

RED NEURONAL DE APRENDIZAJE PROFUNDO PARA PRONOSTICO DE LA ROYA DE LOS CAFETALES BAJO SOMBRA EN CHIAPAS Y VERACRUZ

DEEP LEARNING NEURAL NETWORK FOR FORECASTING RUST OF SHADED COFFEE PLANTATIONS IN CHIAPAS AND VERACRUZ

Fernando Paz¹ y Luis Alberto Palacios²

¹Programa Mexicano del Carbono y Colegio de Postgraduados, Texcoco, Estado de México, México
Autor para correspondencia: ferpazpel@gmail.com

² SConsultor en Recursos Hidráulicos, Hermosillo, Sonora

RESUMEN

La cafeticultura, especialmente bajo sombra, es una actividad importante para los ingresos de los productores. Los impactos de la roya del café han producido patrones de comportamiento que inciden en la deforestación y degradación forestal, implicando emisiones de gases de efecto invernadero. Se revisan los sistemas de monitoreo epidemiológico existentes, especialmente el de SENASICA y la generación de las bases de datos meteorológicas usando imágenes satelitales, como datos de entrada en un modelo de red neuronal de aprendizaje profundo. La red neuronal es presentada y discutida en relación al sobre ajuste con el uso de todos los datos, con esquemas para reducir esta situación. La red neuronal es aplicada a la base de datos de entrada, con variables meteorológicas con diferentes desfases en tiempo con relación al tiempo del pronóstico. Los resultados obtenidos, todos los datos, fueron buenos ($R^2 = 0.8$), por que el modelo puede utilizarse en forma confiable y precisa. Al final se discuten recomendaciones para obtener resultados mejores y más estables.

Palabras clave: *roya del café, cafetales bajo sombra, métodos de muestreo, meteorología satelital, aprendizaje profundo en redes neuronales, sobre ajuste*

ABSTRACT

Coffee growing, especially under shade, is an important activity for producers' income. The impacts of coffee rust have produced behavior patterns that affect deforestation and forest degradation, implying greenhouse gas emissions. Existing epidemiological monitoring systems are reviewed, especially that of SENASICA and the generation of meteorological databases using satellite images, as input data in a deep learning neural network model. The neural network is presented and discussed in relation to overfitting with the use of all data, with schemes to reduce this situation. The neural network is applied to the input database, with meteorological variables with different time lags in relation to the forecast time. The results obtained, all the data, were good ($R^2 = 0.8$), because the model can be used reliably and accurately. Finally, recommendations are discussed to obtain better and more stable results.

Key Words: *coffee rust, shaded coffee plantations, sampling methods, satellite meteorology, deep learning in neural networks, overfitting*

INTRODUCCIÓN

La producción de café es una actividad productiva de alta importancia para México. La cafecultura en México es una de las principales fuentes de ingreso de los productores, siendo el sur-sureste la región de la mayoría de la producción de café, tanto orgánico como convencional. Chiapas produce el 41 % del volumen nacional y Veracruz el 24 % (CEDRSSA, 2019), por lo que estos dos estados producen cerca de dos terceras partes de la producción nacional. El café bajo sombra arbórea es una práctica común en la región, junto con la producción de café orgánico (Escamilla *et al.*, 2005).

La epidemia de la roya (*Hemileia vastatrix*) es una enfermedad que ha afectado la salud de los cafetales, principalmente de café arábigo bajo sombra arbórea. La enfermedad se presentó por primera vez en México a principio de los 80s (Pliego *et al.*, 1983; Avelino *et al.*, 1989). En el año 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), tanto a nivel anual como bienal (Cerdeña *et al.*, 2017). La reducción de la producción de café en Chiapas, especialmente en la Sierra Madre de Chiapas fue alta (Libert-Amico *et al.*, 2016 y 2020), con impacto en los medios de vida de los productores. Como consecuencia de la epidemia de la roya se generaron cambios del uso del suelo de cafetales a milpas de maíz y potreros ganaderos (Libert-Amico y Paz-Pellat, 2018a) que produjeron deforestación, así como degradación forestal por la reducción de la sombra de los cafetales al introducir variedades de café (catimores) con resistencia a la roya, aunque son susceptibles a otras plagas y enfermedades (Libert-Amico *et al.*, 2016). La tendencia observada de deforestación y degradación forestal por el impacto de la epidemia de la roya ha sido

generalizada como producto de la intensificación y homogeneización de los paisajes productivos (Avelino *et al.*, 2015; Perfecto *et al.*, 2019; Harvey *et al.*, 2021), donde la resiliencia ecológica ha sido afectada (Libert-Amico, 2018a) e impactado la vulnerabilidad de los paisajes cafetaleros ante el cambio climático. Los cafetales bajo sombra arbórea tienen contenidos altos de carbono que asemejan a los bosques y selvas naturales (Soto-Pinto *et al.*, 2015; Salas-Aguilar *et al.*, 2018; Soto-Pinto y Jiménez-Ferrer, 2018, Paz *et al.*, 2022). La deforestación y degradación forestal asociada a la roya del cafeto, y precios bajos del café, ha provocado pérdidas de carbono (Libert-Amico y Paz-Pellat, 2018a; Soto-Pinto y Jiménez-Ferrer, 2018; Paz-Pellat, 2020 y 2022), emitiendo gases efecto invernadero hacia la atmosfera.

