



INSTITUTO MEXICANO DE TECNOLOGÍA DEL AGUA
COORDINACIÓN DE DESARROLLO PROFESIONAL E INSTITUCIONAL
SUBCOORDINACIÓN DE POSGRADO

TESIS
ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN
DE CULTIVO DE MAÍZ BAJO RIEGO MEDIANTE
PERCEPCIÓN REMOTA

que para obtener el grado de
Maestro en
Ciencias y Tecnología del Agua

presenta
Braulio Antonio Vázquez Rodríguez

Tutor: Dr. Ronald Ernesto Ontiveros Capurata

Con fundamento en los artículos 21 y 27 de la Ley Federal del Derecho de Autor y como titular de los derechos moral y patrimoniales de la obra titulada “ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE CULTIVO DE MAÍZ BAJO RIEGO MEDIANTE PERCEPCIÓN REMOTA”, otorgo de manera gratuita y permanente al Instituto Mexicano de Tecnología del Agua, autorización para que fijen la obra en cualquier medio, incluido el electrónico, y la divulguen entre su personal, estudiantes o terceras personas, sin que pueda percibir por tal divulgación una contraprestación.

Braulio Antonio Vázquez Rodríguez

Jiutepec, Morelos a 26 de febrero de 2019

Dedicatoria

A mis padres, familia, amigos y todo aquel interesado en los temas que se tratan en el presente trabajo.

Agradecimientos

Al Instituto Mexicano de Tecnología del Agua, por ofrecerme la oportunidad de profundizar mis estudios y prepararme académicamente; al Dr. Ronald Ontiveros Capurata, por su confianza y por compartirme sus conocimientos, fundamentos necesarios para la elaboración de este trabajo. A los sinodales por su valiosa retroalimentación.

Índice

1. Introducción	1
1.1 Antecedentes	3
1.2 Planteamiento del problema	4
1.3 Justificación	5
1.4 Objetivos	6
1.4.1 General	6
1.4.2 Específico	6
1.5 Hipótesis	7
2. Marco Teórico	8
2.1 El espectro electromagnético solar	8
2.2 Percepción Remota	12
2.2.1 Sistemas satelitales de adquisición mediante sensores remotos	13
2.2.2 Satélites Terrestres de la Serie LANDSAT	14
2.3 Respuesta espectral de la vegetación	17
2.4 Modelos de balance de energía basados en percepción remota	19
2.4.1 Algoritmo de balance de energía en superficie (SEBAL)	21
2.4.2 Algoritmo con calibración interna (METRIC)	22
2.5 Requerimientos hídricos de cultivo	24
2.5.1 Evapotranspiración de cultivo	25
2.5.2 Modelo de Penman-Monteith	28
3. Evapotranspiración de cultivo por un modelo de balance de energía	30
3.1 Introducción	30
3.2 Materiales y métodos	32
3.2.1 Ubicación de la zona de estudio	32
3.2.2 Bancos de información de la zona de estudio	33
3.2.3 Corrección y calibración de imágenes LANDSAT	37
3.2.4 Modelos de balance de energía de la zona de estudio	39
3.3 Resultados	49
3.3.1 Comparación entre los modelos de balance de energía	50
3.3.2 Calibración y validación de un modelo de balance de energía	51
3.3.3 Variabilidad espacio-temporal de ET_c	56
3.4 Conclusiones	62

4. Evapotranspiración de cultivo de maíz estimado mediante índices espectrales	64
4.1 Introducción	64
4.2 Materiales y métodos	65
4.2.1 Bancos de información	65
4.2.2 Índices espectrales relacionados a la ET_c	66
4.2.3 Índice de vegetación de diferencia normalizada (NDVI)	68
4.2.4 Índice de vegetación mejorado (EVI)	69
4.2.5 Índice de vegetación ajustado al suelo (SAVI)	69
4.2.6 Índice de área foliar (LAI)	70
4.2.7 Índice de vegetación senescente de diferencia normalizada (NDSVI)	71
4.2.8 Índices de labranza (STI, NDTI)	72
4.2.9 Índices de agua de diferencia normalizada (NDWI, ENDWI)	73
4.2.10 Índices de deficiencia de humedad (MSI, EMSI)	74
4.2.11 Índice de estrés hídrico (DSWI)	75
4.2.12 Índices de sequía de diferencia normalizada (NDDI, ENDDI)	76
4.2.13 Índices de cobertura de residuos de cultivo (CRC1, MCRC, SRNDI)	77
4.2.14 Índices de vegetación térmico (VIT, NBRT)	78
4.3 Resultados	80
4.3.1 Análisis de los índices espectrales	80
4.3.2 Estimación de la ET_c de maíz mediante índices espectrales	83
4.4 Conclusiones	91
5. Conclusiones generales	93

Anexos

Bibliografía y referencias

Índice de figuras y tablas

Figuras

- Figura 2.1. Componentes de la radiación electromagnética (modificada de Campbell, 2011), p. 9.
- Figura 2.2. Aproximación de la respuesta energética de la irradiancia solar en la superficie terrestre por longitud de onda., p. 12.
- Figura 2.3. Representación conceptual de un sistema de percepción remota y sus componentes: energía, fuente y sensor, modificada de Curran (1985), p. 13.
- Figura 2.4. Comparación de las bandas espectrales (1-11) de los sistemas *LANDSAT* (NASA, 2018), p. 15.
- Figura 2.5. Factores ambientales caracterizables mediante sensores remotos, modificada de Lein (2012), p. 17.
- Figura 2.6. Reflectancia espectral de distintos materiales (modificada de Hou et al., 2016), p. 18.
- Figura 2.7. Modelo conceptual del balance de energía para un sistema suelo-planta, modificada de Waters et al., (2002), p. 21.
- Figura 2.8. Fenómenos que intervienen en el balance hídrico, modificada de Allen et al. (2006), p. 25.
- Figura 2.9. Representación conceptual de la evolución de K_c en diferentes etapas fisiológicas de un cultivo, modificada de Allen et al. (2006), p. 26.
- Figura 2.10. Modelo conceptual de la relación ET_c , ET_0 y K_c , modificada de Allen et al. (2006), p. 27.
- Figura 2.11. Modelo conceptual de las componentes de la resistencia aerodinámica sobre una superficie agrícola, modificada de Allen et al. (1998), p. 28.
- Figura 3.1. Mapa de localización de la zona de estudio; norte de Sinaloa (UTM, 12N), p. 32.
- Figura 3.2. Número de imágenes por sensor *LANDSAT*, p. 33.
- Figura 3.3. Distribución anual del número de imágenes obtenidas por tipo de sensor *LANDSAT*, p. 35.
- Figura 3.4. Distribución mensual del número de imágenes obtenidas, p. 35.
- Figura 3.5. Croquis de ubicación de las estaciones climáticas utilizadas en el análisis, p. 36.
- Figura 3.6. Proceso de cálculo del flujo de calor sensible (H), modificada de Chemin y Din Ahmad (2000), p. 47.
- Figura 3.7. Serie completa del modelo A, ET_c media en la zona de estudio., p. 50.
- Figura 3.8. Comparación en series de tiempo de modelos A y B (*EEFLUX*), y representación gráfica de sus residuos, p. 51.
- Figura 3.9. Distribución de frecuencias de ET_c por mes: A es el modelo en estudio y B el modelo *EEFLUX*., p. 52.
- Figura 3.10. Modelos de calibración del modelo A; A es el modelo en estudio y B el modelo *EEFLUX*, p. 54.
- Figura 3.11. Modelos de validación del modelo A; A es el modelo en estudio y B el modelo *EEFLUX*, p. 56.
- Figura 3.12. Variabilidad espacial de ET_c [mm/d], (a) Media absoluta de ET_c , (b) Desviación estándar de ET_c , (c) Mínima absoluta de ET_c , (d) Máxima absoluta de ET_c ., p. 57.
- Figura 3.13. Serie anual y tendencia de ET_c media para la zona de estudio, p. 58.
- Figura 3.14. Mapas anuales de la zona de estudio de ET_c media [mm/d], p. 59.
- Figura 3.15. Serie mensual y curva suavizada de ET_c media para la zona de estudio, p. 60.
- Figura 3.16. Mapas mensuales de la zona de estudio de ET_c media [mm/d], p. 61.

- Figura 4.1. Mapa de ubicación de las parcelas en estudio dentro de la zona de estudio, p. 65.
- Figura 4.2. Distribución de la superficie sembrada y número de cultivos de maíz en la zona de estudio, p. 66.
- Figura 4.3a. Variación de los índices espectrales considerados para los meses de enero a junio, p. 81.
- Figura 4.3b. Variación de los índices espectrales considerados para los meses de julio a diciembre., p. 82.
- Figura 4.4. Distribución de los valores del coeficiente de determinación de los 23 índices analizados, p. 83.
- Figura 4.5a. Matriz de correlaciones de Pearson de los índices espectrales para los meses de enero a junio, p. 84.
- Figura 4.5b. Matriz de correlaciones de Pearson de los índices espectrales para los meses de julio a diciembre, p. 79.
- Figura 4.6. Modelos de regresión lineal mensuales de la ET_c (A), a partir de índices espectrales, p. 88.
- Figura 4.7. Modelos de validación para la estimación de ET_c mediante índices espectrales, A es el modelo de ET_c calculado, p. 89.
- Figura 4.8. Serie temporal y distribución de la ET_c para cultivo de maíz bajo riego en los módulos de Santa Rosa y Batequis estimados mediante modelos espectrales, media (μ) y desviación estándar (σ), p. 91.

Tablas

- Tabla 2.1. Misiones históricas *LANDSAT* (NASA, 2016), p. 15.
- Tabla 2.2. Rangos espectrales de los sensores *LANDSAT* 5, 7 y 8 (NASA, 2018), p. 16.
- Tabla 2.3. Resolución de las distintas bandas espectrales de la serie *LANDSAT* (NASA, 2018), p. 16.
- Tabla 2.4. Métodos de estimación de la ET_0 , p. 27.
- Tabla 3.1. Distribución quincenal de las imágenes *LANDSAT* bajo condiciones de claridad por año y sensor, p. 34.
- Tabla 3.2. Coeficientes de ponderación por banda ($\omega\lambda$) y sensor, para estimar el albedo de superficie, p. 41.
- Tabla 3.3. Modelos de calibración para el modelo A, a partir del modelo *EEFLUX* (i.c. = 0.95), p. 53.
- Tabla 3.4. Modelos de validación del modelo A, a partir del modelo *EEFLUX* (i.c. = 0.95), p. 55.
- Tabla 3.5. Estimación del volumen medio mensual requerido por hectárea para la zona de estudio, p. 62.
- Tabla 4.1. Tabla resumen y descripción de los índices espectrales considerados para la estimación de ET_c , p. 67.
- Tabla 4.2. Valores estadísticos de los índices espectrales considerados (i.c. = 0.95), p. 80.
- Tabla 4.3. Tercer cuartil de los coeficientes de determinación (R^2 i.c. 0.95) por mes, p. 86.
- Tabla 4.4. Índices espectrales seleccionados y valores R^2 (i.c. 0.95), por mes, p. 86.
- Tabla 4.5. Modelos de regresión lineal para la estimación de ET_c a partir de índices espectrales por mes, p. 87.
- Tabla 4.6. Modelos de validación para la estimación de ET_c por índices espectrales (i.c. = 0.95), p. 89.
- Tabla 4.7. Valores estadísticos de la ET_c de maíz en los módulos Santa Rosa y Batequis (i.c. = 0.95), p. 90.

Resumen

Los modelos de balance de energía son herramientas útiles para estimar la ET_c en áreas agrícolas extensas, no obstante, para realizar una estimación adecuada se debe contar con datos climáticos de buena resolución temporal y calidad en su adquisición. Por otro lado, los índices espectrales son modelos matemáticos que trabajan sobre imágenes satelitales y sirven como indicadores de las propiedades físicas de sistemas superficiales, lo que resulta de gran utilidad en las actividades agrícolas. Se generó un modelo para la estimación de la ET_c de maíz bajo riego mediante índices espectrales para la zona agrícola comprendida por los módulos de riego Santa Rosa y Batequis, del distrito de riego 075 - Río Fuerte, en Sinaloa. Un total de 201 imágenes satelitales de 1995 a 2018 de los sensores *LANDSAT* 5, 7 y 8, fueron procesadas mediante la metodología *SEBAL - METRIC* y fueron comparadas con el modelo *EEFLUX*, con el cual se calibró y validó mostrando un ECM promedio de 1.26 [mm/d]; Se observó un mínimo de la ET_c en el año 1999 con 2.68 [mm/d] y máximo en 2008 con 4.08 [mm/d]; la serie temporal de ET_c indica una tendencia positiva de incremento igual a $2.6 \cdot 10^{-5}$ [mm/d] anual. A partir de la relación lineal entre el modelo de balance de energía y 23 índices espectrales relacionados con la ET_c , se obtuvieron por mes modelos lineales, entre los cuales la relación entre el índice *NBRTI* y la ET_c del modelo de balance de energía obtuvo un $R^2 = 0.72$, en abril; el total de los modelos se validaron y se obtuvo un ECM promedio de 0.88. El análisis de la ET_c del cultivo de maíz en la zona de estudio mediante la metodología propuesta osciló de entre 1.28 y 9.37 [mm/d], con media de 3.8 ± 1.35 [mm/d] correspondientes a diferentes ciclos agrícolas entre los años 1998 a 2018.

Capítulo 1

Introducción

En México el uso del agua en el sector agrícola es prioritario para alcanzar la seguridad alimentaria y la producción de alimentos para la población. En el país, 60.9% del agua utilizada para uso consuntivo proviene de fuentes superficiales como ríos, arroyos y lagos, mientras que el 39.1% restante, corresponde a fuentes subterráneas (CONAGUA, 2018). De acuerdo con lo reportado por la Comisión Nacional del Agua, hasta 2017, del total de volumen de agua concesionado (270,917 hm³), el 22% fue destinado para uso agrícola (inscrito y pendientes, según la clasificación del REPDA), representando con ello 67.87% del volumen de agua por uso consuntivo, siendo el riego su principal modalidad de uso; El rubro agrícola en consecuencia es el mayor consumidor del recurso respecto a otros usos como el abastecimiento público, el cual representa 14.4%, mientras el industrial integrado solo el 4.9%.

Dentro del sector agrícola del país, uno de los cultivos de cereales más importantes es el maíz grano, el cual registró para su modalidad bajo riego al cierre de 2017 el nivel más alto de producción respecto a los demás cultivos alcanzando 13 357 198 [toneladas], y la mayor superficie cosechada, con 1 594 242 [ha], logrando con ello ser el cultivo de mayor importancia económica. En este contexto, el estado de Sinaloa ha resultado constantemente el mayor productor de esta gramínea, sumando en 2017 el 45.8% del total de la producción nacional (SIAP, 2018).

Para lograr el desarrollo del sector agrícola se han involucrado temas sobre la sostenibilidad y gestión del recurso hídrico dentro de las políticas públicas. Diversos programas de modernización como la tecnificación del riego se han planteado dentro del Plan Nacional Hídrico 2014 – 2018. Este tipo de estrategias han generado retos técnicos que requieren un análisis preciso de los volúmenes de riego adecuados para satisfacer la producción agrícola, y al tiempo, no comprometer la disponibilidad de agua en zonas vulnerables. En consecuencia, el monitoreo, y la eficiencia en el manejo del recurso hídrico, pueden ayudar a mitigar una posible sobreexplotación, y obtener mayores rendimientos en los productos agrícolas.

Uno de los problemas que enfrenta la gestión del recurso hídrico en el sector agrícola se presenta en los distritos de riego, donde las acciones de asignación de volúmenes de agua comúnmente denominadas “tandeos” (Pedroza-González e Hinojosa-Cuéllar, 2013), impactan en la disponibilidad del agua en las zonas agrícolas, cuando el personal a cargo regula los volúmenes a los usuarios con un método empírico, surgiendo con ello la necesidad de contar con una alternativa que permita asignar de manera precisa el volumen requerido por los cultivos.

Por otra parte, el método convencional para estimar los volúmenes de riego, parte de la información de estaciones climáticas, cuyo uso como fuente puntual de datos genera un sesgo en la estimación de volúmenes requeridos en grandes extensiones de cultivo, dificultando su aplicación a gran escala en los distritos de riego.

En el sector hídrico el uso de sensores remotos y técnicas de percepción remota se han desarrollado junto con la tecnología satelital desde mediados del siglo XX; en la actualidad representan una herramienta fundamental para la gestión e investigación del recurso hídrico, pues permiten de forma precisa cuantificar, monitorear y caracterizar volúmenes de agua, así como su variación en la superficie, sub-superficie y atmósfera terrestre.

En consecuencia, para el presente trabajo se propone el uso de sensores remotos como una alternativa para el análisis y cuantificación de la evapotranspiración de cultivo (ET_c), aplicada en una zona agrícola bajo riego ubicado al norte Sinaloa, en donde los requerimientos hídricos de cultivo estarán representados por este mismo parámetro (Farg, Arafat, Abd El-Wahed, y El-Gindy, 2012).

1.1 Antecedentes

Estimar la evapotranspiración de los cultivos bajo riego mediante imágenes de sensores remotos ha resultado en la aparición de diversos métodos, esto de acuerdo con el tipo de sensor y bandas del espectro electromagnético que registran. En este sentido, metodologías particulares como los modelos de balance de energía han sido desarrollados para imágenes satelitales *LANDSAT*, tal como el caso de *SEBAL* (Bastiaanssen, 1995), *METRIC* (R. Allen et al., 2007), *ResET* (Elhaddad y Garcia, 2008), *S-SEBI* (Roerink, Su, y Menenti, 2000) y *SEBS* (Su, 2002), entre otros.

En 2011, Elhaddad, Garcia, y Chavez, realizaron una comparación entre un método de estimación de la evapotranspiración basado en modelos de balance de energía: *ReSET*, contra mediciones de lisímetros de campo como método de validación, el resultado mostró un error del 11% entre ambos métodos, para cultivos varios bajo riego.

El trabajo de Liu et al. (2016), aborda el cálculo de la ET_c mediante un modelo de balance de energía (*SEB-A*). El trabajo compara la metodología contra valores de un sistema Eddy-Covarianza, mostrando una correlación R^2 de 0.71 entre ambos, no obstante, el cálculo de la evapotranspiración al estar apoyado en esencia de las mediciones de estaciones en campo, requiere de una buena cobertura de datos para trabajar adecuadamente.

La posibilidad de calcular índices a partir de las imágenes multispectrales como el índice de vegetación de diferencia normalizada (*NDVI*) o el índice de vegetación ajustado a suelo (*SAVI*), entre otros, abren la posibilidad de relacionar la ET_c con formas simples de cálculo, y aplicación directa.

El trabajo de Farg et al. (2012), reporta una correlación lineal múltiple fuerte ($0.82 < R^2 < 0.97$) entre los índices *NDVI* y *SAVI*, obtenidos de imágenes satelitales *SPOT-4*, y el coeficiente de desarrollo del cultivo K_c , permitiendo estimar una ET_c para cada etapa de desarrollo del cultivo, a partir de la relación del coeficiente con la evapotranspiración de referencia (ET_0) calculado con la ecuación de Penman-Monteith (Allen, Pereira, Raes, y Smith, 2006).

Marshall, Thenkabail, Biggs, y Post (2016), por su parte realizaron un análisis regional de la evapotranspiración, compararon mediciones entre radiómetros distintos, y relacionaron un sistema Eddy-Covarianza con el *NDVI*. En sus resultados se observó así un coeficiente de correlación R^2 de 0.51 para el radiómetro de bandas discretas y de 0.68 para el hiperespectral.

1.2 Planteamiento del problema

La evapotranspiración de un cultivo es estimada comúnmente mediante métodos directos utilizando lisímetros, o indirectos como el balance de agua en el suelo; además, existen formulaciones teóricas o empíricas como la razón de Bowen, y el balance de energía. En cualquier caso, se requiere de información puntal que debe ser obtenida en campo; sean lisímetros, estaciones climáticas o sistemas más avanzados como Eddy-Covarianza, estos incrementan los costos de proyecto al demandar personal, mantenimiento y seguridad, dificultando la obtención de mediciones precisas cuando se pretende analizar áreas extensas a escala de cultivo.

Por otra parte, el consumo de agua por los cultivos no es uniforme espacialmente, este depende de parámetros de alta variabilidad espacial como el tipo de suelo y variables climáticas como temperatura, humedad relativa, velocidad del viento y radiación solar; mediante el uso de sensores remotos se pretende obtener información precisa espacial y temporalmente sobre estos parámetros, lo que permitirá hacer un cálculo más eficiente de los requerimientos hídricos en cultivos bajo riego.

1.3 Justificación

El análisis conjunto de la información de sensores remotos y la fenología de los cultivos, ha demostrado ser una buena herramienta para estimar cuantitativamente los fenómenos físicos presentes en distintos cultivos. Este hecho, ha permitido entre otras cosas precisar sitios con exceso o deficiencia de nutrientes o humedad dentro de los mismos.

Dicho lo anterior, es posible estimar de forma indirecta la evapotranspiración de cultivo bajo riego, a partir de la información de los sensores remotos. Este tipo de información presenta una ventaja sobre los métodos tradicionales al estar definida espacialmente de origen, lo que ha propiciado su uso en análisis a detalle del fenómeno.

Finalmente, al estimar los valores de ET_c se favorece una gestión eficiente en el riego (Johnson y Trout, 2012). El análisis espacio-temporal de este parámetro, basado en sensores remotos, mejora la planeación que requiere el sector hídrico y agrícola, al ofrecer una alternativa para cuantificar la cantidad de agua a utilizar en los cultivos; y al sustentar la planeación de ciclos futuros con dicho análisis, se impacta favorablemente los rendimientos agrícolas al tiempo que se anticipa la sobreexplotación, y se monitorea la disponibilidad del recurso hídrico.

1.4 Objetivos

1.4.1 General

El objetivo del presente trabajo es estimar la evapotranspiración del cultivo (ET_c) de maíz bajo riego mediante percepción remota empleando modelos de balance de energía e índices espectrales, en la zona agrícola comprendida por los módulos de riego Santa Rosa y Batequis del Distrito de Riego 075 (Río Fuerte), en el Estado de Sinaloa durante el periodo 1998-2018.

1.4.2 Específicos

- › Elaborar un banco de imágenes satelitales para una zona agrícola de los módulos de riego Santa Rosa y Batequis del Distrito de Riego 075 (Río Fuerte) en el Estado de Sinaloa durante el periodo 1995-2018.
- › Calcular los valores de evapotranspiración de cultivo mediante un modelo de balance de energía basado en imágenes satelitales, para el banco de imágenes elaborado y conformar una base de datos geoespacial de ET_c .
- › Efectuar un análisis histórico de la base de datos geoespacial de ET_c y determinar los periodos anual y mensual de máximo y mínimo del parámetro.
- › Generar y validar un modelo basado en índices espectrales a partir del modelo de balance de energía obtenido, que permita estimar los valores de evapotranspiración de cultivo de maíz bajo riego para una zona agrícola de los módulos de riego Santa Rosa y Batequis, Distrito de Riego 075 (Río Fuerte) en el Estado de Sinaloa.

1.5 Hipótesis

La hipótesis del presente trabajo recae en probar si la estimación de la evapotranspiración del cultivo de maíz bajo riego a partir de índices espectrales tiene la suficiente precisión para considerarse una herramienta válida para estimar los volúmenes de riego en una zona agrícola.

Capítulo 2

Marco teórico

2.1 El espectro electromagnético solar

A partir de los procesos y reacciones nucleares que ocurren en el sol, se generan radiaciones de energía electromagnética en un amplio espectro de frecuencias y longitudes de onda, al aproximarse a la Tierra esta interacciona con distintos fenómenos físicos; dentro de la atmósfera, la agrupación de los elementos presentes en medios y sistemas propios del planeta, al paso de la energía dan como resultado que solo una parte de la radiación alcance la superficie terrestre, la energía puede entonces: ser reflejada, transmitida o dispersada, mientras que otra parte es capturada debido a la interacción con el campo magnético terrestre.

La radiación electromagnética consiste de dos campos físicos; el campo eléctrico (E), que varía su magnitud en dirección perpendicular a su dirección de propagación, y en un campo magnético (H) perpendicular al campo eléctrico (Campbell, 2011), su representación esquemática puede apreciarse en la figura 2.1.

Las propiedades físicas de la energía electromagnética se caracterizan por tener longitud de onda, frecuencia, amplitud y fase, su velocidad (c) es constante e igual a 299 792 [km/s] y se relaciona a la frecuencia (ν) a una la longitud de onda (λ) mediante la ecuación 1.

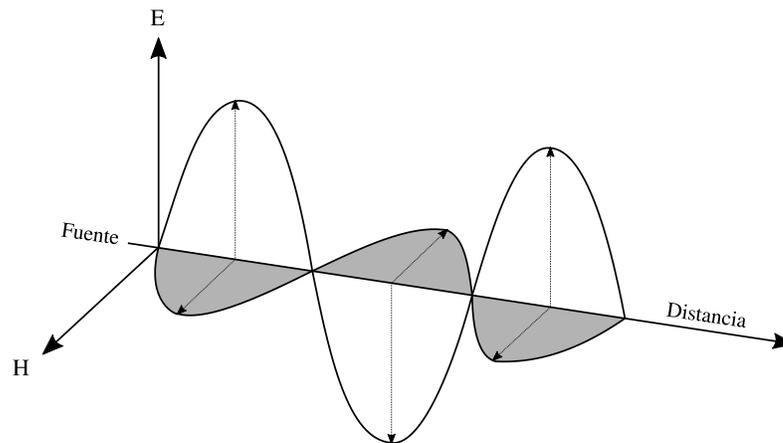


Figura 2.1. Componentes de la radiación electromagnética (modificada de Campbell, 2011)

$$c = \lambda\nu \quad \text{Ec.1}$$

Existe, además, una relación entre estas características de la energía radiante y la temperatura de un objeto; es decir, todo objeto cuya temperatura sea mayor que el cero absoluto se encontrará emitiendo energía. La cantidad de energía emitida a determinada longitud de onda dependerán de su temperatura; al aumentar esta propiedad, la cantidad total de energía emitida aumenta, y la longitud de onda de la máxima emisión tiende a acortarse (Campbell, 2011).

La forma en la que se relacionan entre el flujo de energía radiante y la temperatura, se establece en la Ley de Stefan-Boltzmann. Fue descubierta experimentalmente en 1879 por Josef Stefan, y en 1884 Ludwig Boltzmann la derivó teóricamente (Blevin y Brown, 1971), sentando con ello las bases del modelo que expresa la radiación de energía térmica para un cuerpo oscuro, expresada en la ecuación 2.

$$\Phi = \sigma T^4 \quad \text{Ec. 2}$$

Dónde:

$\Phi \left[\frac{J}{m^2s} \right]$: Flujo de energía emitido por unidad de área por un cuerpo oscuro.

$\sigma = 5,6644 \cdot 10^{-8} \left[\frac{W}{m^2K^4} \right]$: Constante de Stefan-Boltzmann, (Blevin y Brown, 1971).

$T [K]$: Temperatura termodinámica absoluta del cuerpo oscuro.

Posteriormente en los trabajos de Max Planck de 1884 a 1901, que estuvieron basados hasta ese momento en el aún teorema de la radiación de Kirchhoff 1859-1860, dieron origen a la Ley de radiación de Kirchhoff. En dicha ley, el autor establecía una relación entre la intensidad de radiación y la temperatura a cierta longitud de onda para un cuerpo oscuro basándose en la Ley del desplazamiento de Wien (1896). Esta última establece una relación inversamente proporcional entre la temperatura y la longitud de onda de máxima energía de radiación para un cuerpo oscuro, la cual se expresa en la ecuación 3.

$$\lambda_{max} = \frac{b}{T} \quad \text{Ec.3}$$

Dónde:

$\lambda_{max} [m^{-1}]$: Longitud de onda de máxima energía.

$b = 2.89777729 \cdot 10^{-3} [m K]$; constante de desplazamiento de Wien.

$T [K]$: Es la Temperatura de emisión.

En 1901, Planck examinó la Ley de Wien apegándose al concepto de la entropía de un resonador vibrante en un medio diatérmico arbitrario, obteniendo la Ley de distribución de la energía de un cuerpo oscuro a una longitud de onda dada, expresada en la ecuación 4.

$$E = \frac{8\pi ch}{\lambda^5} \frac{1}{e^{(ch/k\lambda T)} - 1} \quad \text{Ec.4}$$

Dónde:

$E, \left[\frac{\text{erg}}{\text{cm}^2 \cdot \text{s}}\right]$ = Energía radiante o irradiancia.

$T, [\text{grad}]$: Es la Temperatura de emisión.

$\lambda, [\text{cm} \cdot \text{grad}]$: Longitud de onda.

$h = 6.55 \cdot 10^{-27} [\text{erg} \cdot \text{s}]$: Constante de Planck.

$c = 3,10 \cdot 10^{10} \left[\frac{\text{cm}}{\text{s}}\right]$: Velocidad de la luz

$k = 1.33 \cdot 10^{-16} \left[\frac{\text{erg}}{\text{grad}}\right]$: Constante de Boltzmann

Finalmente, la Ley de Planck (Ec. 4), puede expresar la irradiancia de una fuente esférica, suponiendo su radio (R_S) igual a 696 392[Km], y una temperatura constante de 5778 [K], es decir un símil solar; y cuya distribución sobre la superficie de un cuerpo esférico de radio 6 357 [Km] (r_T), aproximadamente el radio terrestre, puede obtenerse aplicando la ecuación 5.

$$I_S(\lambda, T) = \frac{2\pi c^2 h}{\lambda^5} \frac{1}{e^{\left(\frac{ch}{k\lambda T}\right)} - 1} \left(\frac{r_T^2}{R_S^2}\right) \quad \text{Ec.5}$$

Dónde:

$I_S \left[\frac{\text{W}}{\text{m}^2 \cdot \text{nm}}\right]$ = Irradiancia por unidad de superficie y longitud de onda.

$T [K]$: Es la temperatura de emisión.

$\lambda [\eta\text{m}]$: Longitud de onda de emisión.

$h = 6.62 \cdot 10^{-34} [\text{J} \cdot \text{s}]$: Constante de Planck.

$c = 299792458 \left[\frac{\text{m}}{\text{s}}\right]$: Velocidad de la luz

$k = 1.38 \cdot 10^{-23} \left[\frac{\text{J}}{\text{K}}\right]$: Constante de Boltzmann

$h = 6.62 \cdot 10^{-34} [\text{J} \cdot \text{s}]$: Constante de Planck

$R_S, r_T [m]$: Radio solar, y terrestre promedio respectivamente

El espectro de irradiancia (Ec. 5), para un objeto de características similares al sol, se muestra en la figura 2.2. La longitud de onda de emisión máxima (Ec. 3) se ubica en 501.52[nm]; como se aprecia, la esta representación gráfica muestra los límites entre el espectro ultravioleta, visible e infrarrojo como referencia. Esta energía, que interacciona con los sistemas como se ha mencionado al principio del capítulo, al ser reflejada cambia sus propiedades pudiendo ser captada por sensores, información que debe ser interpretada y es objeto de análisis en la investigación de los sistemas de percepción remota y aplicaciones diversas.

