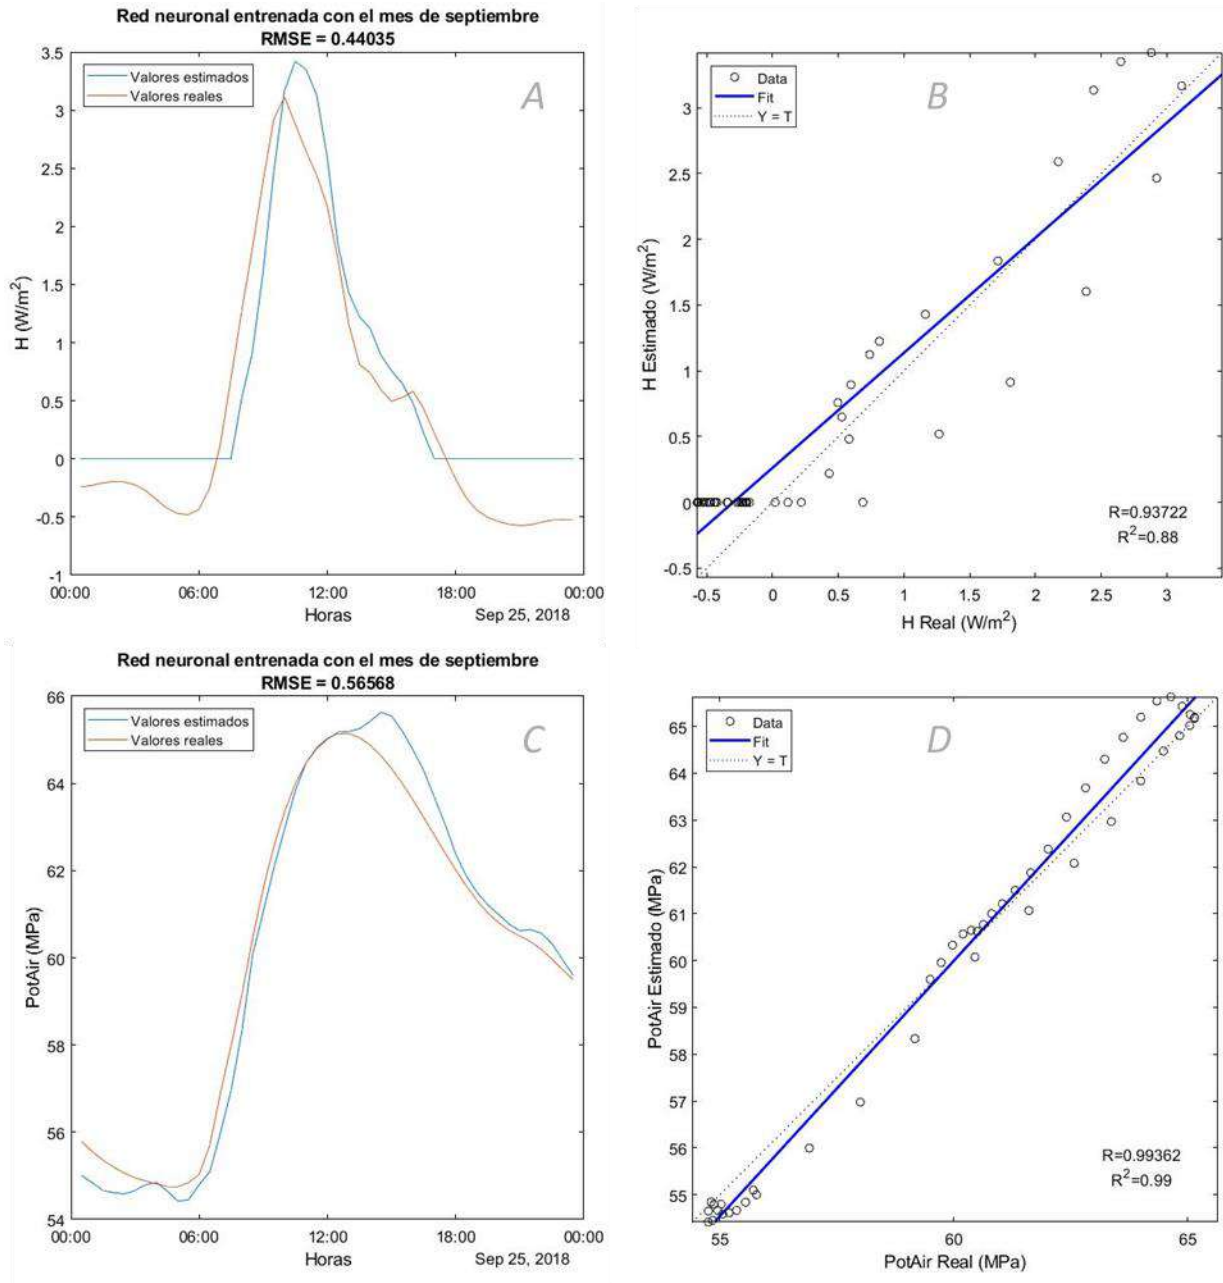


Figura 36 Validación del modelo de caja negra para el día 25 de septiembre (Parte 2).