Para el pronóstico del avance de la roya en los cafetales se han utilizado variables meteorológicas (Kushalappa *et al.*, 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). 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).

Los muestreos de la infección de roya de los cafetos siguen los lineamientos definidos por la Dirección General de Sanidad del Servicio Nacional de Sanidad, Inocuidad y Calidad Agroalimentaria (DGS-SENASICA, 2013, 2014). La roya del cafeto hizo su aparición en la cafeticultura mexicana en 1981, en el área del Soconusco Chiapas en los límites con Guatemala. La enfermedad no ocasiono los daños ocurridos en otros países y con la implementación de prácticas culturales tales como la regulación de sombra, poda de cafeto y la aplicación de fungicidas de acción preventiva a base de cobre, se mantuvieron niveles de infección económicamente aceptables. Sin embargo, recientemente Centroamérica se reportó en el cultivo de café (*Coffea spp*) un brote de roya, la cual durante dos años (2010-2012) presentó incrementos en intensidad de daño. Lo anterior implicó daños en la producción hasta de un 30%, con defoliación severa de plantas. En Chiapas, en septiembre y octubre de 2012 se dieron condiciones anormales de humedad y temperatura favorables para que la roya del cafeto tuviera un comportamiento agresivo, dando como consecuencia un proceso de defoliación severo. Adicionalmente, el proceso de defoliación fue favorecido por la ocurrencia de corrientes de vientos fuertes y del movimiento de personal que realiza las labores de cosecha en los cafetales, dando como resultado la necesidad de integrar una campaña emergente para la atención de la roya del cafeto.

Con la finalidad de evitar pérdidas en la calidad y cantidad de producción de café en los ciclos posteriores, a partir de 2013 operó la campaña contra la roya del cafeto, como parte de un programa integral para el control de la enfermedad en los estados de Chiapas, Oaxaca, Puebla y Veracruz, donde se realizaron acciones de muestreo, capacitación a técnicos y productores, divulgación, control cultural

Como parte de la estrategia nacional contra la roya del cafeto, se contempló ejecutar acciones de vigilancia epidemiológica fitosanitaria para determinar la presencia o ausencia y en su caso la severidad de la roya del café en las principales zonas cafetaleras como elemento importante para determinar la curva epidemiológica que permita establecer sistemas de calendarios fijos para su manejo preventivo. En este sentido, se establecieron al menos en áreas de riesgo parcelas centinelas centrales y satelitales por municipio de acuerdo a la herramienta de muestreo estadístico, mismas que fueron distribuidas homogéneamente por toda la zona cafetalera según el estrato altitudinal en zonas de mayor inductividad y de preferencia ubicadas en las rutas de trampeo de la broca del café. Las parcelas que fueron evaluadas fueron seleccionadas en función de la presencia de variedades susceptibles, superficie sembrada con cafeto y disponibilidad de las plantaciones conforme a la tipología de fincas y productores (orgánica y/o convencional) y estrato altitudinal (mapas de riesgo). De forma estratégica se establecieron estaciones climáticas con la finalidad de registrar los datos climáticos que predisponen a una epidemia de roya, tales como la temperatura, precipitación, humedad relativa, precipitación y radiación solar.

Este trabajo tiene como objetivo el desarrollo de un 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

Los sistemas, y sus protocolos, de vigilancia epidemiológica en Centroamérica han sido revisados por Avelino *et al.* (2019), donde se consideran variables de monitoreo y diseño muestral. Preston (2007) revisa los procedimientos y técnicas de muestreo, donde las variables de muestreo son la incidencia (porcentaje de hojas por árbol/arbusto o proporción de árboles/arbustos infectados) y la severidad (porcentaje de tejido foliar o de la planta infectado).

La variable incidencia, o severidad, es generalmente modelada con fines predictivos. Los diferentes métodos de modelación utilizados por diferentes autores incluyen la regresión multivariada (Kushalapa, 1981; Kushalappa y Eskes, 1989; Brown *et al.*, 1995; Sudha *et al.*, 2020; Merle *et al.*, 2020b), el uso de redes neuronales (Pinto *et al.*, 2002; de Oliveira *et al.*, 2020), aplicación de redes Bayesianas (Pérez-Arisa, 2012), método de árboles de decisión (Meira *et al.*, 2008), así como minería de datos (técnicas de aprendizaje automático) (Girolamo *et al.*, 2014; Quiñonez *et al.*, 2022).