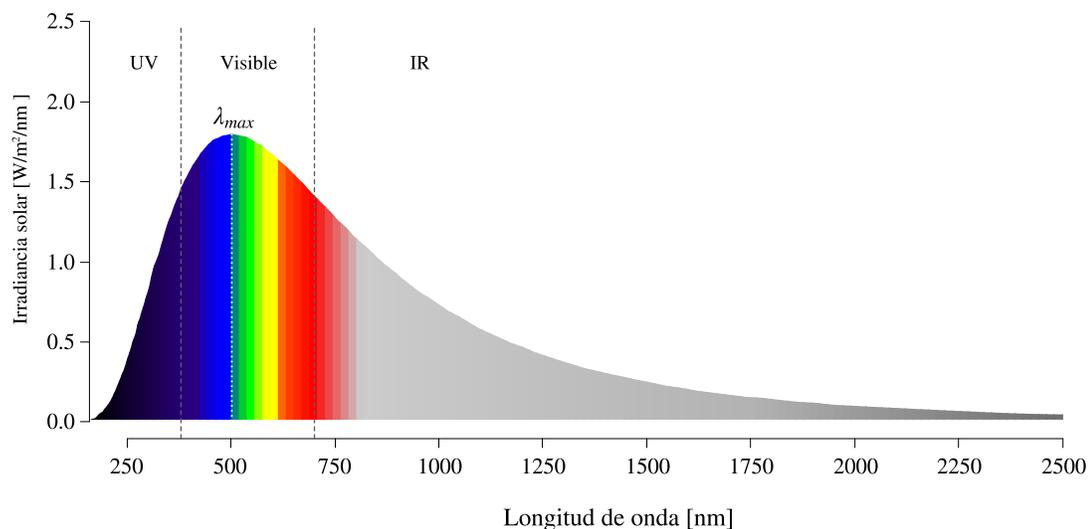


Figura 2.2. Aproximación de la respuesta energética de la irradiancia solar en la superficie terrestre por longitud de onda.

2.2 Percepción remota

La percepción remota es una técnica ampliamente aceptada para obtener información sobre las propiedades físicas o químicas de ciertas superficies u objetos a distancia mediante la obtención de imágenes capturadas por sensores del

espectro electromagnético montados sobre dispositivos móviles sean satélites, sobrevuelos de aviones, drones, etc.

Curran (1985), se refiere a la percepción remota como el uso de sensores de la radiación electromagnética para registrar imágenes del ambiente que puedan ser interpretadas para producir información útil. Por otra parte, conceptualiza un sistema de percepción remota a partir de cuatro componentes: una fuente, la interacción con la superficie terrestre, la interacción con la atmósfera y el sensor; una representación conceptual se muestra en la figura 2.3.

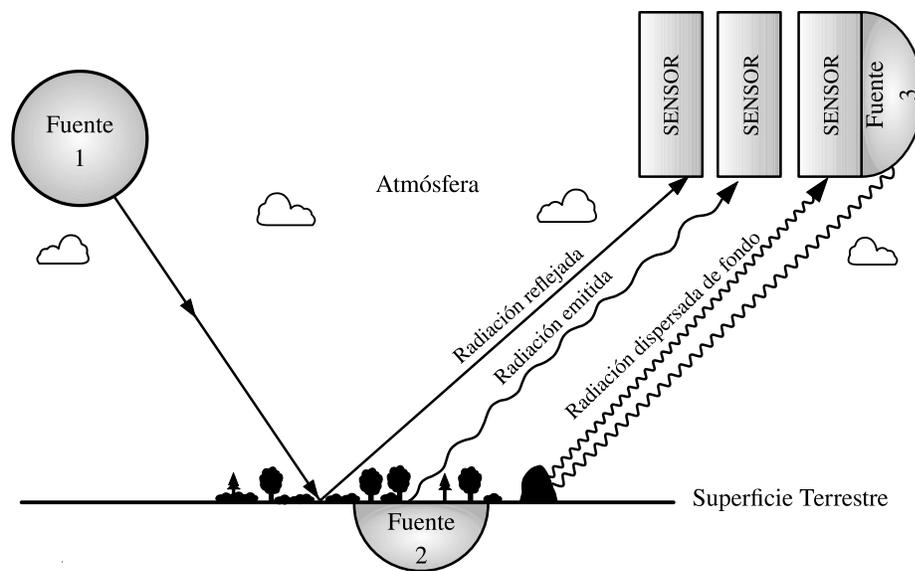


Figura 2.3. Representación conceptual de un sistema de percepción remota y sus componentes: energía, fuente y sensor, modificada de Curran (1985).

2.2.1 Sistemas satelitales de adquisición mediante sensores remotos

A lo largo de la historia, han existido gran número de sistemas de observación terrestre (OT). Los satélites, en este caso, orbitando con diferentes tipos de sensores, han ayudado a obtener imágenes del planeta desde la década de 1960. La

clasificación por importancia ambiental de estos sistemas divide en tres categorías (Curran, 1985): la primera, los controlados remotamente, como las series *Mercury*, *Gemini*, *Apollo*, *Shuttle*, entre otros; la segunda, los no controlados como *LANDSAT*, *MODIS*, *SPOT*, *ASTER*, *ERS*, *Quick Bird*, *IKONOS*, *Orb View*, *World view*, *Rapid Eye*, entre otros, utilizados mayormente en el monitoreo de usos de suelo, la agricultura y oceanografía; y la tercera, los meteorológicos como *GOES*, *NIMBUS*, *TIROS* entre otros, en la climatología y pronóstico del tiempo (Guo, Zhang, y Zhu, 2015).

2.2.2 Satélites terrestres de la serie *LANDSAT*

Los sensores *LANDSAT* (*Land Satellite*), fueron diseñados para adquirir vistas regionales de la superficie terrestre con niveles de resolución moderada. Sus sistemas satelitales operan en orbitas sincrónicas al sol y son de tipo polar con intervalos de paso a tiempos regulares.

Desde finales del siglo XX y principios del XXI, han sido lanzadas diversas misiones *LANDSAT*, a cargo de la Administración Nacional de la Aeronáutica y del Espacio (*NASA* por su acrónimo inglés). De estos satélites, algunos han dejado de operar, mientras otros más son programados para sustituir sus tecnologías. La tabla 2.1 presenta la síntesis de las misiones de 1972 a 2013.

De acuerdo a la generación y tecnología estos sistemas se clasifican como: de escaneo multiespectral (*MSS*, *Multispectral Scanner System*), cartografía temática (*TM*, *Thematic Mapper*), y cámaras *RBV* (*Return Beam Vidicon*) (Richards, 1986), los sistemas L1 a L6; de cartografía temática mejorada (*ETM* y *ETM +*, *Enhanced Thematic Mapper*), el sistema L7, y los sensores de operación terrestre (*OLI*, *Operational Land Imager*) y térmico infrarrojo (*TIRS*, *Thermal Infrared Sensor*), el sistema L8 (NASA, 2016).

Los sistemas satelitales *LANDSAT* llevan consigo sensores que captan de forma discreta diferentes rangos del espectro electromagnético reflejado por la superficie terrestre, representando la respuesta de esta interacción de forma digital en mallas de valores que son interpretadas como imágenes multiespectrales.

Tabla 2.1. Misiones históricas *LANDSAT* (NASA, 2016).

Generación <i>LANDSAT</i>	Sensores	Lanzamiento	Relevación
L1	RBV MSS	1972	1978
L2	RBV MSS	1975	1983
L3	RBV MSS	1978	1983
L4	MSS TM	1982	1993
L5	MSS TM	1984	2013
L6	ETM	1993	1993
L7	ETM+	1999	-
L8	OLI, TIRS	2013	-
L9	TIRS	2020-21?	-

Con cada generación se presenta un tipo de sensor diferente, así, la resolución y bandas de sensibilidad mejoran su precisión respecto a la tecnología sustituida. Una comparación entre las bandas espectrales numeradas de origen en los sistemas *LANDSAT* y que son utilizadas en este trabajo se muestra en la figura 2.4.

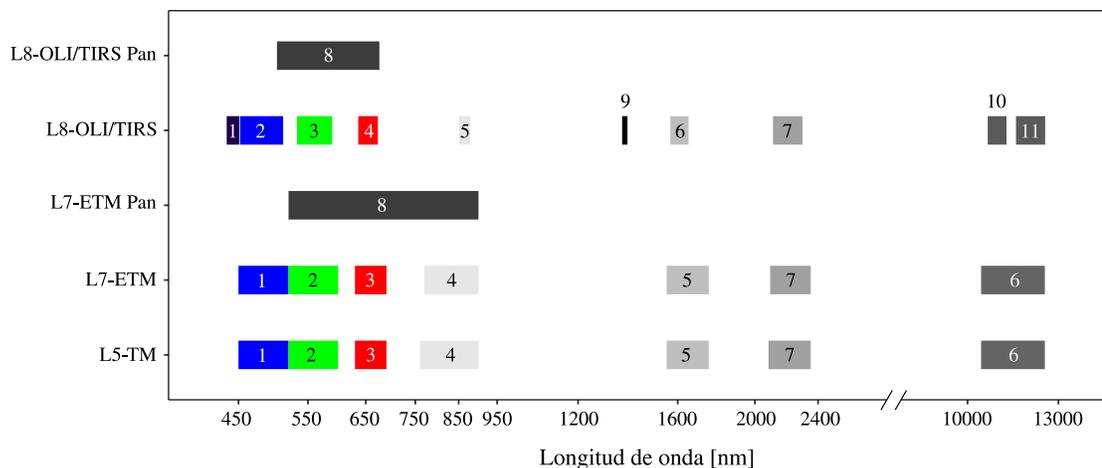


Figura 2.4. Comparación de las bandas espectrales (1-11) de los sistemas *LANDSAT* (NASA, 2018).

Cada banda numerada responde una longitud de onda central, por convención se asigna una nomenclatura en lengua inglesa según sea el caso; así, la banda cercana a longitud central del color azul corresponde a la letra B, verde G, rojo R, infrarrojo cercano IR, e infrarrojos de onda corta SWIR1 y SWIR2 (Tabla 2.2).

Tabla 2.2. Rangos espectrales de los sensores *LANDSAT* 5,7 y 8 (NASA, 2018).

Nomenclatura	B	G	R	NIR	SWIR1	SWIR2	IRTérmico
λ central [nm]	485	560	660	830	1650	2215	11455
λ min[nm]	450	520	630	760	1550	2080	10400
λ max[nm]	520	600	690	900	1750	2350	12510
Sensor	Número de banda						
L5 - TM	1	2	3	4	5	7	6
L7 - ETM	1	2	3	4	5	7	6
L8 - OLI/TIRS	2	3	4	5	6	7	10, 11

Por otra parte, existe una diferencia entre los tamaños de sensor térmico de las diferentes generaciones, lo cual afecta el tamaño del pixel de las imágenes digitales que se pretenden analizar; la tabla 2.3 muestra dichas diferencias de resolución.

Tabla 2.3. Resolución de las distintas bandas espectrales de la serie *LANDSAT* (NASA,2018).

Sensor	L5-TM	L7-ETM	L8-OLI/TIRS
Resolución[m] (B, G, R, NIR, SWIR1, SWIR2)	30	30	30
Resolución [m] (Infrarrojo térmico)	120 x 30	60 x 30	100 x 30

Al ser sistemas instrumentales de medición de carácter público, la información disponible es bruta, por lo que cada imagen debe ser calibrada y corregida. En este caso, se deben corregir por efectos de la atmósfera (TOA, *Top of atmosphere*), para conseguir los valores radiométricos correctos de la imagen; a partir de esta, se obtienen los valores de reflectancia de superficie para realizar apropiadamente la interpretación y análisis de la información. La metodología completa se describe en la sección 3.2.2 del capítulo 3.

2.3 Respuesta espectral de la vegetación

Diferentes factores ambientales pueden ser caracterizados mediante el análisis de la información de sensores remotos. Estos fenómenos de origen diverso y ocurrencia en la superficie terrestre, son objeto de análisis espacial y temporal. Como ejemplo, la figura 2.5 muestra a estos por categorías generales y nivel geográfico (Lein, 2012), entendiendo que deben ser abordados mediante distintas técnicas de percepción remota.

La actividad agrícola está sujeta a regulaciones y a la planeación en políticas de carácter socio-demográfico como el uso de suelos. Además, es uno de los factores que modifican las condiciones físicas de los suelos constantemente, por lo que es monitoreada en búsqueda de cambios, y analizada a diferentes niveles, como: características fisiológicas de los cultivos, relación entre plantas y suelos, procesos fisicoquímicos, biogeoquímicos, e importancia económica, entre otros.

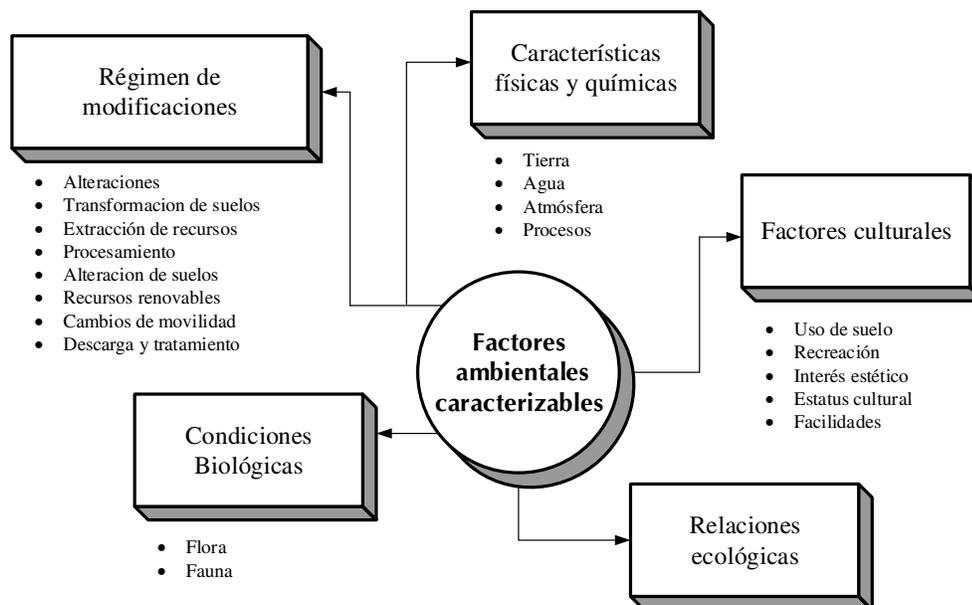


Figura 2.5. Factores ambientales caracterizables mediante sensores remotos, modificada de Lein (2012).

El aprovechamiento eficiente del agua en la agricultura, implica dotar de volúmenes precisos del recurso durante el crecimiento de los cultivos y satisfacer sus procesos fisiológicos; cuando es absorbida por las raíces de cada organismo, y conducida a las hojas, diversos procesos como la nutrición o la turgencia celular se llevan a cabo. Como resultado, las propiedades reflexivas de la energía solar en la superficie vegetal se ven afectadas por el contenido de agua, por ende, el grado en el que la energía solar es absorbida en la vegetación estará en función de la cantidad total presente en la hoja y su espesor (Jensen, 2005).

Determinar cuantitativamente las propiedades reflectivas de un cultivo depende de la cobertura de dosel, número de plantas y características del suelo, entre otros parámetros. Así, la medición de la reflectancia en estas superficies mostrará entonces un efecto combinado de diversas características locales (Hou, Wang, Xu, Reid, y Han, 2016). Como se aprecia en figura 2.6, el comportamiento espectral de distintas superficies como la vegetación verde o saludable, vegetación seca, el suelo desnudo y otras superficies, son distintas y presentan variaciones en su reflectancia para distintas zonas del espectro.

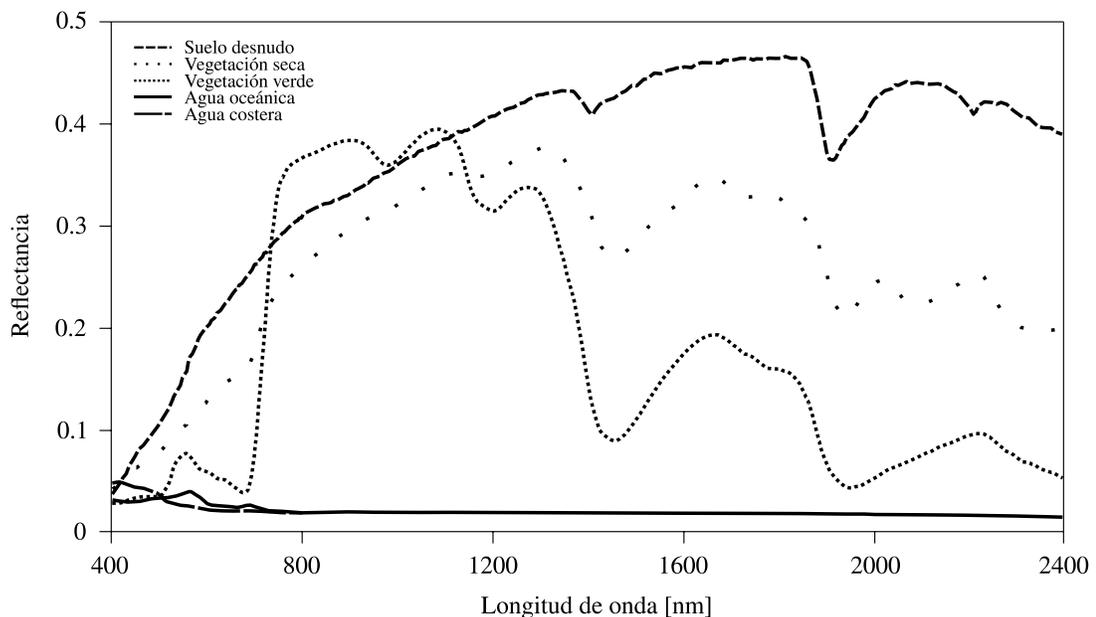


Figura 2.6. Reflectancia espectral de distintos materiales (modificada de Hou et al., 2016)

El comportamiento espectral de la vegetación muestra un pico de intensidad en la banda verde; sin embargo, éste es mayor en el rango de los infrarrojos. Por ejemplo, al distinguir entre la vegetación verde, que se supondría de buena salud de otra seca, se observan diferencias entre las distintas bandas infrarrojas (figura 2.6); la interpretación de este fenómeno funciona como indicador de la condición de una planta o en su caso, de cultivos.

Desde la década de los 60's se han modelado distintas variables biofísicas de la vegetación usando los datos radiométricos de sensores satelitales. Involucrando el uso de los llamados índices de vegetación, números adimensionales generados por la combinación algebraica de bandas espectrales específicas, se han establecido relaciones interpretativas que definen el estado de la vegetación. Esta condición estará definida para cada sitio geográfico caracterizado por el valor de un píxel dentro de una imagen adquirida, indicando con ello la abundancia, ausencia o actividad de la vegetación en el sitio.

El *NDVI*, *Normalized Difference Vegetation Index*, o índice de vegetación de diferencia normalizada, es uno de los índices de vegetación más utilizados en la percepción remota, originalmente fue utilizado para determinar la condición salud de la vegetación, la descripción de este y otros índices de vegetación y suelo, se abordan con detalle en la sección 4.2 del capítulo 4.

2.4 Modelos de balance de energía basados en percepción remota

La aplicación de los modelos de balance de energía a la información adquirida de sensores remotos satelitales tiene como objeto representar geográficamente las estimaciones de flujos de energía reflejada de distintas superficies y gran

extensión. Esto se logra a partir de resolver una serie de modelos matemáticos que describen la interacción de la energía solar con los sistemas involucrados.

Usualmente, estos modelos se utilizan para estimar la evapotranspiración en superficies de carácter forestal y agrícola; teóricamente, están basados en la redistribución de la humedad y el calor en el suelo y la atmósfera que ocurre con la incidencia de la energía. Dado que estos sistemas están conectados físicamente mediante la superficie del suelo, se origina un balance energético en el sistema debido a un equilibrio termodinámico entre: un proceso de transporte en flujo turbulento, dominado por las características atmosféricas, y un proceso de transporte en flujo laminar generado en el suelo (Bastiaanssen, 1995).

El modelo general del balance de energía en la superficie terrestre se expresa en la ecuación 6, y toma en cuenta las principales componentes de la radiación directa y reflejada en un modelo aditivo.

$$R_n = G + H + \lambda ET \quad [W \cdot m^{-2}] \quad \text{Ec.6}$$

Donde:

R_n : Es el flujo de radiación neta

G : Densidad de flujo de calor a la superficie

H : Densidad de flujo de calor sensible

λET : Densidad de flujo de calor latente

Debido a que la evaporación del agua consume energía, se puede obtener el valor del consumo energético de este proceso y estimar así la densidad de flujo de calor latente (λET) mediante la ecuación anterior, el cual es asociado a los procesos de evaporación y transpiración de la vegetación descritos en el apartado 2.5.1.

Este modelo puede ser aplicado a una malla de valores de reflectancia, por ejemplo, a valores digitales resultado del procesamiento de una imagen satelital, y así aplicar espacialmente el modelo.

2.4.1 Algoritmo de balance de energía en superficie (*SEBAL*)

La aplicación de los modelos de balance de energía hace posible el análisis de los flujos de energía radiante de las superficies; a partir de este, es posible estimar la evapotranspiración de superficies vegetales, parámetro de particular importancia para este trabajo.

Mediante el cálculo del flujo de calor latente (λET), puede ser estimada la evapotranspiración de cultivo (ET_c). La explicación conceptual de la aplicación de este tipo de métodos se muestra en la figura 2.7, donde se representan gráficamente los flujos de energía componentes de la ecuación de balance (Ec. 6), para un sistema suelo – planta, propio de cultivos agrícolas.

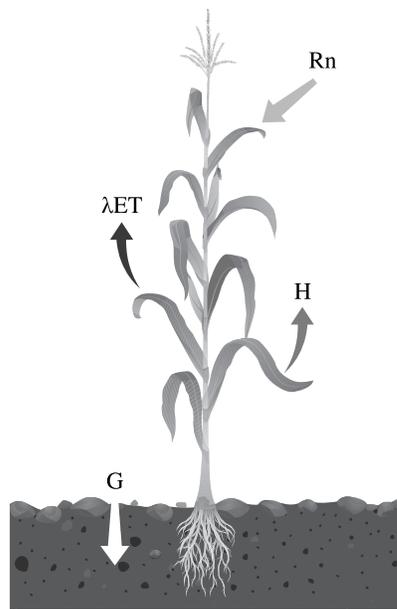


Figura 2.7. Modelo conceptual del balance de energía para un sistema suelo-planta, modificada de Waters et al., (2002).

El algoritmo *SEBAL* (*Surface Energy Balance at Land*), desarrollado por Bastiaanssen (1995), resuelve la ecuación de balance de energía enfocándose a zonas de cultivo; utilizando los valores de reflectancia de imágenes *LANDSAT*, se obtienen pixel a pixel los flujos instantáneos de radiación neta (R_n), calor sensible (H), calor latente (λET) y de suelo (G). El algoritmo realiza una estimación de la evapotranspiración de cultivo tomando información de estaciones climatológicas cercanas. Para obtener la ET_c , multiplica la evapotranspiración de referencia acumulada en la estación por la fracción evapotranspirativa de referencia (ET_{rf}), siendo esta última la tasa entre la componente de calor latente (λET) y la evapotranspiración de referencia (ET_0) en cada pixel. Una descripción más detallada de este algoritmo, así como sus ecuaciones son presentadas en el tercer capítulo.

Este método ha sido utilizado en diversos trabajos (ie. Kiptala, Mohamed, Mul, y Van Der Zaag, 2013; Li, Zhan, Xu, Jiang, & Xiong, 2013), siendo ampliamente aceptado; En nuestro país ha formado parte de estudios hidrológicos encargados por el principal organismo de gestión del recurso, la CONAGUA, a diferentes organismos internacionales (i.e. WaterWatch-CONAGUA, 2005).

Existen variaciones del modelo original como *S-SEBI* (Roerink, Su, y Menenti, 2000), *SEBS* (Su, 2002), *ReSET* (Elhaddad y Garcia, 2008) o *METRIC* (R. Allen et al., 2007), entre otros, que han sido desarrolladas con el propósito de obtener una distribución geoespacial de la evapotranspiración de cultivos.

2.4.2 Algoritmo con calibración interna (*METRIC*)

En 2007, Richard Allen muestra el desarrollo de una metodología para estimar la evapotranspiración: *METRIC* (*Mapping evapotranspiration with internalized calibration*, Allen, 2007a, 2007b), la cual está basada en la teoría de balance de

energía en superficie *SEBAL* desarrollada por Bastiaanssen et al. (1998), de la cual utiliza ciertos algoritmos.

Una de las diferencias evidentes entre los métodos *SEBAL* y *METRIC* es que este último realiza una auto-calibración a fin de restar los errores debidos a la estimación por separado del flujo de radiación neta R_n , el flujo de calor del suelo G , y el flujo de calor sensible H (*SEBAL*), transfiriendo el error únicamente al cálculo del flujo de calor sensible H ; además es un proceso automatizado.

En resumen, *METRIC* utiliza las mismas relaciones del método *SEBAL* para obtener los valores del flujo de radiación neta R_n , el flujo de calor del suelo G , y el flujo de calor sensible H , la relación G/R_n , y la energía consumida por la evapotranspiración λET (Ec.6), no obstante, existe diferencia en el cálculo de la fracción evapotranspirativa de referencia (Λ), y la selección de los pixeles fríos y calientes, detalles que se abordan en la sección 3.2.4 del capítulo 3.

Derivado del método *METRIC*, ha sido desarrollado *EEFLUX* (*Earth Engine Evapotranspiration Flux*), una aplicación pública en línea que ofrece al usuario mapas de ET_c y parámetros relacionados. El acceso a esta información permite realizar análisis históricos pues cuenta con una base de datos de imágenes satelitales extensa. Al momento de realizar el presente trabajo, la plataforma refirió a la actualización de junio de 2018 (*EEFLUX* v.0.10.4).

Además de utilizar la base de datos de imágenes *LANDSAT*, corregida radiométricamente y por topografía, *EEFLUX* toma información climática de distintos sistemas de observación terrestre o de asimilación satelital como: *NLDAS-NASA*, provee al modelo datos meteorológicos por hora a 12 [km] de resolución, disponibles para treinta años solo para la región norteamericana; *GridMET-USGS*, datos meteorológicos corregidos a 4 [km] de resolución, de la misma forma, solo para la zona norteamericana; *CSFV2-NOAA*, un sistema de

pronóstico climático a 6[hr]; y *RTMA-NOAA/NCEP*, un sistema en tiempo real empleado para completar datos climáticos.

Finalmente, *EEFLUX* se apoya la base de datos de uso de la *FAO*, a diferentes resoluciones, espacial y temporal (Kilic, Allen, Huntington, y Ozturk, 2015). *EEFLUX* es un modelo automatizado que comienza a ser utilizado en investigaciones como una referencia a los modelos de balance tradicionales o manuales como *SEBAL* (i.e. Foolad et al., 2018).

2.5 Requerimientos hídricos de cultivo bajo riego

El requerimiento de riego se define como la profundidad (o cantidad) de agua necesaria para satisfacer la pérdida de agua por evapotranspiración; en otras palabras, es la cantidad de agua necesaria para que los diversos cultivos crezcan óptimamente (*FAO*, 2016). Debe apreciarse desde dos puntos de vista, el crecimiento de los cultivos y sostenibilidad del recurso.

El requerimiento de agua de cultivos bajo riego, toma el supuesto de ausencia de precipitación, puede ser expresado mediante la ecuación 7 y, por tanto, se puede asumir que la evapotranspiración es igual a lámina regada.

$$R_h \leftrightarrow V_{ET} - V_R \quad \text{Ec.7}$$

Donde:

R_h : Es el requerimiento hídrico del cultivo bajo riego

V_R : Es el volumen de riego suministrado al cultivo

V_{ET} : Es el volumen de agua evapotranspirado por el cultivo

2.5.1 Evapotranspiración de cultivo

La evapotranspiración es la combinación de dos procesos separados por los cuales se pierde agua en el suelo y en las plantas o cultivos debido a la transpiración (Allen et al., 2006). La forma canónica de calcular la evapotranspiración, utiliza la ecuación de balance hídrico aplicada a cultivos, consiste en evaluar para la ecuación de balance hídrico (Ec. 8) los flujos de agua entrantes y salientes de la zona radicular del cultivo dentro de un determinado periodo de tiempo (Allen et al., 2006). Una representación esquemática de este fenómeno se muestra en la figura 2.8.

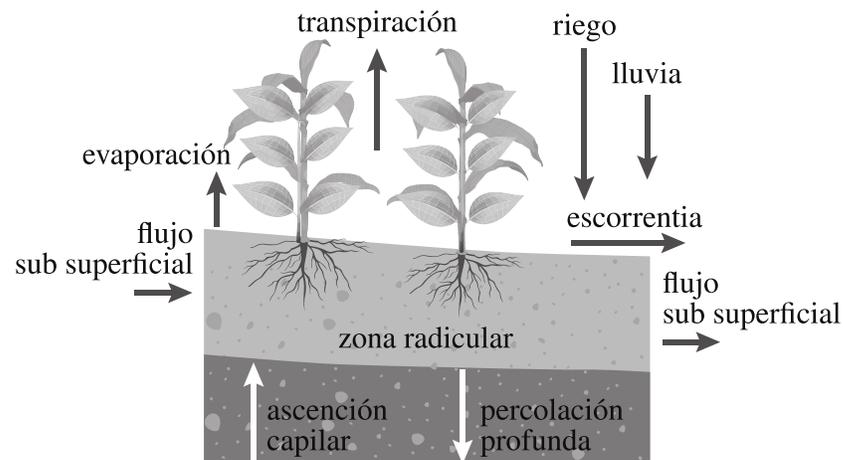


Figura 2.8. Fenómenos que intervienen en el balance hídrico, modificada de Allen et al. (2006).

$$ET = R + P + ES - D \pm \Delta FS \pm \Delta SW, \left[\frac{mm}{día} \right] \quad \text{Ec. 8}$$

Donde:

ET: Evapotranspiración

R : Cantidad de agua usada para el riego

P: Cantidad de precipitación

ES : Cantidad de Escurrimiento superficial

D: Cantidad de agua perdida por percolación profunda

ΔFS : Diferencia del Flujo sub-superficial

ΔSW : Cambio de contenido de agua en el suelo

Dado que la ET_c varía para cada especie vegetal y de su etapa de desarrollo, la cantidad de agua que requieran los cultivos estará en función de su etapa fisiológica; dicha etapa puede ser cuantificada mediante un parámetro denominado coeficiente de cultivo (K_c). La figura 2.9 muestra la evolución de K_c en diferentes etapas de desarrollo de un cultivo.

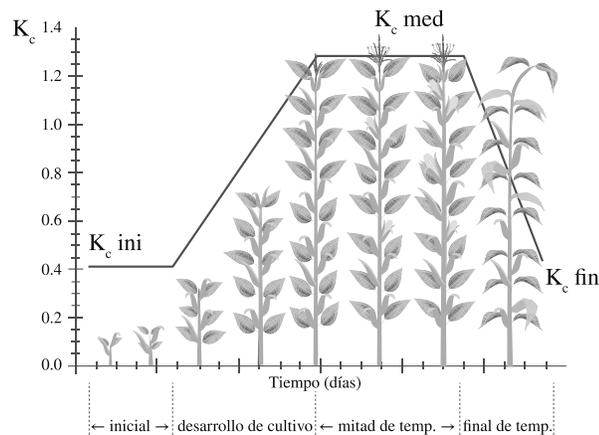


Figura 2.9. Representación conceptual de la evolución de K_c en diferentes etapas fisiológicas de un cultivo, modificada de Allen et al. (2006).

