

# DESARROLLO DE UNA BASE DE DATOS METEOROLÓGICA USANDO INFORMACIÓN SATELITAL

## DEVELOPMENT OF A METEOROLOGICAL DATABASE USING SATELLITE INFORMATION

Luis Alberto Palacios<sup>1</sup> y Fernando Paz<sup>2</sup>

<sup>1</sup> Consultor en Recursos Hidráulicos, Hermosillo, Sonora

<sup>2</sup> Programa Mexicano del Carbono y Colegio de Postgraduados, Texcoco, Estado de México, México

Autor para correspondencia: luis.palacios59@gmail.com

### RESUMEN

La epidemia de la roya del café ha afectado la salud de los cafetales bajo sombra, y otros tipos. Para poder modelar el avance de la epidemia de la roya es necesario contar con variables meteorológicas, diferentes retrasos y duraciones. El objetivo de la contribución fue el desarrollar una base de datos diaria y resolución espacial de 1 km para la temperatura mínima y máxima, así como la humedad relativa y la precipitación. Para iniciar las estimaciones se realizó un preproceso de la información. Usando imágenes satelitales del sensor MODIS se generó una base de datos de la temperatura, obteniendo coeficientes de determinación de 0.71 para la temperatura máxima y 0.87 para la mínima. Para la humedad relativa, máxima y mínima, se presenta el algoritmo para su estimación, obteniéndose resultados aceptables. En el caso de la precipitación las estimaciones fueron realizadas con un proceso de reducción de escala, obteniéndose un coeficiente de determinación de 0.45, que conserva los patrones esperados de la precipitación.

**Palabras clave:** *roya del café, meteorología, imágenes satelitales, temperatura mínima, temperatura máxima, humedad relativa, precipitación*

### ABSTRACT

The coffee rust epidemic has affected the *health* of shade-grown and other coffee plantations. In order to model the progress of the rust epidemic, it is necessary to have meteorological variables, different delays and durations. The objective of the contribution was to develop a daily database with spatial resolution of 1 km for the minimum and maximum temperature, as well as relative humidity and precipitation. To start the estimates, a pre-processing of the information was carried out. Using satellite images from the MODIS sensor, a temperature database was generated, obtaining determination coefficients of 0.71 for the maximum temperature and 0.87 for the minimum. For the relative humidity, maximum and minimum, the algorithm for its estimation is presented, obtaining acceptable results. In the case of precipitation, the estimates were made with a scale reduction process, obtaining a determination coefficient of 0.45, which preserves the expected precipitation patterns.

**Key Words:** *coffee rust, meteorology, satellite images, minimum temperature, maximum temperature, relative humidity, precipitation*


## INTRODUCCIÓN

La epidemia de la roya (*Hemileia vastatrix*) ha estado afectando la salud de los cafetales bajo sombra en los estados de Chiapas y Veracruz, entre otros. En el 2012, en Centroamérica y México, se presentó un brote atípico de la epidemia de la roya del cafeto con impacto en la producción de café (Avelino *et al.*, 2015; Libert-Amico y Paz-Pellat, 2018) lo que ha producido deforestación (cambio de uso de suelo forestal a milpa o potrero ganadero) y degradación forestal (perdida de la sombra arbórea del cafetal), con la consiguiente pérdida de los almacenamientos de carbono y emisiones de gases efecto invernadero,


Actualmente, el café se cultiva en 15 estados de México, con una superficie establecida de 710,897 hectáreas. Sin embargo, la superficie sembrada en: Chiapas, Veracruz, Oaxaca y Puebla, representan el 85 % de la superficie cultivada y el 88% del valor de la producción (SIAP, 2021).

La roya (*Hemileia vastatrix*) es la enfermedad más destructiva del cafeto y la de mayor importancia económica a nivel mundial, debido a que provoca la caída prematura de las hojas, propiciando la reducción de la capacidad fotosintética, así como el debilitamiento de árboles enfermos y en infecciones severas puede ocasionar muerte regresiva en ramas e incluso la muerte de árboles (Arneson, 2011).

En términos productivos la situación del cultivo es preocupante ya que en 15 años (2007-2021) la superficie y producción han tenido una tendencia decreciente. En este período, con datos de SIAP (2023), la superficie se redujo en 90 mil hectáreas y la producción en 512 mil toneladas (Figuras 1 y 2). Las tendencias históricas sugieren que el problema productivo del cafeto es de tipo integral y no solo fitosanitario o climático.



**Figura 1. Superficie sembrada y cosechada de café en México (fuente: SIACON, SIAP, 2021)**



**Figura 2. Producción de café en México (fuente: SIACON, SIAP, 2021)**

Para el pronóstico del avance de la roya en los cafetales se han utilizado variables meteorológicas (Kushalappa, 1989; Merle *et al.*, 2020a y b). Las variables utilizadas en los diferentes modelos han sido: temperaturas (bulbo seco) del aire, precipitación, humedad relativa, insolación, viento, temperatura de punto de rocío, así como características de los cafetos, de la siembra, manejo de los cafetales, fertilización de los suelos, entre otras. Para

las variables que inciden en la epidemia de la roya, un punto crítico es la selección de variables meteorológicas y de contexto (características de los cafetales y de la sombra, manejo del cafetal, entre otras). Para la selección de variables meteorológicas se han utilizado diferentes metodologías (Toniutti *et al.*, 2017; Hinnah *et al.*, 2018; Liebig *et al.*, 2019; Merle *et al.*, 2020b), incluyendo técnicas de aprendizaje automático (Lasso *et al.*, 2020).

Las principales variables utilizadas en la literatura para el pronóstico del avance de la roya del café son: temperatura máxima (tmax) y mínima (tmin) (Kushalappa, 1989; Pedro, 1983; Alfonsi *et al.*, 2019a y b), humedad relativa o HR (Pinto *et al.*, 2002; Hinnah, 2018 y 2020; Liebig *et al.*, 2019) y precipitación o P (Hinnah, 2018; Merle *et al.*, 2022) con periodos de tiempo previo al pronóstico de 15, 30 y 45 días, principalmente (Kushalappa y Eskes, 1989; Hinnah, 2018; Pinto *et al.*, 2002) y otros periodos (Merle *et al.*, 2022).

Desafortunadamente, en México la información del servicio meteorológico nacional (SMN) no está actualizada y con huecos de información faltante, por lo que se ha propuesto el uso de información satelital para este objetivo (Fox, 2000). Las imágenes satelitales de diferentes resoluciones espaciales y temporales permiten realizar estimaciones de variables meteorológicas de la temperatura máxima y mínima (Zhu *et al.*, 2017), además de la precipitación y otras variables (Karger *et al.*, 2021; Thornton *et al.*, 2021).

Este trabajo tiene como objetivo el desarrollo de una base de datos meteorológicas usando imágenes satelitales para el sistema de pronóstico de la roya del café y forma parte del proyecto “Resiliencia y estabilidad socioecológica de la cafecultura mexicana bajo sombra: hacia nuevos paradigmas” (Bolaños-González *et al.*, 2021), financiado por el CONACYT.

## **MATERIALES Y MÉTODOS**

Es importante dar seguimiento a las variables meteorológicas que propician la aparición y propagación de la roya. De esta manera es posible delimitar las regiones propensas a la afectación de esta plaga en tiempo casi real.

El principal problema de monitorear la meteorología en México es la falta de información actualizada. Los registros de las estaciones del Servicio Meteorológico Nacional tienen la información publicada hasta el 31 de diciembre de 2018. Por otro lado, estos registros son puntuales, las estaciones tienen diferentes intervalos de registro y presentan datos faltantes. Para el análisis de la propagación y afectación de la roya del cafeto, es necesario contar con la información meteorológica con distribución espacial en malla, a una resolución temporal diaria y espacial de 1 km por píxel.

Las variables climatológicas que se estimarán con 1 km de resolución por píxel, en proyección Cónica Conforme de Lambert, México ITRF2008 (EPSG: 6372), son:

- Temperatura máxima y mínima diaria
- Precipitación total diaria
- Humedad relativa máxima y mínima

Se analizó el uso de datos en malla de Asimilación y Reanálisis Meteorológicos, diarios u horarios; sin embargo, la información se encuentra disponible a resoluciones más gruesas y/o sus registros tienen un retraso de 3 meses o más.

Finalmente se optó por utilizar, para las temperaturas máxima y mínima, el conjunto de datos de temperatura en superficie de MODIS, los cuales se encuentran con la resolución temporal y espacial requeridas. Para la precipitación se hizo una reducción de escala del conjunto de datos horarios Global Satellite Mapping of Precipitation (GSMaP) v6 (Okamoto

et al., 2005). Para el caso de la humedad relativa máxima y mínima se calculó a partir del conjunto de datos NCEP Climate Forecast System Version 2 (Saha *et al.*, 2014) y su reducción de escala.

