

EVALUACIÓN DE LA CALIDAD FÍSICA DEL CAFÉ ORGÁNICO BAJO SOMBRA EN CHIAPAS. MÉXICO

EVALUATION OF THE PHYSICAL QUALITY OF ORGANIC COFFEE UNDER SHADE IN CHIAPAS. MÉXICO



Fernando Paz¹, Luis Alberto Palacios², Esteban Escamilla³ y A.S. Velázquez⁴

¹Programa Mexicano del Carbono y Colegio de Postgraduados, Estado de México, México

Autor para correspondencia: ferpazpel@gmail.com

²Consultor en Recursos Hidráulicos, Hermosillo, Sonora

³Universidad Autónoma de Chapingo, Chapingo, Estado de México,

⁴Facultad de Ciencias, Universidad Autónoma del Estado de México, Campus El Cerrillo, Toluca, Estado de México.

RESUMEN

La producción de café es de suma importancia en el sureste de México, principalmente en el estado de Chiapas. El café orgánico, bajo sombra, se ha consolidado como una estrategia de mercadeo orientada a los cafés diferenciados y de especialidad. El control de calidad del producto es un requisito para tener acceso a los mercados de calidad, particularmente con relación a los atributos físicos y sensoriales de los granos de café. Los principales atributos físicos evaluados en los estudios de calidad del café son el rendimiento de café pergamino a café oro, la producción de frutos sanos y de planchuela sana, así como el tamaño de los granos. Usando la base de datos de la UACH-INCAFECH-CONACYT de 2018 se implementaron redes neuronales de aprendizaje profundo para evaluar la calidad física de la producción de café. Las evaluaciones resultaron adecuadas ($R^2 > 0.75$) a través de variables químicas asociadas a micro y macronutrientes, sin los efectos de sobre ajustes indeseados, permitiendo su uso en forma robusta y confiable en las aplicaciones.

Palabras clave: *café orgánico bajo sombra, micro y macronutrientes suelo, calidad física del café, red neuronal de aprendizaje profundo, datos limitados*

ABSTRACT

Coffee production is of paramount importance in southeastern Mexico, mainly in the state of Chiapas. Organic, under-shade, coffee has become consolidated as a marketing strategy developed towards differentiated and specialty coffees. Product quality control is a requirement to have access to quality markets, particularly in relation to the physical and sensory attributes of coffee beans. The main physical attributes evaluated in coffee quality studies are coffee parchment to coffee gold yield, healthy fruit and healthy planchuela production, as well as bean size. Using the UACH-INCAFECH-CONACYT database of 2018 deep learning neural networks were implemented to assess the physical quality of coffee production. The assessments turned out to be adequate ($R^2 > 0.75$) across chemical variables associated with micro and macronutrients, without the effects of undesired over fitting, allowing their use in a robust and reliable manner in applications.

Key Words: *organic coffee under shade, soil micro and macronutrients, coffee physical quality, deep learning neural network, limited data*

INTRODUCCIÓN

La producción de café es una actividad de suma importancia en el sureste de México, especialmente en el estado de Chiapas, donde incide fuertemente en los medios de vida de los productores. La caficultura, en los últimos años, ha estado orientada hacia la producción orgánica (Escamilla et al., 2005) y mercados diferenciados y de especialidad (Escamilla y Landeros, 2016), que son productos de café de alta calidad y con certificaciones. El café orgánico generalmente es de plantaciones bajo sombra arbórea (Escamilla *et al.*, 2005 y 2012; Rosas *et al.*, 2008; López-García et al., 2016), lo cual genera importantes servicios ecosistémicos (Libert *et al.*, 2020) con impacto en las reservas de carbono (Libert-Amico y Paz-Pellat, 2018).