Allen et al. (2006), proponen una forma de estimar la ET_c durante los distintos periodos de desarrollo del cultivo; mediante la relación guardada por la evapotranspiración de una superficie de referencia bajo condiciones estándar ET_0 , y el coeficiente de cultivo K_c . Dicha relación se expresa mediante la ecuación 9, mientras la figura 2.10, muestra su modelo conceptual simplificado.

$$ET_c = K_c ET_0 \quad \text{Ec. 9}$$

Donde:

ET_c [$mm\ d^{-1}$] : Evapotranspiración del cultivo

K_c [adimensional] : Coeficiente del cultivo (fenología del cultivo)

ET_0 [$mm\ d^{-1}$] : Evapotranspiración del cultivo de referencia

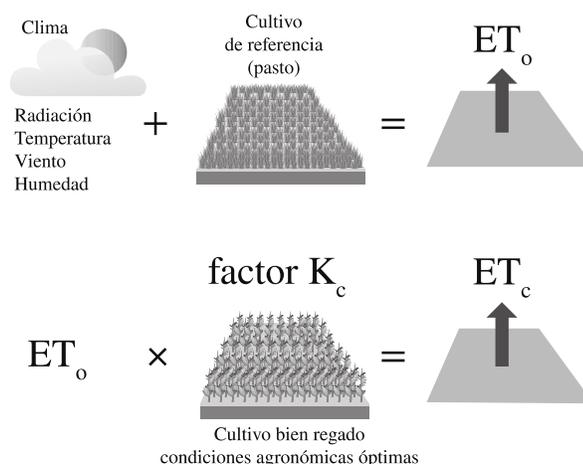


Figura 2.10. Modelo conceptual de la relación ET_c , ET_o y K_c , modificada de Allen et al. (2006).

Se han desarrollado modelos matemáticos para estimar la ET_o , algunos de los cuales se muestran en la tabla 2.4. Estos modelos son empleados según la disponibilidad de datos climáticos, utilizan variables como la radiación solar (R_s), radiación neta (R_n), el flujo de calor del suelo (G), la temperatura máxima (T_{max}), mínima (T_{min}), media (T_{med}) o diferencia (δT); la pendiente de la curva de presión de vapor (Δ), la constante psicrométrica (γ), así como diversos coeficientes experimentales (a, T_1); sin embargo, existe un método robusto, el modelo de Penman-Monteith el cual se describe en la siguiente sección.

Tabla 2.4. Métodos de estimación de la ET_o .

Método	Modelo matemático	Autor
Hansen	$ET_o = 0.408 \cdot 0.7 \left(\frac{\Delta}{\Delta + \gamma} \right) R_s$	Hansen (1984)
Hargreaves	$ET_o = 0.0023 \cdot R_s \cdot (T_{med} + 17.8) \cdot \delta T^{0.5}$	Hargreaves y Samani (1985)
Jones-Ritchie	$ET_o = 0.00387 \cdot (0.6 \cdot T_{max} + 0.4 \cdot T_{min} + 29) R_s \cdot a$	Jones y Ritchie (1990)
Priestley - Taylor	$ET_o = 0.408 \cdot 0.7 \left(\frac{\Delta}{\Delta + \gamma} \right) (R_n - G)$	Priestley y Taylor (1972)
Turc	$ET_o = (0.3107 \cdot R_s + 0.65) \left(\frac{T_1}{T_{med} + 15} \right)$	Turc (1962)

2.5.2 Modelo de Penman-Monteith

El modelo planteado por Penman en 1948, parte de conocer variables como la temperatura, humedad, horas de sol y velocidad del viento para calcular la evaporación de una superficie de agua expuesta, fue objeto de varias revisiones y recomendaciones posteriores que llevaron a desarrollar el modelo de Penman-Monteith (Allen et al., 1998).

En 1990 se integra el modelo conocido como *FAO - Penman-Monteith*, como un método estándar para calcular la ET_0 de una superficie hipotética de pasto verde de gran extensión; el método incorpora el efecto de la resistencia aerodinámica de superficies y elementos que este tipo de vegetación experimentaría al paso del viento, representado conceptualmente en la figura 2.11. Asume además varias características físicas como la altura de la vegetación (h), en 0.12[m], una resistencia superficial (r_s) de 70 [s/m], resistencia aerodinámica (r_a) en función de la velocidad del viento (u_2), e igual a $208/u_2$ [s/m], albedo de superficie (α) de 0.23, y un nivel de referencia absoluto, a 2[m] sobre la superficie.

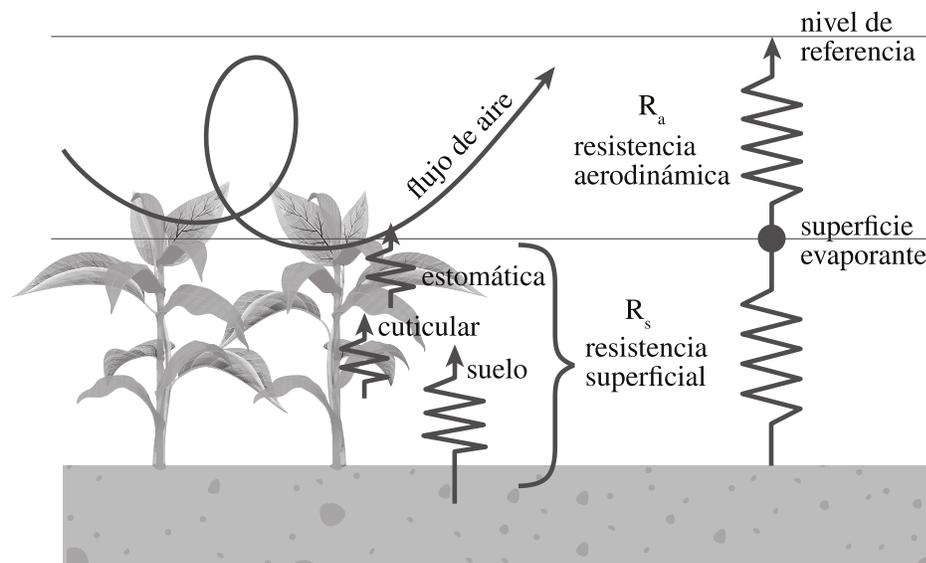


Figura 2.11. Modelo conceptual de las componentes de la resistencia aerodinámica sobre una superficie agrícola, modificada de Allen et al. (1998).

El resultado es la expresión *FAO-Penman-Monteith* (Allen et al., 1998), que se muestra en la ecuación 10, mientras la ecuación 11 muestra la versión para el cálculo por hora de ET_0 .

$$ET_0 = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34u_2)} \quad \text{Ec.10}$$

$$ET_0 = \frac{0,408\Delta(R_n - G) + \gamma \frac{37}{T_{hr} + 273} u_2 (e^0(T_{hr}) - e_a)}{\Delta + \gamma(1 + 0,34u_2)} \quad \text{Ec.11}$$

Donde:

- ET_0 Evapotranspiración de referencia ($mm \text{ día}^{-1}$)
- R_n Radiación neta en la superficie del cultivo ($MJ \text{ m}^{-2} \text{ día}^{-1}$)
- G Flujo del calor de suelo ($MJ \text{ m}^{-2} \text{ día}^{-1}$)
- T Temperatura media del aire a 2m de altura ($^{\circ} C$)
- T_{hr} Temperatura media del aire a 2m de altura periódica a 1 hr ($^{\circ} C$)
- u_2 Velocidad del viento a 2 m de altura ($m \text{ s}^{-1}$)
- e_s Presión de vapor de saturación (kPa)
- e_a Presión real de vapor (kPa)
- e^0 Presión de vapor de saturación a temperatura, periódico a 1 hr (kPa)
- $e_s - e_a$ Déficit de presión de vapor (kPa)
- Δ Pendiente de la curva de presión de vapor ($kPa \text{ }^{\circ}C^{-1}$)
- γ Constante psicrométrica igual a $0.000665 * P_{est}$ ($kPa \text{ }^{\circ}C^{-1}$)
- P_{est} Presión atmosférica en la estación de medición (kPa)

Capítulo 3

Evapotranspiración de cultivo mediante un modelo de balance de energía

3.1 Introducción

Para el sector hídrico y agrícola, las técnicas de percepción remota han resultado herramientas indispensables para analizar diferentes tipos de sistemas físicos. Dentro de estas, los modelos de balance de energía han tenido gran aceptación en el análisis de la evapotranspiración de cultivos; comenzaron a desarrollarse desde finales del siglo XX, y han continuado su desarrollo con la llegada de nueva tecnología espacial y sensores remotos.

Diversas investigaciones han utilizado las formulaciones teóricas de modelos de balance de energía para analizar la ET_c desde mediados del siglo XX (i.e. Deacon, 1950; Choudhury, Idso, y Reginato, 1987). Posteriormente, estos métodos fueron adaptados a la información adquirida por sensores remotos, surgiendo metodologías como *SEBAL* (Bastiaanssen et al., 1998), *S-SEBI* (Roerink, Su, y Menenti, 2000), *SEBS* (Su, 2002), *ReSET* (Elhaddad y Garcia, 2008), *METRIC* (Allen et al., 2007), *EEFLUX* (Ayse Kilic et al., 2015), entre otros; todos ellos con el propósito de calcular este parámetro en áreas extensas.

SEBAL y *METRIC* han sido metodologías ampliamente aceptadas gracias a los principios físicos con que fueron planteados. *METRIC*, es uno de los más

utilizados al ser un algoritmo que automatiza el proceso de cálculo a diferencia de *SEBAL*, el cual es considerado manual o semi-automático; trabajos como el de Büyükcangaz et al. (2017) y Allen et al. (2007), muestran algunas aplicaciones.

A fin de evaluar su aplicabilidad y precisión para estimar ET_c , se han comparado diversos modelos de balance de energía, por ejemplo, Bhattarai, Shaw, Quackenbush, Im, y Niraula (2016) reportan valores de R^2 de entre 0.59 y 0.87 para la relación de la ET_c medida en campo y la calculada con el método *METRIC* con un ECM de 0.95; y para el método *SEBAL* un R^2 entre 0.68 a 0.87 y ECM de 0.83, en distintos tipos de cultivo. En el trabajo de Foolad et al. (2018) se comparan dos tipos de métodos *METRIC*, manual contra *METRIC-EEFLUX*, este último automatizado; se reportan valores de R^2 de 0.89 y 0.95, con ECM de 0.23 y 1.36 para fechas diferentes respectivamente.

Por otra parte, en la región norte del estado de Sinaloa no se cuenta con un análisis geoespacial de la evapotranspiración que permita estimar el gasto de los cultivos con precisión. Las mediciones de este parámetro son comúnmente adquiridas de forma convencional con métodos directos mediante lisímetros o indirectos como la razón de Bowen y el balance de energía, por ejemplo, Ojeda-Bustamante et al. (2006), proponen una calendarización de riego en la zona basada en estos; no obstante, este tipo de métodos que requieren de información obtenida en campo de carácter puntual.

El objetivo de este capítulo es conformar una base de datos a partir del cálculo de un modelo de balance de energía siguiendo la metodología *METRIC* para una zona dentro del distrito de riego 075 Río Fuerte; así como realizar un análisis espacio-temporal de ET_c , que pueda ayudar a gestionar el recurso hídrico dentro de los ciclos agrícolas en la región y sirva como antecedente para la generación de políticas del uso del recurso hídrico.

3.2 Materiales y métodos

3.2.1 Ubicación de la zona de estudio

El distrito de riego 075 - Río Fuerte se localiza en el norte del estado de Sinaloa, México, cuya extensión y ubicación regional se muestra en la figura 3.1. Dentro de esta zona administrativa, se encuentran los módulos de riego Santa Rosa y Batequis, que para efectos de este trabajo se encuentran considerados dentro de un polígono de 22 142 hectáreas.

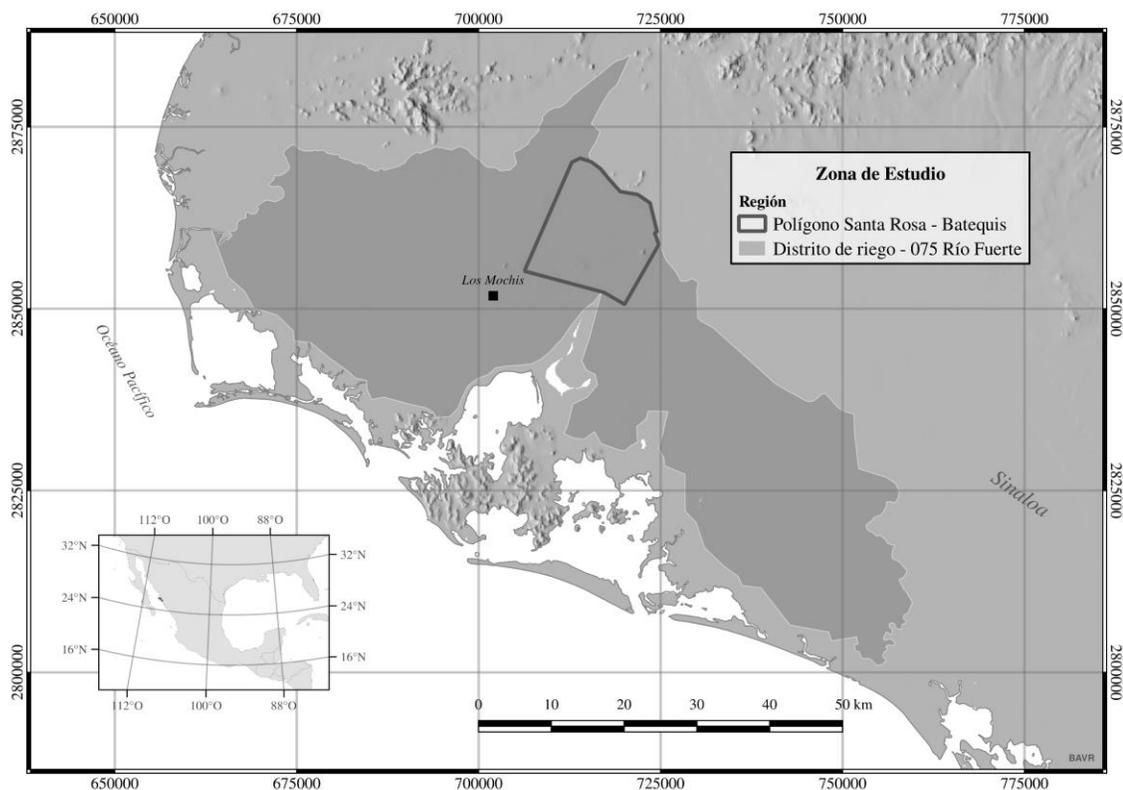


Figura 3.1. Mapa de localización de la zona de estudio; norte de Sinaloa (UTM, 12N).

El área de estudio es una zona de producción agrícola muy importante, cuyos cultivos principales son el maíz grano, frijol, la caña de azúcar, el jitomate y el

chile verde entre otros; el ciclo agrícola inicia la primera quincena de octubre para concluir en la segunda quincena de mayo, es decir en un ciclo de otoño a verano.

Las normales climatológicas del Servicio Meteorológico Nacional (2016), reportan en la estación Ahome ubicada a menos 2[km] de la zona de estudio en el municipio de los Mochis, Sinaloa, una temperatura máxima de 33°C, mínima de 18.7°C y media de 25.9°C, precipitación anual de 357.4 mm y evaporación total de 2,123.3 mm, con clima cálido – húmedo para el periodo de 1981 a 2010.

3.2.2 Bancos de información de la zona de estudio

Se utilizaron 201 imágenes satelitales de tres sensores de serie *LANDSAT*, específicamente de los sensores *L5-TM*, *L7-ETM* y *L8-OLI/TIRS*. La figura 3.2 muestra gráficamente el número de imágenes por sensor, las cuales corresponden a distintas fechas de adquisición entre los años 1995 a 2018.

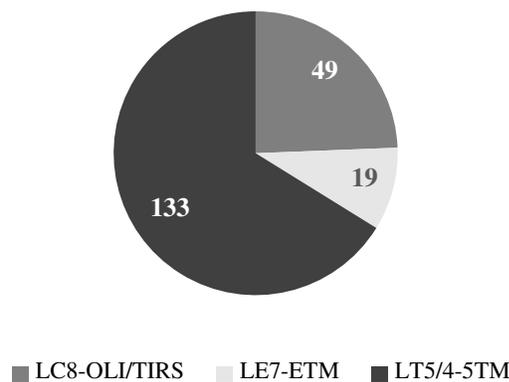


Figura 3.2. Número de imágenes por sensor *LANDSAT*.

Las imágenes satelitales utilizadas fueron descargadas del Servicio Geológico Norteamericano (*USGS*) usando las aplicaciones disponibles públicamente en línea: *EarthExplorer*, *Glovis* y *ESPA* (*USGS*, 2018b).

La selección de las imágenes siguió un criterio que consistió en revisar y contabilizar aquellas imágenes que presentasen claridad y mínima cobertura de nubes en la zona de estudio, de los tres sensores *LANDSAT*. En la tabla 3.1 se muestra la distribución por quincenas de las imágenes seleccionadas bajo el condicionamiento anterior por año y tipo de sensor; se aprecia para los años 1999 a 2003 se registró información de dos tipos de sensores, el L5 y L7.

Tabla 3.1. Distribución quincenal de las imágenes *LANDSAT* bajo condiciones de claridad por año y sensor.

Mes	ENE		FEB		MAR		ABR		MAY		JUN		JUL		AGO		SEP		OCT		NOV		DIC		
	QUINCENA																								
AÑO	1	2	1	2	1	2	1	2	1	2	1	2	1	2	1	2	1	2	1	2	1	2	1	2	
1995	L5	L5					L5	L5	L5	L5	L5	L5											L5	L5	
1996	L5			L5			L5		L5						L5		L5				L5				
1997				L5			L5		L5				L5				L5		L5	L5	L5	L5			
1998			L5	L5	L5		L5		L5														L5	L5	L5
1999																				L7			L7	L7	
	L5	L5			L5	L5			L5						L5				L5		L5				
2000				L7		L7				L7												L7			
	L5	L5		L5			L5		L5	L5					L5						L5			L7	
2001		L7				L7		L7																	
						L5									L5		L5	L5			L5				
2002	L7		L7													L7						L7		L7	
		L5							L5	L5	L5	L5										L5		L5	
2003				L7	L7					L7															
	L5	L5					L5	L5	L5	L5			L5	L5	L5				L5	L5	L5	L5			
2004	L5					L5			L5	L5	L5				L5				L5		L5			L5	
2005	L5			L5	L5	L5		L5	L5								L5		L5	L5					
2006										L5		L5	L5		L5							L5		L5	
2007				L5		L5		L5	L5	L5															
2008				L5	L5	L5	L5	L5				L5							L5	L5	L5			L5	
2009				L5						L5														L5	
2010		L5	L5			L5			L5	L5	L5											L5	L5	L5	L5
2011	L5	L5		L5	L5																	L5			
2013						L8		L8	L8			L8								L8			L8	L8	
2014		L8		L8				L8	L8	L8							L8	L8	L8			L8	L8	L8	
2015	L8	L8	L8			L8		L8	L8	L8				L8						L8		L8	L8		
2016						L8		L8	L8	L8	L8									L8			L8		
2017						L8				L8	L8						L8	L8	L8	L8	L8	L8			
2018	L8	L8	L8					L8	L8																

En el resumen anual que se muestra en la figura 3.3, el año 2012 se muestra con ausencia de imágenes dado que el único sensor en operación fue el L7-ETM. El sensor L7 presentó errores en su funcionamiento a partir del año 2003, afectando la calidad de las imágenes subsecuentes; dichas imágenes con sectores vacíos de información, fueron omitidas en el presente trabajo para evitar el sesgo en el análisis posterior.

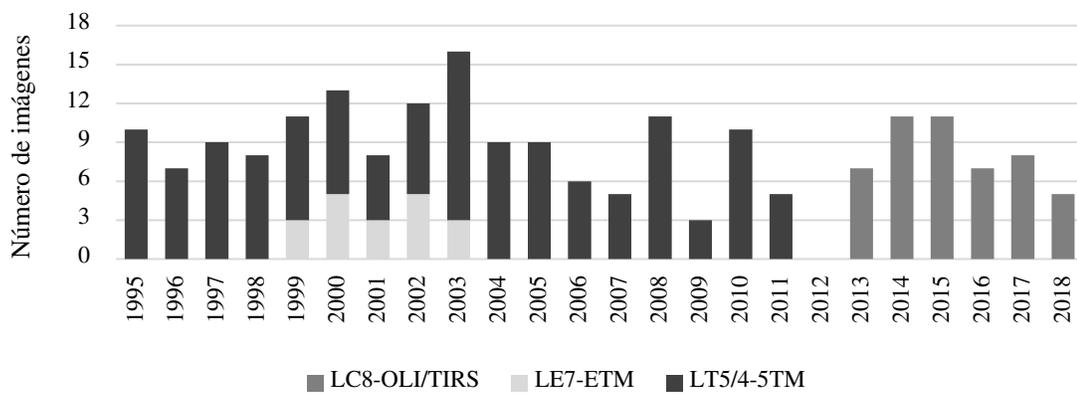


Figura 3.3. Distribución anual del número de imágenes obtenidas por tipo de sensor LANDSAT.

La cantidad de imágenes por mes se muestra gráficamente en la figura 3.4, siendo mayo el mes con mayor número de imágenes, y el de menor julio; el promedio de imágenes por mes durante el periodo de estudio fue de 17.

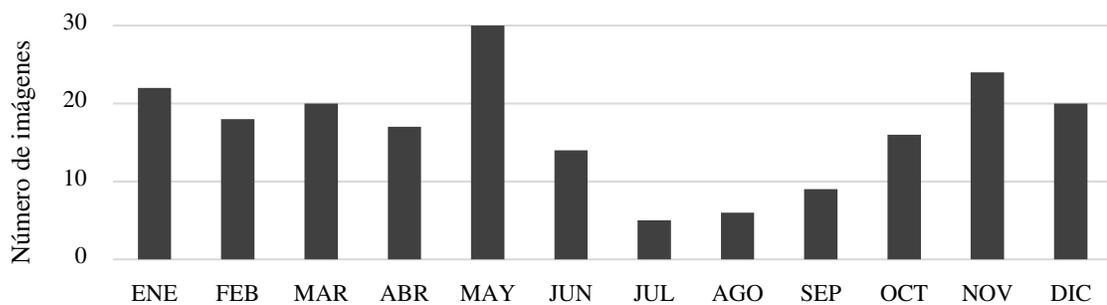


Figura 3.4. Distribución mensual del número de imágenes obtenidas.

La corrección radiométrica y calibración atmosférica de las imágenes se efectuó de dos formas, una manual siguiendo el método expuesto en la sección 3.2.3, y otra automática, mediante el software QGIS (*QGIS Development Team, 2017*). El procesamiento efectuado para obtener los modelos de ET_c fue realizado con el paquete denominado “*water*” (Olmedo, Ortega-Farias, de la Fuente-Sáiz, Fonseca-Luego, y Fuentes-Penailillo, 2016), paquetería del software *R* (*R Development Core Team, 2018*), en el cual se llevó a cabo el análisis posterior de los modelos.

La información climática utilizada en los modelos de ET_c , provino de cuatro estaciones climatológicas pertenecientes a la red del INIFAP (2017), las cuales fueron seleccionadas por su cercanía a la zona de estudio (< 5 Km). Estas estaciones fueron: JJ. Ríos, Taxtes, Camajoa, La Genoveva, cuya ubicación se muestra en la figura 3.5. Los parámetros obtenidos fueron: temperaturas máxima, mínima y media, velocidad de viento, humedad relativa y radiación global.

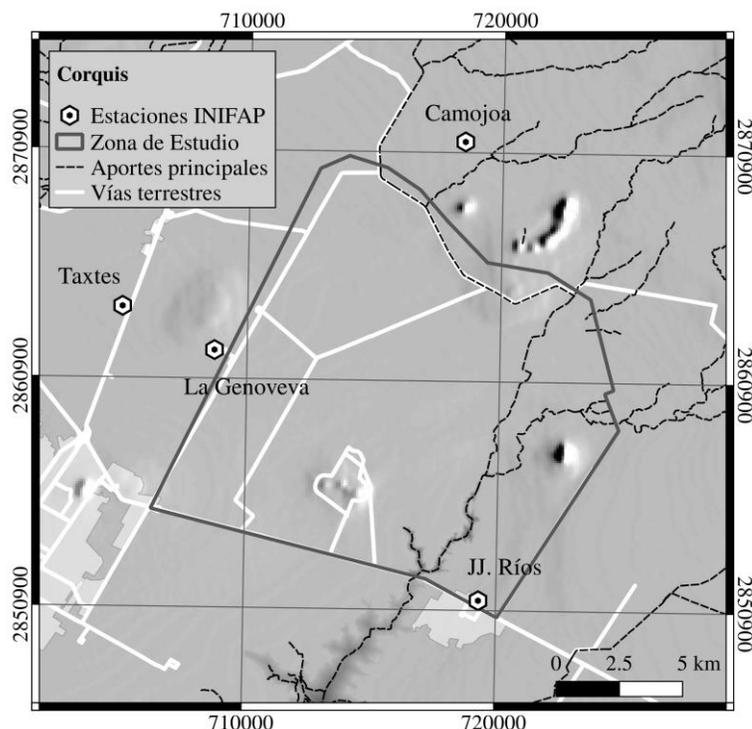


Figura 3.5. Croquis de ubicación de las estaciones climáticas utilizadas en el análisis.

3.2.3 Corrección y calibración de imágenes *LANDSAT*

Con el propósito de obtener valores de reflectancia que puedan ser tratados dentro de modelos físicos, es necesario convertir los números digitales calibrados de las imágenes satelitales. Una de las metodologías para realizar lo anterior es expuesta por Chander, Markham, y Helder (2009), utilizada para las imágenes *LANDSAT* de los sensores *L5-TM* y *L7-ETM* sin preprocesamiento en este trabajo.

Como primer paso en esta metodología, se transformó a los números digitales calibrados de cada banda ($\lambda = 1$ a 5 , y 7), a valores de radiancia mediante la ecuación 12.

$$L_{\lambda} = \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \right) \cdot (Q_{cal} - Q_{calmin}) + LMIN_{\lambda} \quad \text{Ec.12}$$

Donde:

L_{λ} : Es la radiancia de la banda espectral λ [$W/m^2 \text{ sr } \mu m$]

Q_{cal} : Valor cuantificado y calibrado del pixel [Número digital o *DN*]

Q_{calmin} : Valor mínimo cuantificado y calibrado del pixel correspondiente a $LMIN_{\lambda} = 1$ [Número digital o *DN*]

Q_{calmax} : Valor máximo cuantificado y calibrado del pixel correspondiente a $LMAX_{\lambda} = 255$ [Número digital o *DN*]

$LMIN_{\lambda}$: Radiancia espectral en el sensor escalada a Q_{calmin} , [$W/(m^2 \text{ sr } \mu m)$]

$LMAX_{\lambda}$: Radiancia espectral en el sensor escalada a Q_{calmax} , [$W/(m^2 \text{ sr } \mu m)$]

Los coeficientes $LMIN_{\lambda}$ y $LMAX_{\lambda}$, son constantes de calibración que se incluyen en los metadatos de cada imagen. Posteriormente, se obtuvieron los valores de reflectancia en la capa límite superior de la atmósfera (*Top of Atmosphere*, o *TOA*), mediante la aplicación de la ecuación 13.

$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{ESUN_{\lambda} \cdot \text{sen } \theta_{ES}} \quad \text{Ec.13}$$

Donde:

ρ_{λ} : Es la reflectancia de la banda térmica [*adimensional*]

L_{λ} : Radiancia de la banda espectral λ [$W/m^2 \text{ sr } \mu m$]

d : Distancia Sol-Tierra [*Unidades astronómicas*]

$ESUN_{\lambda}$: Irradiancia media exoatmosférica de la banda λ [$W/m^2 \text{ sr } \mu m$]

θ_{ES} : ángulo de elevación solar local al momento de la adquisición [*grados*]

Para el sensor L8-OLI/TIRS, se tomó en cuenta la metodología de la USGS (2018a), como primer paso se obtuvieron los valores de radiancia aplicando la ecuación 14 para cada banda espectral.

$$L_{\lambda} = (ML * Q_{cal}) + A_L \quad \text{Ec.14}$$

Donde:

L_{λ} : Es la radiancia por banda espectral [$W/m^2 \text{ sr } \mu m$]

Q_{cal} : Valor cuantificado y calibrado del pixel [Número digital o *DN*]

A_L, ML : factores de escalamiento de radiancia (metadatos)

Y posteriormente, se obtuvieron los valores de reflectancia en la capa límite superior de la atmósfera (*TOA*), aplicando las ecuaciones 15 y 16.

$$\rho'_{\lambda} = M_{\rho} * Q_{cal} + A_{\rho} \quad \text{Ec.15}$$

$$\rho_{\lambda} = \frac{\rho'_{\lambda}}{\text{sen}(\theta_{ES})} \quad \text{Ec.16}$$

Donde:

ρ'_{λ} : Es la reflectancia de la banda térmica [*adimensional*]

Q_{cal} : Valor cuantificado y calibrado del pixel [Número digital o *DN*]

M_{ρ}, A_{ρ} : factores de escalamiento de reflectancia (metadatos)

θ_{ES} : ángulo de elevación solar local al momento de la adquisición [*grados*]

Los valores digitales de las bandas térmica se convirtieron a valores de temperatura de brillo espectral para los tres sensores mediante la ecuación 14; para los sensores L5 y L7, $\lambda = 6$, mientras que para el sensor L8, $\lambda = 10$ u 11, siendo la banda 10 la recomendación para el cálculo del balance de energía por su ganancia.

$$T_S = \frac{K_2}{\ln\left(\frac{K_1}{L_{\lambda}} + 1\right)} \quad \text{Ec.14}$$

Donde:

T_S : Es la temperatura de brillo de superficie [*K*]

K_1, K_2 : Constantes de calibración, valores de metadatos [$W/m^2 \text{ sr } \mu m$], [*K*]

L_{λ} : Radiancia de la banda espectral térmica [$W/m^2 \text{ sr } \mu m$]

3.2.4 Modelos de balance de energía de la zona de estudio

A partir de la corrección radiométrica y por efectos de atmósfera, de los valores de reflectancia es posible calcular el modelo de balance de energía, para este trabajo se utilizó un modelo combinado semi automatizado utilizando *METRIC* y *SEBAL*, se resolvió cada uno de los componentes de la ecuación de balance de energía (Ec.6), y se obtuvo para cada imagen considerada los valores del flujo de radiación neta R_n , flujo de calor del suelo G , flujo de calor sensible H , latente λET y finalmente de ET_c . Un resumen de los pasos se describe a continuación:

1) Obtención del Albedo (α)

El albedo, es la proporción de radiación incidente que es reflejada por la superficie terrestre, un método para obtener el valor del albedo se describe en el trabajo de Morse, Allen, y Kramber (2000), mediante la ecuación 15, la cual está en función de la elevación, y diversas condiciones expresadas en las ecuaciones 16 y 17.

$$\alpha = \frac{\alpha_{toa} - \alpha_{pr}}{\tau_{sw}^2} \quad \text{Ec.15}$$

$$\tau_{sw} = 0.75 * 2 * 10^{-5} * z \quad \text{Ec.16}$$

Dónde:

α : Es el albedo

α_{toa} : El albedo en el límite superior de la atmósfera

α_{pr} : Es el albedo de trayectoria, igual a 0.03 (Bastiaanssen, 2000)

τ_{sw} : Es la transmitancia en un sentido con condiciones de claridad [$\text{W}/\text{m}^2\text{K}$]

z : Es la elevación sobre el nivel del mar [m], del modelo digital de elevaciones.