Con el fin de agilizar el proceso de generación de las variables se utilizó Google Earth Engine (Gorelick *et al.*, 2017), el cual es un marco de desarrollo geomático en la nube, con petabytes de conjuntos de datos e imágenes satelitales y la capacidad de análisis masivo. Los conjuntos de datos se actualizan diariamente de acuerdo con la disponibilidad en las fuentes de éstos. Las ventajas de utilizar este proceso en la nube, es que no se tienen que descargar todas las imágenes requeridas, sólo los resultados de interés, aparte de que el proceso de análisis se realiza en paralelo en la infraestructura computacional de Google.

### **Preproceso de datos meteorológicos.**

Las estadísticas de la red de estaciones meteorológicas de México publicadas por CONAGUA no están actualizadas y presenta una gran cantidad de huecos, la información disponible es la termo pluviométrica: temperaturas mínima y máxima, precipitación y evaporación. Al consultar la página web del Servicio Meteorológico Nacional, la información estadística consiste en un archivo KML de Google Earth con información de las estaciones y ligas a archivos de texto con la información meteorológica diaria, mensual, tres períodos normales, estadísticas y valores extremos.

Para generar una base de datos meteorológicos que pudiera manipularse, se programó código en Python y se realizaron los siguientes procesos:

- Se transformó el archivo KML de la información de las estaciones, a formato Excel

- La información de las estaciones se importó al programa QGIS, a donde también se importaron los polígonos de los estados de Chiapas y Veracruz.
- Se generó un buffer de  $0.25^\circ$  alrededor de los vértices de los polígonos de los estados (aproximadamente 28 km, Figura 3), y se seleccionaron las estaciones meteorológicas que estaban dentro del mismo. Se exportaron las estaciones seleccionadas a un archivo Excel.
- Se leyeron los datos de las estaciones y se ligó a los archivos de texto de información diaria, los cuales se descargaron.
- Se realizó un análisis sintáctico de los archivos de texto, con los que se generó una base de datos SQLite. Se agregaron a la base de datos los registros a partir del año 2000.


Una vez generada la base de datos, se analizaron las longitudes de registro de las estaciones (Figura 4) y se realizó un análisis de homogeneidad y consistencia a las series temporales. La información se encuentra actualizada hasta el 31 de diciembre de 2018, con diferentes longitudes de registro. Se estimó el porcentaje de datos faltantes para las estaciones (Figura 5), y se seleccionaron aquellas que sus datos faltantes fueran menores o iguales al 10%, ya que, generalmente, cuanto mayor sea el porcentaje de datos faltantes, la información será menos homogénea.



**Figura 3. Selección de Estaciones Meteorológicas**








**Figura 4. Datos faltantes**

Dado que el análisis consiste en una regresión, no se estimaron los datos faltantes. Para análisis de homogeneidad se utilizaron las pruebas de Pettitt, prueba de homogeneidad normal estándar (SNHT), Buishand en cuatro variantes: prueba Q, prueba U, prueba de rango y prueba de relación de verosimilitud. Para el análisis se utilizó la biblioteca de Python pyHomogeneity (Hussain, 2020). Los análisis de homogeneidad se realizaron en los registros más largos sin huecos de las estaciones. Los resultados muestran que todas las estaciones presentan por lo menos un par de pruebas que detectan información no-homogénea, tanto para temperatura mínima como para la máxima. Esto concuerda con el análisis realizado por Guajardo-Panes *et al.* (2017), donde reportan que, para la temperatura mínima y máxima, sólo el 31 y 30% de las estaciones cumplió con el criterio de homogeneidad, las pruebas

fueron similares a las efectuadas excluyendo las pruebas Buishand U y relación de verosimilitud.

Como siguiente paso se procedió la detección de datos anómalos, con el fin de eliminarlos del proceso de regresión. El algoritmo utilizado fue el de bosque de aislamiento (Liu *et al.*, 2008) mediante la biblioteca sklearn de Python (*sklearn.ensemble.IsolationForest*). La mayoría de los enfoques existentes, basados en modelos para la detección de anomalías construyen un perfil de instancias normales, luego identifican las instancias que no se ajustan al perfil normal como anomalías. El Bosque de Aislamiento es un método basado en un modelo fundamentalmente diferente que aísla explícitamente las anomalías en lugar de perfilar los puntos normales. Los bosques de aislamiento, similares a los bosques aleatorios, se construyen con base en árboles de decisión y dado que no hay etiquetas predefinidas, es un modelo no supervisado. En un bosque de aislamiento, los datos sub muestreados aleatoriamente se procesan en una estructura de árbol basada en características seleccionadas aleatoriamente. Es menos probable que las muestras que se adentran más en el árbol sean anomalías, ya que requirieron más cortes para aislarlas. De manera similar, las muestras que terminan en ramas más cortas indican anomalías, ya que fue más fácil para el árbol separarlas de otras observaciones. En la Figura 6 se muestra un ejemplo de anomalías detectadas en un grupo cercano de estaciones.



**Figura 5. Ejemplo de anomalías detectadas**

### Temperatura en superficie

Para la temperatura en superficie se utilizó la estimada por los satélites MODIS Aqua y Terra, los cuales tienen un producto diario de temperatura en superficie a 1 km de resolución. Los horarios de paso de los satélites en el ecuador son a las 10:30 y 22:30 para Terra, y a las 1:30 y 13:30 para Aqua, ambos en hora solar media. Las horas de adquisición no corresponden a las que se presentan las temperaturas mínima y máxima, por lo que es necesario un ajuste.

Para estimar las temperaturas superficiales mínima y máxima, se utilizarán las observadas en estaciones termo pluviométricas, dado que, de acuerdo con Mildrexler *et al.*, 2011:

*"Para condiciones cálidas y en tipos de cobertura no boscosa, la temperatura en superficie terrestre (TST) está más estrechamente relacionada con las características radiativas y termodinámicas de la Tierra que la temperatura del aire (Ta). Las zonas áridas, los matorrales, pastizales, sabanas y las tierras de cultivo tienen valores  $TST_{max}$  entre 10 °C y 20 °C más calientes que el  $Ta_{max}$  correspondiente a temperaturas más altas. Los tipos de*

*cubierta forestal son la excepción con una relación cercana a 1:1 entre  $TST_{max}$  y  $Ta_{max}$  en todo el rango de temperatura y 38 °C como el límite superior aproximado de  $TST_{max}$ , con la excepción de los tipos de bosques caducifolios subtropicales donde  $TST_{max}$  ocurre después de la senescencia del dosel."*

Si se considera lo establecido por el Instituto Nacional de Ecología (2013):

*"México está posicionado en las estadísticas mundiales en el sector de cafés sustentables, pues más del 90% de los productores cultivan café bajo sombra, esto significa que las hileras de cafeto están a la sombra de numerosos árboles en las parcelas de cultivo. Lo que hace al café de sombra uno de los cultivos más amigables con el ambiente es la cantidad de árboles de variadas especies y alturas que dan sombra al café. Los cafetales bajo sombra son un tipo de sistema agroforestal que, al constituirse en la masa forestal más extensa en la zona central montañosa de Veracruz, proporcionan importantes servicios hidrológicos parecidos a los de los bosques que remplazaron."*

En los últimos años, ha habido cada vez más estudios que emplean la TST obtenida de imágenes de sensores remotos para la estimación de  $Ta$  debido a la alta resolución espacial y temporal, la libre disponibilidad y el fácil acceso (Benali *et al.*, 2012; Gallo *et al.*, 2011; Noi *et al.*, 2016). La diferencia entre TST y  $Ta$  está fuertemente influenciada por las características de la superficie y las condiciones atmosféricas (Jin y Dickinson, 2010; Vancutsem *et al.*, 2010; Huag *et al.*, 2015; Lin *et al.*, 2016).

El proceso de ajuste consiste en correr una regresión para las temperaturas mínima y máxima medida a 2 m como variables dependientes; las temperaturas estimadas por el sensor Aqua del satélite MODIS, la elevación sobre el nivel del mar y orientación del píxel

correspondiente, la duración del día, el índice de área foliar (IAF) y las coordenadas del píxel que contiene la estación meteorológica, como variables independientes. Solo se utilizó la información del sensor Aqua debido a que el horario de adquisición de datos es más cercano a las de las temperaturas máxima y mínima.