El café orgánico, y de especialidad, requiere de controles de calidad para su certificación (Sosa *et al.*, 2004; Escamilla *et al.*, 2005; Escamilla y Landeros, 2016), por lo que es crítico la evaluación de la calidad del café producido. Los factores que determinan la calidad del café son los ambientales y agronómicos (Santoyo *et al.*, 1996; Wintgens, 2004), reflejándose en una mejor nutrición y disponibilidad de agua. La calidad del café se caracteriza por atributos físicos y sensoriales. Los factores genéticos y ambientales se reflejan en el tamaño y forma de los granos de café. En los mercados internacionales, atributos como la altitud (Bertrand *et al.*, 2006) de los cafetales y la presencia de sombra arbórea (DaMatta, 2007) son usados como criterios de calidad, y cantidad, del café. La variedad de café tiene un papel importante en la calidad, y cantidad, de frutos en la cosecha del café (Hein y Gatzweiler, 2005; Kathurima *et al.*, 2009). Los factores genéticos y ambientales se reflejan en el tamaño y forma de los granos de café y propiedades organolépticas (Santoyo *et al.*, 1996; Cheng *et al.*, 2016).

La química de los suelos, tal como los macronutrientes (C, H, N, P, K, Ca, Mg y S) y micronutrientes (Fe, Zn, Mn, B, Cu, Mo) ha sido analizada para caracterizar la calidad del café (Rosas, 2006; Escamilla, 2012), lo cual es de reciente implementación en México (Pérez *et al.*, 2005; Pérez-Portilla *et al.*, 2011). El análisis de las variedades de café y su efecto en su calidad ha sido considerado en varios estudios (Escamilla *et al.*, 2015; López-García *et al.*, 2016 y 2021).

Entre los principales atributos físicos evaluados en los estudios de calidad es el rendimiento del café pergamino a oro, cantidad de kilogramos de café pergamino necesarios para obtener un quintal de café oro; la producción de frutos vanos (flotan agua); la planchuela sana, la planchuela es un grano típico de forma plano convexa similar a la mitad de un elipsoide; y el tamaño de los granos, principalmente para preparación europea.

La producción de cafés de especialidad orientada a nichos de mercado ha sido propuesta como una estrategia para la sustentabilidad de los sistemas socioecológicos del café (Morales y Bolaños, 2022). Este trabajo tiene como objetivo el desarrollo de un sistema de caracterización y pronóstico de la calidad física del café a través del uso de una base de datos de propiedades del suelo y del café (UACH-INCAFECH-CONACYT, 2018) en función de la química de los suelos 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

La base de datos analizada corresponde a UACH-INCAFECH-CONACYT (2018) y no ha sido estudiada previamente.

La Figura 1 muestra la distribución de los sitios de muestreo de cafetales orgánicos bajo sombra en las 13 regiones de Chiapas, México.