Capítulo 5: Discusión

El análisis de correlación realizado mostró poca relación entre las variables registradas y los flujos de energía resultantes, solamente el flujo de calor sensible obtuvo una relación significativa con los valores de radiación de onda corta, flujo de calor en el suelo, temperatura sónica y la radiación ascendente de onda larga. Relaciones que cumplieron con la restricción de $R > 0.7$, $\rho > 0.7$ y $p < 0.001$. Se encontraron valores correlación negativa de la radiación ascendente de onda larga, la temperatura sónica y el flujo de calor en el suelo, al relacionarse con la humedad relativa del medio ($R = -0.92$, $R = -0.90$ y $R = -0.81$ respectivamente). Las correlaciones negativas suelen ser un comportamiento común dentro del análisis de flujos en ecosistemas según (Lasslop et al., 2012), donde se analizaba la correlación que existía entre la temperatura en diferentes puntos del bosque (suelo, aire) y el intercambio neto del ecosistema.

(Pérez Sánchez, 2009) realizó un análisis de correlación entre el contenido de CO_2 en el suelo y algunas variables medidas como la presión, temperatura del aire, temperatura del suelo y la velocidad de fricción. Para el estudio realizado, no se observó una correlación significativa entre la presión barométrica y las demás variables registradas, pero si una correlación entre la velocidad de fricción y la velocidad del viento ($R = 0.74$, $p < 0.001$), al igual que en el trabajo de (Anandakumar, 1999), además, de una correlación entre el flujo de calor sensible y la radiación neta.

Los resultados obtenidos para el modelo de caja gris, desde el completo hasta el simplificado, muestra lo que se conoce como “*underfitting*”, donde el modelo no puede replicar el comportamiento de los datos (no tiene suficiente información para describir el sistema).

(Albertson et al., 1995) realizó una aproximación del valor de H en una zona árida, utilizando la teoría de similitud atmosférica para el segundo momento de la temperatura del aire. Los

resultados de su modelo fueron comparados con los cálculos generados por el método Eddy Covariance, cuyo coeficiente R^2 fue de 0.85. (Yao et al., 2014) presentó un registro de comparaciones de LE en diferentes puntos mediante un modelo bayesiano que involucraba cinco algoritmos: espectroradiómetro de imágenes de resolución moderada (MODIS, por sus siglas en inglés), Penman-Monteith para detección remota, Priestley Taylor basado en LE, MS-PT (Modified Satellite-based Priestley Taylor) y el algoritmo semi empírico de Penman para LE., obteniendo valores superiores a 0.7 para el coeficiente R^2 . (Ortega-Farias et al., 2007) utilizó el modelo de Shuttleworth y Wallace (SW) para determinar el valor de LE sobre un viñedo en la región de Maule, Chile. Dicho modelo consistía en combinar dos modelos unidimensionales respecto a la transpiración del cultivo y la evaporación del suelo. Los resultados del modelo SW se compararon con el método de Eddy covariance obteniendo un coeficiente R^2 de 0.77.

Se analizan los modelos antes mencionados, utilizando el coeficiente R^2 para lograr comparar la efectividad de algunos modelos utilizados según la literatura, donde puede observarse que las redes neuronales como método de estimación/predicción resultan ser muy efectivas. En nuestro estudio, las estimaciones de LE ($R^2 > 0.91$), H ($R^2 > 0.86$), FC ($R^2 > 0.88$) y PotAir ($R^2 > 0.88$) representan una predicción bastante ajustada a los datos reales.

Capítulo 6: Conclusiones

Este trabajo propuso la utilización de dos métodos para la estimación de parámetros que simulen el comportamiento del bosque de manglar de la Bahía de Panamá, realizando una revisión bibliográfica sobre los modelos utilizados por otros autores, así como el desarrollo de una metodología para el procesamiento de datos meteorológicos que serían utilizados dentro de la investigación.

El desarrollo de un análisis de correlación entre las variables registradas, se pudo observar significancias solamente con el flujo de calor sensible (H) y el flujo de calor en el suelo. Dentro del periodo de tiempo analizado, no se disponía del sensor que mide la radiación fotosintética activa (PAR), la cual hubiese tenido una correlación directa con FC según la literatura analizada.

El adecuado tratamiento de los datos que se utilizaron fue fundamental para obtener resultados ajustado a la realidad, debido a que los métodos aplicados necesitaban encontrar patrones entre los datos durante el proceso de entrenamiento, para luego predecir el comportamiento durante la validación del modelo. Los datos que son registrados por la torre pueden poseer mediciones erradas debido a presencia de algún fenómeno externo que afecte su calibración. Así mismo, el comportamiento del viento y las condiciones climáticas pueden influir en la presencia de ruido en los datos registrados por lo que se recomienda el procesamiento antes de utilizarlos en el modelo.