Las variables auxiliares se incluyeron debido a la influencia que tienen en la variación espacial y temporal de la temperatura. La elevación sobre el nivel del mar está relacionada con procesos termodinámicos (adiabáticos), que establecen que la temperatura de un gas aumenta al aumentar su presión, independientemente de los intercambios de calor, por lo que la temperatura del aire disminuye con la elevación, al disminuir la presión atmosférica (Lai *et al.*, 2012). La orientación de la pendiente en un píxel está relacionada con la cantidad de radiación que recibe y dirección de vientos predominantes (sotavento, barlovento). La duración del día tiene relación con la variabilidad estacional de la temperatura y con la cantidad de radiación que recibe. El IAF se incluye por el efecto de la vegetación sobre los flujos de calor sensible, latente y en el suelo, del balance de energía en superficie. La ubicación geográfica (latitud y longitud) está relacionada con la variabilidad espacial (cercanía al mar). Se incluyeron originalmente los ángulos de visión e iluminación de cada píxel, pero su efecto no era significativo, por lo que no se consideraron en el análisis final.

Para la regresión no se utilizó el método de mínimos cuadrados ordinario, dada la relación no-lineal de algunas variables auxiliares, por lo que se optó por ajustar una red neuronal artificial. La red consta de la capa de entrada con las 7 variables independientes, dos capas ocultas de 16 neuronas la primera y 8 la segunda, y una capa de salida que corresponde a la estimación de la variable dependiente. La función de activación fue la Unidad Lineal de Error Gaussiano (GELU, por sus siglas en inglés) para ambas capas ocultas.

El modelo de optimización es Adam, el cual es un método de descenso de gradiente estocástico que se basa en la estimación adaptativa de momentos de primer y segundo orden. Los parámetros del modelo fueron: una tasa de aprendizaje = 0.001,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 1 \times 10^{-7}$ . La función por minimizar fue el cuadrado medio del error, con métricas del error estándar (raíz del error cuadrático medio) y el error absoluto medio.

#### *Datos faltantes en el conjunto TST de MODIS.*

Para el llenado de datos faltantes se usa la metodología propuesta por Shiff, Helman y Lensky (2021), los cuales combinaron las temperaturas en superficie de MODIS (TST) con las temperaturas modeladas del Sistema de Pronóstico Climático Versión 2 (CFSv2) para derivar un conjunto de datos TST global continua (sin datos faltantes) a una resolución espacial de 1 km. El análisis temporal de Fourier se utilizó para derivar la estacionalidad (meteorología) píxel por píxel, para las temperaturas TST y CFSv2. Los vacíos se llenaron agregando la anomalía de temperatura CFSv2 al TST climatológico. En años bisiestos no se calcula el 31 de diciembre. Sin embargo, dada la alta nubosidad existente en los estados de Veracruz y Chiapas, no fue posible ajustar correctamente las series de Fourier para los datos de MODIS. Los sensores ubicados en los satélites MODIS sólo pueden estimar la TST si no hay nubes, ya que éstas son opacas en las bandas térmicas. Se realizó un análisis y se observaron zonas con nubosidad mayor al 95% de días en los meses de junio, julio y agosto por lo que no existen suficientes datos para un correcto ajuste de las series de Fourier en esos meses.

Otro problema que se presenta en zonas con alta nubosidad es que, aunque se adquiriera un píxel, éste puede estar contaminado por cirrus o nubes delgadas semitransparentes lo que, al eliminarlos, reduce aún más la cantidad de píxeles válidos. Se eliminaron los píxeles

contaminados con base en la banda de calidad que incluye el conjunto de datos MODIS (QC\_Day, QC\_Night), ya que la contaminación puede llevar a errores en la estimación de la TST superiores a los 3 K. La banda de calidad define si un píxel está contaminado y la gravedad de la contaminación, por lo que es posible enmascarar los píxeles más contaminados.

Para determinar píxeles válidos se decodifican los bits en las bandas de calidad y se aplica la siguiente regla, los que no cumplan se enmascaran:

- Bits 0-1  $\leq 1$  (LST producido tanto de buena como de otra calidad)
- Bits 2-3 = 0 (Buena calidad de datos)
- Bits 4-5 Ignorar, cualquier valor está bien
- Bits 6-7 = 0 (Error promedio de LST  $\leq 1K$ )

Una forma de resolver la falta de datos para el ajuste de la serie de Fourier es utilizar otro conjunto de datos para rellenar los datos faltantes de MODIS, para posteriormente realizar el ajuste de la serie de Fourier. Un conjunto de datos que es apropiado para este proceso es Daymet (Thorton *et al.*, 2020), este conjunto proporciona datos como estimaciones cuadrículadas de 1 km de espaciamiento de parámetros meteorológicos diarios para América del Norte, Hawái y Puerto Rico. Las variables Daymet incluyen los siguientes parámetros: temperatura mínima, temperatura máxima, precipitación, radiación de onda corta, presión de vapor, equivalente de agua de nieve y duración del día. El conjunto de datos cubre el período comprendido entre el 1 de enero de 1980 y el 31 de diciembre (o el 30 de diciembre en años bisiestos) del año calendario completo más reciente. Se encuentra actualizado hasta el 31 de diciembre de 2021, por lo que no es posible utilizarlo en tiempo “casi-real”.




Las regresiones de las temperaturas máxima y mínima de las estaciones meteorológicas se corrieron contra los datos de TST de MODIS completados mediante el conjunto Daymet.


*Rellenado del conjunto de datos MODIS con Daymet.*

Para la estimación de la TST de día y noche a partir de las temperaturas máximas y mínimas del conjunto Daymet, se utilizó una red neuronal similar a la del modelo discutido previamente. Aparte de las temperaturas máxima y mínima de Daymet, se utilizaron las mismas variables auxiliares: IAF, duración del día, elevación, orientación, latitud y longitud del píxel.


En las figuras 7 y 8 se presenta el ajuste de las regresiones de las redes neuronales de las temperaturas en superficie de día y noche de MODIS, en función de las temperaturas máxima y mínima de Daymet; mientras que en las Figuras 9 y 10 se muestra la distribución de errores en la estimación. En las gráficas de ajuste la rampa de colores corresponde a la estimación de densidad de kernel (KDE, por sus siglas en ingles), la cual es una forma no paramétrica para estimar la función de densidad de probabilidad de una variable aleatoria (la escala está normalizada de 0 a 1).




**Figura 7. Ajuste de la temperatura de día de MODIS a partir de la temperatura máxima en Daymet.**



**Figura 8. Ajuste de la temperatura de noche de MODIS a partir de la temperatura mínima en Daymet.**



**Figura 9. Distribución de errores en la estimación de la temperatura de día de MODIS**




**Figura 10. Distribución de errores en la estimación de la temperatura de noche de MODIS**

El llenado de los píxeles faltantes en la temperatura en superficie de MODIS se realizó al correr la red neuronal para un día específico y reemplazar los píxeles enmascarados por


nubes y contaminación por nubes, con los estimados en función de las temperaturas de Daymet.

Para la estimación de las temperaturas máxima y mínima se corrió una regresión mediante una red neuronal entre las TST continuas (rellenados con Daymet) y las temperaturas de las estaciones meteorológicas tal como se comentó anteriormente.


En las figuras 11 a 14 se muestra el ajuste de las redes, así como la distribución de los errores de estimación.




**Figura 11. Ajuste de la temperatura máxima ambiental con MODIS TST**



**Figura 12. Ajuste de la temperatura mínima ambiental con MODIS TST**



**Figura 13. Distribución de errores en la estimación de Tmax**



**Figura 14. Distribución de errores en la estimación de Tmin**

#### *Estimación de temperaturas en días nublados*

Una vez realizado el llenado para los años 2003 al 2021 (a escala diaria), se procedió a aplicar la metodología propuesta por Shiff, Helman y Lensky (2021):

*“consistente en realizar un análisis temporal de Fourier (ATF) para derivar las temperaturas climatológicas del satélite sin nubes (MODIS TST) y las temperaturas CSFv2. El ATF describe los ciclos estacionales de temperatura en términos de componentes anuales, semestrales y trianuales (o "armónicos"), cada uno descrito por su fase y amplitud. Estos armónicos de Fourier pueden recombinarse, proporcionando una señal suavizada, que aquí se considera como las temperaturas climatológicas esperadas:*

$$TST_{clim}(t) = \overline{TST} + \sum_{i=1}^n A_i \cos(\omega_i t - \varphi_i) \quad (1)$$

$TST_{clim}(t)$  es la TST climatológico de MODIS en el día juliano  $t$ ;  $\overline{TST}$  es el TST anual medio,  $A_i$  es la amplitud de la  $i$ -ésima componente armónica, mientras que  $n$  es el número de componentes armónicos. Se usaron los tres primeros armónicos ( $n=3$ ),  $\phi_i$  es la fase y  $\omega_i$  es la frecuencia ( $\omega_i = 2\pi i/365$ ) de la  $i$ -ésima componente armónica. Se aplicó ATF en MODIS TST para derivar el TST climatológico y en CSFv2 para derivar la temperatura climatológica a partir de la cual se calculó la anomalía ( $T_{anom}$ , la desviación de la temperatura real de la temperatura climatológica).”