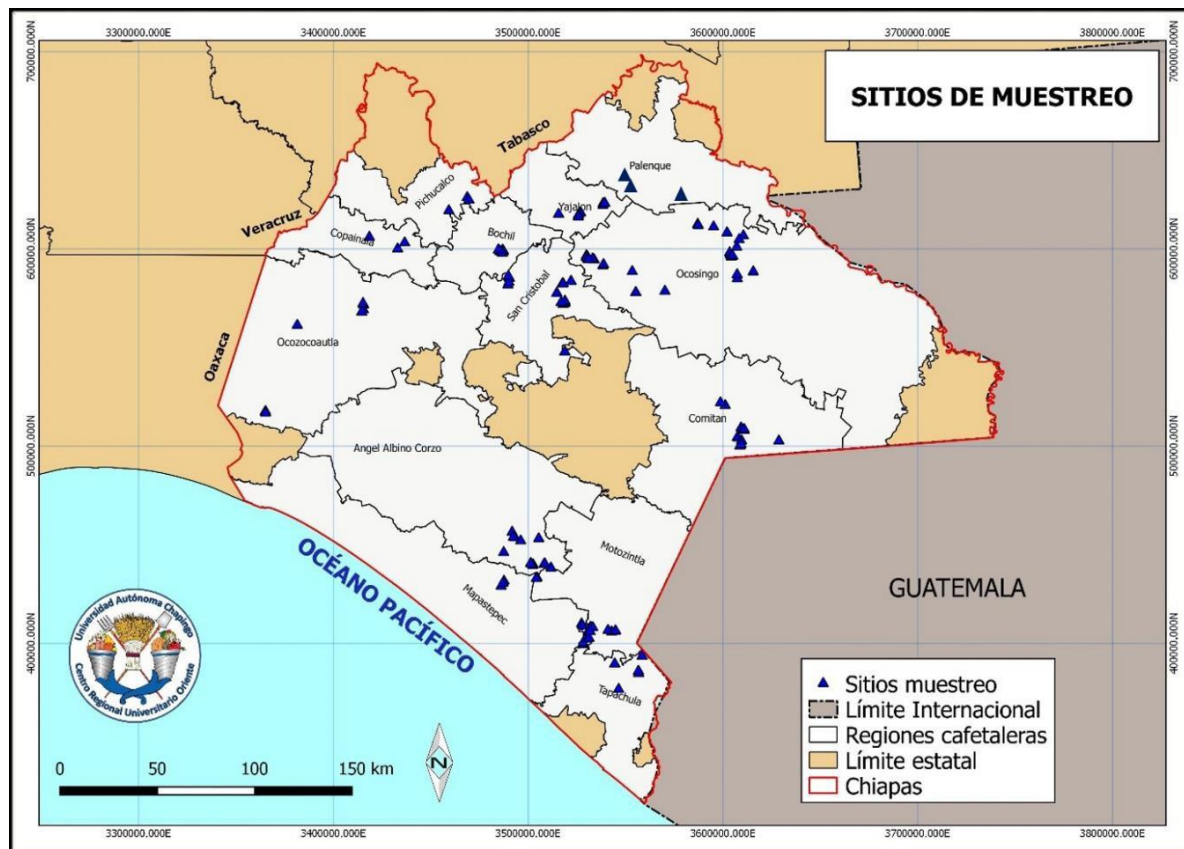


Figura 1. Distribución geográfica de los sitios de muestreo en Chiapas

Recolección de muestras

Para el muestreo de los suelos de los cafetales, se utilizaron parcelas de muestreo de 25 m x 25 m, donde alrededor de cada vértice del cuadrado se colectaron muestras con una pala recta a una profundidad de muestreo de 30 cm. Adicional a las cuatro muestras de los vértices se tomó una muestra en el centro de la parcela. Las 5 muestras fueron utilizadas para obtener una muestra compuesta al homogeneizarlas usando “cuarteos diagonales” hasta obtener una muestra de 1.0 kg. La muestra se colocó en una bolsa de polietileno, se etiquetó y se trasladó a las instalaciones de la

UACH (CRUO/CENACAFE) en Huatusco, Veracruz en donde se procedió a su secado en temperatura ambiente y bajo sombra. Secada la muestra se dividió en dos partes de medio kg, almacenándose para su análisis físico y químico. El numero de muestras fue de 141 para las determinaciones en laboratorio.

Para las muestras de café, se procedió la cosecha en el periodo de diciembre a febrero del ciclo cafetalero 2016-2017. Considerando que la época de maduración de los frutos del café se prolonga por varios meses y la cosecha se realiza en varios cortes, todas las muestras de café cereza se hicieron durante el corte principal (el de mayor volumen). En cada parcela se cosecharon alrededor de 12 kg de fruto en estado optimo de maduración, de la variedad predominante en los sitios seleccionados en los cafetales de los productores. La cosecha se realizo en forma manual, con especial atención de que las cerezas estuvieran en un grado optimo de maduración y se evitara cosechar granos verdes, inmaduros o “pintones”, secos o agrios.

Del total de café cosechado se pesaron 10 kg de frutos maduros, después de un proceso de selección en el que se eliminaron los frutos que no tuvieron maduración uniforme y algunas impurezas (hojas, pedúnculos, etc.) y se procedió a homogeneizar la muestra. De la muestra del total de café cereza se obtuvieron tres submuestras, cada uno de 100 g, en las que se determinó las variables: peso promedio de fruto (g), porcentaje de frutos dañados por la broca del café, porcentaje de frutos vanos o vacíos (flotan en el agua) y eficiencia o rendimiento del proceso de beneficiado de café cereza a pergamino (kg). Se recopiló la información de los registros y se procedió a reintegrar las submuestras a la muestra original para proceder al beneficiado. Los datos de los atributos físicos se determinaron en el Laboratorio de Calidad de Café de la UACH-CRUO de Huatusco, Veracruz en los meses de febrero a junio de 2017, evaluándose semanalmente cinco muestras. Los datos físicos determinados fueron: rendimiento industrial del proceso de beneficiado

de café pergamino a oro (kg), color del café oro, porcentaje de granos normales (tipo planchuela), porcentaje de los granos anormales (caracol, triangulo, conchas, elefantes) y tamaño de los granos, medido en zarandas o malla con orificios, para determinar el tamaño grande (preparación europea).