Existen diferentes metodologías para obtener el albedo corregido por efecto atmosférico, esto de acuerdo al origen de los datos. Para este trabajo, para *LANDSAT 5TM*, *7ETM* y *8OLI/TIRS*, se obtuvo aplicando la ecuación 17.

$$\alpha_{toa} = \sum(\omega_{\lambda} \cdot \rho_{\lambda}) \quad \text{Ec.17}$$

Dónde:

ρ_{λ} : valor de reflectancia de la banda λ

ω_{λ} : Coef. de ponderación de la irradiancia exoatmosférica de la banda λ

Los coeficientes de ponderación ω_λ son obtenidos de la irradiancia media exo-atmosférica de cada banda λ . La tabla 3.2 muestra los coeficientes utilizados en el cálculo del albedo para este trabajo.

Tabla 3.2. Coeficientes de ponderación por banda (ω_λ) y sensor, para estimar el albedo de superficie.

Sensor	B	G	R	NIR	SWIR1	SWIR2	Referencia
L5TM	0.298	0.270	0.231	0.155	0.033	0.013	Chander et al., 2009
L7TM	0.298	0.271	0.229	0.155	0.034	0.013	Chander et al., 2009
L8 OLI/TIRS	0.300	0.277	0.233	0.143	0.036	0.012	Da Silva et al., 2016

2) Obtención del valor de radiación de onda corta entrante $R_{S\downarrow}$

Morse et al. (2000), muestran que la radiación de onda corta de entrada asumiendo una condición atmosférica libre de nubes que puede ser obtenida aplicando la ecuación 18.

$$R_{S\downarrow} = G_{sc} * \cos(\theta) * d_r * \tau_{sw} \quad \text{Ec.18}$$

Dónde:

$R_{S\downarrow}$: Radiación de onda corta entrante [W/m^2]

G_{sc} : Constante solar 1367 [W/m^2]

θ : Ángulo zenital solar [rad]

d_r : Inversa de la distancia Sol-Tierra [m^{-1}]

τ_{sw} : Es la transmitancia en un sentido con condiciones de claridad [$\text{W}/\text{m}^2\text{K}$]

3) Obtener el valor de radiación de onda larga saliente $R_{L\uparrow}$

Este parámetro se estimó mediante la ecuación 19 (Morse et al., 2000).

$$R_{L\uparrow} = \varepsilon_0 * \sigma * T_s^4 \quad \text{Ec.19}$$

Dónde:

$R_{L\uparrow}$: Radiación de onda larga saliente [W/m^2]

ε_0 : Emisividad del ancho de banda en la superficie

σ : Constante de Stefan-Boltzmann ($5.67 \cdot 10^{-8}$ [W/m^2])

T_s : Es la temperatura de brillo de superficie [K]

Tomando la emisividad como la relación mostrada en la ecuación 20:

$$\varepsilon_0 = 0.95 + 0.01 * LAI, \text{ cuando } NDVI > 0 \text{ y } LAI < 3 \quad \text{Ec.20}$$

Dónde:

LAI : Es el índice de área foliar, ver sección 4.2.4.

$NDVI$: El índice de vegetación de diferencia normalizada, ver sección 4.2.1.

4) Obtención de la radiación de onda larga entrante $R_{L\downarrow}$

Se obtuvo a partir de la ecuación 21, propuesta por Bastiaanssen et al. (1998) la cual está definida como la emisividad de la atmósfera en condiciones de claridad.

$$R_{L\downarrow} = 1.08 * (-\ln(\tau_{sw}))^{0.265} * \sigma * T_{0ref}^4 \quad \text{Ec.21}$$

Dónde:

K_{\downarrow} : Radiación de onda corta entrante [W/m^2]

τ_{sw} : Es la transmitancia en un sentido con condiciones de claridad

σ : Constante de Stefan-Boltzmann ($5.67 \cdot 10^{-8}$ [W/m^2])

T_{0ref} : Temperatura en un punto de referencia con buen riego

5) Resolver la ecuación de radiación neta de la superficie R_n

El flujo de radiación neta se calculó con la ecuación 22, descrita en el trabajo de Morse et al. (2000):

$$R_n = (1 - a)R_{S\downarrow} + (R_{L\downarrow} - R_{L\uparrow}) - (1 - \varepsilon_0)R_{L\downarrow} \quad \text{Ec.22}$$

Dónde:

R_n : Flujo de radiación neta [W/m^2]

a : Es el albedo de superficie

$R_{S\downarrow}$: Radiación de onda corta entrante [W/m^2]

$R_{L\downarrow}$: Radiación de onda larga entrante [W/m^2]

$R_{L\uparrow}$: Radiación de onda larga saliente [W/m^2]

ε_0 : Emisividad del ancho de banda en la superficie

6) Obtención del flujo de calor del suelo G

Se puede obtener directamente por la propuesta de Choudhury, Idso, y Reginato, (1987), o mediante la propuesta por Allen, Pereira, Raes, y Smith (1998). El flujo de calor del suelo (G) se obtuvo mediante el modelo descrito por la ecuación 23.

$$G = 0.4 * e^{-0.5*LAI} * R_n \quad \text{Ec.23}$$

Dónde:

G : Flujo de calor del suelo [W/m^2]

LAI : Índice de área foliar

R_n : Flujo de radiación neta [W/m^2]

Otra forma en la que puede ser calculado es mediante su despeje de la relación de calor almacenado en el suelo y vegetación debida a la conducción R_n , según Bastiaanssen (2000) con la ecuación 24.

$$\frac{G}{R_n} = \frac{T_s}{\alpha} (0.0038\alpha + 0.0074\alpha^2)(1 - 0.98 * NDVI^4) \quad \text{Ec.24}$$

Dónde:

$\frac{G}{R_n}$: Relación del calor almacenado en suelo y vegetación

T_s : Es la temperatura de brillo de superficie [K]

α : Es el albedo de superficie

$NDVI$: Es el índice de vegetación de diferencia normalizada

7) Obtención del momento de resistencia aerodinámica (MRA), o Z_{0m}

Chemin y Din Ahmad (2000), toman en cuenta las condiciones aerodinámicas de la vegetación la cual está en función de su altura y distribución espacial. Su valor se puede aproximar mediante la ecuación 25.

$$Z_{0m} = a + b * NDVI \quad \text{Ec.25}$$

Dónde:

$$a = \ln(0.02) - [b * (0.02)] \quad \text{Ec.26}$$

$$b = \frac{(NDVI_{max} - 0.02)}{\ln\left(\frac{h_v}{7}\right) - \ln(0.002)} \quad \text{Ec.27}$$

$NDVI$: Índice de vegetación de diferencia normalizada

$NDVI_{max}$: Valor local máximo del $NDVI$

h_v : altura promedio de la vegetación cuando se tiene $NDVI_{max}$ [m]

8) Selección de pixel caliente y frío.

Para conocer el aporte del flujo de calor sensible (H) en el modelo de balance, cada pixel con vegetación requerirá de conocer un gradiente de temperatura δT en referencia a su condición aerodinámica a fin de estimar la densidad de su aporte, esto se logra a partir de la relación lineal que guardan las temperaturas entre dos superficies extremas con características distintas. Se han propuesto metodologías para la selección de estos puntos extremos denominándose pixel frío y pixel caliente, donde un pixel frío representa una superficie con vegetación densa y húmeda, mientras un pixel caliente representa una superficie seca sin vegetación.

Según el método de Olmedo et al. (2016), la selección de estos dos parámetros puede llevarse sobre el área de estudio y localizarlos mediante el cumplimiento una serie de condiciones sobre otros parámetros conocidos como se muestra a continuación.

$$pixel\ frío \left\{ \begin{array}{l} 3 \leq LAI \leq 6 \\ 0.18 \leq \alpha \leq 0.25 \\ 0.03 \leq Z_{0m} \leq 0.08 \\ NDVI \geq NDVI_{max} - 0.15 \\ T_s < T_{max} - 5 \end{array} \right.$$

$$pixel\ caliente \left\{ \begin{array}{l} 0.13 \leq \alpha \leq 0.15 \\ Z_{0m} \leq 0.005 \\ 0.1 \leq NDVI \leq 0.28 \\ T_s > T_{max} - 5 \end{array} \right.$$

Dónde:

α : Es el albedo de superficie

LAI : Índice de área foliar

Z_{0m} : Momento de resistencia aerodinámica o MRA

$NDVI$: Índice de vegetación de diferencia normalizada y máximo $NDVI_{max}$

T_s : Temperatura de superficie y máximo valor T_{max}

9) Obtención del flujo de calor sensible H

La estimación del flujo de calor sensible H , se logra mediante la aplicación de la ecuación de Bastiaanssen et al. (1998), (Ec.28).

$$H = \frac{\rho_a c_p \delta T_a}{r_{ah}} \quad \text{Ec.28}$$

Dónde:

H : Flujo de calor sensible [W/m^2]

ρ_a : Densidad del aire [kg/m^3]

c_p : Calor específico del aire igual a 1004 [$\text{J}/\text{kg}/\text{K}$]

δT_a : Gradiente de temperatura [$^{\circ}\text{C}$]

r_{ah} : Resistencia aerodinámica al transporte de calor [s/m]

Es un proceso iterativo que ajusta el gradiente de temperatura a condiciones de estabilidad aerodinámica simulando una superficie por encima del plano de desplazamiento nulo o momento de resistencia aerodinámica (MRA). Comienza con dos condiciones neutrales iniciales: $r_{ah,0}$, en función de la velocidad del viento estimada a 200[m], la velocidad de fricción en cada pixel, y un H_0 obtenido de la ecuación de balance para ambos extremos (frío y caliente), se obtiene entonces una primera aproximación del δT , el cual se sustituye en la ecuación 28, obteniendo la primera iteración de H ; posteriormente mediante la corrección de Monin-Obukhov (L, Ψ) se vuelve a calcular r_{ah} en función de la velocidad de fricción (u_*) y se resuelve H_B para la ecuación de balance en los puntos extremos, recalculando con ello δT para estimar un nuevo valor de H mediante la ecuación 28. Esto se realiza hasta obtener el error mínimo entre las iteraciones sucesivas de H ; la figura 3.6 muestra conceptualmente este proceso. Las ecuaciones pueden ser consultadas en el trabajo de Allen (2007).

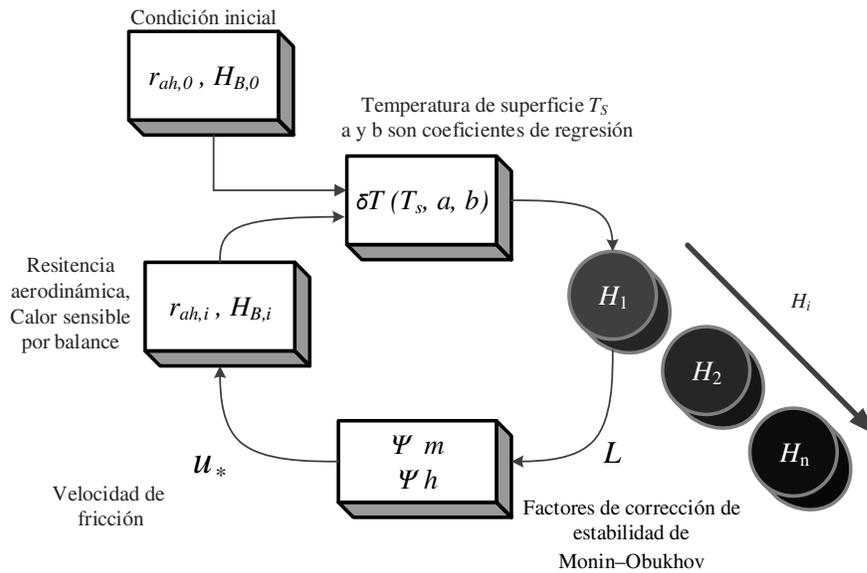


Figura 3.6. Proceso de cálculo del flujo de calor sensible (H), modificada de Chemin y Din Ahmad (2000).

10) Obtención de λET y ET instantánea

Retomando la ecuación de balance (Ec.6), se puede obtener entonces el valor de la energía latente consumida por la evapotranspiración λET , ecuación 29.

$$\lambda ET = R_n - G - H \text{ [W/m}^2\text{]} \quad \text{Ec.29}$$

Dónde:

λ : Calor latente de vaporización [J/kg]

LAI : Índice del área de hoja

R_n : Flujo de radiación neta [W/m²]

G : Flujo de calor del suelo [W/m²]

H : Flujo de calor sensible [W/m²]

A partir de esta, se estima la evapotranspiración instantánea, correspondiente a la hora de adquisición de la imagen.

$$ET_{inst} = 3600 * \frac{\lambda ET}{\lambda} [mm/hr] \quad \text{Ec.30}$$

Dónde:

$\lambda = [2.501 - (0.00236 * (T_s - 273.15))]10^6$, es el calor latente de vaporización [J/kg]

11) Obtención de la evapotranspiración de cultivo ET_c por día

La ET_c diaria se puede calcular mediante la ecuación 31.

$$ET_c \left[\frac{mm}{d} \right] = C_{rad} * \Lambda * ET_{24} \quad \text{Ec. 31}$$

Dónde:

Λ : Es la fracción evapotranspirativa (Ec. 32) [W/m²]

$$\Lambda = \frac{ET_{inst}}{ET_{ref}} [mm/día] \quad \text{Ec.32}$$

C_{rad} : Factor de corrección de terreno, para superficie llana = 1.0 [kg/m³]

ET_{24} : Suma de la evapotranspiración de referencia la estación en 24 horas

ET_{ref} : Es la evapotranspiración de referencia al momento de adquisición

ET_{24} es calculado mediante la ecuación FAO-Penman-Monteith por hora (Ec. 11, sección 2.5.2), mientras ET_{ref} es el modelo calculado durante la hora de adquisición de cada imagen procesada.

En esencia, *METRIC* está basado en el modelo *SEBAL*; sin embargo, existen diferencias en la condición de selección de pixel frío y caliente; además, para el

cálculo de la diferencia de temperaturas (δT), y en cómo se determina la fracción evapotranspirativa Λ (Ec. 32), ya que *SEBAL* utiliza las ecuaciones 33 y 34 para calcular ET_c .

$$\Lambda = \frac{\lambda ET}{R_n - G} [mm/día] \quad (\text{Ec.33})$$

$$ET_{24} = \frac{86400 * ET_{rF} * (R_{n24} - G_{24})}{\lambda} [mm/día] \quad (\text{Ec.34})$$

Donde R_{n24} y G_{24} son la radiación neta y el flujo de calor del suelo durante el día (24 horas), respectivamente.

3.3 Resultados

La información de las estaciones climáticas del INIFAP (2017): J.J. Ríos, Camajoa, La Genoveva y Taxtes, registraron una temperatura media promedio de 23.36 [°C], temperatura mínima promedio de 16.27 [°C], temperatura máxima promedio de 31.88 [°C], velocidad media del viento promedio de 5.25 [m/s], radiación global promedio de 477.7 [W/m²], humedad relativa promedio de 66.71%, evaporación diaria promedio de 5.19 [mm/d], precipitación diaria promedio de 0.75 [mm/d], y evapotranspiración de referencia diaria promedio de 4.66 [mm/d], durante el periodo 2006 a 2017.

Se calculó el modelo de balance de energía para 201 imágenes satelitales *LANDSAT* de los sensores L5-TM, L7-ETM y L8-OLI/TIRS, de la zona de estudio siguiendo en primera instancia la metodología del modelo *SEBAL* (pasos 1 a 7), agregando el cálculo del flujo de calor sensible H y el cálculo de la fracción

evapotranspirativa Λ , para obtener la ET_c del modelo *METRIC* (pasos 9 a 11), constituyendo así el modelo A.

La serie completa de valores medios por día del modelo calculado (modelo A), se muestra en la figura 3.7, donde se aprecia el valor máximo de 7.36 [mm/d] para el día 24/06/2008, y mínimo de 1.47 [mm/d] el día 06/09/2000. Los valores medios de la zona oscilaron entre 0.02 a 11.28 [mm/día].

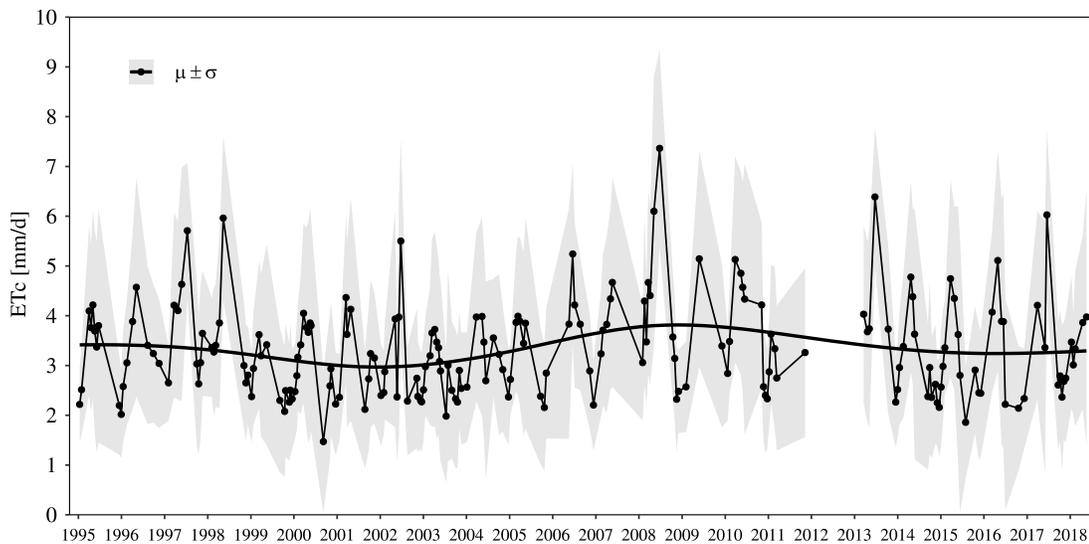


Figura 3.7. Serie completa del modelo A, ET_c media en la zona de estudio.

3.3.1 Comparación entre los modelos de balance de energía

Se comparó el Modelo A, con el modelo *EEFLUX* (A. Kilic, Allen, Huntington, y Ozturk, 2018), se obtuvieron 201 modelos de tipo *METRIC*, y se consideró como modelo teórico para este trabajo, constituyendo el Modelo B.

Se calculó la diferencia entre los valores medios de ET_c de ambos modelos; la figura 3.8 muestra gráficamente la comparación en series de tiempo de ambos, así como la magnitud de los residuos (δ). La diferencia promedio se situó en 0.91

[mm/d], con una desviación estándar de ± 0.71 [mm/d] y un error cuadrático medio (ECM) de 1.15[mm/d], para el periodo de estudio de 1995 a 2018.

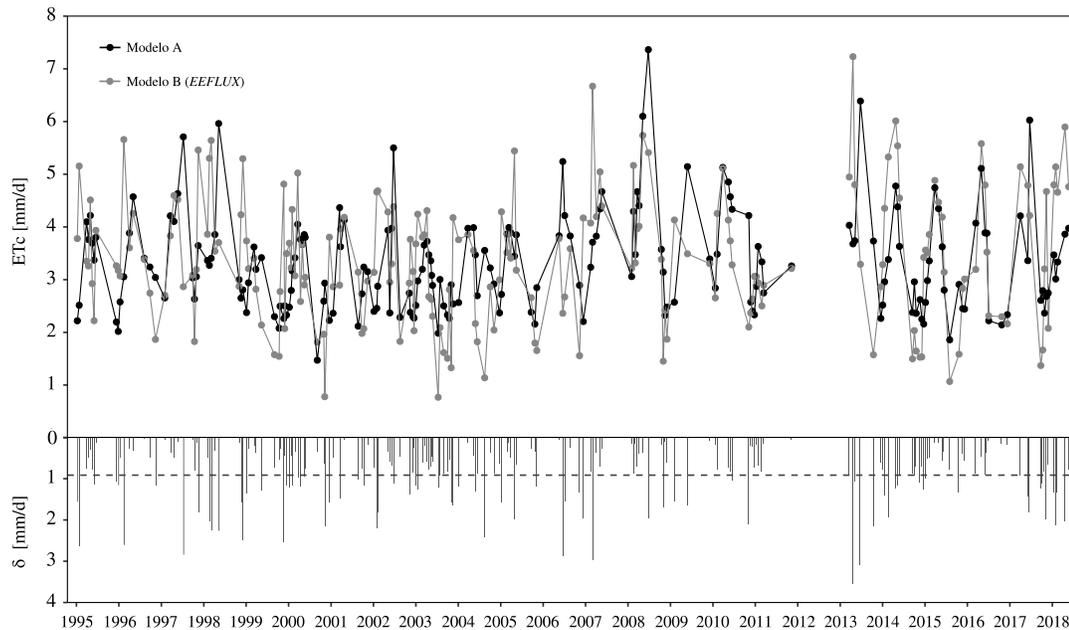


Figura 3.8. Comparación en series de tiempo de modelos A y B(EEFLUX), y representación gráfica de sus residuos.

La disparidad entre ambos modelos recae en el origen de los datos climatológicos que cada modelo utiliza para aproximarse a la ET_c ; mientras el modelo A utiliza datos climáticos de las estaciones del INIFAP (2016) e información de las normales climatológicas del Servicio Meteorológico Nacional (2016) correspondientes al día de adquisición, el modelo B (EEFLUX) toma los datos de modelos climatológicos geoespaciales de la USGS y NASA (Allen R., et al. 2015).

3.3.2 Calibración y validación de un modelo de balance de energía

Se tomaron dos muestras aleatorias $n_1 = 101$ y $n_2 = 100$ del total de modelos de ET_c , 201, tanto del modelo calculado (modelo A); como de sus correspondientes en tiempo del modelo de EEFLUX (modelo B).

De la primera muestra $n_1 = 101$, se extrajeron a su vez muestras aleatorias de tamaño $n_{\text{píxeles}} = 100$ en cada modelo, cantidad basada en una muestra poblacional por modelo de $N_{\text{píxeles}} = 412\,720$, suponiendo un margen de error esperado igual a 0.5, y una desviación esperada de 2.5. La figura 3.9 muestra la comparación por mes de la distribución de frecuencias de ET_C .

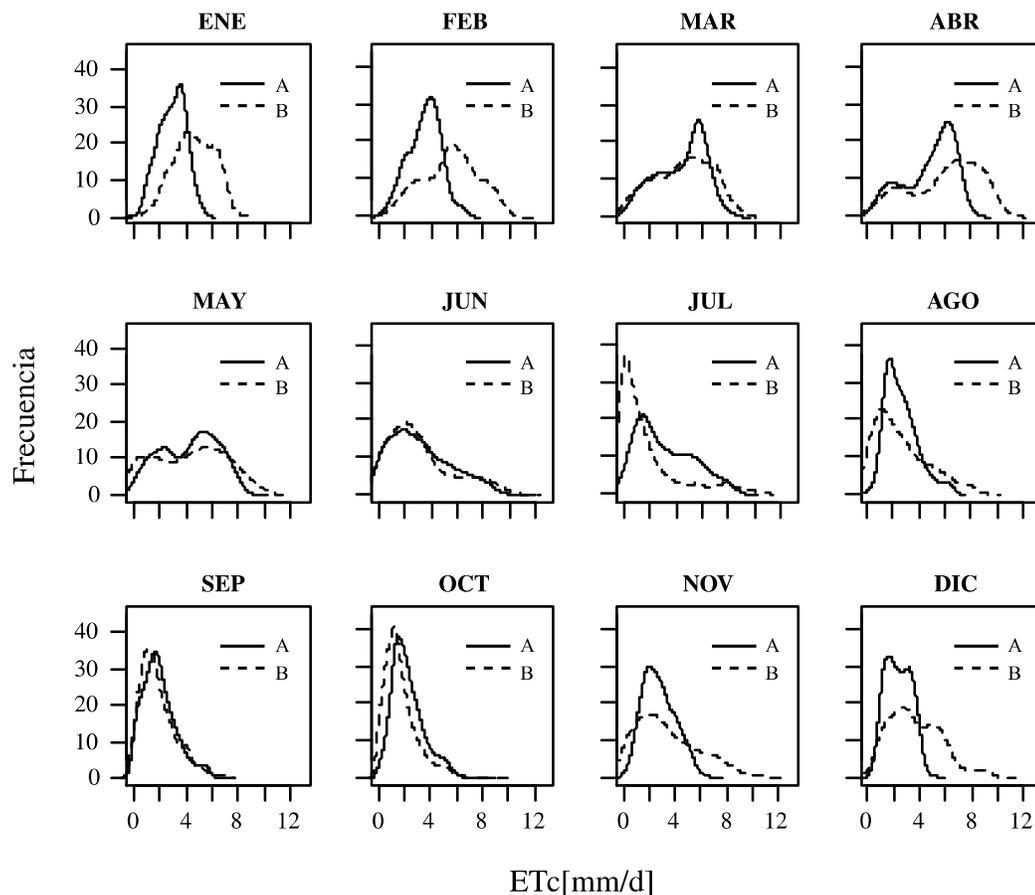


Figura 3.9. Distribución de frecuencias de ET_C por mes; A es el modelo en estudio y B el modelo *EEFLUX*.

Se observó que ambos modelos tienen un comportamiento similar. La forma de la distribución de frecuencias de ET_C del modelo A es comparable al B en los meses de marzo, mayo, junio, y septiembre, donde presenta mayor semejanza, mientras para los demás meses esta se reduce (Figura 3.9).

Considerado el origen de los datos y la similitud de los modelos, se propuso la hipótesis de existencia o inexistencia de relación lineal entre ambos. Se realizó un modelo de regresión por mes con el fin de calibrar el modelo A según la época del año; lo anterior, basado en el comportamiento observado anteriormente.

De igual forma, para ambos modelos de ET_C , se tomó la primera muestra aleatoria de $n_l = 101$; se realizó la regresión lineal simple por mes con $n_{\text{píxeles}} = 100$ muestras de cada modelo, cantidad basada en una muestra poblacional de $N_{\text{píxeles}} = 412\,720$, suponiendo un margen de error esperado igual a 0.5 y una desviación esperada de 2.5. Y, siguiendo la teoría de mínimos cuadrados de Chambers y Hastie (1992), implementada mediante software *R* (*R Development Core Team, 2018*), se obtuvieron 12 modelos lineales cuyos parámetros se muestran en la tabla 3.3.

Tabla 3.3. Modelos de calibración para el modelo A, a partir del modelo *EEFLUX* (i.c. = 0.95).

Mes	Pendiente	Intercepto	R ²	Probabilidad
Enero	1.09	1.41	0.57	8.5E-202
Febrero	1.30	0.93	0.59	5.3E-194
Marzo	1.05	-0.08	0.80	4.5E-284
Abril	1.29	-0.19	0.90	1.2E-254
Mayo	1.07	-0.21	0.74	0.0E+00
Junio	0.93	0.21	0.75	8.4E-182
Julio	0.90	-1.06	0.61	1.5E-84
Agosto	1.51	-1.31	0.85	3.8E-83
Septiembre	0.83	0.18	0.68	5.9E-126
Octubre	0.88	-0.29	0.68	2.3E-224
Noviembre	1.38	-0.35	0.50	1.7E-242
Diciembre	1.43	0.30	0.49	1.4E-148

Una representación gráfica se muestra en la figura 3.10. Los coeficientes de correlación de Pearson para los modelos lineales calculados presentaron una correlación media a fuerte cuya intensidad varía de acuerdo con el mes.

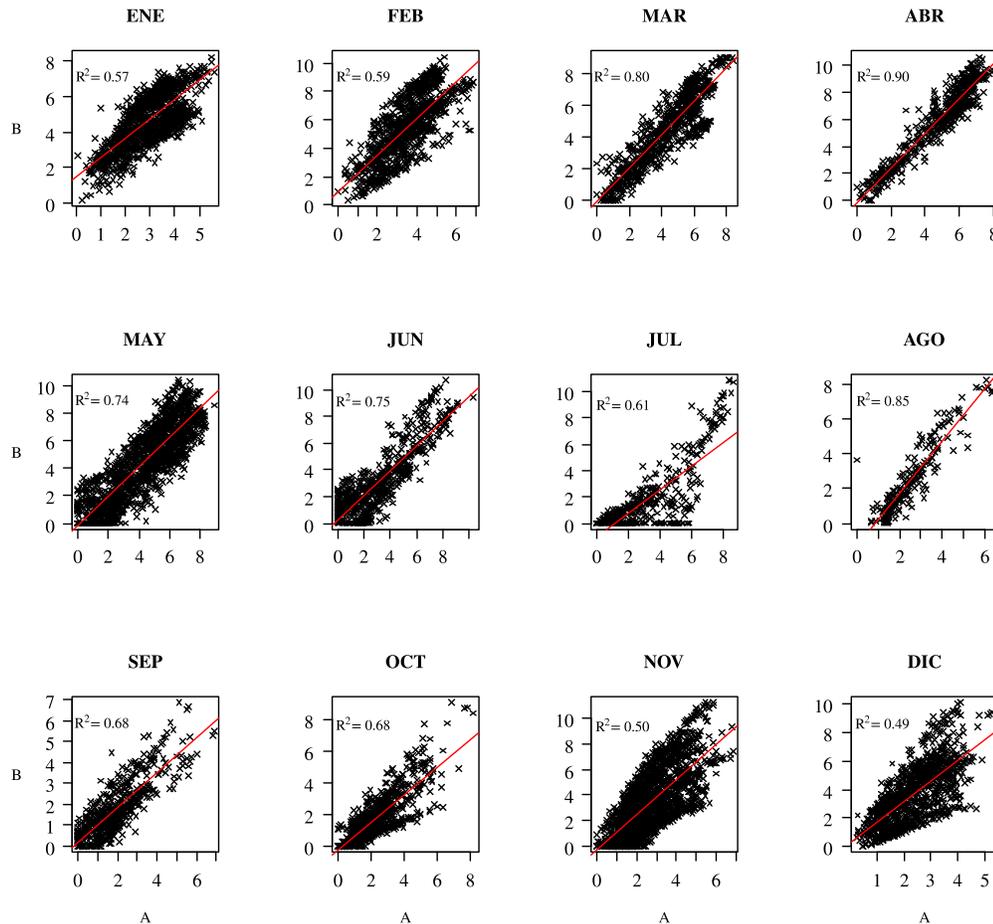


Figura 3.10. Modelos de calibración del modelo A; A es el modelo en estudio y B el modelo *EEFLUX*.

Se observó al mes de noviembre con la correlación lineal más débil ($R^2 = 0.5$), mientras el mes de abril la más fuerte ($R^2 = 0.90$). Ambos meses con valores de probabilidad menores al nivel de significancia de 0.05 ($p < 0.05$), demostrando que el modelo fue apropiado.

La segunda muestra de modelos de ET_c ($n_2 = 100$), fue utilizada para validar los modelos de calibración. Se aplicaron los modelos de calibración sobre el modelo A y se propuso la hipótesis de relación lineal entre el resultado y el modelo B a fin de comprobar el error; se utilizó la metodología de Chambers y Hastie (1992) en este último paso.

El valor del coeficiente R^2 para el proceso de validación osciló entre 0.18 y 0.95. Para la mayoría de los meses mostró baja intensidad, representando con ello un sesgo en el proceso de validación (ver tabla 3.3). Por otra parte, los valores de probabilidad fueron menores al valor de significancia de 0.05 ($p < 0.05$).

El valor del error cuadrático medio (ECM) más bajo se presentó en el mes de julio, esto debido en parte a la poca cantidad de imágenes del mes ($n_{\text{img}} = 7$); el máximo se presentó en noviembre con 1.73; además, se observaron respuestas múltiples en los modelos de validación, exceptuando los meses de mayo y julio, tal como se observa en la figura 3.11, indicando un comportamiento no estacional de ET_c para los demás meses. En cuanto al error absoluto medio (EAM), este tuvo un comportamiento similar al ECM, un valor mínimo en 0.25 para el mes de julio y máximos de 1.38 y 1.34 en abril y noviembre respectivamente (Tabla 3.4).