Para calcular  $A_i$  y  $\phi_i$ , en lugar de utilizar el conjunto de datos de MODIS TST, se utilizaron series de tiempo de un año (365 días julianos) con los datos de temperatura máxima y mínima estimados en este trabajo para cada día juliano.

Para estimar la temperatura real en el tiempo  $t$  ( $T_{cont}(t)$ ) se suma la anomalía de temperatura CSFv2 ( $T_{anom}(t)$ ) a la T climatológica observado a escala fina (1 km) ( $T_{clim}(t)$ ):

$$T_{cont}(t) = T_{clim}(t) + T_{anom}(t) \quad (2)$$

En el trabajo de Shiff, Helman y Lensky las observaciones satelitales reales de cielo despejado (MODIS TST) se utilizan en el conjunto de datos siempre que estén disponibles. Se usa  $TST_{cont}$  solo para estimar los datos TST que faltan (píxeles nublados o contaminados). La relación entre TST y la temperatura del aire a 2 m no es globalmente consistente, sin embargo, se usan datos de CFSv2 solo para condiciones nubladas en las que la TST y la temperatura del aire a 2 m suelen estar cerca (por ejemplo, dentro de 2 °C).

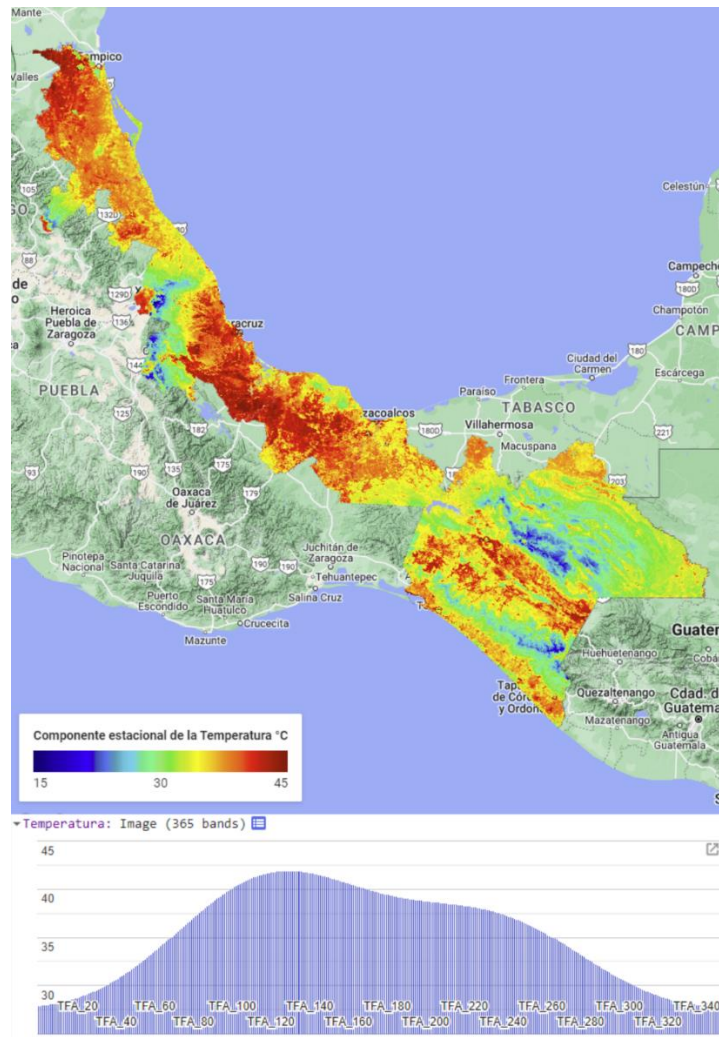
No obstante, a diferencia de la metodología aplicada por Shiff, Helman y Lensky, el relleno de datos faltantes se aplicó a las temperaturas máxima y mínima estimadas a partir de la TST de MODIS, por lo que los errores son menores. En la Figura 15 se muestra la

temperatura máxima climatológica para el día juliano 150, así como la distribución de la temperatura climatológica a lo largo del año para un píxel.

De esta manera, para estimar la temperatura máxima y mínima continuas, se corre la red neuronal ajustada con las temperaturas de las estaciones y las TST de MODIS enmascaradas por nubes y píxeles contaminados. Posteriormente se aplica la metodología de Shiff, Helman y Lensky para sustituir los píxeles enmascarados por los estimados. Esto se puede realizar en tiempo casi-real (un día de diferencia).

Pronaii 319069





**Figura 15. Temperatura máxima climatológica para el día juliano 150 y la distribución estacional de un píxel**

En la Figura 16 y 17 se muestra de manera esquemática el proceso de generar las temperaturas climatológicas y diarias (2003-2021).

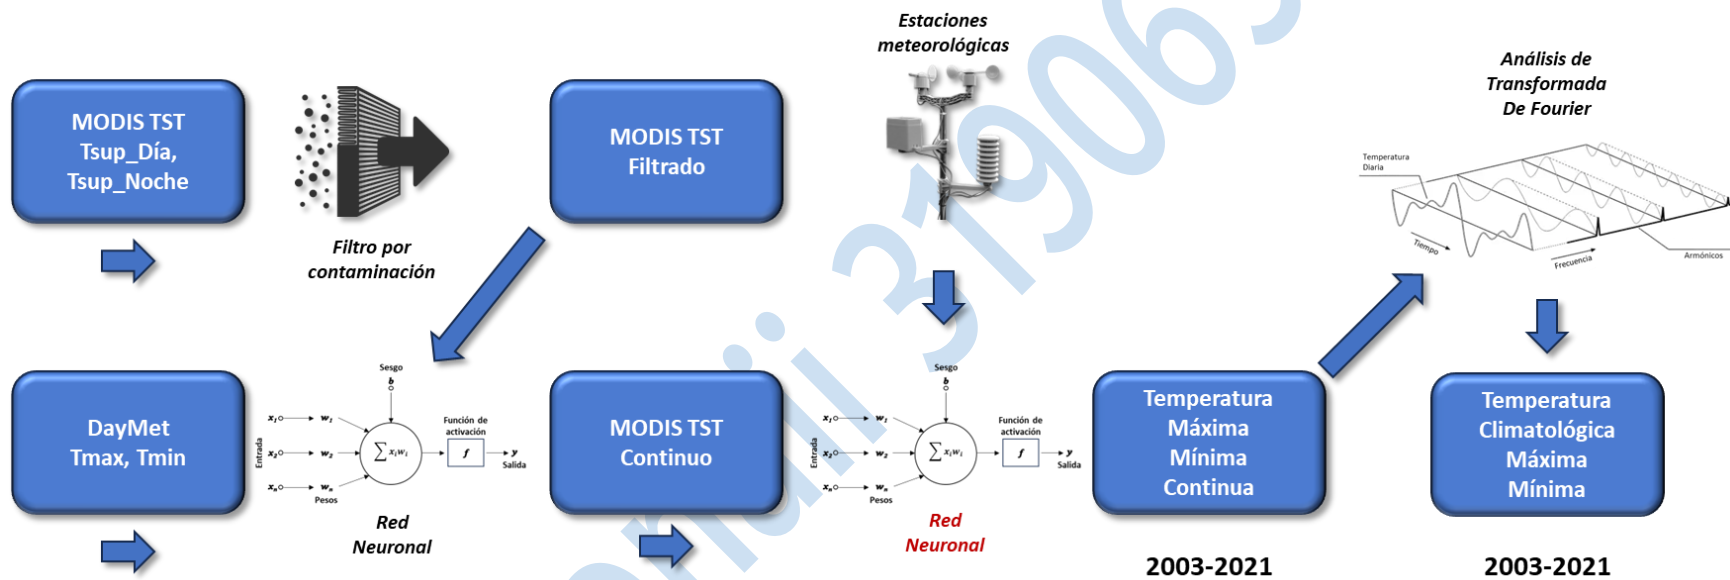


Figura 16. Proceso para generar las temperaturas climatológicas mediante análisis de la transformada de Fourier