Recomendaciones para la fertilidad de los suelos

Existen numerosas guías o recomendaciones para la fertilidad de los suelos en cafetales (Carbajal, 1984; Sadeghian, 2008; Bedoya y Salazar, 2014) lo que resulta difícil de aplicar dadas las diferencias en las recomendaciones. Por ejemplo, en el Cuadro 1 se muestran las recomendaciones de dosis óptimas para la fertilidad del suelo, realizadas por diferentes instituciones, donde se aprecian algunas diferencias con relación a las dosis.

Cuadro 1. Rangos de fertilidad del suelo recomendados. Adaptado de Rosas (2006)

Variable	Rango	Institución
Textura	Franca	INMECAFÉ-NESTLÉ, México
	Media	ICAFÉ-MAG, Costa Rica
	Franca a migajón arcilloso	CENICAFÉ, Colombia
pH	4.5-5.5	INMECAFÉ-NESTLÉ, México
	4.9-5.6	CENICAFÉ, Colombia
	5.5-6.5	ICAFÉ-MAG, Costa Rica
Materia orgánica (g/kg)	70.0-100.0	INMECAFÉ-NESTLÉ, México
	11.4-12.6	CENICAFÉ, Colombia
Nitrógeno total (g/kg))	5.0-8.0	INMECAFÉ-NESTLÉ, México
Potasio (mg/kg)	195.5-273.7	INMECAFÉ-NESTLÉ, México
	117.3-160.3	CENICAFÉ, Colombia
	78.2-586.5	ICAFÉ-MAG, Costa Rica
Fósforo (mg/kg)	15.0-20.0	INMECAFÉ-NESTLÉ, México
	6.0-14.0	CENICAFÉ, Colombia
	10.0-40.0	ICAFÉ-MAG, Costa Rica
Calcio (mg/kg)	801.6-1202.4	INMECAFÉ-NESTLÉ, México
	320.6-841.6	CENICAFÉ, Colombia
	801.6-4008.0	ICAFÉ-MAG, Costa Rica
Magnesio (mg/kg)	> 243.0	INMECAFÉ-NESTLÉ, México
	60.75-170.1	CENICAFÉ, Colombia

	121.5-1215.0	ICAFÉ-MAG, Costa Rica
Hierro (mg/kg)	10.0-50.0	ICAFÉ-MAG, Costa Rica
Cobre (mg/kg)	1.0-20.0	ICAFÉ-MAG, Costa Rica
Manganeso (mg/kg)	5.0-10.0	ICAFÉ-MAG, Costa Rica
Zinc (mg/kg)	3.0-15.0	ICAFÉ-MAG, Costa Rica

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.

En el Cuadro 2 se muestran las estadísticas para las variables fisicoquímicas y el rendimiento de café pergamino a oro.

Cuadro 2. Estadísticas de las variables de entrada y rendimiento

Variable	Número	Media	Desv. Est.	Min	25%	50%	75%	Max
Rendimiento	414	55.7202415	1.64455487	51.15	54.9	55.62	56.2	68.5
Arena	414	49.8635749	14.9995456	12.16	40.44	49.48	62.43	79.16
Limo	414	18.9431884	7.53345632	7.6	13.64	17.62	23.6	63.6
Arcilla	414	31.2400483	13.3996245	6.88	21.6	30.88	39.96	67.64
pH Agua	414	5.65350242	0.635797	4.18	5.27	5.55	5.925	7.68
C	414	30.848715	10.3651318	9.106	24.708	30.914	37.12	65.946
N	414	2.38249034	0.51734066	0.087	2.21	2.52	2.76	3.12
P	414	6.07937198	10.1992968	0.26	1.19	2.79	5.76	80.89
Ca	414	2703.03691	2028.78339	96.8	1237.25	2357.8	3638.8	15239.4
Mg	414	369.270048	297.932761	19.28	163.2075	275.23	477.63	1407.88
Na	414	12.0123913	8.21285662	3.45	6.9	9.66	16.1	78.43
K	414	138.026449	97.8150947	26.91	76.83	117	167.31	826.02
Fe	414	54.1332367	29.8277322	8.15	29.88	50.06	74.08	162.4
Cu	414	1.7994686	1.13600068	0.11	0.94	1.64	2.46	5.65
Zn	414	1.25316425	1.07853563	0.15	0.58	0.935	1.57	6.54