Dependiendo del modelo se tienen las siguientes conclusiones:

Modelo de Caja Gris

Se aplicó la analogía de la Ley de Ohm para determinar algunos parámetros característicos del área del estudio como la conductividad hidráulica por árbol ($1/R$) y el almacenamiento de agua (C). El modelo utilizó como variable de entrada el calor latente (LE) registrado por la torre de

medición, y mediante la utilización del software MATLAB se obtenía el desarrollo de las ecuaciones en espacio de estado que indicarían los valores respectivos para las resistencias y capacitancias existentes en el modelo. Realizando las corridas respectivas a cada mes, no se logró obtener valores físicos que representaran el comportamiento de la especie, el sistema requería de más información para lograr la conexión entre los flujos registrados por la torre y las condiciones de la especie seleccionada. Se utilizó la base de datos completa de enero a junio de 2018 y se validó en los días 28 y 29 de agosto, mostrando una mala adaptación a los datos reales. Luego se propuso la utilización de un sistema simplificado, donde se reducía la cantidad de resistencias y capacitancias, así como el agrupar los días dependiendo del comportamiento observado en los datos de LE. Se encontraron 9 comportamientos y se seleccionó el que menos variaciones presentaba, para luego validarlo con los días 11 de mayo y 2 de junio. El modelo mejoró su capacidad de predicción del comportamiento, pero el coeficiente R^2 obtenido seguía siendo bajo (0.37 y 0.43).

Modelo de Caja Negra

Se aplicó un modelo de caja negra, desarrollado mediante la aplicación de redes neuronales utilizando el paquete Deep Learning del software MATLAB. La utilización de las redes neuronales para la predicción de los flujos de energía (LE, H, FC) resultaron sumamente efectivos, obteniendo valores de R^2 mayores a 0.86 en las corridas realizadas en los meses de enero, febrero, mayo y septiembre de 2018.

Trabajos Futuros

- Profundizar en la conceptualización del modelo de caja gris para otros parámetros o métodos que permitan la estimación de los flujos de energía generados por el árbol.
- Considerar un comportamiento no lineal para el modelo de caja gris.

- Levantamiento de datos en campo como:
 - Inventario forestal, estudios fisicoquímicos/suelo, hidroperiodo.
 - Características de la especie *Avicennia bicolor* (conductancia estomática/mesofílica, conductividades hidráulicas, respiración de las hojas, potencial de agua en las hojas/suelo, etc.) que permitan complementar el modelo de caja gris, así como la utilización de otras ecuaciones presentadas en este trabajo.
- Considerar más aspectos geomorfológicos que permitan comprender mejor el comportamiento de los diferentes flujos analizados.
- Extracción de más información mediante el procesamiento de los datos disponibles.
- Aplicar modelos de teledetección para complementar los datos obtenidos mediante el método Eddy Covariance en la zona de estudio.
- Incrementar el análisis de metodologías para el tratamiento de datos meteorológicos.
- Aplicar el modelo de caja negra a otra base de datos para su efectividad en otras condiciones meteorológicas.

Referencias

- Afram, A., & Janabi-Sharifi, F. (2015). Gray-box modeling and validation of residential HVAC system for control system design. *Applied Energy*, *137*, 134–150.
<https://doi.org/https://doi.org/10.1016/j.apenergy.2014.10.026>
- Albertson, J. D., Parlange, M. B., Katul, G. G., Chu, C. -R, Stricker, H., & Tyler, S. (1995). Sensible Heat Flux From Arid Regions: A Simple Flux-Variance Method. *Water Resources Research*, *31*(4), 969–973. <https://doi.org/10.1029/94WR02978>
- Alongi, D. M. (2012). Carbon sequestration in mangrove forests. *Carbon Management*, *3*(3), 313–322. <https://doi.org/10.4155/cmt.12.20>
- Alongi, D. M. (2014). Carbon Cycling and Storage in Mangrove Forests. *Annual Review of Marine Science*, *6*(1), 195–219. <https://doi.org/10.1146/annurev-marine-010213-135020>
- Anandakumar, K. (1999). Sensible heat flux over a wheat canopy: Optical scintillometer measurements and surface renewal analysis estimations. *Agricultural and Forest Meteorology*, *96*(1–3), 145–156. [https://doi.org/10.1016/S0168-1923\(99\)00026-X](https://doi.org/10.1016/S0168-1923(99)00026-X)
- Ávila Hernandez, A. (2019). *Simulación de una vivienda con techo verde y su efecto en el confort térmico*. <https://rinacional.tecnm.mx/handle/TecNM/1374>
- Barr, J. G., Fuentes, J. D., Engel, V., & Zieman, J. C. (2009). Physiological responses of red mangroves to the climate in the Florida Everglades. *Journal of Geophysical Research: Biogeosciences*, *114*(2), 1–13. <https://doi.org/10.1029/2008JG000843>
- Bashir, D., Montañez, G. D., Sehra, S., Segura, P. S., & Lauw, J. (2020). An Information-

Theoretic Perspective on Overfitting and Underfitting. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12576 LNAI, 347–358. https://doi.org/10.1007/978-3-030-64984-5_27

Bayona, C., & Romero, H. M. (2015). *Establecimiento del sistema Eddy Covariance en el cultivo de palma de aceite para cuantificar el rendimiento como sumidero de CO₂*. August, 1–8.
https://www.researchgate.net/publication/340846647_Establecimiento_del_sistema_Eddy_Covariance_en_el_cultivo_de_palma_de_aceite_para_cuantificar_el_rendimiento_como_sumidero_de_CO2

Benfield, S. L., Guzman, H. M., & Mair, J. M. (2005). Temporal mangrove dynamics in relation to coastal development in Pacific Panama. *Journal of Environmental Management*, 76(3), 263–276. <https://doi.org/10.1016/j.jenvman.2005.02.004>