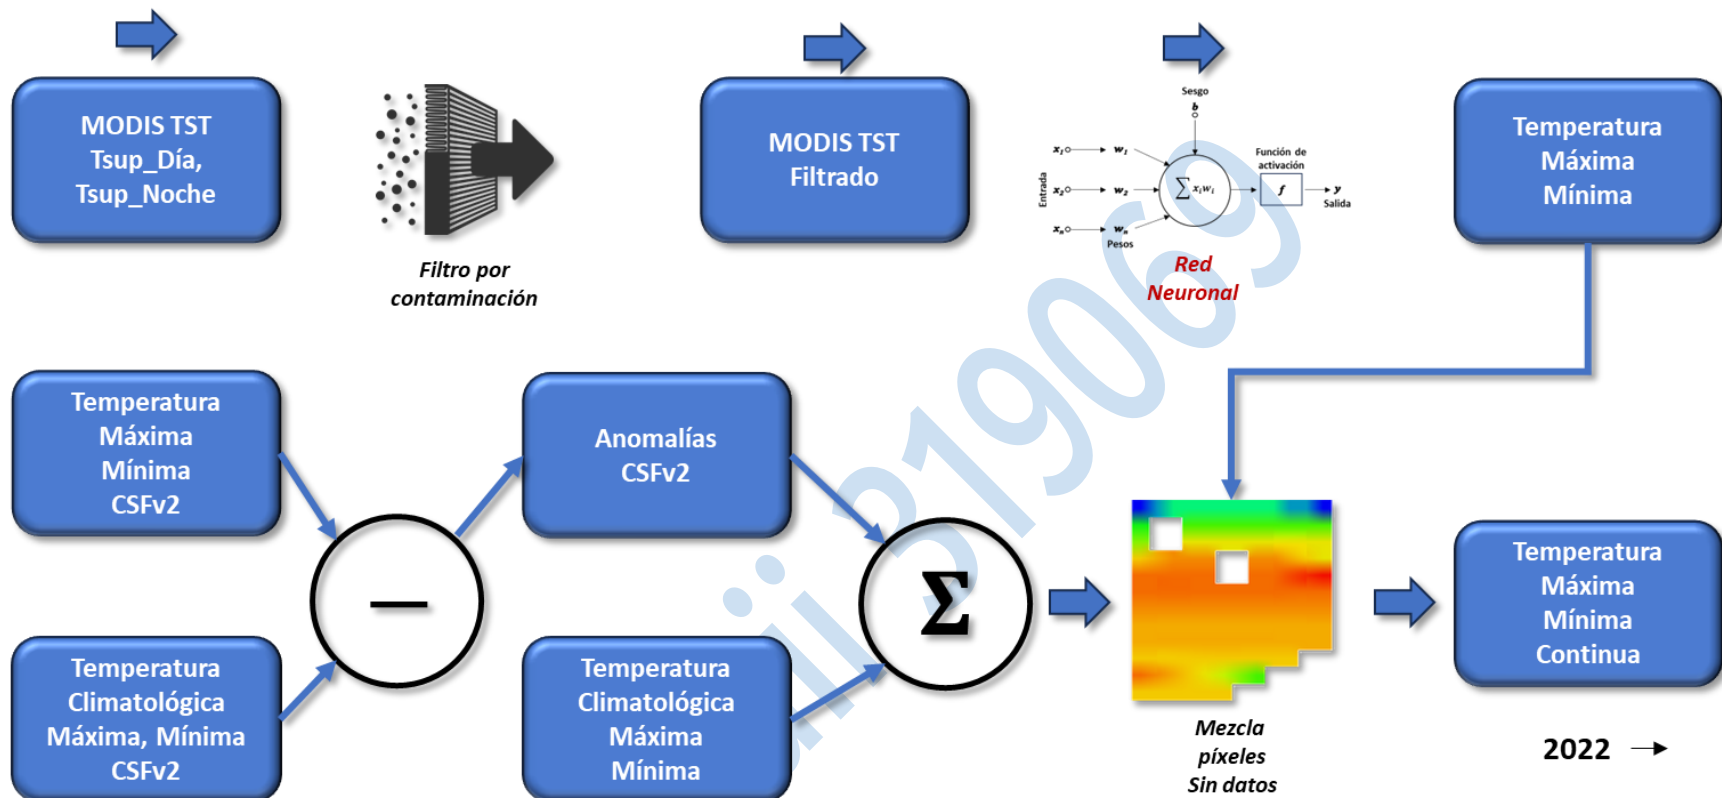


Figura 17. Generación de temperaturas máximas y mínimas continuas

## **Humedad Relativa Máxima y Mínima.**

La humedad presente en el aire es una variable relevante, ya que afecta la salud, confort, e influye en procesos industriales, la agricultura y en la incidencia y propagación de enfermedades, por nombrar algunos. Generalmente se utiliza la humedad relativa para representar la cantidad de agua presente en la atmósfera, sin embargo, también están los conceptos de humedad absoluta y humedad específica.

La humedad absoluta es la cantidad de vapor de agua (masa) contenido en un determinado volumen de aire. La humedad específica es el mismo concepto que la humedad absoluta, pero cambiando las unidades de medición, en este caso se trata de unidad de masa de agua por unidad de masa de aire. Tanto en la humedad absoluta como en la específica, el agua siempre está en forma de vapor. La humedad relativa es la relación entre cantidad de vapor de agua contenida en el aire (humedad absoluta o específica) y la máxima cantidad que el aire sería capaz de contener a esa temperatura (humedad absoluta o específica a saturación).

En México no existen registros largos de humedad relativa medidos en estaciones meteorológicas, ya que las estaciones del Servicio Meteorológico Nacional solo reportan información de precipitación, evaporación y temperaturas máxima y mínima. Los únicos registros son los disponibles de las estaciones automáticas ubicadas en las zonas agrícolas, sin embargo, al ser muchas particulares, no se encuentran publicadas en todos los Estados. Desgraciadamente tampoco existen conjuntos de datos que contemplen la humedad relativa en tiempo casi real, por lo que se tiene que estimar de manera indirecta.

La mejor alternativa que se encontró fue la de utilizar la humedad específica publicada por el Sistema de pronóstico Climático versión 2 y realizar una reducción de escala mediante las temperaturas mínimas y máximas y la elevación a 1km.

El Sistema de Pronóstico Climático (CFS) de los Centros Nacionales para la Predicción Ambiental de Estados Unidos (NCEP), es un modelo completamente acoplado que representa la interacción entre la atmósfera de la Tierra, los océanos, la tierra y el hielo marino. CFS fue desarrollado en el Centro de Modelado Ambiental (EMC) en NCEP (Saha *et al.*, 2014).

Además de los esfuerzos de reanálisis, el modelo CFS se usó para generar un nuevo pronóstico (reforecast) de pronósticos meteorológicos anteriores. Los nuevos pronósticos ayudan a comprender mejor la capacidad del modelo para producir pronósticos meteorológicos precisos. Los nuevos pronósticos de CFS se inicializaron con datos de CFSR, que fueron la mejor estimación de las condiciones iniciales a partir de la asimilación de datos de observación en el modelo de CFS. Las predicciones de reforecast comienzan a mediados de diciembre de 1981. Los datos de reforecast de CFS se usaron para generar climatologías de calibración para su uso con los pronósticos de tiempo estacional operativos CFS versión 2 (CFSv2). Juntos, los datos CFSR y reforecast CFS se conocen como el Reanálisis y Re pronóstico del Sistema de Pronóstico Climático (CFSRR). El análisis y los pronósticos operativos de CFSv2 continúan el conjunto de datos desde abril de 2011 hasta el presente.

Los pronósticos se inicializan cuatro veces al día (0000, 0600, 1200 y 1800 UTC), generan información climática con una resolución de píxel de 22,264 m por lado.

Para la estimación de la humedad relativa en función de la humedad específica, hay que utilizar termodinámica de gases. La humedad específica se define como la masa del vapor de agua dividida por la masa de todo el aire, incluido el vapor de agua:

$$q = \frac{m_{vapor\ agua}}{m_{aire\ total}} = \frac{m_v}{m_{at}} \quad (3)$$

La relación de mezcla del vapor de agua ( $w$ ) es la masa del vapor de agua dividida por la masa del aire seco sin el vapor de agua:

$$w = \frac{m_{\text{vapor agua}}}{m_{\text{aire seco}}} = \frac{m_v}{m_{as}} \quad (4)$$

la relación de mezcla de vapor de agua se usa ampliamente para calcular la cantidad de vapor de agua. La relación de mezcla del vapor de agua no tiene unidades, pero a menudo se establece en  $\text{g kg}^{-1}$ .