Recientemente se ha desarrollado un modelo de la infección de la roya siendo aplicado en Centroamérica (Merle *et al.*, 2022; PROGAGICA, 2020), después de su calibración. La incidencia y severidad de la roya depende de las relaciones entre la cantidad de la enfermedad y la cantidad de tejido vegetal, por lo que varía en función de la cantidad de tejido vegetal. Aunque el modelo de Merle *et al.* (2022) es dependiente del microclima, carga fructífera, inoculo presente y edad y tamaño de las lesiones, una versión dependiente de solo el microclima ha sido desarrollada

(PROGAGICA, 2020), la cual es la base de un modelo de infección y diseño del sistema de alerta temprana de la roya. En el modelo no se pronostica ni la incidencia ni la severidad de la enfermedad de la roya, si no sus cambios en: (a) de la ausencia de lesión hasta su aparición, (b) de la lesión sin esporas hasta su aparición y (c) de la lesión con esporas hasta el incremento del área esporulada. Merle *et al.* (2020b) indican que la aparición de síntomas o la severidad del daño en los cafetos por la roya, puede verse influida por combinaciones complejas de variables meteorológicas que actúan en diferentes momentos y por diferentes duraciones.

Muestreo de la infección de la roya del cafeto en Chiapas y Veracruz

La DGS-SENASICA (2013, 2014) definen los protocolos para la medición del avance de la roya del café, donde el muestreo se realiza en dos niveles, en parcelas centinelas y en cafetales considerados de alto riesgo al daño de roya del cafeto, a fin de detectar oportunamente focos de infestación, así como contar con elementos para que los técnicos tengan opciones de decisión para dar a conocer a los productores el método de control que fitosanitariamente más convenga de acuerdo a la condición de cada cafetal. Cuando se detecten focos de infección, se coordina la aplicación de productos a base cobre. Para el muestreo se establecieron al menos 10 parcelas centinelas distribuidas homogéneamente por toda la zona cafetalera según el estrato altitudinal en las zonas de mayor inductividad, por municipio cafetalero de mayor superficie, de preferencia ubicadas en las rutas de trampeo de la broca del café, lo que permite optimizar tiempos y recursos. Por cuestiones de operatividad el marco referencial de la parcela centinela es un área no mayor a 1.0 hectárea. La metodología de muestreo fue la siguiente: (1) Uso de parcelas centrales, donde se utiliza un muestreo sistemático en bloques de 40x40 plantas, para evaluación de

severidad en planta y defoliación al alternar evaluación, una planta si y una no (400 plantas total); para evaluación del número de hojas con roya, se evalúa una planta cada cuatro (200 plantas total), se selecciona una rama desarrollada por estrato. Adicionalmente, sobre el bloque de 40x40 plantas se encima un método "T", en el cual se evalúa severidad en hoja y variables fenológicas, se marcan ramas evaluadas con pintura aerosol para trazabilidad de evaluación. Se utilizan métodos de muestreo sistemático: A) Evaluación de severidad planta, defoliación y número de hojas con roya. B) Considera método "T" superpuesto a bloque 40x40 plantas para evaluación de severidad en hoja y variables fenológicas. (2) Parcelas satelitales: Utiliza método de muestreo "T", el cual consta de 40 plantas, en las cuales se evalúa severidad en planta y defoliación. Severidad en hoja, hojas con roya, hojas jóvenes y hojas viejas, y variables fenológicas alternar evaluación, una planta si y otra no (20 plantas total). La Figura 1 muestra la escala de severidad de planta usada en campo.




Figura 1. Escala de severidad de planta. Fuente: DGS-SENASICA (2013).

Las bases de datos de los muestreos tienen la fecha de la evaluación, la severidad promedio en planta y severidad promedio foliar, además de la defoliación (solo Veracruz). Los años analizados de muestreos corresponden de 2013 a 2016.

Base de datos de meteorología satelital

El desarrollo de una base de datos meteorológica usando información satelital ha sido documentada por Palacios y Paz (2023). Las principales variables utilizadas en la literatura 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.*, 2022) y otros periodos (Merle *et al.*, 2022).

En el Cuadro 1 se muestran las estadísticas de las variables meteorológicas usadas, además del día juliano de evaluación y la latitud y longitud de la localización del muestreo. Los periodos de tiempo utilizados son 16_30 (del día juliano 16 al 30 antes del día de predicción), 31_45 que corresponde al día juliano 31 al 45 antes del día de predicción y 1_45 correspondiente al día 1 al 45 antes del día de predicción. Las variables son tmin (temperatura mínima), tmax (temperatura máxima), trango (rango de temperatura tmax-tmin), humedad relativa mínima (HRmin), HR promedio ($HR_{prom} = \{HR_{max} + HR_{min}\} / 2$) y precipitación (Prec). La base de datos meteorológica es a nivel diario y consta del día juliano del 15 de febrero al día ultimo de mayo.