Berthou, T., Stabat, P., Salvazet, R., & Marchio, D. (2014). Development and validation of a gray box model to predict thermal behavior of occupied office buildings. *Energy and Buildings*, 74, 91–100. <https://doi.org/https://doi.org/10.1016/j.enbuild.2014.01.038>

Brastein, O. M., Perera, D. W. U., Pfeifer, C., & Skeie, N. O. (2018). Parameter estimation for grey-box models of building thermal behaviour. *Energy and Buildings*, 169, 58–68.
<https://doi.org/10.1016/j.enbuild.2018.03.057>

Brooks, J., Chen, M. A., Mora, D., & Tejedor-Flores, N. (2021). A critical review on mathematical descriptions to study flux processes and environmental-related interactions of mangroves. *Sustainability (Switzerland)*, 13(12), 1–14. <https://doi.org/10.3390/su13126970>

- Burba, G., & Anderson, D. (2008). A Brief Practical Guide to Eddy covariance CO₂ flux measurements. In *Ecological applications : a publication of the Ecological Society of America* (Vol. 18, Issue 6). <http://www.ncbi.nlm.nih.gov/pubmed/18767616>
- Campbell, G. S. (1985). *Soil physics with BASIC : transport models for soil-plant systems*. Elsevier.
- Campbell, G. S., & Norman, J. M. (1977). An Introduction to Environmental Biophysics. In *Journal of Environmental Quality* (Vol. 6, Issue 4). <https://doi.org/10.2134/jeq1977.00472425000600040036x>
- CARBORED-II. (2010). *Red de monitorización de los flujos de carbono en ecosistemas mediterráneos Españoles, Cuantificación y estudio de procesos*. <http://www.ceam.es/CARBOREDII/paginas/metodos.htm>
- Cardona, J. P., Leal, J. J., & Ustariz, J. E. (2020). Mathematical modeling of white and black box in engineering education. *Formacion Universitaria*, 13(6), 105–118. <https://doi.org/10.4067/S0718-50062020000600105>
- Carrasco, O. (2018). *Tesis Doctoral Transporte de agua en plantas . El balance hídrico en tallos de árboles nativos del norte de Argentina : uso e importancia de los reservorios internos de agua*.
- Castro, M. (2019). *Derretimiento de los polos: evolución, causas, consecuencias, soluciones - Lifeder*. <https://www.lifeder.com/derretimiento-de-los-polos/>
- Chatting, M., LeVay, L., Walton, M., Skov, M. W., Kennedy, H., Wilson, S., & Al-Maslamani,

- I. (2020). Mangrove carbon stocks and biomass partitioning in an extreme environment. *Estuarine, Coastal and Shelf Science*, 244. <https://doi.org/10.1016/j.ecss.2020.106940>
- Clough, B. F., Dixon, P., & Dalhaus, O. (1997). Allometric relationships for estimating biomass in multi-stemmed mangrove trees. *Australian Journal of Botany*, 45(6), 1023–1031. <https://doi.org/10.1071/BT96075>
- Colombo, R., Marín, O., Irazábal, S., & Tezara, W. (2007). Relaciones hídricas, fotosíntesis, y anatomía foliar de dos especies del género *Calotropis*. *Interciencia*, 32(11), 791–796.
- Columbia Engineering. (n.d.). *Artificial Intelligence (AI) vs. Machine Learning | Columbia AI*. Retrieved May 26, 2022, from <https://ai.engineering.columbia.edu/ai-vs-machine-learning/>
- da Motta Portillo, J. T., Londe, V., & Moreira, F. W. A. (2017). Aboveground biomass and carbon stock are related with soil humidity in a mangrove at the Piraquê-Açu River, Southeastern Brazil. *Journal of Coastal Conservation*, 21(1), 139–144. <https://doi.org/10.1007/s11852-016-0482-4>
- Das, S., & Crépin, A. S. (2013). Mangroves can provide protection against wind damage during storms. *Estuarine, Coastal and Shelf Science*, 134(October 1999), 98–107. <https://doi.org/10.1016/j.ecss.2013.09.021>
- Defew, L. H., Mair, J. M., & Guzman, H. M. (2005). An assessment of metal contamination in mangrove sediments and leaves from Punta Mala Bay, Pacific Panama. *Marine Pollution Bulletin*, 50(5), 547–552. <https://doi.org/10.1016/j.marpolbul.2004.11.047>
- Design and run experiments to train and compare deep learning networks - MATLAB -*

MathWorks América Latina. (n.d.). Retrieved March 14, 2022, from <https://la.mathworks.com/help/deeplearning/ref/experimentmanager-app.html>

Domínguez, M., & Martínez, P. (2019). Beneficios ambientales usos forestales maderables y no maderables del manglar en la planicie costera. *Research Gate, June*, 243–247.

Duke, N. (2010). *Avicennia bicolor*. <https://www.iucnredlist.org/es/species/178847/7625682>

Edwards, W. R. N., Jarvis, P. G., Landsberg, J. J., & Talbot, H. (1986). A dynamic model for studying flow of water in single trees. *Tree Physiology, 1*(3), 309–324.

<https://doi.org/10.1093/treephys/1.3.309>

El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? In I. El Naqa, R. Li, & M. J. Murphy (Eds.), *Machine Learning in Radiation Oncology: Theory and Applications* (pp. 3–11). Springer International Publishing. https://doi.org/10.1007/978-3-319-18305-3_1

FAO. (2007). The world's mangroves 1980-2005. *FAO Forestry Paper, 153*, 89.