Tabla 3.4. Modelos de validación del modelo A, a partir del modelo *EEFLUX* (i.c. = 0.95).

Mes	Pendiente	Intercepto	R^2	Probabilidad	EAM	ECM
Enero	0.87	1.03	0.34	9.8E-103	1.13	1.37
Febrero	0.81	0.20	0.53	3.2E-133	0.99	1.20
Marzo	1.07	0.56	0.58	1.0E-225	1.26	1.63
Abril	0.98	-0.10	0.64	2.3E-267	1.38	1.71
Mayo	1.07	-0.14	0.88	0.0E+00	0.78	0.98
Junio	0.92	-0.52	0.71	1.0E-215	1.19	1.49
Julio	1.01	0.47	0.95	1.3E-64	0.25	0.33
Agosto	0.49	0.84	0.31	1.5E-34	1.15	1.36
Septiembre	1.32	-0.90	0.78	9.3E-132	0.60	0.75
Octubre	1.42	-0.19	0.59	1.5E-136	1.26	1.43
Noviembre	0.41	1.45	0.18	1.4E-37	1.34	1.73
Diciembre	0.80	0.79	0.55	2.5E-173	0.96	1.24

De acuerdo a lo anterior, julio y mayo fueron los meses donde los modelos A y B presentaron la mejor relación lineal por temporada; por el contrario, los meses de enero, marzo, abril, agosto, octubre y noviembre presentaron las correlaciones más débiles. En general, al presentarse respuestas múltiples, los valores del ECM

aumentan, indicando una relación lineal no favorable para meses donde se presenta este comportamiento, y se optó por no aplicar los modelos de calibración en estos.

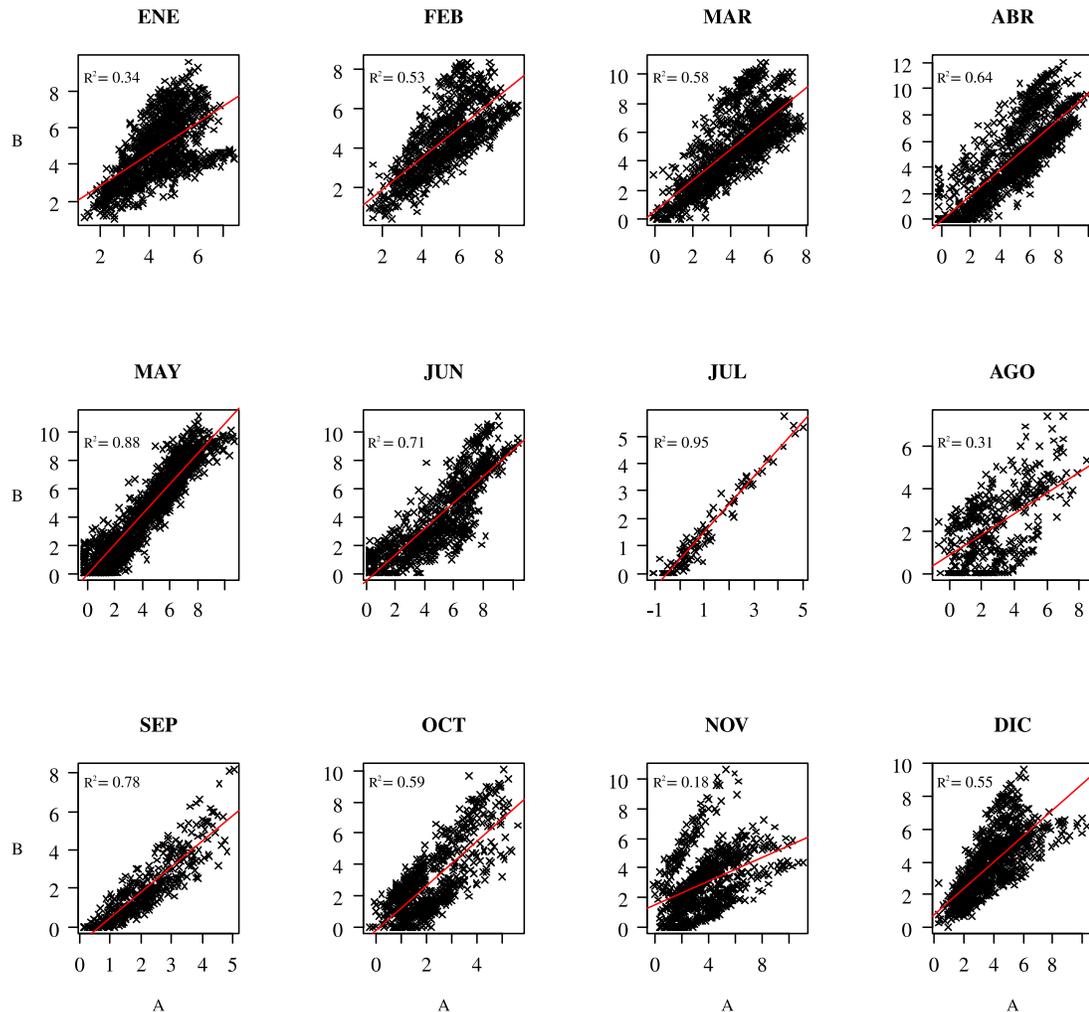


Figura 3.11. Modelos de validación del modelo A; A es el modelo en estudio y B el modelo *EEFLUX*.

3.3.3 Variabilidad espacio-temporal de ET_c

Del total de modelos generados ($N_M = 201$), se realizó un análisis espacial estadístico de los valores de ET_c correspondientes al periodo 1995 a 2018. El resultando se muestra en los mapas de la figura 3.12.

En la figura 3.12, se observa la variabilidad espacial del parámetro correspondiente al modelo de ET_c calculado (modelo A); muestra los mapas de ET_c media, desviación estándar, valores mínimos y máximos, para el periodo de 1995 a 2018 de la zona de estudio.

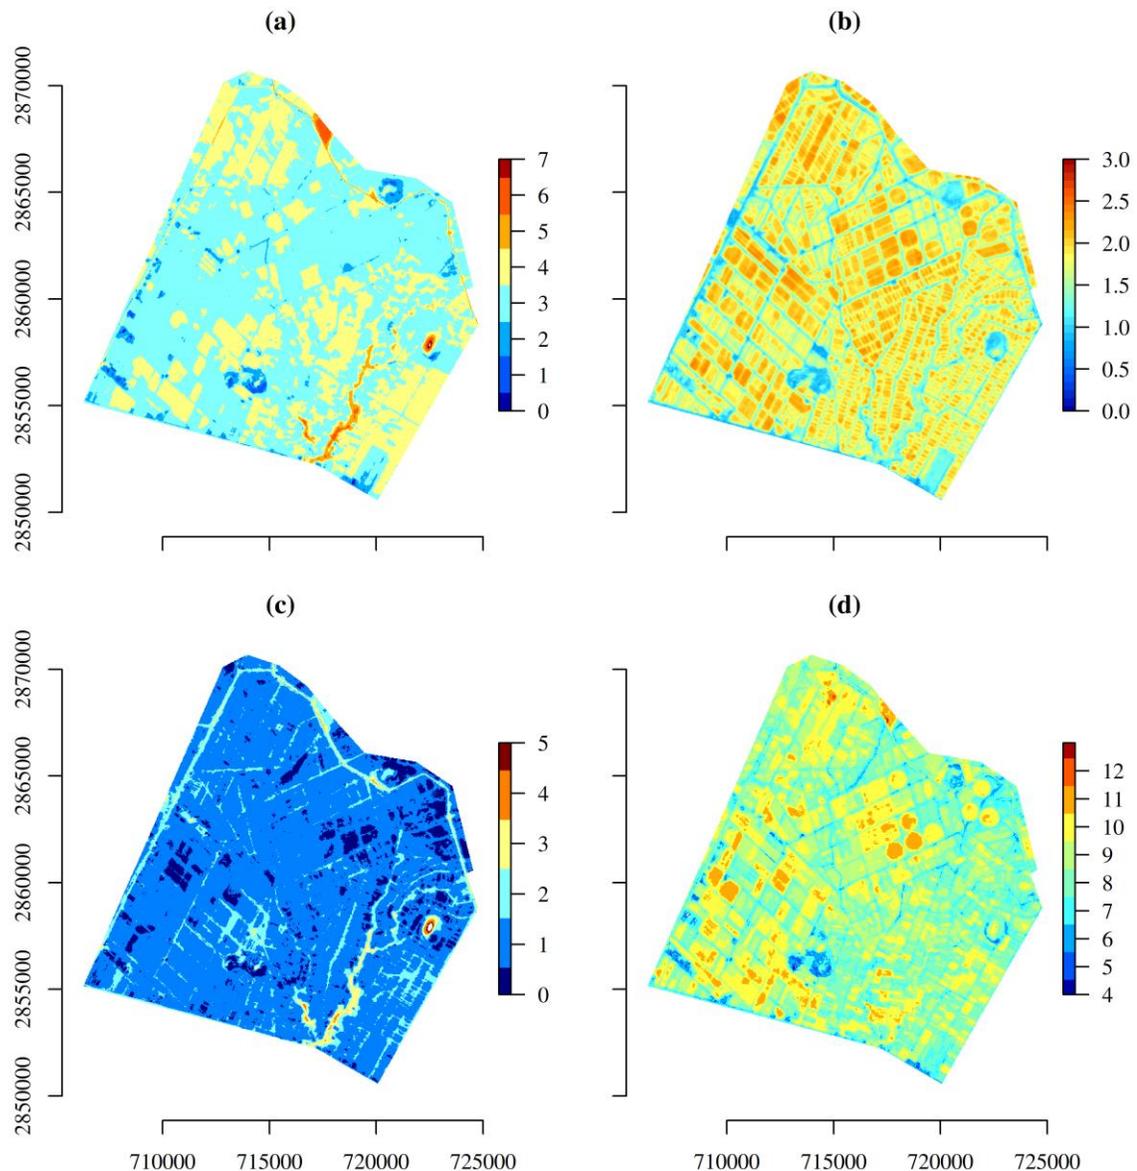


Figura 3.12. Variabilidad espacial de ET_c [mm/d], (a) Media absoluta de ET_c , (b) Desviación estándar de ET_c , (c) Mínima absoluta de ET_c , (d) Máxima absoluta de ET_c .

La figura 3.12(a) muestra que los valores altos de ET_c media se concentran donde existe vegetación perene como arbustos y plantas herbáceas diversas, en elevaciones topográficas y en el aporte principal de agua localizado al este de la región de estudio. En la figura 3.12(b), se observa que las variaciones altas de ET_c se presentan en zonas de cultivo indicando que son las zonas de mayor dinámica del parámetro. Respecto a los valores máximos y mínimos, estos se observaron dentro de zonas de cultivo, como se aprecia en la figura 3.12(c) y 3.12(d) respectivamente; donde el comportamiento de los valores máximos se traduce en consumos de exceso.

La evolución del valor de anual de ET_c promedio para la zona de estudio se muestra en la figura 3.13. Se observó una oscilación de los valores entre 2.68 y 4.08 [mm/día], con mínimo en el año 1999 y máximo en el año 2008 respectivamente, un modelo lineal de la serie temporal indica una tendencia positiva, representando un incremento de $2.6 \cdot 10^{-5}$ [mm/d] anual del parámetro.

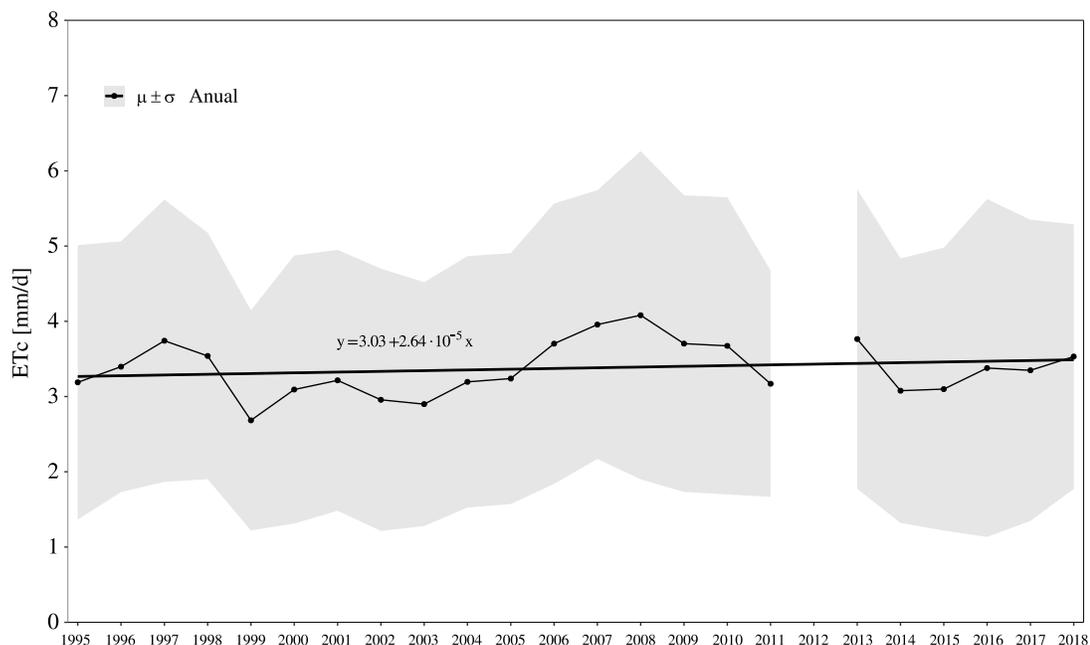


Figura 3.13. Serie anual y tendencia de ET_c media para la zona de estudio.

La figura 3.14 muestra los mapas anuales de ET_c promedio se obtuvieron para periodos de 5 años, incluyendo 2018. Se aprecia un ligero incremento de las áreas que registran valores de $ET_c > 5$ [mm/d].

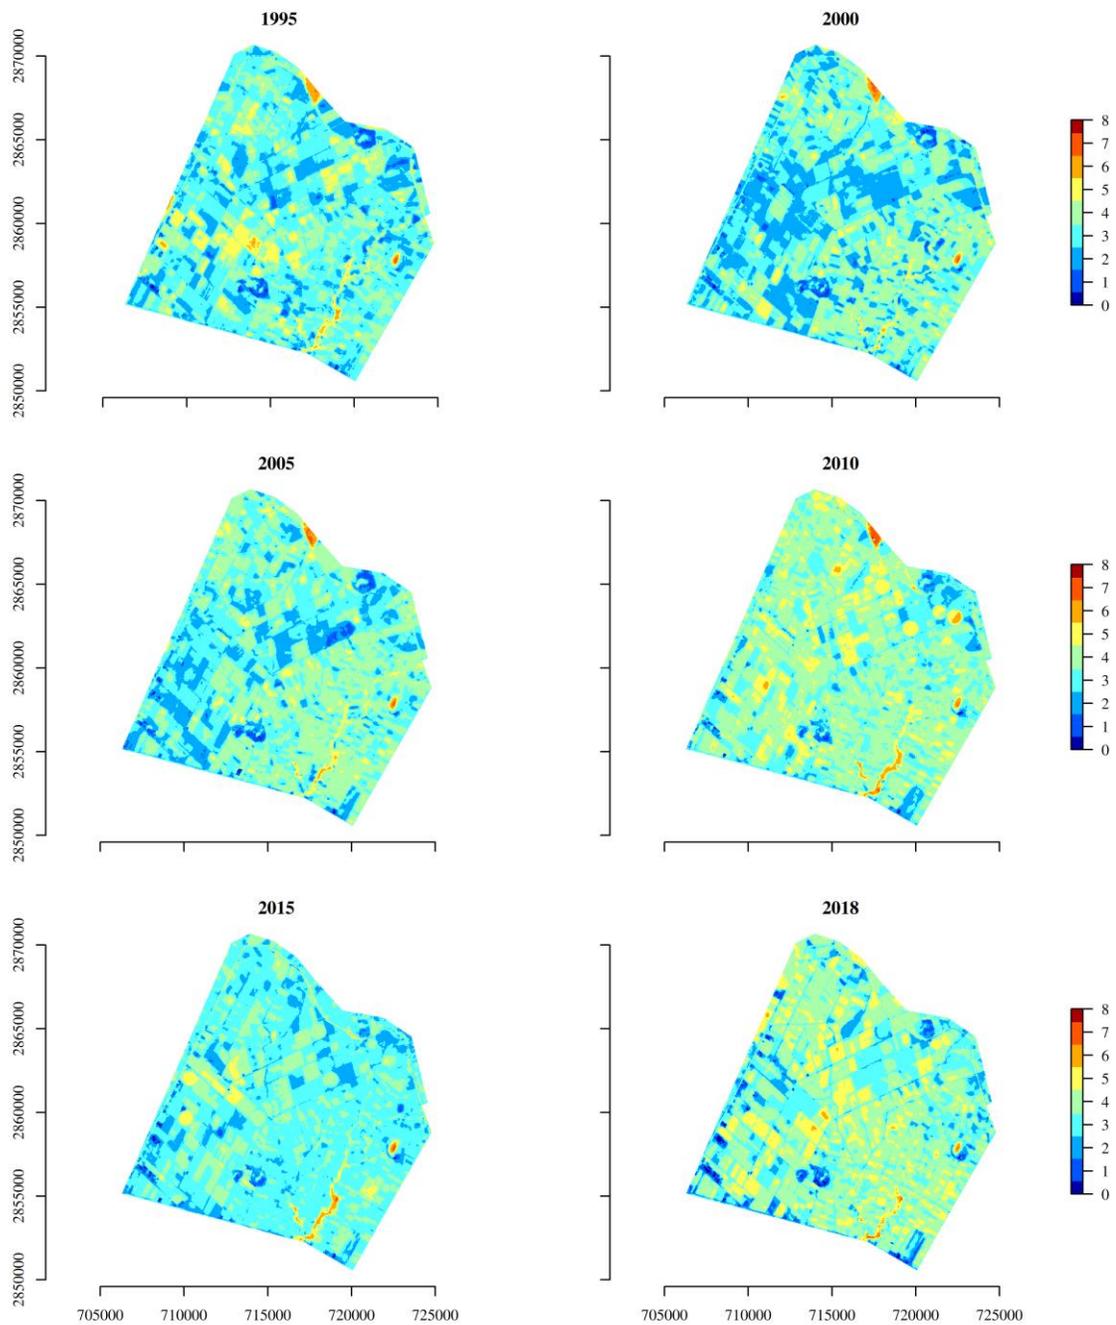


Figura 3.14. Mapas anuales de la zona de estudio de ET_c media [mm/d].

Se analizaron los valores de ET_c media de forma mensual. La figura 3.15 muestra la serie mensual, con un suavizamiento para resaltar el comportamiento monomodal de la misma; se aprecia que los valores más altos en el periodo de marzo a junio y los menores de septiembre a enero. Esta información, muestra al mes de junio como el periodo de mayor ET_c en el año con 4.14[mm/d], mientras que el mes de diciembre registra el menor valor con 2.24[mm/d].

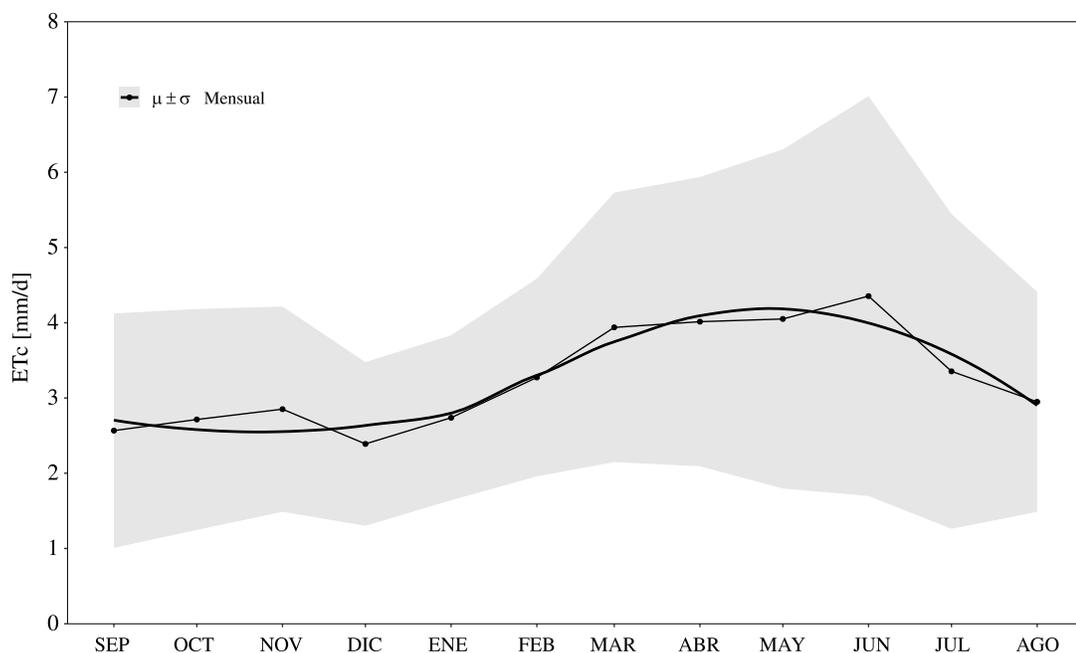


Figura 3.15. Serie mensual y curva suavizada de ET_c media para la zona de estudio.

La figura 3.16 muestra los mapas del comportamiento mensual del ET_c . Este corresponde con lo expresado en la serie temporal (Figura 3.15), donde los valores más altos se presentan en los meses de marzo a junio. El aumento en las temperaturas de los meses de verano, de la superficie cultivada y de la conclusión de las etapas de desarrollo de la mayoría de los cultivos, eleva las tasas evapotranspirativas en la zona; esto, contrastado con las etapas iniciales donde se presentan valores más bajos de ET_c (otoño e invierno), como consecuencia de un descenso en las temperaturas.

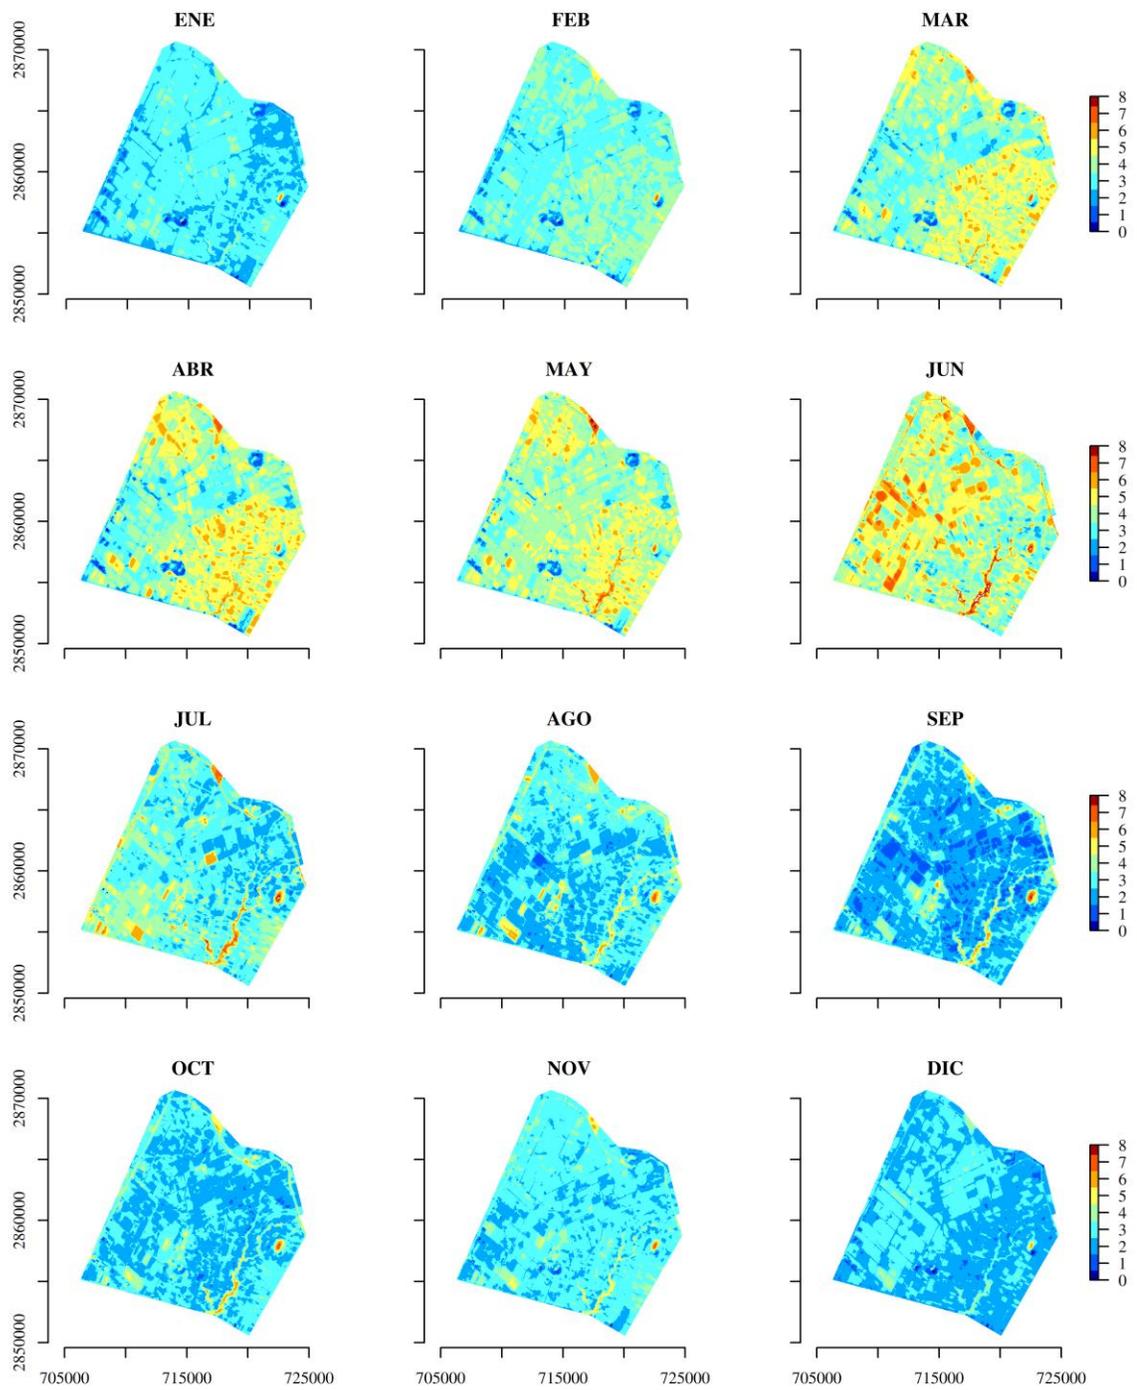


Figura 3.16. Mapas mensuales de la zona de estudio de ET_c media [mm/d].

La tabla 3.5 muestra la estimación de los valores de volumen promedio mensuales requeridos por hectárea para el área de estudio. El cálculo toma en consideración los valores de ET_c del modelo A, y la superficie de la zona de estudio, la cual asciende a 22 142[ha]; el promedio anual del valor del volumen requerido por hectárea para la zona asciende a 33.7 [m^3 /día/ha].

Tabla 3.5. Estimación del volumen medio mensual requerido por hectárea para la zona de estudio.

Mes	Volumen promedio requerido [m^3/día/ha]
Enero	25.55
Febrero	30.62
Marzo	37.03
Abril	37.45
Mayo	37.60
Junio	41.45
Julio	30.98
Agosto	27.58
Septiembre	24.09
Octubre	25.77
Noviembre	26.60
Diciembre	22.44

3.4 Conclusiones

La diferencia entre el modelo A y B, representa diferentes tipos de error en el tipo de adquisición y procesamiento de los datos climáticos en ambos modelos. El modelo B correspondiente al método *METRIC-EEFLUX* es un modelo aceptado por que utiliza la información climática de sistemas satelitales, mientras el modelo A utiliza estaciones puntuales en tierra. La calibración del modelo A respecto al B, resultó en la reducción de errores (ECM y EAM) solo para los meses de mayo y julio, e incrementando para los demás meses (tabla 3.3).

El análisis histórico de la evolución de ET_c a escalas temporal mensual y anual, recuperan el comportamiento del parámetro. Anualmente oscila entre 2.68 a 4.08 [mm/día], con mínimo en el año 1999 y máximo en el año 2008 respectivamente. El mes de junio representó el periodo con la mayor ET_c en el año, con 4.14[mm/d], mientras el mes de diciembre la de menor valor con 2.24[mm/d]. Dichos valores implican distintos requerimientos hídricos de cultivo por mes; la tabla 3.5 muestra el resumen de estos valores.

Los resultados indican que los modelos de balance e energía alimentados con información de estaciones climatológicas en tierra cercanas a una zona agrícola y los sensores remotos satelitales, representan una alternativa para estimar la variabilidad espacial de la ET_c con moderada precisión; esta metodología podría ser utilizada en un futuro como una herramienta de apoyo en investigaciones posteriores y en la toma de decisiones y formulación de políticas de gestión de recursos hídricos más eficientes.

Capítulo 4

Evapotranspiración de cultivo de maíz estimado mediante índices espectrales

4.1 Introducción

La forma en la que el espectro electromagnético reflejado es discretizado por los sensores remotos satelitales permite generar modelos que pueden interpretarse como indicadores de condiciones y propiedades físicas de las superficies. La celeridad con la que los índices pueden ser estimados llevan a considerarlos como una herramienta asequible, sustentada en modelos empíricos o teóricos. En este sentido, uno de los objetivos del presente trabajo planteó generar un modelo mediante el uso de índices espectrales que permita conocer la distribución espacial de ET_c .

Se ha relacionado el uso de los índices espectrales como el $NDVI$ con la ET_c , por medio de la relación entre la ET_o (ecuación 9, Allen et al., 1998), la cual permite calcular el K_c a partir del $NDVI$ en diferentes etapas de desarrollo del cultivo. Mediante esta relación se ha estimado a la ET_c , alcanzando valores de R^2 entre 0.80 y 0.97 (Hunsaker, Pinter, Barnes, y Kimball, 2003; y Farg et al., 2012).

Se propusieron las hipótesis de correlación y relación tradicionales entre 23 índices espectrales y los modelos de balance de energía calculados por el método *METRIC*

(capítulo 3). Por tal motivo, se busca que los índices seleccionados por sus cualidades espectrales, reflejen una posible relación con la ET_c .

Para este trabajo, se contó con un banco de información histórica de siembras y cosechas de los cultivos de maíz de una zona de cultivos al norte del estado de Sinaloa, para los ciclos agrícolas comprendidos entre los años 1998 a 2018.

4.2 Materiales y métodos

4.2.1 Bancos de información

Un total de 27 parcelas dentro de módulos de riego Santa Rosa y Batequis, del distrito 075-El Fuerte, han sido monitoreadas mediante el Sistema de Pronóstico de Riego en Tiempo Real, SPRITER v.3 (Ojeda-Bustamante et al., 2000), durante los ciclos agrícolas 1999 a 2018. La figura 4.1 muestra el mapa de su ubicación.