Red neuronal de aprendizaje profundo

El aprendizaje profundo se utiliza para modelar patrones complejos y problemas de predicción. En general, el reconocimiento de patrones se puede describir como un proceso de reducción de información, mapeo de información o etiquetado de información. En el caso de la regresión, los algoritmos de aprendizaje automático y profundo pueden llevar a cabo el auto aprendizaje de patrones ocultos

dentro de los datos para hacer predicciones; esto es, relacionan las variables independientes con las dependientes de una manera eficaz y eficiente.

Cuadro 1. Estadísticas de las variables de entrada.

Variable	No. datos	Media	Desv. Estándar	Min	25%	50%	75%	Max
sev_planta	4147	11.2271411	13.38067983	0.03	2.9497475	5.606741	13.494735	60
latitud	4147	17.5218169	1.704157857	14.95221	15.65013	17.29254	19.08456	19.95503
longitud	4147	94.5054374	2.191322737	-97.27257	-96.88095	-93.15461	-92.43368	-91.55217
dia_juliano	4147	96.1798891	29.68469049	45	70	97	119	148
tmin_16_30	4147	15.6541612	2.896785017	5.526667	13.64	15.78667	17.84667	22.30667
tmax_16_30	4147	28.0491729	2.978663903	14.98667	25.883335	28.06	30.30667	35.83333
trango_16_30	4147	12.3950116	2.310587068	3.493333	11.02667	12.37333	13.63333	19.91333
HRmin_16_30	4147	44.0850092	7.337308556	25.86667	39.53333	43.33333	48.13334	86.46667
HR_prom_16_30	4147	67.573089	7.115140136	41.16667	63.46667	68.33334	72.5	93.23333
Prec_16_30	4147	36.7031106	28.86682327	0	14	30.2	53.049995	181.9
tmin_31_45	4147	15.0765839	2.907026134	4.84	12.98667	15.13333	17.296665	21.94666
tmax_31_45	4147	27.3678611	3.119421537	14.88667	25.076665	27.21333	29.72333	35.75333
trango_31_45	4147	12.2912772	2.372091514	3.533334	10.83333	12.3	13.59	20.40667
HRmin_31_45	4147	44.1778153	7.467542945	25.86667	39.4	43.6	48.4	86.53333
HR_prom_31_45	4147	67.6056747	7.193344158	41.43333	63.46667	68.4	72.56667	93.26667
Prec_31_45	4147	33.3406076	29.14958226	0	11.8	25.2	49	294.6
tmin_1_45	4147	15.6754238	2.794240577	5.784445	13.72667	15.76	17.77667	22.10444
tmax_1_45	4147	28.0031223	2.893208285	15.88667	25.89222	27.99111	30.17778	35.08
trango_1_45	4147	12.3276988	2.242502113	3.780001	11.04222	12.29333	13.505555	19.84667

Una red neuronal para regresión entre variables climáticas y la enfermedad de la roya del café es una red que se utiliza para predecir la severidad de la enfermedad de la roya del café en función de variables meteorológicas. Las redes neuronales son un tipo de aprendizaje automático o profundo que se inspiran en el funcionamiento del cerebro humano. Están formadas por una serie de nodos interconectados, y cada nodo representa una función matemática. La red aprende a predecir la salida a partir de la entrada ajustando los pesos de los enlaces entre los nodos.

En el caso de la enfermedad de la roya del café, las variables climáticas que se utilizaron como entrada de la red neuronal incluyen la temperatura, la humedad relativa y la precipitación. Estas variables se agruparon en diferentes rangos de fechas previas a la evaluación del daño por la roya. La salida de la red neuronal es la escala de severidad de la roya en la planta de café, expresada en porcentaje de hojas afectadas por planta.

Una red neuronal artificial (RNA) es un modelo computacional inspirado en el funcionamiento del cerebro humano que se utiliza para realizar tareas de procesamiento de información y aprendizaje automático. Consiste en un conjunto interconectado de unidades básicas llamadas neuronas artificiales o nodos, organizadas en capas. Estas capas son:

1. Capa de entrada: Esta capa recibe los datos de entrada, que en el presente caso corresponde a las variables climáticas explicadas previamente.
2. Capas ocultas: Estas capas se encuentran entre la capa de entrada y la capa de salida. Cada neurona en una capa oculta procesa la información recibida de las neuronas de la capa anterior, aplicando pesos y funciones de activación para producir una salida. Cuantas más capas ocultas tenga una red, más profunda se considera, y se dice que tiene una arquitectura de "redes neuronales profundas".
3. Capa de salida: La capa de salida produce los resultados finales de la red neuronal, en este caso la escala de severidad de la roya en las plantas (porcentaje).