<https://doi.org/978-92-5-105856-5>

FAO. (2011). Introducción a la evapotranspiración del cultivo. *Evapotranspiración Del Cultivo Guías Para La Determinación de Los Requerimientos de Agua de Los Cultivos. ESTUDIO FAO RIEGO Y DRENAJE 56.*, 323.

Fiscus, E. L., Klute, A., & Kaufmann, M. R. (1983). An Interpretation of Some Whole Plant Water Transport Phenomena. *Plant Physiology, 71*(4), 810–817.

<https://doi.org/10.1104/pp.71.4.810>

Früh, T., & Kurth, W. (1999). The hydraulic system of trees: Theoretical framework and

numerical simulation. *Journal of Theoretical Biology*, 201(4), 251–270.

<https://doi.org/10.1006/jtbi.1999.1028>

García-González, L., & González-Santos, A. I. (2020). Desarrollo de un modelo de caja gris para el caso base de la planta Tennessee Eastman. *Revista Ingeniería Electrónica, Automática y Comunicaciones ISSN: 1815-5928*, 41(1), 18–33.

Gómez, L. F., Montoya, E. C., López, Y., & Riaño, N. M. (2001). Estimación de la fotosíntesis en plantas completas y validación de un modelo matemático para el cafeto /*Coffea arabica*/ L. *Simposio Internacional Medición y Monitoreo de La Captura de Carbono En Ecosistemas Forestales*, 1–18.

González, J., Tejedor-flores, N., & Franco, A. (2020). Cuantificación de flujos de CO₂ en un ecosistema de manglar en la Bahía de Panamá. In *Políticas públicas territoriales y desarrollo regional* (pp. 243–256).

https://cihh.utp.ac.pa/sites/default/files/documentos/2021/pdf/cap_xiv_cuantificacion.pdf

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. In *Nature* (Vol. 26, Issue 7553). MIT Press.

Guzmán, H. M., Barnes, P. A. G., Lovelock, C. E., & Feller, I. C. (2005). A site description of the CARICOMP mangrove, seagrass and coral reef sites in Bocas del Toro, Panama. *Caribbean Journal of Science*, 41(3), 430–440.

Haykin, S. (1999). *Neural Networks: A comprehensive foundation*. Prentice Hall.

Hölttä, T., Vesala, T., Sevanto, S., Perämäki, M., & Nikinmaa, E. (2006). Modeling xylem and

phloem water flows in trees according to cohesion theory and Münch hypothesis. *Trees - Structure and Function*, 20(1), 67–78. <https://doi.org/10.1007/s00468-005-0014-6>

Hoyos-Santillan, J., Lomax, B. H., Large, D., Turner, B. L., Boom, A., Lopez, O. R., & Sjögersten, S. (2015). Getting to the root of the problem: litter decomposition and peat formation in lowland Neotropical peatlands. *Biogeochemistry*, 126(1–2), 115–129. <https://doi.org/10.1007/s10533-015-0147-7>

Hoyos-Santillan, J., Lomax, B. H., Large, D., Turner, B. L., Boom, A., Lopez, O. R., & Sjögersten, S. (2016). Quality not quantity: Organic matter composition controls of CO₂ and CH₄ fluxes in neotropical peat profiles. *Soil Biology and Biochemistry*, 103, 86–96. <https://doi.org/10.1016/j.soilbio.2016.08.017>

Hoyos-Santillan, J., Lomax, B. H., Large, D., Turner, B. L., Lopez, O. R., Boom, A., Sepulveda-Jauregui, A., & Sjögersten, S. (2019). Evaluation of vegetation communities, water table, and peat composition as drivers of greenhouse gas emissions in lowland tropical peatlands. *Science of the Total Environment*, 688, 1193–1204. <https://doi.org/10.1016/j.scitotenv.2019.06.366>

Hoyos, R. G., Estela Urrego, L. G., & Lema, Á. T. (2013). Respuesta de la regeneración natural en manglares del Golfo de Urabá (Colombia) a la variabilidad ambiental y climática intra-anual. In *Rev. Biol. Trop. (Int. J. Trop. Biol. ISSN (Vol. 61, Issue 3)*.

Ishida, A., Yamamura, Y., & Hori, Y. (1992). Roles of leaf water potential and soil-to-leaf hydraulic conductance in water use by understorey woody plants. *Ecological Research*, 7(3), 213–223. <https://doi.org/10.1007/BF02347090>