Dado que  $m_{as} = m_{at} - m_v$ , se pueden reorganizar las ecuaciones para obtener la relación entre  $w$  (relación de mezcla de vapor de agua) y  $q$  (humedad específica):

$$w = \frac{q}{1-q} \quad (5)$$

La humedad relativa (HR) es otra medida del vapor de agua en la atmósfera, aunque se debe tener cuidado al usarla porque una humedad relativa baja puede no significar una relación de mezcla de vapor de agua baja (es decir, a altas temperaturas) y una humedad relativa alta puede todavía ser aire bastante seco (es decir, a bajas temperaturas).

Según la definición de la Organización Meteorológica Mundial (WMO):

$$HR = \frac{w}{w_s} \quad (6)$$

donde  $w_s$  es la relación de mezcla de saturación (la relación de mezcla a la que  $HR = 100\%$ ).  $w$  y  $w_s$  pueden tener unidades de  $\text{g kg}^{-1}$  o  $\text{kg kg}^{-1}$ , siempre que sean consistentes. La humedad relativa generalmente se expresa como un porcentaje. Así, cuando  $w = w_s$ ,  $HR = 1 = 100\%$ . En la mayoría de los problemas relacionados con la HR, es importante tener en cuenta las conversiones entre fracciones decimales y porcentajes.

Una definición más física de la cantidad relativa de humedad en el aire es la relación de saturación, S:

$$S = \frac{e}{e_s} \quad (7)$$

donde  $e$  es la presión de vapor y  $e_s$  es la presión de vapor de saturación.

Si se considera la Ley de los gases ideales y con un poco de álgebra:

$$e = \rho_v R_v T, \quad p_d = \rho_d R_d T \quad \varepsilon \equiv \frac{R_d}{R_v} \quad (8)$$

$$w = \frac{\varepsilon e}{p_d} = \frac{\varepsilon e}{p - e} \quad (9)$$

donde  $\varepsilon = 0.621957$  es la masa molar del agua ( $R_v \sim 18.02 \text{ kg mol}^{-1}$ ) dividida por la masa de aire seco ( $R_d \sim 28.97 \text{ kg mol}^{-1}$ ) y  $T$  la temperatura (K). En la saturación, se puede reemplazar  $w$  con  $w_s$  y  $e$  con  $e_s$  en la ecuación (9).

La presión de vapor a saturación se puede estimar en función de la temperatura utilizando la ecuación de Tetens (Monteith y Unsworth, 2013):

$$e_s(t) = e_s(T^*) \exp\{A(T - T^*)/(T - T')\} \quad (10)$$

donde:  $A = 17.27$ ,  $T^* = 273.15 \text{ K} = 0 \text{ }^\circ\text{C}$ ,  $e_s(T^*) = 6.112 \text{ hPa}$ , y  $T' = 29.65 \text{ K}$ .

La presión atmosférica total, se puede estimar en función de la altitud utilizando la fórmula barométrica:

$$p = p_0 \left[ 1 + \frac{L_0}{T_0} h \right]^{\frac{-g_0 M}{R^* L_0}} \quad (11)$$

Si se considera la atmósfera estándar internacional:

- $p_0$  es la presión de referencia (al nivel del mar 1 013.25 hPa)
- $L_0$  es la tasa de caída de la temperatura ( $-0.0065 \text{ K} \cdot \text{m}^{-1}$ )
- $T_0$  es la temperatura de referencia ( $288.15 \text{ K} = 15 \text{ }^\circ\text{C}$ )
- $g_0$  es la aceleración de la gravedad de referencia (al nivel del mar  $9.80665 \text{ m} \cdot \text{s}^{-2}$ )
- $M$  es masa molar del aire ( $0.0289644 \text{ kg} \cdot \text{mol}^{-1}$ )
- $R^*$  es la constante de los gases ideales ( $8.3144598 \text{ J} \cdot \text{mol}^{-1} \cdot \text{K}^{-1}$ )
- $h$  altitud de la presión que se quiere estimar (m)

Para hacer la reducción de escala de la humedad específica del conjunto de datos CFSv2, se consideran los siguientes conjuntos de datos auxiliares:

- GTOPO<sub>30</sub>: el cual es un modelo de elevación digital global (DEM) con un espacio de cuadrícula horizontal de 30 segundos de arco (aproximadamente 1 kilómetro). GTOPO<sub>30</sub> se derivó de varias fuentes rasterizadas y vectoriales de información topográfica.
- Las temperaturas máximas y mínimas estimadas en el presente trabajo (@ 1 km).
- De CFSv2 la banda de humedad específica estimada a 2 m del suelo (@ 22.264 km).

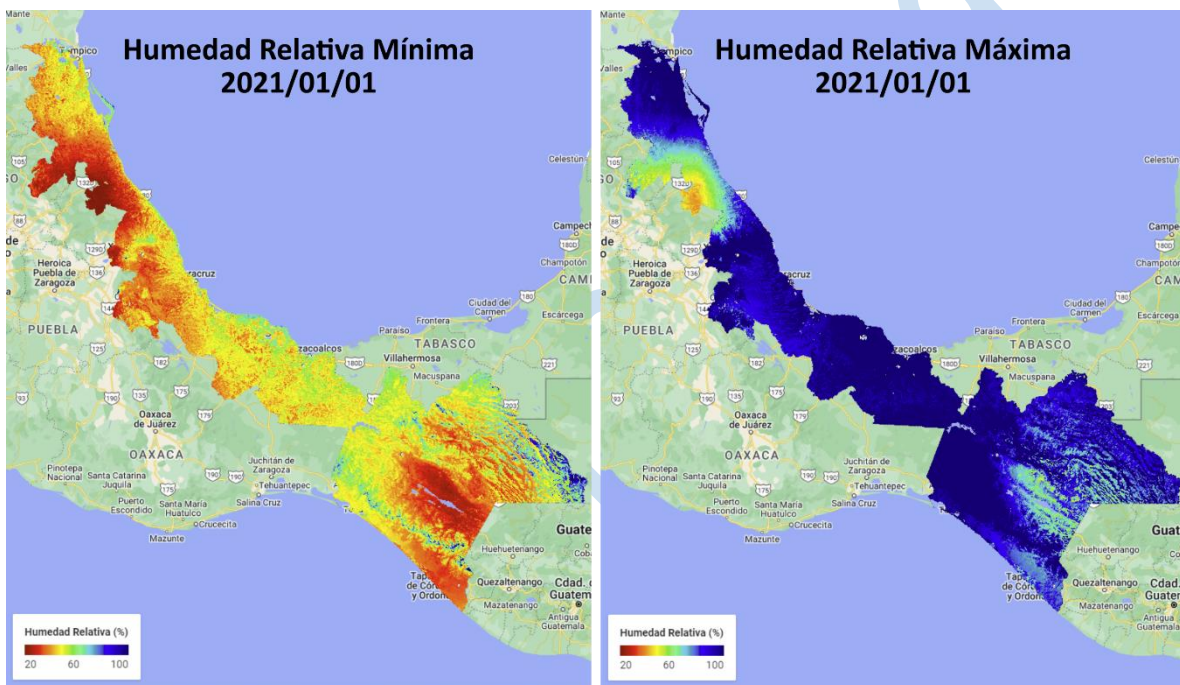
El proceso tuvo los siguientes pasos:

1. En Google Earth Engine se realizó una proyección del conjunto de datos CFSv2 a la de la temperatura (EPSG:6372, escala 1000 m)
2. Con el conjunto de datos GTOPO<sub>30</sub> se estimó la presión atmosférica mediante la ecuación (11)
3. Con las temperaturas máxima y mínima se estimó la presión de vapor a saturación máxima y mínima mediante la ecuación (10)
4. Se calculó la relación de mezcla de la humedad específica mediante la ecuación (5)



5. Se calculó la relación de mezcla de la presión de vapor a saturación mediante la ecuación (9)
6. Se calcularon la humedad relativa máxima y mínima mediante la ecuación (8), considerando la relación inversa entre humedad relativa y temperatura

En la Figura 18 se muestra un ejemplo de la humedad relativa mínima y máxima para el primero de enero de 2021.



**Figura 18. Humedad relativa mínima y máxima para el primero de enero de 2021**

### **Precipitación total diaria.**

Al observar variables meteorológicas, como la temperatura y la precipitación, se pueden notar grandes diferencias en su variabilidad espacial y temporal. Mientras que la temperatura varía lentamente en el espacio y el tiempo, es decir, es una señal de baja frecuencia, la precipitación está mucho más localizada y varía más rápido, es decir, es una

señal de alta frecuencia que es más difícil de predecir con las técnicas convencionales de reducción de escala.