Mn	414	33.6253865	27.6480978	3.09	12.17	24.88	50.31	112.32
----	-----	------------	------------	------	-------	-------	-------	--------

Una red neuronal para regresión entre variables fisicoquímicas y los atributos de calidad del café es una red que se utiliza para predecir la calidad física del café en función de variables fisicoquímicas. 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.

Las variables independientes consideradas en el estudio fueron: la textura del suelo expresada en porcentajes de arena, limo y arcilla, el pH del agua, contenido de: C (g/kg), N (g/kg), P asimilable (mg/kg), Ca ++ (mg/kg), Mg ++ (mg/kg), Na + (mg/kg), K + (mg/kg), Fe (mg/kg), Cu (mg/kg), Zn (mg/kg) y Mn (mg/kg). Se contaron con un máximo de 466 muestras para calidad sensorial, producto de tres o cuatro repeticiones por muestra. Para la estimación del rendimiento se utilizaron 414 muestras, para la planchuela sana se utilizó 416 muestras, eliminándose un valor de 0.0 como posible error. Para fruto vano se usaron 417 muestras y para tamaño grande del grano de café 417 muestras.

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).

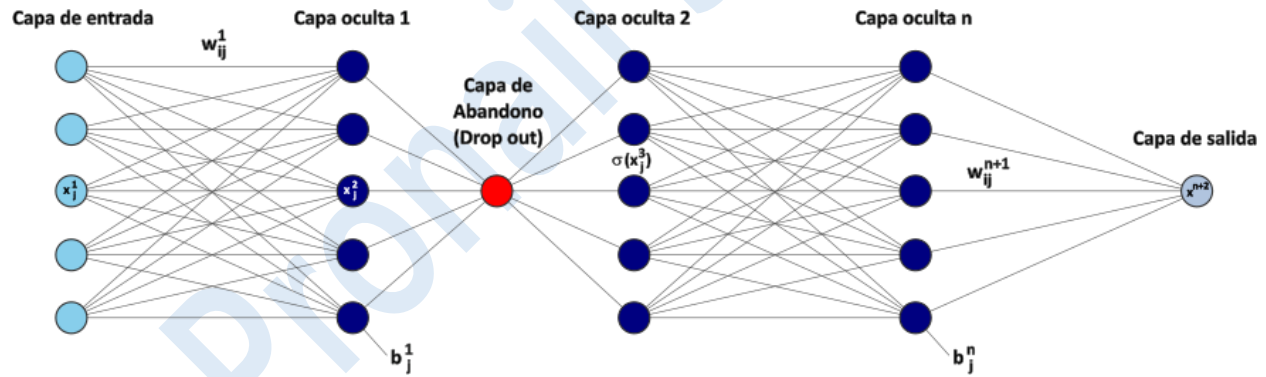


Figura 2. Red neuronal artificial

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 s 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.

Las redes neuronales son los componentes básicos de los modelos de aprendizaje profundo, los cuales han demostrado ser superiores al aprendizaje automático. Sin embargo, las redes neuronales profundas tienen millones de parámetros que aprender y esto significa que son necesarias muchas iteraciones antes de encontrar los valores óptimos. Si se tienen pocos datos, ejecutar una gran cantidad de iteraciones puede resultar en un sobreajuste (varianza alta). Un conjunto de datos grande ayuda a evitar el sobreajuste y a que se generalice mejor, ya que captura la distribución de datos inherente de manera más efectiva.