- Jacobs, C. M. J., Van Den Hurk, B. J. J. M., & De Bruin, H. A. R. (1996). Stomatal behaviour and photosynthetic rate of unstressed grapevines in semi-arid conditions. *Agricultural and Forest Meteorology*, 80(2–4), 111–134. [https://doi.org/10.1016/0168-1923\(95\)02295-3](https://doi.org/10.1016/0168-1923(95)02295-3)
- Jara-Rojas, F., Ortega-Farías, S., Valdés-Gómez, H., Poblete, C., & del Pozo, A. (2009). Model Validation for Estimating the Leaf Stomatal Conductance in cv. Cabernet Sauvignon Grapevines. *Chilean Journal of Agricultural Research*, 69(1), 88–96. <https://doi.org/10.4067/s0718-58392009000100011>
- Jiménez, J. A. (1990). *The Structure and Function of Dry Weather Mangroves on the Pacific Coast of Central America , with Emphasis on A vicennia bicolor Forests*. 13(2), 182–192.
- Jiménez, J. A. (1999). El Manejo de los Manglares en el Pacífico de Centroamérica: Usos Tradicionales y Potenciales. *Spring*, 275–290.
- Jiménez, J. A., & Sauter, K. (1991). Structure and dynamics of mangrove forests along a flooding gradient. *Estuaries*, 14(1), 49–56. <https://doi.org/10.2307/1351981>
- Jones, H. G. (2013). Plants and microclimate: A quantitative approach to environmental plant physiology. In *Plants and Microclimate: A Quantitative Approach to Environmental Plant Physiology* (Vol. 9780521279). <https://doi.org/10.1017/CBO9780511845727>
- Juárez, F. R. (2009). *Modelado por elementos finitos del tronco de un árbol: Comportamiento mecanico de xilema, floema y corteza*.
- Keeling, C. D., Whorf, T. P., Wahlen, M., & van der Plichtt, J. (1995). Interannual extremes in the rate of rise of atmospheric carbon dioxide since 1980. *Nature*, 375(6533), 666–670.

<https://doi.org/10.1038/375666a0>

Kelleway, J. J., Saintilan, N., Macreadie, P. I., Skilbeck, C. G., Zawadzki, A., & Ralph, P. J. (2016). Seventy years of continuous encroachment substantially increases “blue carbon” capacity as mangroves replace intertidal salt marshes. *Global Change Biology*, 22(3), 1097–1109. <https://doi.org/10.1111/gcb.13158>

Kumagai, T. (2001). Modeling water transportation and storage in sapwood - Model development and validation. *Agricultural and Forest Meteorology*, 109(2), 105–115. [https://doi.org/10.1016/S0168-1923\(01\)00261-1](https://doi.org/10.1016/S0168-1923(01)00261-1)

Lasslop, G., Migliavacca, M., Bohrer, G., Reichstein, M., Bahn, M., Ibrom, A., Jacobs, C., Kolari, P., Papale, D., Vesala, T., Wohlfahrt, G., & Cescatti, A. (2012). On the choice of the driving temperature for eddy-covariance carbon dioxide flux partitioning. *Biogeosciences*, 9(12), 5243–5259. <https://doi.org/10.5194/bg-9-5243-2012>

Launiainen, S., Rinne, J., Pumpanen, J., Kulmala, L., Kolari, P., Keronen, P., Siivola, E., Pohja, T., Hari, P., & Vesala, T. (2005). Eddy covariance measurements of CO₂ and sensible and latent heat fluxes during a full year in a boreal pine forest trunk-space. *Boreal Environment Research*, 10(6), 569–588.

Lefevre, C., Rekik, F., Alcantara, V., & Wiese, L. (2017). *Potencial Oculito*. <http://www.fao.org/3/b-i6937s.pdf>

Lin, B. B., & Dushoff, J. (2004). Mangrove filtration of anthropogenic nutrients in the Rio Coco Solo, Panama. *Management of Environmental Quality: An International Journal*, 15(2), 131–142. <https://doi.org/10.1108/14777830410523071>

- Ljung, L. (2010). Approaches to identification of nonlinear systems. *Proceedings of the 29th Chinese Control Conference, CCC'10, August 2010*, 1–5.
- Lovelock, C. E., Feller, I. C., McKee, K. L., & Thompson, R. (2005). Variation in mangrove forest structure and sediment characteristics in Bocas del Toro, Panama. *Caribbean Journal of Science*, 41(3), 456–464.
- Maren, A. J., Harston, C. T., & Pap, R. M. (1990). *Handbook of neural computing applications*. Academic Press.
- Marín, A. M. C., Herrera, N. M. R., Quiñones, A. J. P., Builes, V. H. R., Salazar, A. V., Casas, A. F., & Vinasco, G. A. G. (2017). Energy, water vapor and carbon fluxes in Andean agroecosystems: Conceptualization and methodological standardization. *Acta Agronomica*, 66(1), 27–34. <https://doi.org/10.15446/acag.v66n1.52543>
- Mauricio Betancourt-Portela, J., Pablo Parra, J., & Villamil, C. (2013). EMISIÓN DE METANO Y ÓXIDO NITROSO DE LOS SEDIMENTOS DE MANGLAR DE LA CIÉNAGA GRANDE DE SANTA MARTA, CARIBE COLOMBIANO*. *Boletín de Investigaciones Marinas y Costeras*, 42, 131–152.
- Mazda, Y., & Wolanski, E. (2009). Hydrodynamics and Modeling of Water Flow in Mangrove Areas. In *Coastal Wetlands: An Integrated Ecosystem Approach* (First edit, Issue August). Elsevier. <https://doi.org/10.1016/B978-0-444-53103-2.00008-9>
- McGowan, T., Cunningham, S. L., Guzmán, H. M., Mair, J. M., Guevara, J. M., & Betts, T. (2010). Mangrove forest composition and structure in Las Perlas archipelago, pacific Panama. *Revista de Biología Tropical*, 58(3), 857–869.