Cada conexión entre neuronas en diferentes capas está asociada con un peso, que determina la influencia de la neurona de entrada en la neurona de salida. El

proceso de entrenamiento de una red neuronal implica ajustar estos pesos de manera que la red pueda realizar correctamente la tarea objetivo (Figura 2).

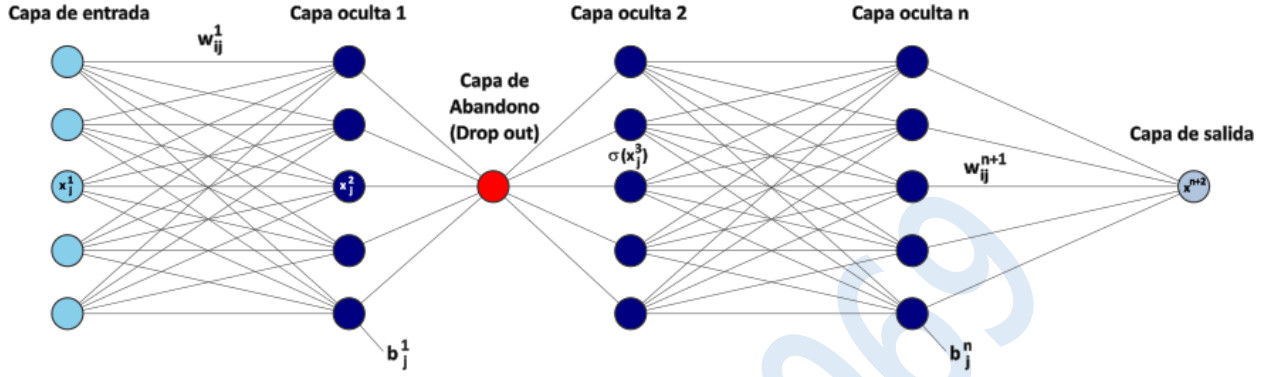


Figura 2. Red neuronal artificial

Dada una red neuronal profunda prealimentada con **NC** capas, w_{ij}^k representa el peso del enlace que conecta la neurona i en la capa $k-1$ con la neurona j en la capa k , b_i^k representa el sesgo (bias) de la neurona i en la capa k y x_i^k representa la salida i de la neurona en la capa k . Con esta notación, se obtiene la ecuación que relaciona la activación de una neurona en la capa k con las activaciones de las neuronas en la capa $k-1$:

$$x_i^k = \sigma\left(\sum_j^{NC} w_{ij}^k x_j^{k-1} + b_i^k\right) \quad (1)$$

donde σ representa la función de activación o transformación neuronal, esta función introduce la no linealidad en la red y permite que la red pueda aprender relaciones y patrones más complejos en los datos.

Cuando una red neuronal prealimentada grande, se entrena en un conjunto de entrenamiento pequeño, generalmente se desempeña mal en los datos de prueba debido al sobre ajuste. Para evitar esa situación, existen diferentes estrategias, entre

las que se encuentran las capas de abandono (Dropout; Srivastava *et al.*, 2014)). Este sobre ajuste se reduce en gran medida al omitir aleatoriamente un porcentaje de las neuronas en cada paso de entrenamiento. Esto evita adaptaciones conjuntas complejas en las que una neurona solo es útil en el contexto de varias otras neuronas específicas. En cambio, cada neurona aprende a detectar una característica que generalmente es útil para producir la respuesta correcta dada la gran variedad combinatoria de contextos internos en los que debe operar. La base de datos utilizada como entrada del modelo fue descrita previamente.

Para la instrumentación de la red neuronal se utilizó TensorFlow de Google, el cual es un marco de desarrollo que facilita la creación de modelos de aprendizaje automático para computadoras de escritorio, dispositivos móviles, la web y la nube. Keras se utiliza como la API de alto nivel de TensorFlow para construir y entrenar modelos de aprendizaje profundo. Se utiliza para la creación rápida de prototipos, la investigación de vanguardia y en producción (Abadi *et al.*, 2016). Se corrió en un cuaderno Jupyter de Python en la plataforma Google Colaboratory, la cual permite ejecutar redes muy complejas en la nube, aprovechando la infraestructura computacional de Google.

La arquitectura de la red neuronal consiste en:

- Capa de entrada con 21 neuronas (variables de entrada).
- Capa de abandono (0.1)
- 3 capas ocultas:

- Primera capa con 96 neuronas, función de activación unidad lineal de error gaussiano (GELU, por sus siglas en inglés; Hendryks y Gimpel, 2016).
- Capa de abandono (0.1)
- Segunda capa con 64 neuronas, función de activación tangente hiperbólica (Tanh)
- Capa de abandono (0.1)
- Tercera capa con 32 neuronas, función de activación GELU
- Capa de abandono (0.1)
- Capa de salida: Con una única neurona, función de activación unidad lineal rectificada (RELU, por sus siglas en inglés), que proporciona la predicción de la severidad de la roya.