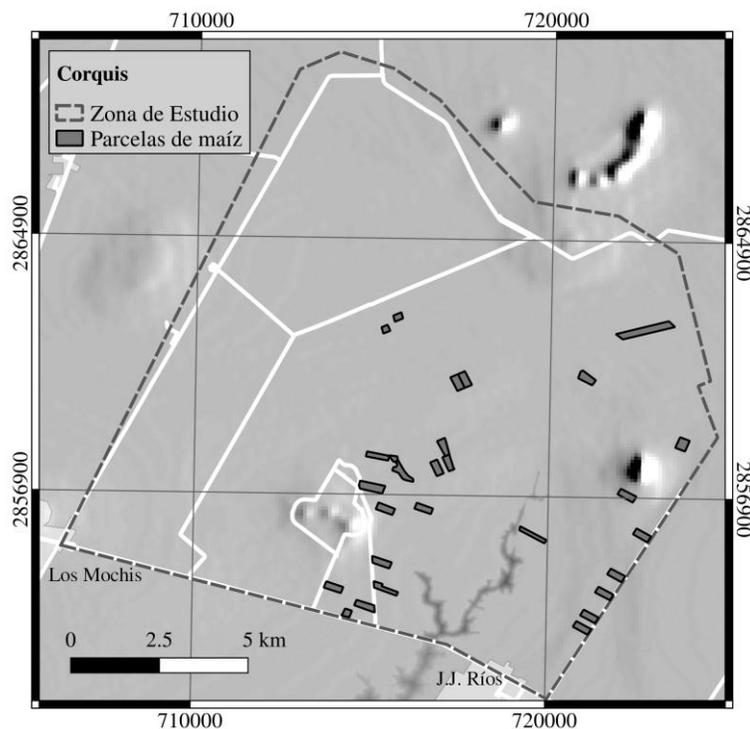


Figura 4.1. Mapa de ubicación de las parcelas en estudio dentro de la zona de estudio.

Por otra parte, los 201 modelos de balance de energía calculados anteriormente, que representan las condiciones de la ET_c en la zona de estudio en distintas fechas entre los años 1995 a 2018, fueron tomados para realizar el análisis.

De acuerdo a lo anterior, el cruce de la información ha resultado en una cobertura de los modelos de ET_c sobre la información catastral y georreferenciada de las 27 parcelas. Se integró una base de datos exclusiva de cultivos de maíz registrados dentro de las fechas de adquisición de las imágenes satelitales, y por consecuencia, de los modelos de ET_c . La figura 4.2 muestra gráficamente la distribución de la cantidad y superficie sembrada en los diferentes ciclos agrícolas de los cultivos de maíz en la zona de estudio.

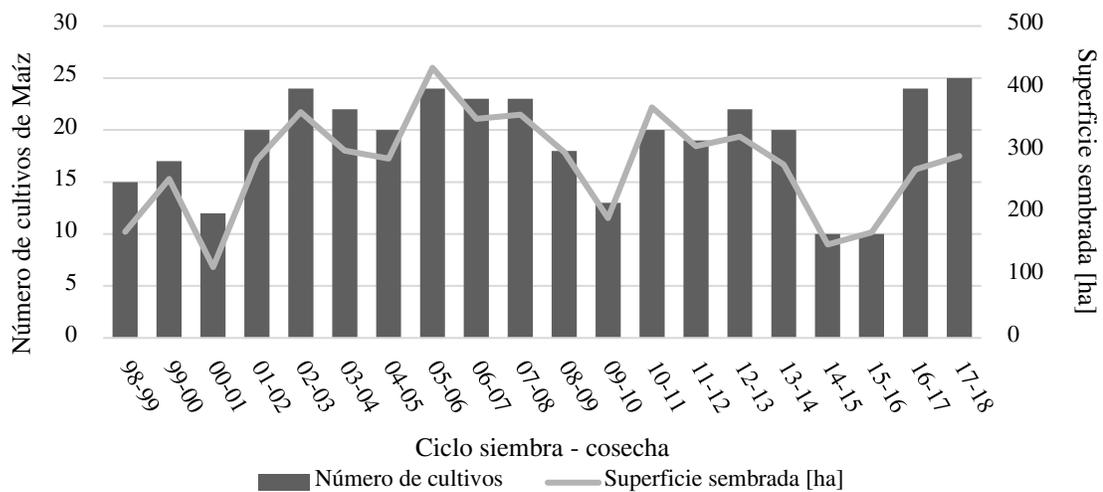


Figura 4.2. Distribución de la superficie sembrada y número de cultivos de maíz en la zona de estudio.

4.2.2 Índices espectrales relacionados con la ET_c

Como fue descrito en la sección 2.3, los índices son un indicador de la condición de una planta. La tabla 4.1 muestra los índices propuestos en este trabajo para la estimación de la ET_c , dentro de clases o categorías temáticas en donde son comúnmente empleados; se muestra a modo de comparación su relación con las

distintas bandas *LANDSAT* que emplean su cálculo (*B*, *G*, *R*, *SWIR1* y *2*, e *IR - Térmico*). Son resumidos por nombre y modelo espectral.

Tabla 4.1. Tabla resumen y descripción de los índices espectrales considerados para la estimación de ET_c

CLASE	ACRÓNIMO	BANDA <i>LANDSAT</i> (5,7,8)	Modelo espectral	NOMBRE
VEGETACIÓN	NDVI	• •	NIR-R/NIR+R	Índice de vegetación de diferencia normalizada
	EVI	• • •	$2.5(NIR-R) / (NIR+6R - 7.5B+1)$	Índice de vegetación mejorado
	CRC	• •	NIR-B/NIR+B	Índice de cubierta de cultivo
	MCRC	• •	NIR-G/NIR+G	Índice modificado de cubierta de cultivo
	NDSVI	• •	SWIR1-R/SWIR1+R	Índice de vegetación senescente de diferencia normalizada
	SRNDI	• •	SWIR2-NIR/SWIR2+NIR	Índice de diferencia normalizada de onda corta
	MRA	• • • • • •	$\exp(a+b*NDVI/\text{albedo})$	Momento de resistencia aerodinámica
	LAI	• •	$-\log((0.69-SAVI) / 0.59) / 0.91$	Índice de área foliar
VEGETACIÓN/SUELO	SAVI	• •	$(1+L) (NIR-R) / L+NIR+R$	Índice de vegetación ajustado a suelo
VEGETACIÓN/TÉRMICO	VI6T	• •	G-T/G+T	Índice termal de vegetación
	NBRT1	• • •	$NIR-(SWIR2*T) / NIR+(SWIR2*T)$	Cociente normalizado de incendio mejorado
SUELO	NDTI	• •	$SWIR1-SWIR2/SWIR1+SWIR2$	Índice de labranza de diferencia normalizada
	STI	• •	SWIR1/SWIR2	Índice de labranza simple
AGUA	NDWI	• •	$NIR-SWIR1/NIR+SWIR1$	Índice de agua de diferencia normalizada
	ENDWI	• •	$NIR-SWIR2/NIR+SWIR2$	Índice de agua mejorado
	MSI	• •	SWIR1/NIR	Índice de deficiencia de humedad
	EMSI	• •	SWIR2/NIR	Índice de deficiencia de humedad mejorado
	DSWI2	• •	SWIR1/G	Índice de estrés hídrico
	DSWI3	• •	SWIR1/R	Índice de estrés hídrico
	DSWI4	• •	G/R	Índice de estrés hídrico
	DSWI5	• • •	$NIR+G/SWIR1+R$	Índice de estrés hídrico
AGUA/SEQUÍA	NDDI	• • •	$NDVI-ENDWI / NDVI+ENDWI$	Índice de sequía de diferencia normalizada
	ENDDI	• • •	$NDVI-NDWI / NDVI+NDWI$	Índice de sequía mejorado

El índice *MRA* o momento de resistencia aerodinámica, es incluido en la selección dados los elementos que utiliza en su cálculo como: albedo, *NDVI*, y altura y distribución del cultivo; para este modelo espectral, *a* y *b* representan los coeficientes de regresión entre este parámetro y el *NDVI*, y son calculados mediante las ecuaciones 25, 26 y 27 de la sección 3.2.3.

Se realizó una consulta de la literatura relacionada con los índices espectrales y la *ET_c* para este trabajo. De acuerdo a la sensibilidad para detectar las propiedades de la vegetación como la salud, la humedad, el contenido de agua o las características del suelo agrícola; 23 índices fueron tomados en cuenta para evaluar la posible relación con el parámetro *ET_c*. A continuación, se muestra una descripción detallada de cada uno estos.

4.2.3 Índice de vegetación de diferencia normalizada (NDVI)

El índice de vegetación de diferencia normalizada denominado *NDVI* (*Normalized Differenced Vegetation Index*), se trata de una combinación algebraica de bandas espectrales que aportan información valiosa como la estructura de la vegetación, el estado de cobertura vegetal, capacidad fotosintética, densidad y distribución de hojas, contenido de agua en hojas, y deficiencia mineral, factores a los que esta combinación de bandas es sensible (Jensen, 2007).

El índice se calcula como la relación de la diferencia de la porción del infrarrojo cercano (*NIR*) y la porción roja del espectro (*R*) entre la suma de estas dos bandas, se expresa mediante la ecuación 35 (Rouse, Hass, Schell, y Deering, 1973).

$$NDVI = \frac{NIR - R}{NIR + R} \quad \text{Ec.35}$$

Donde:

NDVI: Índice de vegetación diferenciada, (-1,1)

NIR: Reflectancia en la región del infrarrojo cercano

R: Reflectancia en la región del rojo

4.2.4 Índice de vegetación mejorado (EVI)

El índice de vegetación mejorado *EVI* (*Enhanced Vegetation Index*), es un índice espectral que deriva del *NDVI*, el cual fue desarrollado inicialmente para trabajar con tres bandas (Rouse et al., 1973). Fue propuesto por Huete (1997) bajo el acrónimo *SARVI2*, un índice que mostró tener una mayor sensibilidad en la porción del infrarrojo cercano que el *NDVI*; posteriormente fue denominado como *EVI* (Huete et al., 2002). Este índice se calcula mediante la ecuación 36.

$$EVI = 2.5 \cdot (NIR - R) / (NIR + 2.4 \cdot R + 1) \quad \text{Ec.36}$$

Donde:

EVI: Índice de vegetación mejorado de 2 bandas

NIR: Reflectancia en la región del infrarrojo cercano

R: Reflectancia en la región del rojo

En la agricultura, este índice ha sido utilizado como estimador de la actividad fotosintética de las plantas; Dong et al. (2015), utilizan un modelo espectral para calcular la productividad fotosintética bruta en cultivos de soya y maíz; otra aplicación se presenta en el trabajo de Zhu et al. (2016), donde se plantea un índice de temporada basado en el *EVI* para analizar la distribución de cultivos.

4.2.5 Índice de vegetación ajustado al suelo (SAVI)

El índice de vegetación con ajuste de suelo, *SAVI* (*Soil Adjusted Vegetation Index*), fue desarrollado por Huete (1988), como una técnica para minimizar la influencia

del brillo del suelo sobre la banda del infrarrojo cercano. En otros términos, se trata de un ajuste que se hace al *NDVI*, mediante factor *L* que varía de 0 a 1, y depende de la cantidad de vegetación presente; cuando $L=0$, el índice es un *NDVI* puro.

$$SAVI = \frac{NIR-R}{NIR+R+L} \cdot (1 + L) \quad \text{Ec.37}$$

Donde:

SAVI: Índice de vegetación con ajuste de suelo (0,1)

NDVI: Índice de vegetación de diferencia normalizada

NIR: Reflectancia en la región del infrarrojo cercano

R: Reflectancia de la región del rojo

L: Factor de ajuste o peso (0,1)

Es utilizado comúnmente como indicador de vegetación seca o húmeda. Se han desarrollado diversas mejoras al índice *SAVI*; una de ellas es el índice *MSAVI* (*Modified Soil Adjusted Vegetation Index*), una variante que mejora la sensibilidad a la vegetación y el rango dinámico de la imagen (Qi et al., 1994); No obstante, Rondeaux et al., (1996) muestran una versión del índice optimizado y adecuado para las aplicaciones en agricultura, el índice *OSAVI* (*Optimized Soil Adjusted Vegetation Index*), el cual fue diseñado para operar de forma simple y sin conocer los parámetros reflectivos del suelo. En este trabajo se utilizó únicamente el índice *SAVI* para estimar el *LAI*, como recomendación en el método *SEBAL* (capítulo 3).

4.2.6 Índice de área foliar (*LAI*)

El índice de área foliar *LAI* (*Leaf Area Index*), es empleado en el estudio de ecosistemas y sistemas forestales, su valor representa la extensión o área de hoja por unidad de suelo (Jordan, 1969).

Una de las formas para obtener el valor de este índice mediante sensores remotos la ofrece Schultz y Engman (2000), la cual resulta ser una fórmula empírica que aproxima el valor de la relación de áreas a partir del índice de vegetación con ajuste de suelo (Ec. 38).

$$SAVI = c_1 - c_2 e^{-c_3 \cdot LAI} \quad \text{Ec. 38}$$

Donde:

SAVI: Índice de vegetación con ajuste de suelo

LAI: Índice de área foliar

$$c_1 = 0.69, c_2 = 0.59, c_3 = 0.91$$

El índice de área foliar se puede despejar de la ecuación 8; el valor del *LAI* se obtiene a partir de la siguiente ecuación:

$$LAI = - \frac{\ln\left(\frac{0.69 - SAVI}{0.59}\right)}{0.91} \quad \text{Ec.39}$$

Donde:

SAVI: Índice de vegetación con ajuste de suelo

LAI: Índice de área foliar

Se trata de un parámetro de suma importancia en la agricultura del cual se pueden estimar las etapas fenológicas de un cultivo y la densidad del follaje; A partir de él, se pueden estimar la evapotranspiración de cultivo ET_c , el intercambio de gases en la atmósfera, la absorción de nutrientes y la productividad de los cultivos (Gowda et al., 2015).

4.2.7 Índice de vegetación senescente de diferencia normalizada (NDSVI)

Propuesto por Qi et al. (2002), el *NDSVI* (*Normalized Difference Senescent Vegetation Index*), es un índice originalmente aplicado a sensores *LANDSAT*, el

cual se fundamenta en un incremento de la señal generada por la vegetación en etapa senescente debido a la cercanía de la primera banda infrarroja de onda corta (*SWIR1*) y la región de absorción del espectro electromagnético del agua, reflejando la pérdida del agua en los tejidos de las hojas. La expresión matemática de este índice se muestra en la ecuación 40.

$$NDSVI = \frac{SWIR1 - R}{SWIR1 + R} \quad \text{Ec. 40}$$

Donde:

NDSVI: Índice de vegetación senescente de diferencia normalizada

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

R: Reflectancia en la región del rojo

El *NDSVI*, es un índice normalmente utilizado en la conservación de suelos, ligado a la cobertura de residuos de cultivo e indicador de la erosión de suelos (i.e. Gelder et al., 2009; Zhongming et al., 2010).

4.2.8 Índices de labranza (*STI*, *NDTI*)

Los índices de labranza o de arado *STI* y *NDTI* (*Simple Tillage Index* y *Normalized Difference Tillage Index*), fueron propuestos por Van Deventer, Ward, Gowda, y Lyon (1997), donde fueron utilizados para clasificar las características del manejo del suelo agrícola. Estos logran identificar entre prácticas de labranza como la tradicional y de conservación, reportando una precisión de clasificación de 0.82 y 0.93 respectivamente, sin existir una distinción significativa de los resultados para ambos; no obstante, son considerados en este trabajo por sus cualidades espectrales siendo necesario un análisis de la caracterización de otro parámetro como la evapotranspiración por medio de estos. La forma matemática para calcularlos se muestra en las ecuaciones 41 y 42.

$$STI = \frac{SWIR1}{SWIR2} \quad \text{Ec. 41}$$

$$NDTI = \frac{SWIR1 - SWIR2}{SWIR1 + SWIR2} \quad \text{Ec. 42}$$

Donde:

STI: Índice simple de labranza

NDTI: Índice de labranza de diferencia normalizada

SWIR1 y *SWIR2*: Reflectancias en la primera y segunda región del infrarrojo de onda corta

El uso de estos índices permite evaluar y monitorear las prácticas de la labranza, la identificación de áreas en riesgo de erosión de suelos, y la pérdida de nutrientes en zonas de cultivo (Zheng, Campbell, y de Beurs, 2012).

4.2.9 Índices de agua de diferencia normalizada (NDWI, ENDWI)

Uno de los usos de los modelos espectrales en la agricultura, se presenta en el trabajo de McNairn y Protz (1993), donde proponen la utilización de diferentes índices de diferencia normalizada entre las bandas infrarrojas para identificar y cuantificar los residuos del cultivo de maíz, entre ellos utiliza dos indicadores que normalizan la banda infrarroja (*NIR*) del sensor L5 con las bandas de onda corta *SWIR1* y *SWIR2* respectivamente.

Gao (1996) por su parte, retoma estos dos índices utilizando mediciones radiométricas de una respuesta favorable debida a la absorción de agua por la vegetación a los 860 y 1240[nm]; finalmente, utiliza la banda *SWIR1* como adaptación para los sensores *LANDSAT*, y expresó el modelo espectral denominado índice de agua de diferencia normalizada *NDWI* (*Normalized*

Difference Water Index), el cual es un indicador del contenido de agua en las hojas, que se expresa mediante la ecuación 43.

$$NDWI = \frac{NIR - SWIR1}{NIR + SWIR1} \quad \text{Ec. 43}$$

Donde:

NDWI: Índice de agua de diferencia normalizada

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

NIR: Reflectancia en la región del infrarrojo cercano

Chen, Huang, y Jackson (2005), propusieron utilizar la segunda banda infrarroja (*SWIR2*) sobre el índice para estimar el contenido de agua en un cultivo de maíz, reportando una correlación $R^2 = 0.74$. El modelo que posteriormente fue denominado como índice mejorado de agua *ENDWI* (*Enhanced Normalized Difference Water Index*), se muestra en la ecuación 44.

$$ENDWI = \frac{NIR - SWIR2}{NIR + SWIR2} \quad \text{Ec. 44}$$

Donde:

ENDWI: Índice de agua de diferencia normalizada mejorado

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

NIR: Reflectancia en la región del infrarrojo cercano

4.2.10 Índices de deficiencia de humedad (MSI, EMSI)

La investigación de Rock, Williams, y Vogelmann (1985) en sitios contaminados por ácido, resultó en un índice indicativo de la sequedad vegetal en función de la tensión de la columna de agua en los xilemas de la vegetación. El índice de deficiencia de humedad *MSI* (*Moisture Stress Index*), retomado en el trabajo de

Domínguez, Kumhálová, y Novák (2017) para los sensores *LANDSAT*, sustituye la banda original centrada en 1650[nm] por la banda más cercana en estos sensores y que corresponde a la banda *SWIR1* (ecuación 45); además, probaron la segunda banda del infrarrojo de onda corta *SWIR2*, este último fue denominado como índice mejorado de deficiencia de humedad *EMSI* (*Enhanced Moisture Stress Index*), cuya expresión matemática se muestra en la ecuación 46.

$$MSI = \frac{SWIR1}{NIR} \quad \text{Ec. 45}$$

$$EMSI = \frac{SWIR2}{NIR} \quad \text{Ec. 46}$$

Donde:

MSI: Índice de deficiencia de humedad

EMSI: Índice de deficiencia de humedad mejorado

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

NIR: Reflectancia en la región del infrarrojo cercano

4.2.11 Índices de estrés hídrico (DSWI)

Apan, Held, Phinn, y Markley (2004) tratan varios índices en su investigación sobre la roya naranja, una infección fúngica de la vegetación considerada uno de los factores que promueve la pérdida de humedad en las plantas, no obstante, este fenómeno no es exclusivo. Utilizaron diversos índices espectrales en imágenes satelitales del sensor *Hyperion* (Pearlman et al., 2000).

Para este trabajo se eligieron cinco índices relacionados al estrés hídrico de la vegetación cuyas expresiones fueron adaptadas a los sensores *LANDSAT* y se muestran en las ecuaciones 47 a 51.

$$DSWI1 = \frac{NIR}{SWIR1} \quad \text{Ec. 47}$$

$$DSWI2 = \frac{SWIR1}{G} \quad \text{Ec. 48}$$

$$DSWI3 = \frac{SWIR1}{R} \quad \text{Ec. 49}$$

$$DSWI4 = \frac{G}{R} \quad \text{Ec. 50}$$

$$DSWI5 = \frac{NIR+G}{SWIR1+R} \quad \text{Ec. 51}$$

Donde:

DSWI 1 a 5: Índice de estrés hídrico

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

NIR: Reflectancia en la región del infrarrojo cercano

G: Reflectancia en la región del verde

R: Reflectancia en la región del rojo

4.2.12 Índices de sequía de diferencia normalizada (NDDI, ENDDI)

El índice de sequía de diferencia normalizada *NDDI* (*Normalized Difference Drought Index*), fue propuesto por Gu, Brown, Verdin, y Wardlow (2007), a partir del análisis del comportamiento de la sequía en pastizales mediante los índices *NDVI* y *NDWI*, que a su vez responden a las condiciones de sequía en la vegetación. Su trabajo planteo un nuevo índice que recogiese la información de las bandas *NIR* y *SWIR2*, como resultado se obtuvo el *NDDI*, un índice que describe una relación proporcional a las condiciones de sequía experimentadas durante el verano; es expresado mediante la ecuación 52. La ecuación 53 muestra la segunda forma del índice, el *ENDDI* (*Enhanced Normalized Difference Drought Index*), el cual recoge la información de la banda *SWIR1* en lugar de la *SWIR2*, y que muestra un carácter similar al del *NDDI*.

$$NDDI = \frac{NDVI - ENDWI}{NDVI + ENDWI} \quad \text{Ec. 52}$$

$$ENDDI = \frac{NDVI - NDWI}{NDVI + NDWI} \quad \text{Ec. 53}$$

Donde:

NDDI: Índice de sequía de diferencia normalizada

ENDDI: Índice de de sequía de diferencia normalizada mejorado

NDVI: Índice de vegetación de diferencia normalizada

NDWI: Índice de agua de diferencia normalizada

ENDWI: Índice de agua de diferencia normalizada mejorado

4.2.13 Índices de cobertura de residuo de cultivo (*CRC1*, *MCRC*, *SRNDI*)

Los índices de cobertura de residuos *CRC* (*Crop Residue Cover*), fueron planteados en el trabajo de Sullivan, Truman, Schomberg, Endale, y Strickland (2006), quienes trabajaron diversos índices (incluido el *NDVI*) para estimar los residuos de cultivo en función del tipo de labranza. Una de sus propuestas fue tomar la banda azul centrada en 485 [nm] y una infrarroja de onda corta en 1650[nm], en un índice denominado *CRC1*, el cual resultó ser sensible a la humedad del suelo y cuya expresión adaptada para los sensores *LANDSAT* se muestra en la ecuación 54.

$$CRC1 = \frac{SWIR1 - B}{SWIR1 + B} \quad \text{Ec. 54}$$

Donde:

CRC1: Índice de cobertura de residuos de cultivo

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

B: Reflectancia en la región del azul

Posteriormente Xiuliang, Jianhang, Zhidan, y Kaishan (2015), ponen a prueba una modificación del índice empleando la banda verde del sensor *LANDSAT 8* para el cultivo de maíz, resultando el índice modificado *MCRC*, cuya expresión se muestra en la ecuación 55.

$$MCRC = \frac{SWIR1 - G}{SWIR1 + G} \quad \text{Ec. 55}$$

Donde:

MCRC: Índice modificado de cobertura de residuos de cultivo

SWIR1: Reflectancia en la primera región del infrarrojo de onda corta

G: Reflectancia en la región del verde

Xiuliang et al. (2015), además utilizan la banda *SWIR2* junto a la banda del rojo, en un índice de diferencia de onda corta normalizada a rojo o *SRNDI* (*Shortwave Red Normalized Difference Index*) cuyo modelo se expresa en la ecuación 56.

$$SRNDI = \frac{SWIR2 - R}{SWIR2 + R} \quad \text{Ec. 56}$$

Donde:

SRNDI: Índice de diferencia de onda corta normalizada a rojo

SWIR2: Reflectancia en la segunda región del infrarrojo de onda corta

R: Reflectancia en la región del rojo

4.2.14 Índices termales de vegetación (VIT, NBRT)

El uso de la banda térmica en investigaciones forestales ha derivado en la aparición de diversos índices termales. Por ejemplo, en el caso de Smith (2004), se utiliza la banda termal en un índice termal de vegetación denominado *VI6T* (*Vegetation*

Index of Thermal band), para determinar compuestos volatilizados en incendios forestales, el cual se calcula mediante la ecuación 57.

$$VI6T = \frac{G - T_S}{G + T_S} \quad \text{Ec. 57}$$

Donde:

G : Reflectancia en la región del verde

T_S : Temperatura de brillo de superficie [K]

El $VI6T$, es retomado en el trabajo de Holden, Smith, Morgan, Rollins, y Gessler (2005) junto con otros índices; entre estos, se encuentra el índice de tasa normalizada de carbonización – termal o $NBRT1$ (*Normalized Burn Ratio-Thermal*), el cual se utiliza para caracterizar y delimitar áreas siniestradas por incendios forestales (Ec. 58).

$$NBRT1 = \frac{NIR - (SWIR2 * T_S)}{NIR + (SWIR2 * T_S)} \quad \text{Ec. 58}$$

Donde:

NIR : Reflectancia en la región del infrarrojo cercano

$SWIR2$: Reflectancia en la segunda región del infrarrojo de onda corta

T_S : Temperatura de brillo de superficie [K]

La finalidad de utilizar los índices termales de vegetación en este trabajo, recae en la relación entre la temperatura de brillo en superficie estimada a partir de la banda térmica de los sensores *LANDSAT* con la evapotranspiración, proceso que involucra el calor latente de vaporización. La evapotranspiración es, además, un componente en el cálculo de los modelos de balance de energía, razón por la cual se espera tengan una relación directa con el parámetro ET_c .

4.3 Resultados

4.3.1 Análisis de los índices espectrales

Se calcularon los índices espectrales para el total del banco de imágenes satelitales; Se tomó una muestra de $n_{\text{píxeles}} = 100$ por imagen, cantidad determinada con base en una muestra poblacional por imagen de $N_{\text{píxeles}} = 412\,720$, suponiendo un margen de error esperado igual a 0.5, y una desviación esperada de 2.5. La variación mensual por índice se muestra en la figura 4.2a y 4.2b, mientras la tabla 4.2 muestra los valores estadísticos, mínimo, máximo, media y desviación estándar del total de los índices para una muestra de $N_{\text{índices}} = 18\,865$.

Tabla 4.2. Valores estadísticos de los índices espectrales considerados (i.c. = 0.95).

	Mínimo	Máximo	Media	Desv. Est.
NDVI	-0.22	0.87	0.34	0.24
EVI	-0.13	1.26	0.33	0.28
CRC	-0.21	0.84	0.33	0.18
MCRC	-0.21	0.82	0.35	0.17
NDSVI	-0.55	0.63	0.25	0.12
SRNDI	-0.86	0.26	-0.31	0.26
MRA	0.01	0.74	0.03	0.03
LAI	-0.13	5.07	0.42	0.72
SAVI	-0.10	0.80	0.23	0.18
VI6T	0.22	0.83	0.57	0.07
NBRT1	0.90	1.00	0.96	0.02
NDTI	-0.25	0.57	0.22	0.12
STI	0.60	3.64	1.62	0.47
NDWI	-0.21	0.63	0.12	0.19
ENDWI	-0.26	0.86	0.31	0.26
MSI	0.23	1.52	0.83	0.28
EMSI	0.08	1.71	0.59	0.30
DSWI2	0.32	3.77	1.70	0.29
DSWI3	0.29	4.47	1.74	0.49
DSWI4	0.58	2.06	1.03	0.24
DSWI5	0.73	3.66	1.29	0.53
NDDI	-0.47	2.80	0.22	0.46
ENDDI	-6.17	9.25	1.11	2.43

Se observó un comportamiento proporcional a la cobertura vegetal por mes, por ejemplo, de enero a junio. En la figura 4.3a se observa mayor variabilidad en los valores de los índices comparado con el periodo verano - invierno; los diagramas de caja tienden a distribuirse simétricamente debido a la gran cobertura de cultivos.

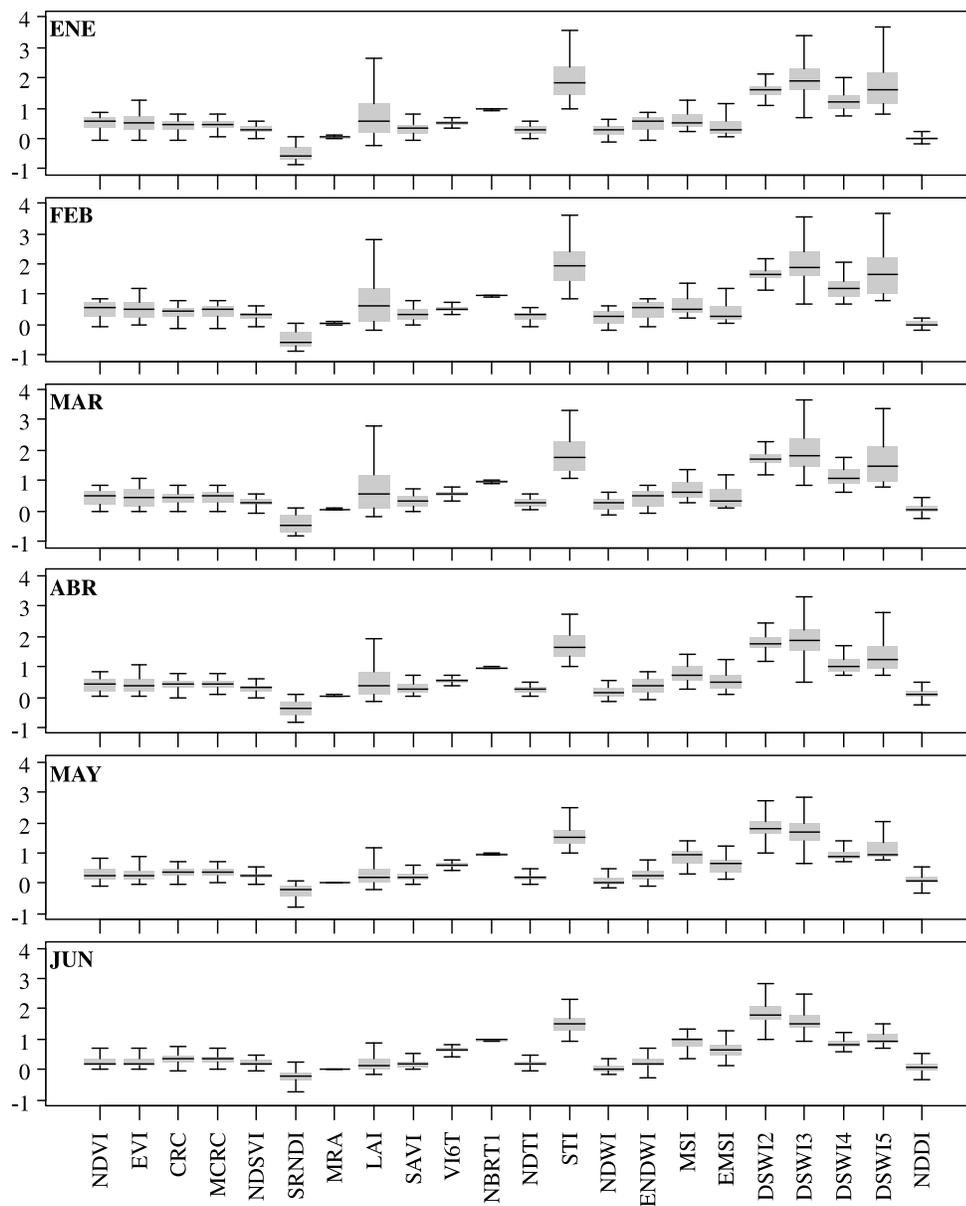


Figura 4.3a. Variación de los índices espectrales considerados para los meses de enero a junio.

De forma similar, se observó para los meses de julio a diciembre, correspondientes al periodo verano - invierno, los valores de los índices presentan propensión a restringirse a rangos más estrechos (menor variabilidad). Este comportamiento coincide con el ciclo agrícola de la región que comienza a mediados de otoño.