<https://doi.org/10.15517/rbt.v58i2.5251>

Mohd Zaki, N. A., Abd Latif, Z., Suratman, M. N., & Zainal, M. Z. (2016). Aboveground biomass and carbon stocks modelling using non-linear regression model. *IOP Conference Series: Earth and Environmental Science*, 37(1). <https://doi.org/10.1088/1755-1315/37/1/012030>

Mosquera-Sánchez, L., Riaño-Herrera, N., Arcila-Pulgarín, J., & Ponce-Dávila, C. A. (1999). FOTOSÍNTESIS, RESPIRACIÓN Y FOTORRESPIRACIÓN EN HOJAS DE CAFÉ *Coffea sp. Cenicafé*, 50(3), 215–221.

Ortega-Farias, S., Carrasco, M., Oliosio, A., Acevedo, C., & Poblete, C. (2007). Latent heat flux over Cabernet Sauvignon vineyard using the Shuttleworth and Wallace model. *Irrigation Science*, 25(2), 161–170. <https://doi.org/10.1007/s00271-006-0047-7>

Ortiz, E. Y., Jimenez, R., Fochesatto, G. J., & Morales-Rincon, L. A. (2019). Caracterización de la turbulencia atmosférica en una gran zona verde de una megaciudad andina tropical. *Revista de La Academia Colombiana de Ciencias Exactas, Físicas y Naturales*, 43(166), 133. <https://doi.org/10.18257/raccefyn.697>

Patricia, L., & Rojas, L. (2011). *PAPEL DE LOS MICROORGANISMOS PLANCTÓNICOS EN EL FLUJO DE CARBONO EN UNA REGIÓN DE SURGENCIA FRENTE A LA COSTA NORTE DE BAJA CALIFORNIA, MÉXICO* [UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA]. <https://repositorioinstitucional.uabc.mx/bitstream/20.500.12930/198/1/ENS068564.pdf>

Pérez Sánchez, E. (2009). *Comportamiento de los flujos gaseosos de CO₂ en el suelo de un*

ecosistema kárstico . Factores que Índice Introducción Resultados.

Prasanna, J., Anand, M., Vijayasekaran, D., & Kumaraguru, A. K. (2017). Allometric model for estimating above ground biomass and carbon storage in Karankadu mangrove swamp, Palk bay, Southeast coast of India. *Indian Journal of Geo-Marine Sciences*, 46(8), 1682–1692.

<https://www.scopus.com/inward/record.uri?eid=2-s2.0->

[85026800757&partnerID=40&md5=5019f96d34fd4e9dae4f65964c79b663](https://www.scopus.com/inward/record.uri?eid=2-s2.0-85026800757&partnerID=40&md5=5019f96d34fd4e9dae4f65964c79b663)

Ray, R., Ganguly, D., Chowdhury, C., Dey, M., Das, S., Dutta, M. K., Mandal, S. K., Majumder, N., De, T. K., Mukhopadhyay, S. K., & Jana, T. K. (2011). Carbon sequestration and annual increase of carbon stock in a mangrove forest. *Atmospheric Environment*, 45(28), 5016–

5024. <https://doi.org/10.1016/j.atmosenv.2011.04.074>

Reverter, B. R. (2008). *Procesamiento y QC/QA de datos micrometeorológicos.*

<https://www.ugr.es/~andyk/Theses/TesisMTAF.pdf>

Reynders, G., Diriken, J., & Saelens, D. (2014). Quality of grey-box models and identified parameters as function of the accuracy of input and observation signals. *Energy and Buildings*, 82, 263–274. <https://doi.org/10.1016/j.enbuild.2014.07.025>

[https://doi.org/https://doi.org/10.1016/j.enbuild.2014.07.025](https://doi.org/10.1016/j.enbuild.2014.07.025)

Richter, O., Nguyen, H. A., & Nguyen, V. P. (2013). *Modeling Phytoremediation by Mangroves.*

1–5.

Ríos, A. (2004). Captación de CO₂ antropogénico en el atlántico. *Udc.Es*, 1–13.

http://www.udc.es/iuem/documentos/doc_xornadas/cambioclimatico/aidafdez.pdf

Rodríguez-Rodríguez, J. A., Mancera-Pineda, J. E., & Rodríguez-P., J. M. (2016). Validación y

aplicación de un modelo de restauración de manglar basado en individuos para tres especies en la Ciénaga Grande de Santa Marta. *Caldasia*, 38(2), 285–299.

<https://doi.org/10.15446/caldasia.v38n2.55360>

Serrano-Ortiz P, K. A. S. y A.-A. L. (2006). La técnica eddy covariance como herramienta para la determinación de la capacidad de asimilación de CO₂ de un ecosistema The eddy covariance technique : a tool to quantify ecosystem CO₂ exchanges. *Acta Granatense*, 4/5, 95–106.