Los pesos se inicializaron aleatoriamente con una distribución normal truncada con media cero y desviación estándar de uno, los sesgos se inicializaron en ceros. Para disminuir la probabilidad de sobre ajuste, los pesos de todas las capas se regularizaron con la penalización de la norma L2 (0.001). Se estableció que el modelo corriera durante 5,000 épocas (iteraciones) para el entrenamiento, pero se le agregó una función de parada temprana que conservara los mejores parámetros de entrenamiento, cuando el valor de la función de pérdida en los datos de validación no disminuyera en 250 épocas consecutivas. Esta parada temprana evita que el modelo memorice los datos de entrada y por consiguiente exista sobre ajuste y el valor de 250 permite que el modelo no se estanque en un óptimo local.

La función de pérdida utilizada fue el error cuadrático medio (ECM), con seguimiento en métricas del error absoluto medio (EAM) y la raíz cuadrada del error

cuadrático medio (RECM, o error estándar). Para la minimización de la función de pérdida se utilizó el algoritmo Adam, el cual es un algoritmo para la optimización con base en gradientes de primer orden de funciones objetivo estocásticas, con base en estimaciones adaptativas de momentos de orden inferior (Kingma y Ba, 2014). Se utilizó una función de reducción de la tasa de aprendizaje del modelo Adam inversa al tiempo, iniciando con un valor de 0.001, de esta manera se mejora la convergencia de la red (Figura 3).

Los datos se dividieron en conjuntos de 70%-15%-15% para el entrenamiento, validación y prueba de la red. Una vez que se ha ajustado el modelo con en el conjunto de validación, se evalúa su rendimiento con el conjunto de prueba. El modelo se entrenó durante 2,669 épocas de las 5,000 establecidas debido a la función de parada temprana.

Las estadísticas de la aplicación de la red neuronal fueron: 4,147 datos totales, 2,903 para entrenamiento, 622 para validación y 622 para prueba, por lo que cada iteración (época) selecciona aleatoriamente 622 conjuntos de datos para validación y 2,903 para entrenamiento. De estos últimos se seleccionan 64 conjuntos de datos, por lo que en cada época la red se entrena 45 veces y se evalúa la validación una vez. Finalizado el entrenamiento se evalúa el modelo con los 622 datos de prueba.

Análisis de resultados

La Figura 4 muestra el historial del entrenamiento de la red con la función de pérdida, mientras que las figuras 5 y 6 muestran las métricas de EAM y el error estándar. La figura 7 muestra el ajuste de la red neuronal con los datos de prueba, mientras que la figura 8 muestra el ajuste con todos los datos.




Figura 3. Reducción de la tasa de aprendizaje del optimizador Adam.




Figura 4. Función de pérdida: Error Cuadrático Medio




Figura 5. Error Absoluto Medio.




Figura 6. Error Estándar.




Figura 7. Ajuste de la red neuronal con los datos de prueba.




Figura 8. Ajuste de la red neuronal con todos los datos.

La evaluación con los datos de prueba resultó con un coeficiente de determinación $R^2 = 0.62$, un error medio absoluto de 4.9 y un error estándar de 7.9. Cuando se utilizan todos los datos para la evaluación, se obtiene un coeficiente de determinación $R^2 = 0.8$, un error medio absoluto de 3.7 y un error estándar de 6.0. Estos valores se deben a la cantidad limitada de datos para el entrenamiento, validación y prueba de la red.

Las gráficas del historial de entrenamiento muestran un buen ajuste para la cantidad limitada de datos y un modelo de aprendizaje profundo. El sobreajuste se minimizó utilizando la regularización de los pesos, capas de abandono y una función de parada temprana, mientras que la convergencia se mejoró al utilizar un programa de reducción de la tasa de aprendizaje en el algoritmo de optimización Adam.

CONCLUSIONES Y RECOMENDACIONES

Los resultados obtenidos al aplicar una red neuronal con aprendizaje profundo generaron resultados satisfactorios (R^2 de 0.8), por lo que puede usarse en forma confiable y precisa.

Es importante tener en cuenta que los modelos de regresión necesitan ser actualizados periódicamente a medida que se recopilan nuevos datos. Esto garantiza que el modelo se mantenga relevante y preciso a lo largo del tiempo.

Es recomendable incluir otro tipo de variables de entrada, tal como las condiciones de manejo de los cafetales y el nivel de tecnificación. También es importante aumentar el número de valores de muestreo para incrementar el conjunto de datos de entrada, con esto se tendría un modelo más robusto y menos propenso al sobreajuste.