Las implicaciones de contar con pocos datos se reflejan en la falta de generalización, el desequilibrio de los datos y la dificultad de optimización. Por otro lado, si la red es muy simple, como las de aprendizaje automático sencillas, se aumenta mucho el sesgo en la estimación, que resulta en un subajuste. Por esto es conveniente lograr un equilibrio entre la varianza y el sesgo (sobre y subajuste).

Por el número reducido de muestras y 15 variables independientes, se optó por una red neuronal de una capa oculta con 128 neuronas, con una función de transformación tangente hiperbólica, y una capa de salida con función de activación de unidad lineal rectificada (ReLU, por sus siglas en inglés). El número de neuronas en la capa oculta, combinado con la función de transformación de la tangente hiperbólica, permite que la red analice las relaciones no lineales

entre las variables independientes que coadyuven a minimizar la función de pérdida. La función de activación ReLU asegura que los valores de salida siempre sean positivos.

Como primer paso, se analizaron los datos para descartar las variables independientes no esenciales y se generó una matriz de correlación para ver la existencia de multicolinealidad. En la Figura 3 se muestra esta matriz.




Figura 3. Matriz de correlación de las variables independientes

Como puede apreciarse en la Figura 3 existe una gran correlación entre el contenido de nitrógeno y carbono en el suelo y en menor grado entre el Ca y Mg y entre el Fe y el Cu. También existe una correlación muy alta entre la arena y la arcilla, no siendo así entre el limo y arcilla. Se generó la matriz para descartar la solución más simple de la regresión múltiple.

La multicolinealidad es un problema en la regresión lineal por mínimos cuadrados, principalmente por la forma en que se ajusta el modelo. Suponiendo que exista una solución única al problema, los parámetros se pueden estimar invirtiendo $X^T X$. Esto no es posible en el caso de colinealidad perfecta ya que la matriz no es invertible, y es problemático en el caso de colinealidad no perfecta, ya que la inversa es inexacta/inestable.

Para las redes neuronales, la multicolinealidad no es un problema, ya que los parámetros se ajustan mediante propagación hacia atrás, lo que no requiere invertir ninguna matriz ni suponer que existe una solución única al problema (de hecho, suele haber más de un óptimo en las redes neuronales). Por ejemplo, en las redes neuronales para la clasificación de imágenes, las variables de entrada suelen estar muy correlacionadas.

Para el entrenamiento de la red se dividió el conjunto de datos en entrenamiento con 56%, validación 14% y prueba 30%, con el fin de comprobar la generalización de la red.

Para evitar desbalances en la red, se normalizaron las variables de entrada al rango -1 a 1 mediante la siguiente ecuación:

$$X_n = 2 \cdot \frac{(X - X_{min})}{(X_{max} - X_{min})} - 1 \dots\dots\dots (2)$$

donde X_n es la variable normalizada, X la variable original y X_{min} y X_{max} los valores mínimo y máximo de las variables en el conjunto de entrenamiento.

La función de pérdida utilizada fue el error cuadrático medio (ECM), con excepción del puntaje de la calidad sensorial que se estableció como LogCosh debido a que se obtuvo un mejor ajuste. Para el seguimiento del ajuste se utilizaron 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 0.005, de esta manera se mejora la convergencia de la red.

Los pesos se inicializaron aleatoriamente con una distribución normal truncada con media cero y desviación estándar de uno, los sesgos se inicializaron en ceros. Se estableció que el modelo corriera durante 6,000 épocas (iteraciones) para el entrenamiento con lotes de 16 conjuntos de datos (batch), 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 sobreajuste y el valor de 250 permite que el modelo no se estanque en un óptimo local.

La red se ajustó utilizando Tensorflow de Google (Abadi *et al.*, 2015), que es un marco de desarrollo de aprendizaje automático muy poderoso que utiliza la biblioteca Keras para facilitar su uso. Se corrió en la plataforma de desarrollo en la nube Google Colaboratory.

En la Figura 4 se presenta el historial del entrenamiento del rendimiento del café pergamino-oro, así como la distribución de errores.

El entrenamiento de las redes ocupó entre 2,300 y 3,500 épocas de las 6,000 establecidas como límite debido a la parada temprana.