Siegenthaler, U., & Sarmiento, J. L. (1993). Atmospheric carbon dioxide and the ocean. *Nature*, 365(6442), 119–125. <https://doi.org/10.1038/365119a0>

Simpson, L. T., Stein, C. M., Osborne, T. Z., & Feller, I. C. (2019). Mangroves dramatically increase carbon storage after 3 years of encroachment. *Hydrobiologia*, 834(1), 13–26. <https://doi.org/10.1007/s10750-019-3905-z>

Sjögersten, S., Black, C. R., Evers, S., Hoyos-Santillan, J., Wright, E. L., & Turner, B. L. (2014). Tropical wetlands: A missing link in the global carbon cycle? *Global Biogeochemical Cycles*. <https://doi.org/10.1002/2014GB004844>

Sjögersten, S., de la Barreda-Bautista, B., Brown, C., Boyd, D., Lopez-Rosas, H., Hernández, E., Monroy, R., Rincón, M., Vane, C., Moss-Hayes, V., Gallardo-Cruz, J. A., Infante-Mata, D., Hoyos-Santillan, J., Vidal Solórzano, J., Peralta-Carreta, C., & Moreno-Casasola, P. (2021). Coastal wetland ecosystems deliver large carbon stocks in tropical Mexico. *Geoderma*, 403(April). <https://doi.org/10.1016/j.geoderma.2021.115173>

Sperry, J. (2000). Hydraulic constraints on plant gas exchange. *Agricultural and Forest*

Meteorology, 104(1), 13–23. [https://doi.org/10.1016/S0168-1923\(00\)00144-1](https://doi.org/10.1016/S0168-1923(00)00144-1)

Sperry, J. S., Adler, F. R., Campbell, G. S., & Comstock, J. P. (1998). Limitation of plant water use by rhizosphere and xylem conductance: Results from a model. *Plant, Cell and Environment*, 21(4), 347–359. <https://doi.org/10.1046/j.1365-3040.1998.00287.x>

Stella, J. M., & Warner, G. S. (2018). Modelling a hydrologic Black-Box. *Tecnología y Ciencias Del Agua*, 9(1), 101–112. <https://doi.org/10.24850/j-tyca-2018-01-07>

Stroock, A. D., Pagay, V. V., Zwieniecki, M. A., & Holbrook, N. M. (2014). The physicochemical hydrodynamics of vascular plants. *Annual Review of Fluid Mechanics*, 46, 615–642. <https://doi.org/10.1146/annurev-fluid-010313-141411>

Tovar Jiménez, E. I. (2018). Aportación De Las Cubiertas Verdes Al Desempeño Térmico De Las Envolventes Arquitectónicas, Mediante El Uso De Diferentes Arreglos Constructivos De Vegetación Nativa De México. *División De Ciencias Y Artes Para El Diseño*, 120. <http://zaloamati.azc.uam.mx/handle/11191/6677>

Tyree, M. T., & Ewers, F. W. (1991). The hydraulic architecture of trees and other woody plants. *New Phytologist*, 119(3), 345–360. <https://doi.org/10.1111/j.1469-8137.1991.tb00035.x>

Tyree, M. T., & Sperry, J. S. (1988). Do Woody Plants Operate Near the Point of Catastrophic Xylem Dysfunction Caused by Dynamic Water Stress? *Plant Physiology*, 88(3), 574–580. <https://doi.org/10.1104/pp.88.3.574>

Uddin Farooqui, N., & B. S. Dangi, C. (2017). Taxonomic Diversity of Mangroves: Analysis of Morphological Characteristics in Different Ecological Niches. *Biosciences, Biotechnology*

Research Asia, 14(1), 161–166. <https://doi.org/10.13005/bbra/2431>

Velázquez-Pérez, C., Tovilla-Hernández, C., Romero-Berny, E. I., & De Jesús-Navarrete, A. (2019). Mangrove structure and its influence on the carbon storage in La Encrucijada Reserve, Chiapas, Mexico. *Madera y Bosques*, 25(3), 1–14. <https://doi.org/10.21829/myb.2019.2531885>

Vide, J. (2020). El cambio climático y los mares. *Mediterráneo Económico*, 33, 103–118. <https://dialnet.unirioja.es/servlet/articulo?codigo=7663538>

Villalobos-Arias, L., Quesada-López, C., Martínez, A., & Jenkins, M. (2021). *Técnicas de ajuste de hiperparámetros de algoritmos de aprendizaje automático para la estimación de esfuerzo: un mapeo de literatura*. 305–318. <https://tinyurl.com/y5z7kcuc>.

Vinh, T. V., Marchand, C., Linh, T. V. K., Vinh, D. D., & Allenbach, M. (2019). Allometric models to estimate above-ground biomass and carbon stocks in *Rhizophora apiculata* tropical managed mangrove forests (Southern Viet Nam). *Forest Ecology and Management*, 434, 131–141. <https://doi.org/10.1016/j.foreco.2018.12.017>

Vogel, S. (2018). *La vida secreta de una hoja*.

Yao, Y., Liang, S., Li, X., Yang, H., Fisher, J. B., Zhang, N., Chen, J., Cheng, J., Zhao, S., Zhang, X., Jiang, B., Sun, L., Jia, K., Wang, K., Chen, Y., Mu, Q., & Feng, F. (2014). Bayesian multimodel estimation of global terrestrial latent heat flux from eddy covariance, meteorological, and satellite observations. *Journal of Geophysical Research*, 3, 6578–6595. <https://doi.org/10.1002/2013JD020864>. Received

Zermeño-González, A., Flores-Guerrero, J. A., Munguía-López, J. P., Gil-Marín, J. A.,

Rodríguez-García, R., Catalán-Valencia, E. A., Ibarra-Jiménez, L., & Zermeño-González,

H. (2010). Evapotranspiración y su relación con la evapotranspiración a equilibrio de una

huerta de nogal pecanero (*Carya illinoensis*) del norte de México. *Agrociencia*, *44*(8),

885–893.