En Google Earth Engine existen conjuntos de datos de precipitación con una buena correlación con datos medidos en estaciones meteorológicas, como el conjunto Climate Hazards Group InfraRed Precipitation With Station Data (CHIRPS, con resolución de  $0.05^\circ$ , Funk *et al.*, 2015), sin embargo, no se actualizan en tiempo casi-real. De los conjuntos con información actualizada al día y ampliamente nombrados en la literatura, se encuentran el conjunto de la NASA Global Precipitation Measurement (GPM) v6 (Huffman *et al.*, 2019) y el conjunto Global Satellite Mapping of Precipitation (GSMaP, Okamoto *et al.*, 2005). GSMaP forma parte del grupo Integrated Multi-satellitE Retrievals for Global Precipitation Mission (IMERG/GPM), sin embargo, los algoritmos son diferentes a los de GPM de la NASA. En un análisis previo con correlaciones directas entre los conjuntos de datos y las estaciones, se observó un mejor ajuste con el conjunto GSMaP, por lo que se seleccionó para realizar una reducción de escala.

Como producto japonés de medición de precipitación global (GPM), la Agencia de Exploración Aeroespacial de Japón (JAXA) proporciona el mapeo satelital global de precipitación (GSMaP) para distribuir un mapa de precipitación global por hora con una cuadrícula de  $0.1^\circ \times 0.1^\circ$  (Kubota *et al.*, 2020). Los valores se estiman utilizando radiómetros infrarrojos y de microondas pasivos multibanda del satélite GPM Core Observatory y con la ayuda de una constelación de otros satélites. El algoritmo de recuperación de la intensidad de precipitación de GPM se basa en un modelo de transferencia radiativa. La intensidad ajustada por pluviómetro se calcula en función de la optimización de la acumulación de 24 horas de la

intensidad de lluvia por hora de GSMaP a la precipitación diaria mediante la medición de pluviómetros NOAA/CPC.

Las variables que se utilizaron para realizar la reducción de escala de GSMaP de 11.132 km a 1 km, fueron:


- temperaturas máximas y mínimas estimadas en este trabajo
- El índice de área foliar medio en 4 días (MCD15A3H.061 MODIS Leaf Area Index/FPAR 4-Day Global 500m)
- La elevación, orientación (GTOPO30)
- Latitud y Longitud geográfica del píxel.

Se realizó una extracción en Google Earth Engine de estos conjuntos de datos y la precipitación acumulada diaria de GSMap proyectada a EPSG:6372 y escala a 1000 metros en las coordenadas de las estaciones meteorológicas. La acumulación de la precipitación en 24 horas se inició a las 8 am hora local, concordando con el horario del conjunto de datos GSMaP que está en Tiempo Universal Coordinado.


Se ajustó una red neuronal para la regresión con la precipitación medida en las estaciones y las variables mencionadas en el párrafo anterior, como variables independientes y la precipitación acumulada diaria de GSMaP como variable dependiente.

El modelo consistió en tres capas ocultas y una de salida, con 32, 16, 8 y 1 neurona respectivamente, las funciones de activación fueron tangente hiperbólica, GELU, GELU y Rectified Linear Units (ReLU), respectivamente. La función de activación ReLU en la capa de salida asegura que todos los resultados son positivos. Se utilizó una red neuronal profunda debido a la complejidad de la ocurrencia de la precipitación.

Dada la ocurrencia localizada y su señal de alta frecuencia, el ajuste de la regresión no fue tan bueno como los de la temperatura, como era de esperar. En la Figura 19 se muestra el ajuste de la regresión mediante redes neuronales y en la Figura 20 la distribución de errores de estimación.




**Figura 19. Ajuste de la regresión de la precipitación total diaria**



**Figura 20. Distribución de errores de la estimación de la precipitación**

Con el fin de evaluar la utilidad de la precipitación estimada mediante la reducción de escala en comparación con la medida en las estaciones meteorológicas, se graficaron dos series temporales. Las estaciones se encuentran ubicadas en las zonas cafetaleras, la primera la estación Unión Zaragoza (7355) en Chiapas y la segunda la estación Sihuapán (30302) en Veracruz. La Figura 21 muestra las series temporales de precipitación.



**Figura 21. Series temporales de precipitación medida y estimada**

Como puede apreciarse en las gráficas, por lo general, la precipitación con reducción de escala subestima las precipitaciones grandes, a la vez que sobreestima la ocurrencia de precipitaciones pequeñas ( $< 0.5$  mm/día), pero sigue el patrón de ocurrencia de la precipitación, que es lo importante en el seguimiento a la incidencia y propagación de la Roya en los cafetales.

## CONCLUSIONES

La base de datos diaria y resolución espacial de 1 km, a partir del 2000, generada permite utilizar esquemas de modelación cuantitativos para analizar el avance de la roya del café en una región determinada. Los estadísticos de comparación de las estimaciones son razonables, dada la alta variabilidad observada en las variables meteorológicas analizadas.

## RECONOCIMIENTO

Los autores agradecen al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo a través del FORDECYT-PRONACES para realizar este trabajo mediante el financiamiento al proyecto 319069 “Resiliencia y estabilidad socioecológica de la cafecultura mexicana bajo sombra: hacia nuevos paradigmas”

## LITERATURA CITADA

- Alfonsi, W.M.V., P. Pereira, J. Zullo, F. Alves and E. Alfonsi. 2019a. Periodo de incubacao da ferrugem do cafeeiro. *Summa Phytopathology* 45:134-140
- Alfonsi, W.M.V., P.P. Coltri, J. Zullo, F.R.A. Patricio, R.R.do Valle, K. Shinji, E.L. Alfonsi and A. Koga-Vicente. 2019b. Geographical distribution of the incubation period of coffee leaf rust in climate change scenarios. *Pesquisa Agropecuaria Brasileira* doi: 10.1590/S1678-3921.pab2019.v54.00273
- Arneson P. A. 2011. The American Phytopathological Society. Roya del Café (*Hemileia vastatrix*). En línea: <https://www.apsnet.org/edcenter/disandpath/fungalbasidio/pdlessons/Pages/-CoffeeRustspan.aspx>. Fecha de consulta: junio de 2023.
- Avelino, J., M. Cristancho, S. Georgiou, P. Imbach, L. Aguilar, G. Bornemann, P. Läderach, F. Anzueto, A.J. Hruska and C. Morales. 2015. The coffee rust crises in Colombia and Central America (2008-2013): impacts, plausible causes and proposed solutions. *Food Sec.* 7:303-321
- Benali, A.; A.C. Carvalho, J.P. Nunes, N. Carvalhais and A. Santos. 2012. Estimating air surface temperature in Portugal using MODIS LST data. *Remote Sens. Environ.* 124:108–121.
- Bolaños-González, M.A., A. Libert-Amico, F. Paz-Pellat, V. Salas-Agular, G. Villalobos-Sánchez, E. Escamilla-Prado, A.S. Velázquez-Rodríguez y E.I. Morales-Reyes. 2021. Resiliencia y estabilidad socioecológica de la cafecultura mexicana bajo sombra: hacia nuevos paradigmas. pp. 633-638. En: J.M. Hernández, M. Manzano, M. Bolaños y P. Ibarra (eds). *Estado Actual del Conocimiento del Ciclo del Carbono y sus Interacciones en México: Síntesis a 2021*. Texcoco, Estado de México, México.
- Fox, J. 2000. Some agrometeorological aspects of pest and disease management for the 21st