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

- Abadi, M. A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. J. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Józefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mane, R. Monga, S. Moore, D. G. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. A. Tucker, V. Vanhoucke, V. Vasudevan, F. B. Viegas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu and X. Zheng. 2016. TensorFlow: Large-scale machine learning on heterogeneous distributed systems. ArXiv preprint: arxiv.org/abs/1603.04467.
- Alfonsi, W.M.V., P. Pereira, J. Zullo, F. Alves and E. Alfonsi. 2019a. Período de incubação 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 Agropecuária Brasileira* doi: 10.1590/S1678-3921.pab2019.v54.00273
- 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
- Avelino, J., R.A. Muller y H. Velasco. 1989. Desarrollo y comportamiento de la roya anaranjada del café en cafetales de porte bajo en vías de tecnificación en la costa de Chiapas (México). pp. 55-81. XII Simposio de Caficultura Latinoamericana. IICA-PROMECAFE. San Pedro Sula, Honduras
- Avelino, J., E. Treminio, F. Casanoves, S. Vilchez, J. Cárdenas y C. Lizardo. 2019. Guía para la Vigilancia de la Roya del Café (*Hemileia vastatrix*). Programa Centroamericano de Gestión Integral de la Roya del Café. IICA. CIRAD-CATIE. Costa Rica
- 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.
- Brown, J.S., M.K. Kenny, J.H. Whan and P.R. Merriman. 1995. The effect of temperature on the development of epidemic of coffee leaf rust in Papua New Guinea. *Crop Protection* 14:671-676
- CEDRSSA. 2019. Propuestas para reactivar la producción y comercialización de café en México 2019-2024. Centro de Estudios para el Desarrollo Rural Sustentable y la Soberanía Alimentaria, Cámara de Diputados - LXIV Legislatura 19 p.

- Cerda, R., J. Avelino, C. Gary, P. Tixier, E. Lechevallier and C. Allinne. 2017. Primary and secondary yield losses caused by pests and diseases: assessment and modeling on coffee. Plos One doi:10.371/journal.pone.0169133
- de Oliveira, L.E., G. de Souza, J.R. da Silva, C.T. Silva and P.S. de Souza. 2020. Machine learning algorithms for forecasting the incidence of *Coffea arabica* pests and diseases. International Journal of Biometeorology doi:10.1007/s00484-019-01856-1
- DGSV-SENASICA. 2013. Manual Técnico para el Manejo Preventivo de la Roya del Cafeto. Dirección General de Sanidad Vegetal. SENASICA. México 30 p.
- DGSV-SENASICA. 2014. Estrategias Operativos para la Vigilancia Epidemiológica Fitosanitaria de la Roya del Cafetos, Plagas de Importancia Económica y Plagas Cuarentenarias, a través del Establecimiento de Parcelas Fijas, Móviles y Áreas de Exploración Transectual. Manual Técnico para el Manejo Preventivo de la Roya del Cafeto. Dirección General de Sanidad Vegetal. SENASICA. México 32 p.
- Escamilla, E., O. Ruiz, G. Díaz, C. Landeros, D.E. Platas, A. Zamarripa y V.A. González. 2005. El agroecosistema café orgánico en México. Manejo Integrado de Plagas y Agroecología (Costa Rica) 76:5-16
- Fox, J. 2000. Some agrometeorological aspects of pest and disease management for the 21st century. Agricultural and Forest Meteorology 103:73-82
- Girolamo, C.D., L.H. Antunes and C.A. Alves. 2014. Modelos de predicao da ferrugem de cafeeiro (*Hemileia vastratix* Berkeley & Broome) por técnicas de mineracao de dados, Coffee Science, Lavras 9:408-418
- Harvey, C.A., A.A. Pritts, M.J. Zwetsloot, K. Jansen, M.M. Pulleman, I. Armbrecht, J. Avelino, J.F. Barrera, C. Bunn, J. Hoyos García, C. Isaza, J. Munoz-Ucros, C.J. Pérez-Aleman, E. Rahn, V. Robiglio, E. Somarriba and V. Valencia. 2021. Transformation of coffee-growing landscapes across Latin America. A Review. Agronomy for Sustainable Development doi:10.1007/s13593-021-00712-0
- Hendrycks, D. and K. Gimpel. 2016. Gaussian Error Linear Units (GELUS). <https://arxiv.org/abs/1606.08415v5>
- 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
- 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
- Kingma, D. P. and J. Ba. 2014. Adam: a method for stochastic optimization. ArXiv preprint: <https://arxiv.org/abs/1412.6980>
- Kushalappa, A.C. 1981. Linear models applied to variation in the rate of coffee rust development. Phytopath. Z. 101:22-30
- 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