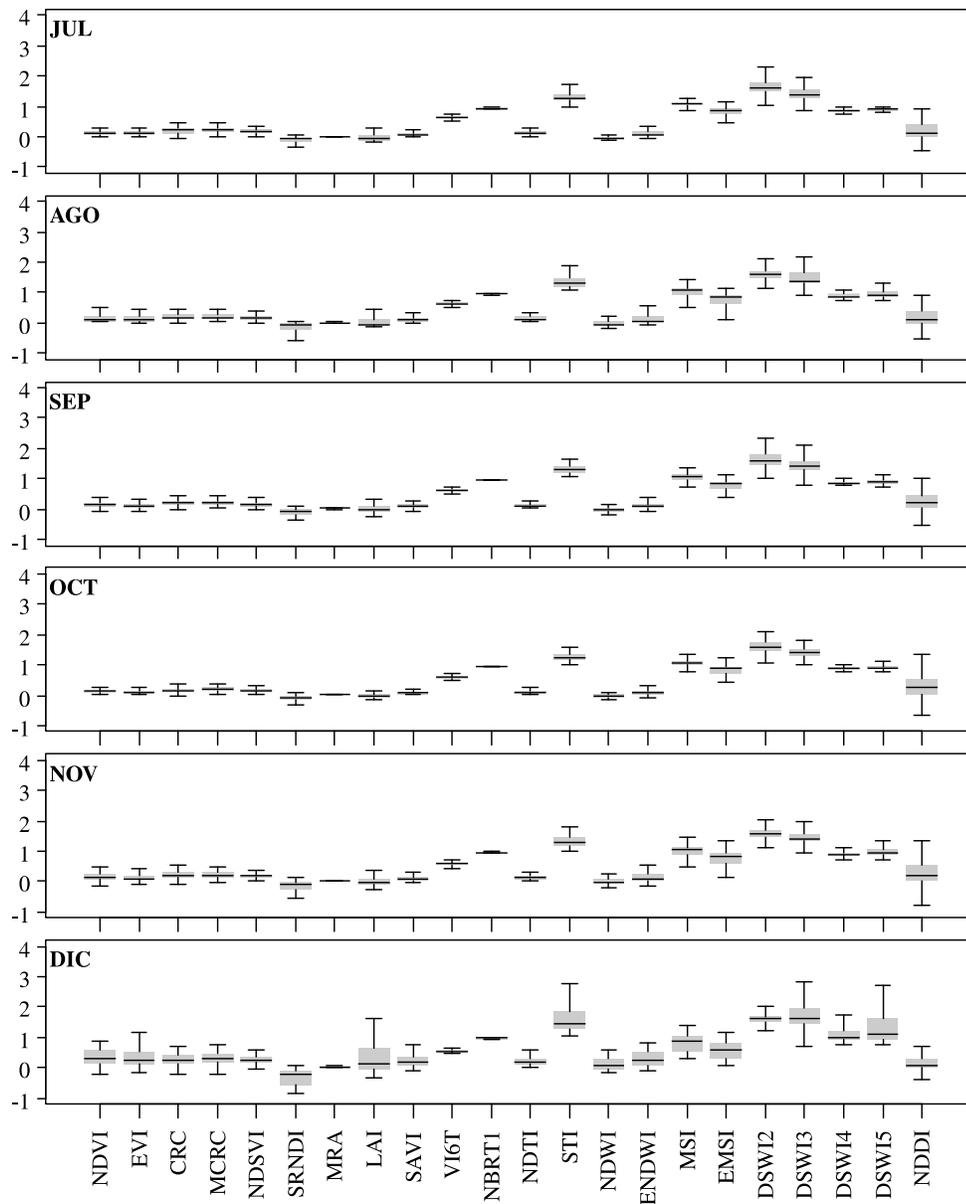


Figura 4.3b. Variación de los índices espectrales considerados para los meses de julio a diciembre.

4.3.2 Estimación de la ET_c de maíz mediante índices espectrales

a) Correlación de los índices espectrales

Para escoger los índices espectrales más representativos, se calculó la correlación simple de Pearson (Chambers y Hastie, 1992), implementada con software *R* (*R Development Core Team, 2018*), entre los 23 índices espectrales calculados y la variable ET_c , del modelo “A”, calculado a partir de un modelo de balance de energía descrito en la sección 3. Una representación gráfica de las matrices de correlación se muestra en las figuras 4.5a y 4.5b.

Se observó una correlación negativa para los índices *SRNDI*, *VI6T*, *MSI*, *EMSI* y *NDDI*, y positiva para el resto en todos los meses; la intensidad de las correlaciones varía de acuerdo al mes para todos los índices; además, los índices *NDDI*, *ENDDI* y *DSWI2* son próximos a tener una correlación lineal nula con ET_c .

A continuación, se obtuvo el coeficiente de determinación entre los índices seleccionados y el modelo de ET_c . La figura 4.4 muestra la distribución de los valores mensuales del coeficiente para todos los índices por mes, donde se aprecia la distribución de al menos la mitad de los valores de los coeficientes concentrados en los rangos más altos para los meses de marzo a mayo, mientras en octubre y noviembre en los más bajos. Los coeficientes de determinación (R^2) oscilaron entre 1.4×10^{-4} y 0.72 con media de 0.35.

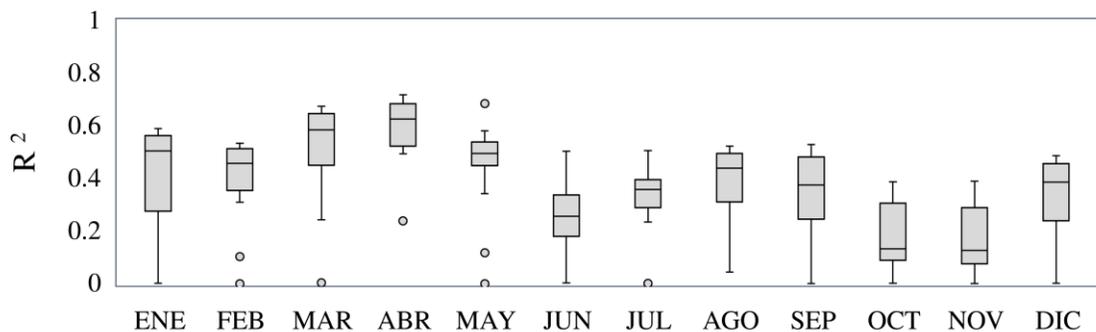


Figura 4.4. Distribución de los valores del coeficiente de determinación de los 23 índices analizados

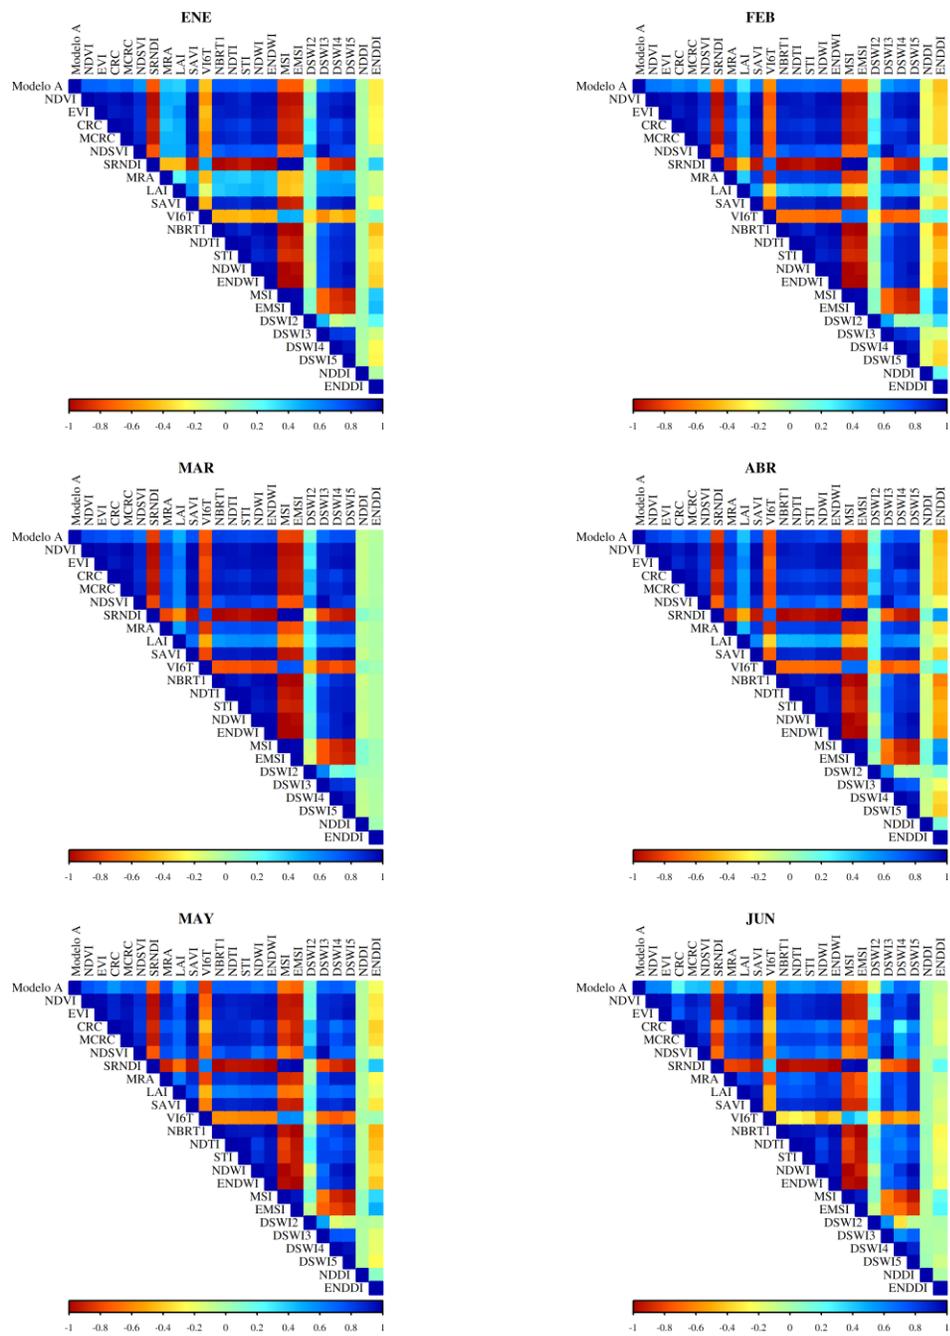


Fig. 4.5a. Matriz de correlaciones de Pearson de los índices espectrales para los meses de enero a junio

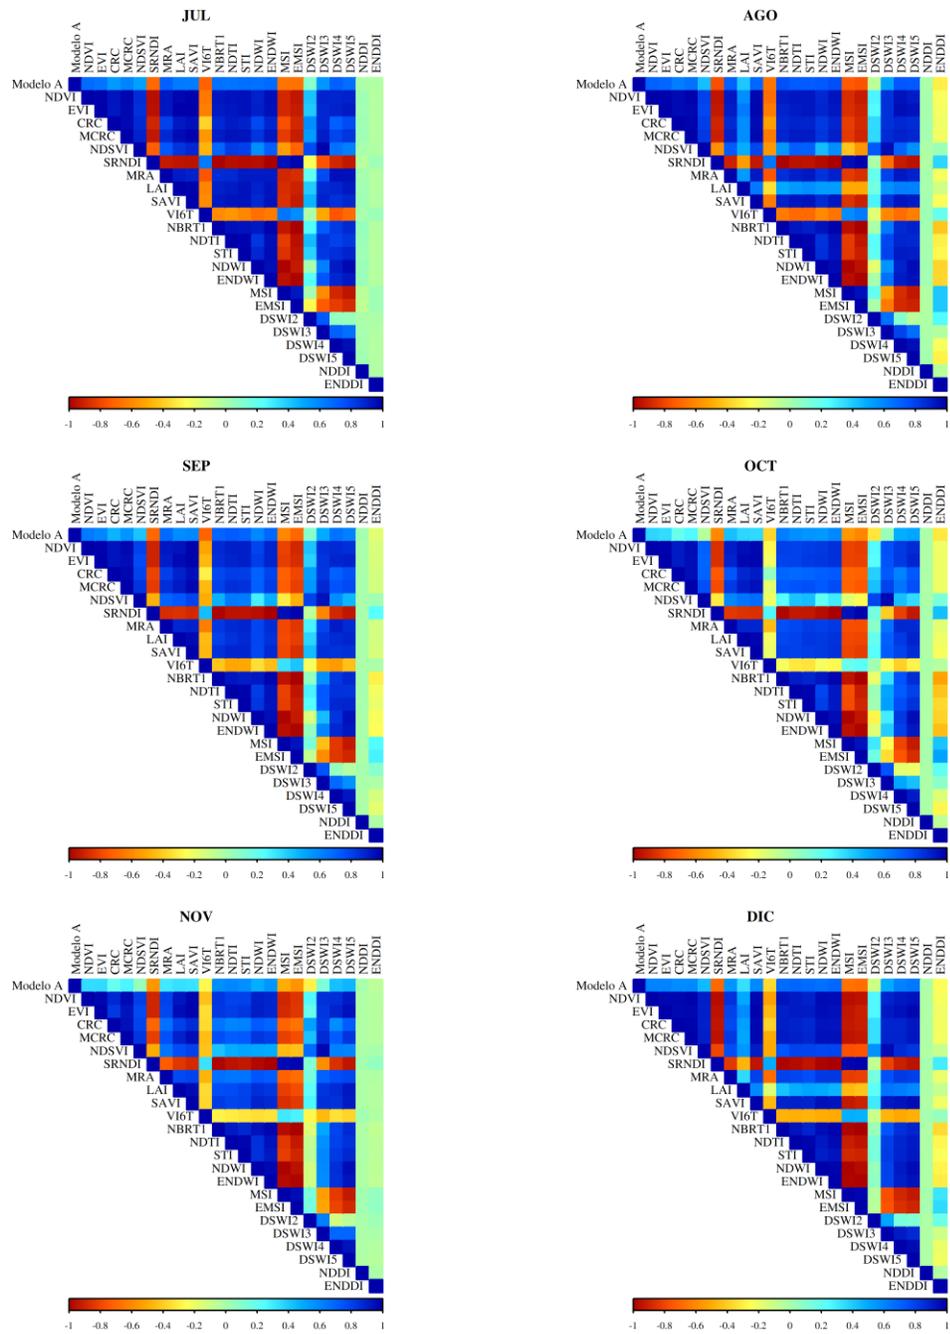


Fig. 4.5b. Matriz de correlaciones de Pearson de los índices espectrales para los meses de julio a diciembre

Para efectos de obtener las mejores relaciones entre los índices y los valores de ET_c , se escogieron los índices que presentan los valores de R^2 superiores al tercer cuartil (Tabla 4.3). De esta manera los índices seleccionados para la generación de los modelos y sus valores de R^2 se pueden observar en la tabla 4.4.

Tabla 4.3. Tercer cuartil de los coeficientes de determinación ($R^2_{i.c. 0.95}$) por mes.

ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
0.5636	0.5133	0.6467	0.6843	0.5393	0.3377	0.3956	0.4955	0.4817	0.3057	0.2893	0.4563

Tabla 4.4. Índices espectrales seleccionados y valores $R^2_{i.c. 0.95}$ por mes.

ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
ENDWI 0.59	ENDWI 0.53	ENDWI 0.67	NBRT1 0.72	VI6T 0.69	DSWI4 0.50	DSWI4 0.51	ENDWI 0.52	NDTI 0.53	NBRT1 0.39	NDTI 0.39	NDTI 0.49
SRNDI 0.59	SRNDI 0.53	SRNDI 0.67	NDTI 0.71	MRA 0.58	DSWI5 0.41	MRA 0.49	SRNDI 0.52	STI 0.51	EMSI 0.36	STI 0.36	ENDWI 0.48
NDWI 0.59	NDTI 0.52	NBRT1 0.67	EMSI 0.71	NDVI 0.58	MRA 0.37	VI6T 0.47	NBRT1 0.52	VI6T 0.49	ENDWI 0.35	NBRT1 0.36	SRNDI 0.48
DSWI5 0.57	NBRT1 0.52	EMSI 0.66	ENDWI 0.70	NDTI 0.55	NDWI 0.36	NDVI 0.42	EMSI 0.51	NBRT1 0.49	SRNDI 0.35	EMSI 0.34	STI 0.47
MSI 0.57	NDWI 0.52	MSI 0.66	SRNDI 0.70	STI 0.54	NDVI 0.36	DSWI5 0.41	NDWI 0.50	SRNDI 0.48	NDTI 0.33	SRNDI 0.33	NBRT1 0.47
NBRT1 0.56	EMSI 0.52	NDWI 0.65	NDVI 0.70	NBRT1 0.54	MSI 0.34	ENDWI 0.40	MSI 0.50	ENDWI 0.48	STI 0.31	ENDWI 0.33	EMSI 0.46
						SRNDI 0.40					

b) Generación de modelos espectrales

Posteriormente, siguiendo la metodología de mínimos cuadrados de Chambers y Hastie (1992), implementada en software *R*; se obtuvo un modelo lineal por mes con los valores del índice espectral que presenta el valor de R^2 más alto en los píxeles seleccionados como muestra. Esto, a fin de no incrementar el valor del error en la predicción, por ejemplo, en los meses que presentan correlaciones débiles a moderadas.

La tabla 4.5 muestra los modelos de regresión lineal obtenidos, donde se puede apreciar que los coeficientes r^2 varían de 0.37 para noviembre a 0.72 en abril, mientras los errores cuadráticos medios (ECM), varían entre 0.75 para diciembre a 1.87 en junio, con promedio de 1.07. El EAM, varía de 0.55 para enero y 1.58 en junio, con promedio de 0.86.

Tabla 4.5. Modelos de regresión lineal para la estimación de ET_c a partir de índices espectrales por mes.

Mes	Índice	Pendiente	Intercepto	R ²	Probabilidad	ECM	EAM
ENE	ENDWI	3.10	1.34	0.55	≈ 0	0.70	0.55
FEB	ENDWI	3.44	1.86	0.52	≈ 0	0.88	0.67
MAR	ENDWI	5.28	1.99	0.67	≈ 0	1.00	0.78
ABR	NBRTI	95.46	-88.18	0.72	≈ 0	0.97	0.76
MAY	VI6T	-28.91	21.78	0.70	≈ 0	1.24	0.99
JUN	DSWI4	11.12	-5.49	0.50	≈ 0	1.87	1.58
JUL	VI6T	-29.43	22.15	0.47	≈ 0	1.48	1.30
AGO	ENDWI	5.06	1.92	0.60	≈ 0	0.83	0.68
SEP	NDTI	13.11	0.45	0.53	≈ 0	1.00	0.79
OCT	NBRTI	78.29	-71.85	0.40	≈ 0	1.08	0.85
NOV	NDTI	9.97	1.45	0.37	≈ 0	1.08	0.84
DIC	NDTI	6.15	1.04	0.49	≈ 0	0.75	0.57

De acuerdo a los resultados, el mes de abril presenta la mejor relación lineal en este análisis, entre el modelo de ET_c y el índice correspondiente *NBRTI*, esto acorde al valor del coeficiente R^2 de 0.72, seguido el mes de mayo ($R^2 = 0.70$), utilizando el índice *VI6T*. En ambos casos el cálculo de estos índices involucra la componente térmica espectral. Para los meses de enero, febrero, junio, julio, y de septiembre a diciembre, donde se presentan las correlaciones de débiles a moderadas y valores más altos del ECM, se concluye que existe una relación lineal débil que se debe tomar con reserva. La figura 4.6 muestra la representación gráfica de los modelos lineales por mes.

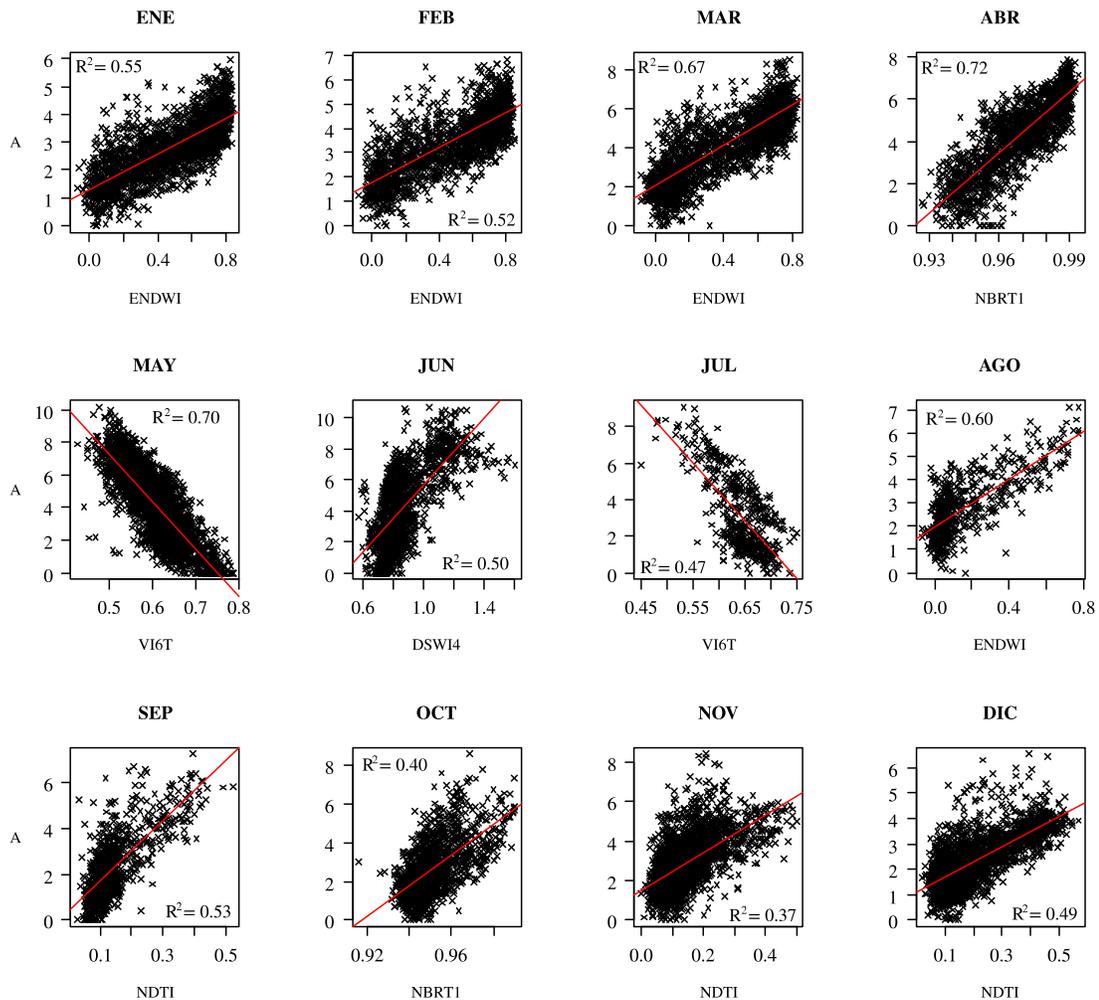


Figura 4.6. Modelos de regresión lineal mensuales de la ET_c (A), a partir de índices espectrales.

c) Validación de los modelos espectrales

La validación de los modelos espectrales mensuales generados se realizó mediante la comparación entre de los valores de ET_c estimados con *METRIC* y los valores obtenidos de los índices espectrales correspondientes para 12 imágenes escogidas al azar durante el periodo de estudio. La figura 4.7 muestra la representación gráfica de los modelos lineales para cada fecha, mientras la tabla 4.6 los coeficientes de la regresión.

Tabla 4.6. Modelos de validación para la estimación de ET_c por índices espectrales (i.c.= 0.95).

Fecha	Pendiente	Intercepto	r^2	Probabilidad	ECM	EAM
21/01/2010	0.75	0.61	0.42	≈ 0	0.56	0.42
21/02/1998	1.03	-0.10	0.56	≈ 0	0.83	0.65
20/03/2008	1.05	0.56	0.73	≈ 0	0.83	0.63
22/04/2014	0.94	0.67	0.67	≈ 0	0.89	0.64
19/05/2018	0.97	-0.52	0.84	≈ 0	0.98	0.75
05/06/1995	1.34	0.21	0.49	≈ 0	1.61	1.31
13/07/2003	0.62	-0.04	0.29	≈ 0	0.99	0.72
16/08/2004	0.95	0.92	0.59	≈ 0	0.64	0.50
04/09/1999	0.82	0.06	0.72	≈ 0	0.71	0.57
16/10/1997	0.69	0.54	0.38	≈ 0	0.91	0.74
19/11/2015	1.15	-0.67	0.45	≈ 0	1.04	0.82
22/12/2004	1.13	-0.59	0.56	≈ 0	0.67	0.55

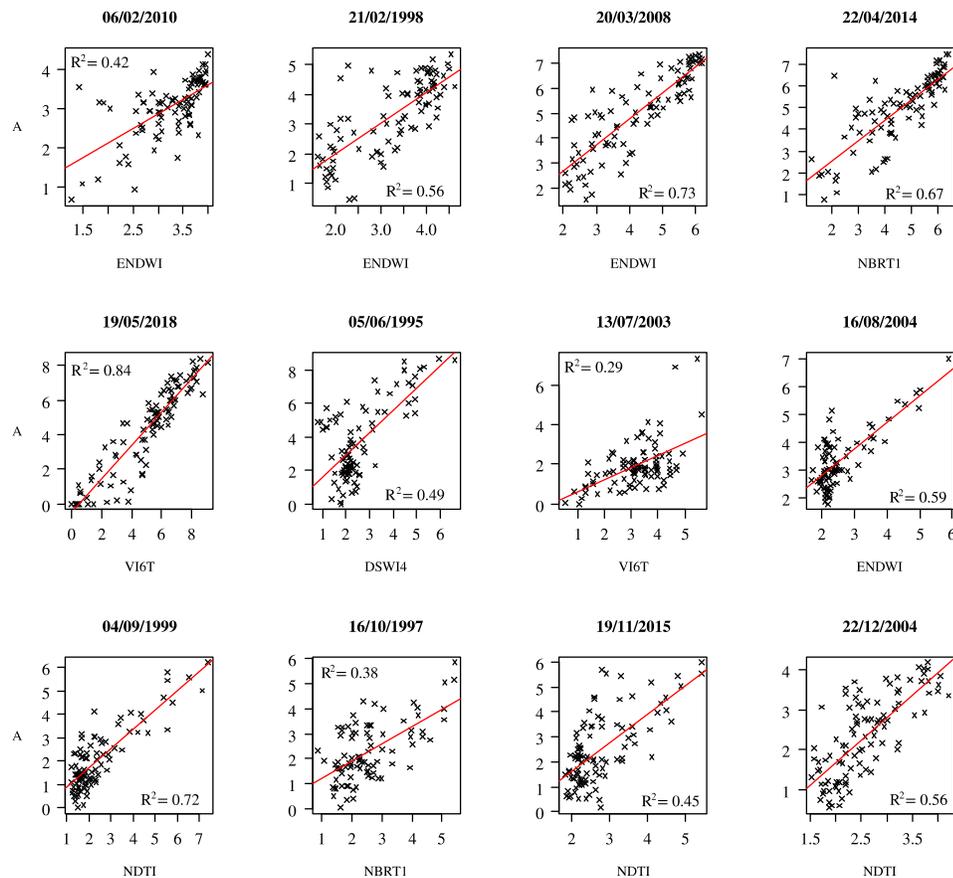


Figura 4.7. Modelos de validación para la estimación de ET_c mediante índices espectrales, A es el modelo de ET_c calculado.

d) Estimación de ET_c mediante índices espectrales

Finalmente, mediante la información de la base de datos de las parcelas que han sido monitoreadas con presencia de cultivo de maíz en los módulos de riego Santa Rosa y Batequis, y cuya distribución del número y superficie sembrada para el periodo de estudio se muestra en la figura 4.2, se obtuvo una serie temporal de los valores de la ET_c estimados a partir de los modelos espectrales calculados para los ciclos agrícolas comprendidos entre los años 1999 a 2018.

La tabla 4.6 muestra para el periodo de estudio los valores estadísticos y el número de pixeles muestras $N_{pixeles}$ del parámetro ET_c , correspondientes a las parcelas con cultivos de maíz de la zona de estudio. Mientras la figura 4.8, muestra la representación gráfica del comportamiento en la distribución de los valores.

Tabla 4.7. Valores estadísticos de la ET_c de maíz en los módulos Santa Rosa y Batequis (i.c. = 0.95).

Ciclo	Mínimo	Máximo	Media	Desv.Est	N
98 – 99	1.52	6.54	3.70	1.44	14525
99 – 00	1.77	5.80	3.72	1.36	55459
00 – 01	1.74	6.13	3.98	1.56	7318
01 – 02	1.69	6.88	3.71	1.28	13932
02 – 03	1.51	6.10	3.66	1.48	24991
03 – 04	1.56	6.06	3.96	1.50	17582
04 – 05	1.95	6.00	4.25	1.25	19832
05 – 06	1.54	6.44	3.81	1.41	3335
06 – 07	1.56	6.39	4.32	1.49	25841
07 – 08	2.21	6.43	4.71	1.30	17543
08 – 09	1.41	4.99	3.05	1.06	8743
09 – 10	1.64	6.02	3.81	1.30	7603
10 – 11	1.68	4.08	2.75	0.69	15309
11 – 12	1.82	3.29	2.40	0.41	651
12 – 13	1.28	5.92	4.58	1.28	6175
13 – 14	1.54	6.24	3.68	1.33	14704
14 – 15	1.59	6.21	3.69	1.52	9198
15 – 16	1.77	6.28	4.23	1.70	3513
16 – 17	1.68	9.37	4.21	2.11	6060
17 – 18	1.72	8.34	3.78	1.50	13178

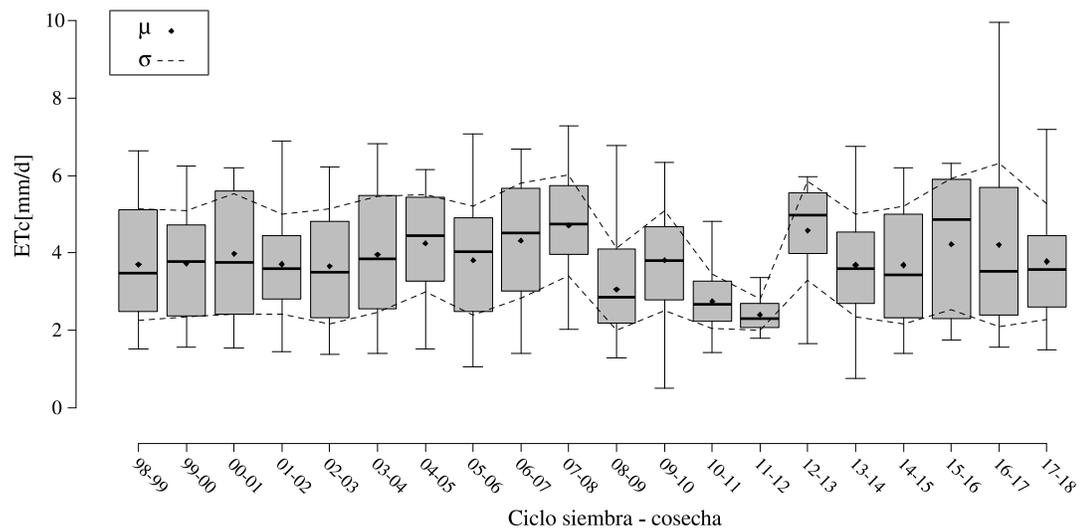


Figura 4.8. Serie temporal y distribución de la ET_c para cultivo de maíz bajo riego en los módulos de Santa Rosa y Batequis estimados mediante modelos espectrales, media (μ) y desviación estándar (σ).