- Funk, C., P. Peterson, M. Landsfeld, D. Pedreros, Y. Verdin, S. Shukla, G. Husak, J. Rowland, A. Hoell and J. Michaelson. 2015. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci Data* 2:150066 doi:10.1038/sdata.2015.66
- Gallo, K.; R. Hale, D. Tarpley and Y. Yu. 2011 Evaluation of the relationship between air and land surface temperature under clear- and cloudy-sky conditions. *J. Appl. Meteorol. Climatol.* 50:767–775.
- Gorelick, N., M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau and R. Moore. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* 202:18-27
- Guajardo-Panes, R.A., G.R. Granados-Ramírez, I. Sánchez-Cohen, G. Díaz-Padilla y F. Barbosa-Moreno. (2017). Validación espacial de datos climatológicos y pruebas de homogeneidad: caso Veracruz, México. *Tecnología y Ciencias del Agua* 8:157-177.
- Hinnah, F.D., P.C. Sentelhas, C.A. Ales and R. Naves. 2018. Weather-based coffee leaf rust apparent infection rate modelling. *International Journal of Biometeorology* doi:10.1007/s00484-018-1587-2
- Hinnah, F.D., P.C. Sentelhas, C.A. Ales, R. Naves and M. Vilhena. 2020. Performance of a weather-based forecast system for chemical control of coffee leaf rust. *Crop Protection* doi:10.1016/j.cropro.2020.105225
- Huang, R.; C. Zhang, J. Huang, D. Zhu, L. Wang and J. Liu. 2015. Mapping of daily mean air temperature in agricultural regions using daytime and nighttime land surface temperatures derived from Terra and Aqua MODIS data. *Remote Sens.* 7:8728–8756.
- Huffman G. J., R. Huang, C. Zhang, J. Huang, D. Zhu, L. Wang and J. Liu. 2019. NASA Global Precipitation Measurement (GPM) Integrated Multi-satellite Retrievals for GPM (IMERG). Algorithm Theoretical Basis Document (ATBD) Version 06. National Aeronautics and Space Administration, 38 p.
- Hussain, M.S. 2020. pyHomogeneity 1.1. <https://pypi.org/project/pyhomogeneity/>. Consultado el 2022/09/01.
- Instituto Nacional de Ecología. 2013. <https://www.inecol.mx/inecol/index.php/es/2013-06-05-10-34-10/17-ciencia-hoy/1059-los-cafetales-bajo-sombra-brindan-mucho-mas-que-cafe>, consultado el 2022/09/10.
- Jin, M. and R.E. Dickinson. 2010. Land surface skin temperature climatology: Benefitting from the strengths of satellite observations. *Environ. Res. Lett.* 5: 044004 13 p.
- Karger, D.N., A.M. Wilson, C. Mahony, N.E. Zimmermann and W. Jetz. 2021. Global daily 1 km land surface precipitation based on cloud cover-informed downscaling. *Nature Scientific Data* doi:10.1038/s41597-021-01084-6
- Kubota, T., K. Aonashi, T. Ushio, S. Shige, Y.N., Takayabu, M. Kachi, Y. Arai, T. Tashima, T. Masaki, N. Kawamoto, T. Mega, M.K. Yamamoto, A. Hamada, M. Yamaji, G. Liu, and R. Oki. 2020. Global satellite mapping of precipitation (GSMaP) products in the GPM era. In *Advances in Global Change Research* (pp. 355-373). (Advances in Global Change Research; Vol. 67). Springer. doi:10.1007/978-3-030-24568-9\_20



- Kushalappa, A.C. 1989. Biology and epidemiology. pp. 13-90. In: A.C. Kushalappa and A.B. Eskes (eds.). *Coffe Rust: Epidemiology, Resistance, and Management*. Chapter 2. CRC Press. Boca Raton, Florida
- Kushalappa, A.C. and A.B. Eskes. 1989. Advances in coffee rust research. *Annu. Rev, Phytopathol.* 27:503-531
- Lai, Y.J.; C.F. Li, P.H., T.H. Wey and C.S. Chang. 2012. Comparison of MODIS land surface temperature and ground-based observed air temperature in complex topography. *Int. J. Remote Sens.* 33:7685–7702.
- Lasso, E., D.C. Corrales, J. Avelino, E.M. Virginio and J.C. Corrales. 2020. Discovering weather periods and crop properties favorable for coffee rust incidence from feature selection approaches. *Computers and Electronics in Agriculture* doi:10.1016/j.compag.2020.105640
- Libert-Amico, A. y F. Paz-Pellat. 2018. Del papel a la acción en la mitigación y adaptación al cambio climático: la roya del cafeto en Chiapas. *Madera y Bosques* doi:10.21829/myb.2018.2401914
- Liebig, T., F. Ribeyre, P. Läderach, H.M. Pehling, P. van Asten and J. avelino. 2019. Interactive effects of altitude, microclimate and shading system on coffee leaf rust. *Journal of Plant Interactions* 14:407-415
- Lin, X.; W. Zhang, Y. Huang, W. Sun, P. Han, L. and F. Sun, F. 2016. Empirical estimation of near-surface air temperature in China from MODIS TST data by considering physiographic features. *Remote Sens.* 8:629 doi:10.3390/rs8080629
- Liu, F. T.; K.M. Ting and Z. Zhou. 2008. Isolation Forest. 2008 Eighth IEEE International Conference on Data Mining pp. 413–422. doi:10.1109/ICDM.2008.17.
- Merle, I., J. Pico, E. Granados, A. Boudrot, P. Tixier, E.M. Virginio, C. Cilas and J. Avelino. 2020a. Unravelling the complexity of coffee leaf rust behavior and development in different *Coffea arabica* agroecosystems. *Phytopathology* 110:418-427
- Merle, I., P. Tixier, E.M. Virginio, C. Cilas and J. Avelino. 2020b. Forecast models of coffee leaf rust symptoms and signs based on identified microclimatic combination in coffee-based agroforestry systems in Costa Rica. *Crop Protection* doi:10.1016/j.cropro.2019.105046
- Merle, I., R. Villarena-Acuña, F. Ribeyre, O. Roupsard, C. Cilas and J. Avelino. 2022. Microclimate estimation under different coffee-based agroforestry systems using full-sun weather data and shade tree characteristics. *European Journal of Agronomy* doi:10.1016/j.eja.2021.126396
- Mildrexler, D. J., M. Zhao and S. Running, S. W. 2011, A global comparison between station air temperatures and MODIS land surface temperatures reveals the cooling role of forests, *J. Geophys. Res.* 116:G03025 doi:10.1029/2010JG001486.
- Monteith, J.L and M.H. Unsworth, 2013. *Principles of Environmental Physics*, 4th edition. Elsevier-Academic Press, New York.
- Noi, P.T., M. Kappas and J. Degener. 2016. Estimating daily maximum and minimum land Air surface temperature using MODIS land surface temperature data and ground truth data in Northern Vietnam. *Remote Sens.* 8:1002 doi:10.3390/rs8121002

- Okamoto K., T. Iguchi, N. Takahashi, K. Iwanami, and T. Ushio. 2005: The global satellite mapping of precipitation (GSMaP) project. Proc. of IGARSS 2005 pp. 3414-3416.
- Pedro, M.J. 1983, Effects of meteorological factors on the development of coffee leaf rust. EPPO Bull. 13:153-155
- Pinto, A.C.S., E.A. Pozza, P.e. de Souza, A.A.A. Pozza, V. talamini, J.M. Boldini and F.S. Santos. 2002. Descricao da epidemia da ferrugem do cefeeiro com redes neuronais. Fitopatol. Bras, 27:517-524
- Saha, S. y coautores. 2014. The NCEP Climate Forecast System Version 2 Journal of Climate J. Climate 27:2185–2208. doi:10.1175/JCLI-D-12-00823.1
- Shiff, S., D. Helman and I.M. Lensky. 2021. Worldwide continuous gap-filled MODIS land surface temperature dataset. Sci Data 8:74 doi:10.1038/s41597-021-00861-7
- SIAP. 2023. Servicio de Información Agroalimentaria y Pesquera, Sistema de Información Agroalimentaria de Consulta (SIACON). Fecha de consulta: junio de 2023.
- Thornton, M.M., R. Shrestha, Y. Wei, P.E. Thornton, S. Kao and B.E. Wilson. 2020. Daymet: daily surface weather data on a 1-km grid for North America, Version 4. ORNL DAAC, Oak Ridge, Tennessee, USA. doi:10.3334/ORNLDAAC/1840
- Thornton, P.E., R. Shrestha, M. Thornton, S.C. Kao, Y. Wei and B.E. Wilson. 2021. Gridded daily weather data for North America with comprehensive uncertainty quantification. Nature Scientific Data doi:10.1038/s41597-021-00973-0
- Toniutti, L., J.C. Breitler, H. Etienne, C. Campa, S. Doulbeau, L. Urban, C. Lambot, J.C. H. Pinilla and B. Bertrand. 2017. Influence of environmental conditions and genetic background of Arabica Coffee (*C. arabica* L.) on leaf rust (*Hemileia vastratix*) pathogenesis. Frontiers in Plant Science doi:10.3389/fpls.2017.02025
- Vancutsem, C., P. Ceccato, T. Dinku and S.J. Connor. 2010. Evaluation of MODIS land surface temperature data to estimate air temperature in different ecosystems over Africa. Remote Sens. Environ. 114:449–465.
- Zhu, W., A. Lü, S. Jia, J. Yan and R. Mahmood. 2017. Retrievals of all-weather daytime air temperature from MODIS products. Remote Sensing of Environment 189:152-163