- 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., C. Ituarte-Lima and T. Elmqvist. 2020. Learning from social-ecological crisis for legal resilience building: multi-scale dynamics in the coffee rust epidemic. *Sustainability Science* 15:485-501
- 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
- Libert-Amico, A., J.C. Wong-González y F. Paz-Pellat. 2016. Impacto de la roya del cafeto en los almacenes de carbono en la Sierra Madre de Chiapas. pp. 219-225. En: F. Paz y R. Torres (eds.). *Estado Actual del Conocimiento del Ciclo del Carbono y sus Interacciones en México: Síntesis a 2016*. Texcoco, Estado de México, México.
- 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
- Meira, C.A.A., L.H.A. Rodrigues and S.A. Moraes. 2008. Analise da epidemia da ferrugem do cefeiro com arvore de decisao. *Tropical Plant Pathology* 33:114-124
- 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. Rounsard, 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
- Palacios, L.A. y F. Paz. 2023. Desarrollo de una base de datos meteorológica usando información satelital. *Elementos para Políticas Públicas*. Enviado para su publicación.
- Paz-Pellat, F. 2020. Costo de las políticas públicas asociadas al manejo de la roya en los cafetales bajo sombra de la Sierra Madre de Chiapas pp. 81-86. En: J.M. Hernández, M. Rojo, M. Fuentes, A. Velázquez y M. Bolaños (eds.). *Estado Actual del Conocimiento del Ciclo del Carbono y sus Interacciones en México: Síntesis a 2020*. Texcoco, Estado de México, México.
- Pedro, M.J. 1983. Effects of meteorological factors on the development of coffee leaf rust. *EPPO Bull.* 13:153-155
- Pérez-Ariza, C.B., A.E. Nicholson and M.J. Flores. 2012. Prediction of coffee rust disease using Bayesian networks. pp. 259-266. In: *Sixth European Workshop on Probabilistic Graphical Models*. Granada, Spain
- Perfecto, I., M.E. Jiménez-Soto and J. Vandermeer. 2019. Coffee landscapes shaping the anthropocene, forced simplification on a complex agroecological landscape. *Current Anthropology* doi: 10.1086/7703413

- 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. Descricão da epidemia da ferrugem do cefeeiro com redes neuronais. *Fitopatol. Bras*, 27:517-524
- Pliego, J.I., P. Ponce y V.M. Sernas. 1983. Epidemiología de la roya del cafeto en el Soconusco, Chiapas, México. pp. 164-174. Memoria del Sexto Simposio Latinoamericano sobre Caficultura. IICA-PROMECAFE. Panamá
- Preston, R. 2007. Measuring plant diseases. pp. 11-27. In: L.V. Maddden, G. Jones and F. van den Bosch (eds.). *The Study of Plant Disease Epidemics*. The American Phytopathological Society
- PROCAGICA. 2020. Guía para el Uso de Modelos Estadísticos de Pronóstico de la Infección, esporulación e Intensificación de la Esporulación. Programa Centroamericano de Gstión Integral de la Roya del Café. Disponible en: <https://www.redpergamino.net/documentos-cientificos>
- Quiñones, L., C.L. Ocaña, A.E. Huaccha, R.E. Acosta, M.E. Milla, M. Rios, R. Yauri, E. Mendoza and A. Pérez. 2022. Detection of rust emergence in coffee plantations using data mining: a systematic review. *Online Journal of Biological Sciences* 22:157-164
- Salas-Aguilar, V.M., F. Paz-Pellat, F. Rojas-García y M. Bolaños. 2018. Almacenes de carbono en sistemas agroforestales cafetaleros de la Sierra Madre de Chiapas. pp. 671-677. En: F. Paz, A. Velázquez y M. Rojo (eds.). *Estado Actual del Conocimiento del Ciclo del Carbono y sus Interacciones en México: Síntesis a 2018*. Texcoco, Estado de México, México.
- Soto-Pinto, L., C.M. Aguirre-Dávila y M.J. Anzueto-Martínez. 2015. Almacenes de carbono en cafetales con distintos manejos en el Norte de Chiapas, México. pp. 256-263. En: F. Paz Pellat, J. Wong González y R. Torres Alamilla (eds.). *Estado Actual del Conocimiento del Ciclo del Carbono y sus Interacciones en México: Síntesis a 2015*. Texcoco, Estado de México, México.
- Soto-Pinto, L. y G. Jiménez-Ferrer. 2018. Contradicciones socioambientales en los procesos de mitigación asociados al ciclo del carbono en sistemas agroforestales. *Madera y Bosques* doi:10.21829/myb.2018.2401887
- Srivastava, N., G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov. 2014. Dropout; a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research* 15: 1929-1958
- Sudha, M., S. Machenahalli, M.S. Giri, A.P. Ranjini and S. Daivasikamani. 2020. Influence of abiotic factor on coffee leaf rust disease caused by the fungus *Hemileia vastatrix* Berk. & Br. under changing climate. *Journal of Agrometeorology* 22:367-371
- 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. Doulebeau, 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 vastatrix*) pathogenesis. *Frontiers in Plant Science* doi:10.3389/fpls.2017.02025
- 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