4.4 Conclusiones

Se obtuvieron 23 índices espectrales por cada imagen satelital de los sensores *LANDSAT L5*, *L7* y *L8*, correspondientes a diferentes fechas entre los años 1995 a 2018 (tabla 3.1, sección 3.2.2), conformando con ello un banco de información de 201 imágenes para la zona de estudio con promedio de 17 imágenes por mes.

La variación de los índices espectrales durante el año, y la relación que algunos guardan con el contenido de agua en los sistemas superficiales, derivó en una hipótesis de relación lineal entre un modelo de ET_c calculado mediante un método de balance de energía y los 23 índices.

Los modelos de regresión lineal se realizaron para toda la base de datos histórica tomando el mejor índice correlacionado por mes, se observaron correlaciones con promedio de 0.48, para los meses de enero, febrero, junio, julio, y de septiembre a diciembre, por lo que para estos meses la estimación debe tomarse bajo reserva.

En los meses de marzo a mayo, se tuvieron correlaciones moderadas a con una máxima igual a 0.72 en el mes de abril mediante el índice termal de vegetación *NBRTI*, que toma en cuenta las bandas térmicas para su cálculo.

La validación de la estimación de la ET_c mediante índices espectrales mostró que los mejores coeficientes de correlación oscilando de 0.67 a 0.84 para los meses de marzo a mayo, siendo mayo el de mayor linealidad y el más representativo. Para estos meses, puede tomarse en consideración estimar la ET_c mediante los índices espectrales correspondientes (ver tabla 4.5).

El análisis de la evapotranspiración del cultivo de maíz mostró una oscilación entre 1.28 y 9.37 [mm/d], dichos valores correspondientes a los ciclos agrícolas 2009-2010 y 2016-2017 respectivamente.

Es necesario mencionar que la estimación de ET_c trae consigo una serie de errores que deben tomarse en cuenta antes de aplicar esta metodología, por ejemplo, el error inherente en las mediciones de las variables climáticas o en la captura de la información de superficie de siembra y momentos de siembra o cosecha; además, errores por truncamiento y redondeo en los cálculos, comenzando por el cálculo de los modelos de balance de energía, y la estimación por índices espectrales del parámetro.

Capítulo 5

Conclusiones generales

Se elaboró un banco de 201 imágenes satelitales de los sensores *LANDSAT 5TM* (133), *7ETM* (19) y *8OLI/TIRS* (49), para la zona agrícola comprendida por los módulos de riego Santa Rosa y Batequis, del Distrito de Riego 075 (Río Fuerte), en el Estado de Sinaloa, para el periodo 1995-2018 cubriendo todos los meses.

Se calcularon los valores de la ET_c mediante un modelo de balance de energía siguiendo la metodología *SEBAL* y *METRIC*; se calibró el modelo calculado para los meses de julio y mayo utilizando el modelo *EEFLUX*. Se comparó la estimación del parámetro, presentando un ECM promedio de 1.26 [mm/d] para la zona de estudio, conformando así, una base de datos geoespacial de ET_c .

Se realizó un análisis histórico de la base de datos geoespacial de ET_c , anualmente presentó un mínimo en el año 1999 de 2.68 [mm/día], un máximo en el año 2008 con 4.08 [mm/día]; mensualmente presentó un máximo de 4.14[mm/d] para el mes de junio y un mínimo de 2.24[mm/d] en el mes de diciembre. La serie temporal de ET_c indica una tendencia positiva con incremento igual a $2.6 \cdot 10^{-5}$ [mm/d] anual.

Se generó y validó un modelo basado en índices espectrales a partir del modelo de balance de energía obtenido. 23 índices espectrales relacionados con la ET_c fueron seleccionados. Se calcularon los modelos de regresión lineal por mes entre los índices espectrales y la ET_c , obteniendo valores de R^2 entre 0.37 y 0.72, y un ECM

promedio de 0.86 [mm/d]. La validación de los meses de marzo a mayo con valores de R^2 entre 0.67 y 0.84, con un ECM entre 0.83 y 0.9 respectivamente.

Se estimó la variación de la ET_c de maíz bajo riego mediante percepción remota empleando modelos espectrales para el periodo 1998-2018, para la zona de estudio. Un total de 27 parcelas de maíz bajo riego localizadas en los módulos de Santa Rosa y Batequis, en el distrito de riego 075-Río Fuerte, que contaban con la información de los ciclos agrícolas entre 1998 a 2018, fueron analizadas bajo el parámetro de ET_c . El análisis mostró que la ET_c oscilo entre 1.28 y 9.37 [mm/d], y una media de 3.8 ± 1.35 [mm/d].

La estimación de ET_c fue sesgada por lo que no hay suficiente precisión para estimar volúmenes de riego adecuados, en parte por la acumulación de errores en los diversos procesos de cálculo y otra por la información climática limitada con que se contaba. Una estimación adecuada se debe contar con datos climáticos de buena resolución temporal y calidad en su adquisición.

Una recomendación sería buscar la relación directa entre los índices espectrales y la ET instantánea del modelo de balance de energía, y buscar calcular la fracción evapotranspirativa con otro método.

En conclusión, es posible estimar la ET_c del cultivo de maíz bajo riego mediante modelos espectrales, siempre y cuando se cuente con una base de datos climatológica de calidad que propicie información más precisa; y con ello, poder influir en la administración del recurso hídrico dentro de los distritos de riego, así como establecer estrategias de riego focalizado y eficiente, a fin de cumplir con las metas de desarrollo sostenible del sector.

Anexos

Comparación de Modelos de balance e índices espectrales de los meses más representativos

Marzo - 20/03/2008

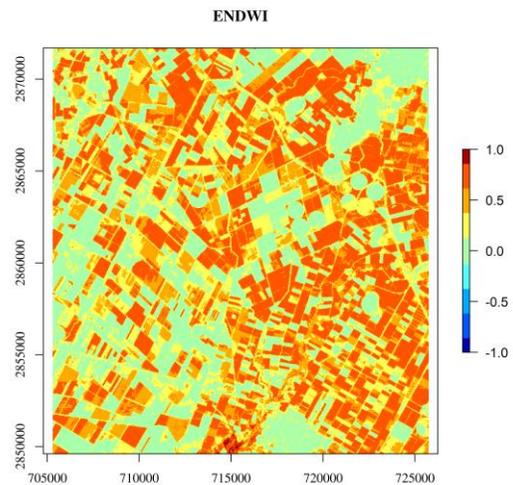
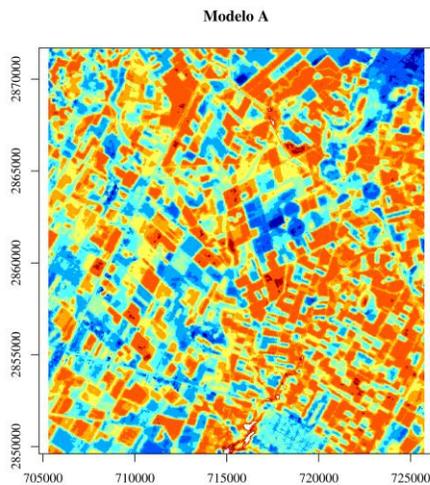
Modelo Espectral: $ENDWI * 5.28 + 1.99, R^2 = 0.67$

Composición RGB



Modelo de balance de energía

Índice espectral



Abril - 22/04/2014

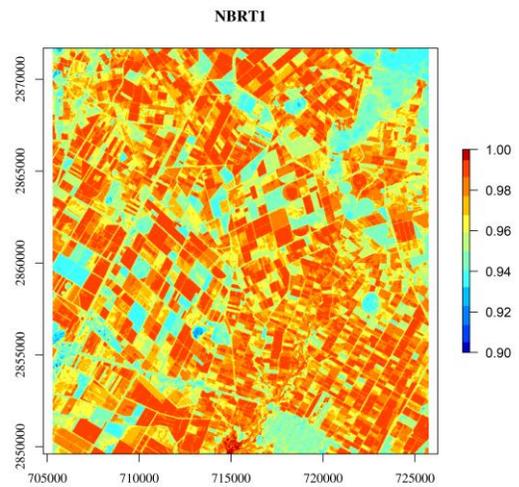
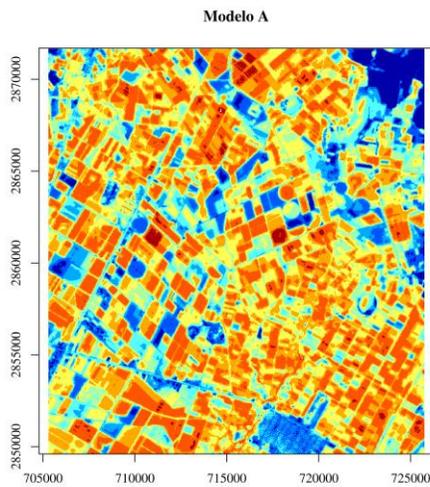
Modelo Espectral: $NBRTI * 95.46 - 88.18, R^2 = 0.72$

Composición RGB



Modelo de balance de energía

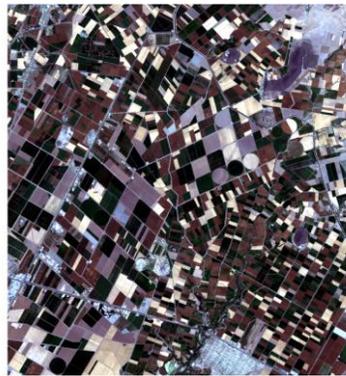
Índice espectral



Mayo - 19/05/2018

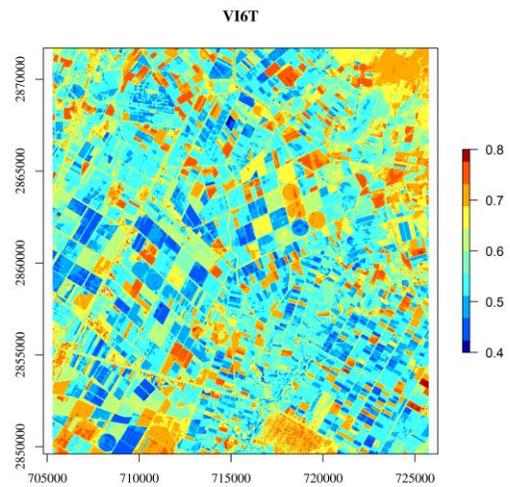
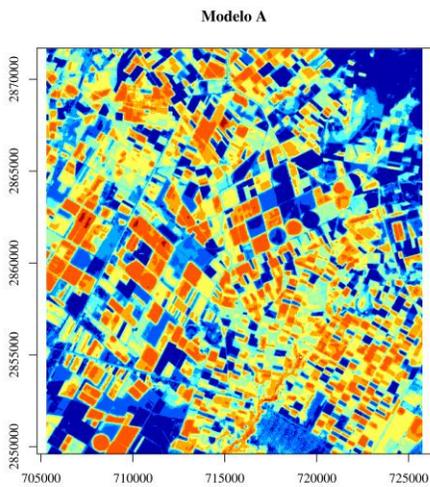
Modelo Espectral: $VI6T * (- 28.91) + 21.78, R^2 = 0.70$

Composición RGB



Modelo de balance de energía

Índice espectral



Bibliografía y referencias

- Allen, R. G. (2007). Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) – Model. *Journal of Irrigation and Drainage Engineering*, 133(Noviembre 2015), 380–394. DOI: 10.1061/(ASCE)0733-9437(2007)133.
- Allen, R. G., Pereira, L. S., Raes, D., y Smith, M. (1998). Crop Evapotranspiration (guidelines for computing crop water requirements). *FAO Irrigation and Drainage Paper*, 56, 333.
- Allen, R. G., Pereira, L. S., Raes, D., y Smith, M. (2006). Evapotranspiración del cultivo Guías para la determinación de los requerimientos de agua de los cultivos. Estudio FAO Riego y Drenaje.
- Allen, R. G., Tasumi, M., Morse, A., Trezza, R., Wright, J. L., Bastiaanssen, W., y Robison, C. W. (2007). Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) – Applications. *Journal of Irrigation and Drainage Engineering*, 133(4), 395–407. DOI: 10.1061/(ASCE)0733-9437(2007)133.
- Apan, A., Held, A., Phinn, S., y Markley, J. (2004). Detecting sugarcane “orange rust” disease using EO-1 Hyperion hyperspectral imagery. *International Journal of Remote Sensing*, 25(2), 489–498. DOI: 10.1080/01431160310001618031.
- Bastiaanssen, W. G. M. (1995). Regionalization of surface flux densities and moisture indicators in composite terrain: a remote sensing approach under clear skies in Mediterranean climates. Doctoral thesis, Wageningen Agricultural University, Wageningen The Netherlands. DOI: 90-5485-465-0.
- Bastiaanssen, W. G. M. (2000). SEBAL-based sensible and latent heat fluxes, 229, 87–100.
- Bastiaanssen, W. G. M., Pelgrum, H., Wang, J., Ma, Y., Moreno, J. F., Roerink, G. J., y Van der Wal, T. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). *Journal of Hydrology*, 213–229. DOI: 10.1016/S0022-1694(98)00254-6.

- Bhattarai, N., Shaw, S. B., Quackenbush, L. J., Im, J., y Niraula, R. (2016). Evaluating five remote sensing based single-source surface energy balance models for estimating daily evapotranspiration in a humid subtropical climate. *International Journal of Applied Earth Observation and Geoinformation*, 49, 75–86. DOI: 10.1016/j.jag.2016.01.010.
- Blevin, W. R., y Brown, W. J. (1971). A Precise Measurement of the Stefan-Boltzmann Constant. *Metrologia*, 7(1), 15–29.
- Büyükçangaz, H., Steele, D. D., Tuscherer, S. R., Hopkins, D. G., y Jia, X. (2017). Evapotranspiration Mapping with Metric to Evaluate Effectiveness of Irrigation in Flood Mitigation for The Devils Lake Basin. *Transactions of the American Society of Agricultural and Biological Engineers*, 60(5), 1575–1591. DOI: 10.13031/trans.12149.
- Campbell. (2011). *Introduction to Remote Sensing*. The Guildford Press. DOI: 10.1002/mds.23834.
- Chambers, J. M., y Hastie, T. J. (1992). *Statistical Models in S*. Wadsworth Brooks/Cole Computer Science Series (Vol. 70). Wadsworth & Brooks/Cole. DOI: 10.1111/j.1747-0285.2007.00557.x.
- Chander, G., Markham, B. L., y Helder, D. L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113(5), 893–903. DOI: 10.1016/j.rse.2009.01.007.
- Chemin, Y., y Din Ahmad, M. ud. (2000). Estimating Evaporation Using the Surface Energy Balance Model (SEBAL). R-102. Lahore, Pakistan. DOI: 10.3910/2009.543.
- Chen, D., Huang, J., y Jackson, T. J. (2005). Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. *Remote Sensing of Environment*, 98(2–3), 225–236. DOI: 10.1016/j.rse.2005.07.008.
- Choudhury, B. J., Idso, S. B., y Reginato, R. J. (1987). Analysis of an empirical model for soil heat flux under a growing wheat crop for estimating evaporation by an infrared-

- temperature based energy balance equation. *Agricultural and Forest Meteorology*, 39(4), 283–297. DOI: 10.1016/0168-1923(87)90021-9.
- CONAGUA. (2018). *Estadísticas del Agua en México*.
- Curran, P. J. (1985). *Principles of Remote Sensing* (1st ed.). Hong Kong: Longman Group Limited.
- Deacon, E. L. (1950). The measurement and recording of the heat flux into the soil. *Quarterly Journal of the Royal Meteorological Society*, 76(330), 479–483. DOI: 10.1002/qj.49707633011.
- Domínguez, J. A., Kumhálová, J., y Novák, P. (2017). Assessment of the relationship between spectral indices from satellite remote sensing and winter oilseed rape yield. *Agronomy Research*, 15(1), 55–68.
- Dong, J., Xiao, X., Wagle, P., Zhang, G., Zhou, Y., Jin, C., y Moore, B. (2015). Comparison of four EVI-based models for estimating gross primary production of maize and soybean croplands and tallgrass prairie under severe drought. *Remote Sensing of Environment*, 162, 154–168. DOI: 10.1016/j.rse.2015.02.022.
- Elhaddad, A., & Garcia, L. (2008). Surface Energy Balance-Based Model for Estimating Evapotranspiration Taking into Account Spatial Variability in Weather. *Journal of Irrigation and Drainage Engineering*, 134(December), 681–689. DOI: 10.1061/(ASCE)0733-9437(2008)134:6(681).
- Elhaddad, A., Garcia, L., y Chavez, J. (2011). Using a Surface Energy Balance Model to Calculate Spatially Distributed Actual Evapotranspiration. *Journal of Irrigation and Drainage Engineering-Asce*, 137(January), 17–26. DOI: 10.1061/(asce)ir.1943-4774.0000276.
- FAO. (2016). *Crop Water Needs*. Recuperado el 1 de enero de 2016, a partir de <http://www.fao.org/docrep/s2022e/s2022e07.htm>
- Farg, E., Arafat, S. M., Abd El-Wahed, M. S., y El-Gindy, A. M. (2012). Estimation of Evapotranspiration ET_c and Crop Coefficient K_c of Wheat, in south Nile Delta of Egypt Using integrated FAO-56 approach and remote sensing data. *Egyptian Journal of Remote Sensing and Space Science*, 15(1), 83–89. DOI: 10.1016/j.ejrs.2012.02.001.

- Foolad, F., Blankenau, P., Kilic, A., Allen, R. G., Huntington, J. L., Erickson, T. A., y Robison, C. W. (2018). Comparison of the Automatically Calibrated Google Evapotranspiration Application—EEFlux and the Manually Calibrated METRIC Application. Preprints, 2018070040(July). DOI: 10.20944/preprints201807.0040.v1.
- Gao, B. C. (1996). NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. DOI: 10.1016/S0034-4257(96)00067-3.
- Gelder, B. K., Kaleita, A. L., y Cruse, R. M. (2009). Estimating mean field residue cover on midwestern soils using satellite imagery. *Agronomy Journal*, 101(3), 635–643. DOI: 10.2134/agronj2007.0249.
- Gowda, P., Oommen, T., Misra, D., Schwartz, R., Howell, T., y Wagle, P. (2015). Retrieving Leaf Area Index from Remotely Sensed Data Using Advanced Statistical Approaches. *Journal of Remote Sensing & GIS*, 05(01), 1–6. DOI: 10.4172/2469-4134.1000156.
- Gu, Y., Brown, J. F., Verdin, J. P., y Wardlow, B. (2007). A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. *Geophysical Research Letters*, 34(6), 1–6. DOI: 10.1029/2006GL029127.
- Guo, H. D., Zhang, L., y Zhu, L. W. (2015). Earth observation big data for climate change research. *Advances in Climate Change Research*, 6(2), 108–117. DOI: 10.1016/j.accre.2015.09.007.
- Hansen, S. (1984). Estimation of Potential and Actual Evapotranspiration. *Hydrology Research*, 15(4–5), 205–212. DOI: 10.2166/nh.1984.017.
- Hargreaves, G. H., y Samani, Z. A. (1985). Reference Crop Evapotranspiration from Temperature. *Applied Engineering in Agriculture*, 1(2), 96–99. DOI: 10.13031/2013.26773.
- Holden, Z. A., Smith, A. M. S., Morgan, P., Rollins, M. G., y Gessler, P. E. (2005). Evaluation of novel thermally enhanced spectral indices for mapping fire perimeters and

- comparisons with fire atlas data. *International Journal of Remote Sensing*, 26(21), 4801–4808. DOI: 10.1080/01431160500239008.
- Hou, W., Wang, J., Xu, X., Reid, J. S., y Han, D. (2016). An algorithm for hyperspectral remote sensing of aerosols: 1. Development of theoretical framework. *Journal of Quantitative Spectroscopy & Radiative Transfer*, 178, 400–415. DOI: 10.1016/j.jqsrt.2016.01.019.
- Huete, A. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59(3), 440–451. DOI: 10.1016/S0034-4257(96)00112-5.
- Huete, A., Didan, K., Miura, T., Rodriguez, E., Gao, X., y Ferreira, L. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213. DOI: 10.1016/S0034-4257(02)00096-2.
- Huete, A. R. (1988). A Soil-Adjusted Vegetation Index (SAVI). *REMOTE SENSING OF ENVIRONMENT*, 25, 295–309. DOI: 10.1016/0034-4257(88)90106-X.
- Hunsaker, D. J., Pinter, P. J., Barnes, E. M., y Kimball, B. A. (2003). Estimating cotton evapotranspiration crop coefficients with a multispectral vegetation index. *Irrigation Science*, 22(2), 95–104. DOI: 10.1007/s00271-003-0074-6.
- INIFAP. (2017). Base de datos - Climatológica. México: Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias.
- Jensen, J. R. (2007). *Remote Sensing of the Environment* (2nd ed.). Pearson Prentice Hall.
- Jensen, J. R. (2005). *Introductory Digital Image Processing A Remote Sensing Perspective* (3rd ed.). Upper Saddle River, NJ.
- Johnson, L. F., y Trout, T. J. (2012). Satellite NDVI assisted monitoring of vegetable crop evapotranspiration in california's san Joaquin Valley. *Remote Sensing*, 4(2), 439–455. DOI: doi:10.3390/rs4020439.
- Jones, J., y Ritchie, J. (1990). *Crop Growth Methods: Management of Farm Irrigation Systems*. ASAE Monograph No. 9. USA: ASAE.

- Jordan, C. F. (1969). Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*, 50(4), 663–666.
- Kilic, A., Allen, R., Huntington, J., y Ozturk, D. (2015). Google Earth Engine Evapotranspiration Flux --- EEFlux. En *International Workshop on Evapotranspiration Mapping for Water Security* (p. 25). Washington DC.
- Kilic, A., Allen, R., Huntington, J., y Ozturk, D. (2018). Earth Engine Evapotranspiration Flux v.0.10.4. Recuperado el 1 de julio de 2018, a partir de <http://eeflux-level1.appspot.com/>
- Kiptala, J. K., Mohamed, Y., Mul, M. L., y Van Der Zaag, P. (2013). Mapping evapotranspiration trends using MODIS and SEBAL model in a data scarce and heterogeneous landscape in Eastern Africa. *Water Resources Research*, 49(12), 8495–8510. DOI: 10.1002/2013WR014240.
- Lein, J. K. (2012). *Environmental Sensing. Development* (Vol. 134). New York, NY: Springer New York. DOI: 10.1007/978-1-4614-0143-8.
- Li, F., Zhan, C., Xu, Z., Jiang, S., y Xiong, J. (2013). Remote sensing monitoring on regional crop water productivity in the Haihe River Basin. *Journal of Geographical Sciences*, 23(6), 1080–1090. DOI: 10.1007/s11442-013-1064-0.
- Liu, S., Su, H., Zhang, R., Tian, J., Chen, S., y Wang, W. (2016). Regional estimation of remotely sensed evapotranspiration using the surface energy balance-advection (SEB-A) method. *Remote Sensing*, 8(8). DOI: 10.3390/rs8080644.
- Marshall, M., Thenkabail, P., Biggs, T., y Post, K. (2016). Hyperspectral narrowband and multispectral broadband indices for remote sensing of crop evapotranspiration and its components (transpiration and soil evaporation). *Agricultural and Forest Meteorology*, 218–219, 122–134. DOI: 10.1016/j.agrformet.2015.12.025.
- Mcnairn, H., y Protz, R. (1993). Mapping corn residue cover on agricultural fields in oxford county, ontario, using thematic mapper. *Canadian Journal of Remote Sensing*, 19(2), 152–159. DOI: 10.1080/07038992.1993.10874543.
- Morse, A., Allen, R. G., y Kramber, W. J. (2000). Final Report Application of the SEBAL Methodology for Estimating Consumptive Use of Water and Streamflow Depletion in the Bear River Basin of Idaho through Remote Sensing Idaho Department of

Water Resources Submitted to The Raytheon Systems Company Earth. The Raytheon Systems Company Earth Observation System Data and Information System Project.

NASA. (2016). A Landsat Timeline. Recuperado a partir de <http://landsat.gsfc.nasa.gov/a-landsat-timeline/>

NASA. (2018). LANDSAT Science - Technical Details. Recuperado el 8 de enero de 2018, a partir de <https://landsat.gsfc.nasa.gov/about/technical-information/>

Ojeda-Bustamante, W., Sifuentes-Ibarra, E., González-Camacho, J. M., Guillén-González, J. Á., y Unland-Weiss, H. (2000). Pronóstico del riego en tiempo real (1a ed.). Jiutepec, Morelos.: Instituto Mexicano de Tecnología del Agua.

Ojeda-Bustamante, W., Sifuentes-Ibarra, E., y Unland-Weiss, H. (2006). Programación integral del riego en maíz en el norte de Sinaloa, México. *Agrociencia*, 40(1), 13–25.

Olmedo, G. F., Ortega-Farias, S., de la Fuente-Sáiz, D., Fonseca-Luego, D., y Fuentes-Penailillo, F. (2016). water: Tools and Functions to Estimate Actual Evapotranspiration Using Land Surface Energy Balance Models in R. *The R Journal*, 8(2), 352–369.

Pearlman, J., Segal, C., Liao, L. B., Carman, S. L., Folkman, M. A., Browne, W., y Ungar, S. G. (2000). Development and operations of the EO-1 Hyperion Imaging Spectrometer, 4135, 243. DOI: 10.1117/12.494251.

Pedroza-González, E., y Hinojosa-Cuéllar, G. A. (2013). Manejo y distribución del agua en distritos de riego: breve introducción didáctica. Instituto Mexicano de Tecnología del Agua (Primera Ed). Jiutepec, Morelos: IMTA.

Planck, M. (1901). On the law of the energy distribution in the normal spectrum. *Ann. Phys*, 4, 1–11. DOI: 10.1002/andp.19013090310.

Priestley, C. H. B., y Taylor, R. J. (1972). On the Assessment of Surface Heat Flux and Evaporation Using Large-Scale Parameters. *Monthly Weather Review*, 100(2), 81–92. DOI: 10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2.

- QGIS Development Team. (2017). QGIS Geographic Information System [software]. Open Source Geospatial Foundation Project.
- Qi, J., Chehbouni, A., Huete., A. R., Kerr, Y. H., y Sorooshian, S. (1994). A modified adjusted vegetation index (MSAVI). *Remote sensing and environment.*, 48(2), 119–126. DOI: 10.1016/0034-4257(94)90134-1.
- Qi, J., Marsett, R., Heilman, P., Biedenbender, S., Moran, S., Goodrich, D., y Weltz, M. (2002). RANGES improves satellite-based information and land cover assessments in Southwest United States. *Eos*, 83(51). DOI: 10.1029/2002EO000411.
- R Development Core Team. (2018). R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>. Vienna, Austria. DOI: ISBN 3-900051-07-0.
- Richards, J. A. (1986). *Remote Sensing Digital Image Analysis an Introduction*. Berlin: Springer-Verlag Berlin Heidelberg.
- Rock, B. N., Williams, D. L., y Vogelmann, J. E. (1985). Field and airborne spectral characterisation of suspected acid deposition damage in red spruce (*Picea Rubens*) stands from vermont. *Proc. of Airborne Imaging Spectrometer Data Anal Workshop*, United States, (February 1985), 51–55.
- Roerink, G., Su, Z., y Menenti, M. (2000). S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 25(2), 147–157. DOI: 10.1016/S1464-1909(99)00128-8.
- Rondeaux, G., Steven, M., y Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95–107. DOI: 10.1016/0034-4257(95)00186-7.
- Rouse, J. W., Hass, R. H., Schell, J. A., y Deering, D. W. (1973). Monitoring vegetation systems in the great plains with ERTS. *Third Earth Resources Technology Satellite (ERTS) symposium*, 1, 309–317. DOI: citeulike-article-id:12009708.
- Schultz, G. A., y Engman, E. T. (2000). *Remote Sensing in Hydrology and Water Management (1st Ed.)*. Springer.

- Servicio Meteorológico Nacional. (2016). Normales Climatológicas (Sinaloa). Recuperado el 1 de enero de 2016, a partir de <https://smn.cna.gob.mx/es/informacion-climatologica-por-estado?estado=sin>
- SIAP. (2018). Anuario Estadístico de la Producción Agrícola 2018. Recuperado el 15 de agosto de 2018, a partir de <https://www.gob.mx/siap/>
- Silva, B. B., Braga, A. C., Braga, C. C., Oliveira, L. M. M. De, Montenegro, S. M. G. L., y Junior, B. B. (2016). Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 20(1), 3–8. DOI: 10.1590/1807-1929/agriambi.v20n1p3-8.
- Smith, A. M. S. (2004). Determining nitrogen volatilised within African savanna fires via ground-based remote sensing. University of London.
- Su, Z. (2002). The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes To cite this version: The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and Earth System Sciences*, 6(1), 85–99. DOI: 10.5194/hess-6-85-2002.
- Sullivan, D. G., Truman, C. C., Schomberg, H. H., Endale, D. M., y Strickland, T. C. (2006). Evaluating techniques for determining tillage regime in the Southeastern Coastal Plain and piedmont. *Agronomy Journal*, 98(5), 1236–1246. DOI: 10.2134/agronj2005.0294.
- Turc, L. (1962). Estimation of irrigation water requirements, potential evapotranspiration: A simple climatic formula evolved up to date. *Ann. Agron*, 12, 13–49.
- USGS. (2018a). Conversion of DN's to Physical Units. En *LANDSAT 8 (L8) Data Users Handbook* (Vol. 3, pp. 54–58).
- USGS. (2018b). Landsat Data Access Portals. Recuperado el 1 de enero de 2018, a partir de <https://www.usgs.gov/land-resources/nli/landsat/data-tools>
- Van Deventer, A. P., Ward, A. D., Gowda, P. M., y Lyon, J. G. (1997). Using thematic mapper data to identify contrasting soil plains and tillage practices. *Photogrammetric Engineering and Remote Sensing*, 63(1), 87–93.

- Waters, R., Allen, R., Tasumi, M., Trezza, R., y Bastiaanssen, W. (2002). Manual for Surface Energy Balance Algorithms for Land, 1–98.
- WaterWatch-CONAGUA. (2005). Mapping Groundwater in Sonora State, Mexico. Netherlands.
- Wien, W. (1896). Ueber die Energievertheilung im Emissionsspectrum eines schwarzen Körpers. *Annalen der Physik*, 294(8), 662–669. DOI: 10.1002/andp.18962940803.
- Xiuliang, J., Jianhang, M., Zhidan, W., y Kaishan, S. (2015). Estimation of maize residue cover using Landsat-8 OLI image spectral information and textural features. *Remote Sensing*, 7(11), 14559–14575. DOI: 10.3390/rs71114559.
- Zheng, B., Campbell, J. B., y de Beurs, K. M. (2012). Remote sensing of crop residue cover using multi-temporal Landsat imagery. *Remote Sensing of Environment*, 117, 177–183. DOI: 10.1016/j.rse.2011.09.016.
- Zhongming, W., Lees, B. G., Feng, J., Wanning, L., y Haijing, S. (2010). Stratified vegetation cover index: A new way to assess vegetation impact on soil erosion. *Catena*, 83(1), 87–93. DOI: 10.1016/j.catena.2010.07.006.
- Zhu, C., Lu, D., Victoria, D., y Dutra, L. V. (2016). Mapping fractional cropland distribution in Mato Grosso, Brazil using time series MODIS enhanced vegetation index and Landsat Thematic Mapper data. *Remote Sensing*, 8(1). DOI: 10.3390/rs8010022.