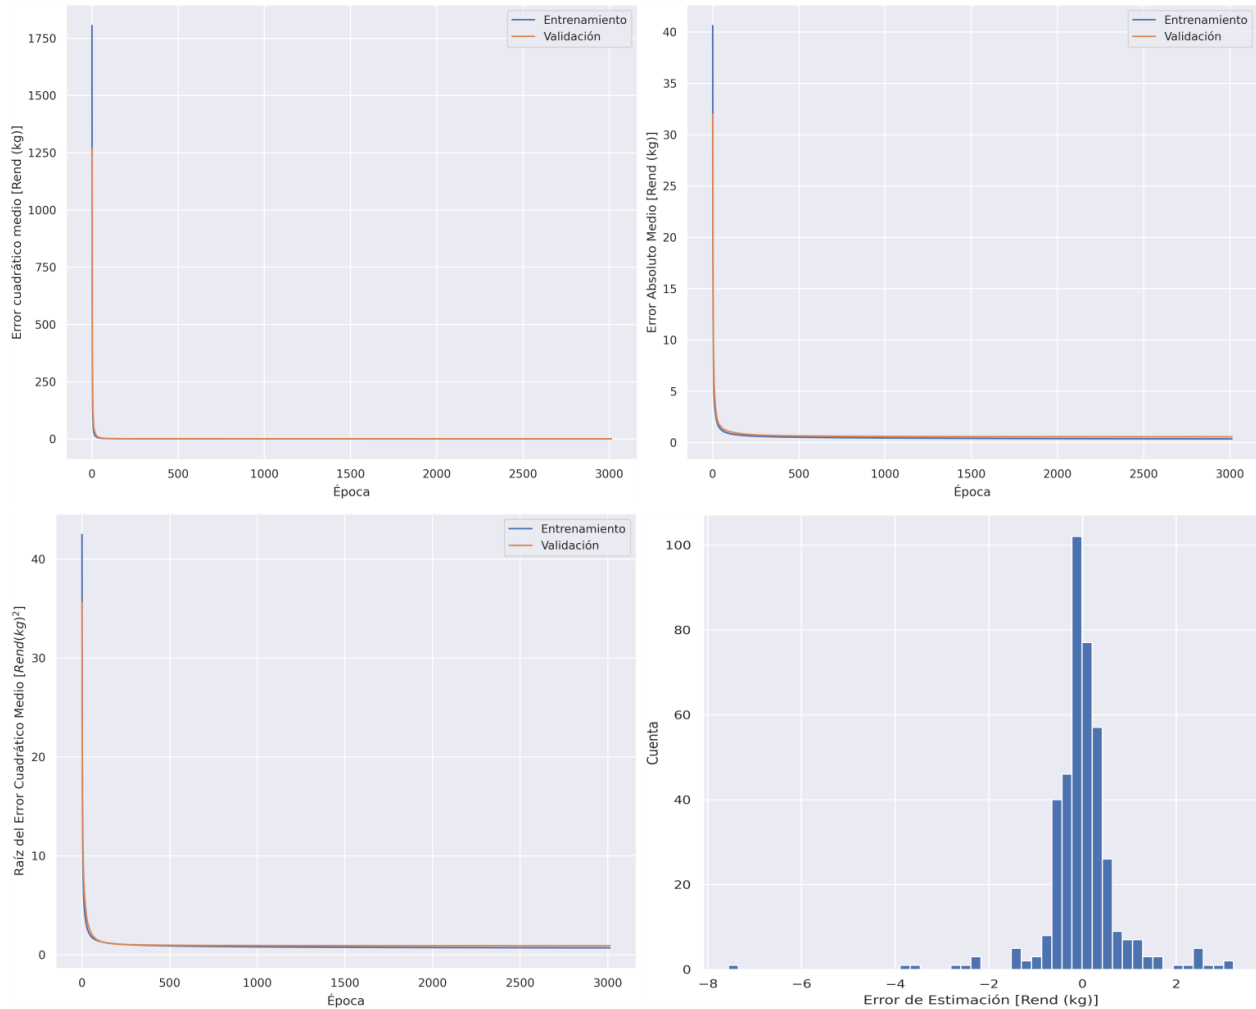


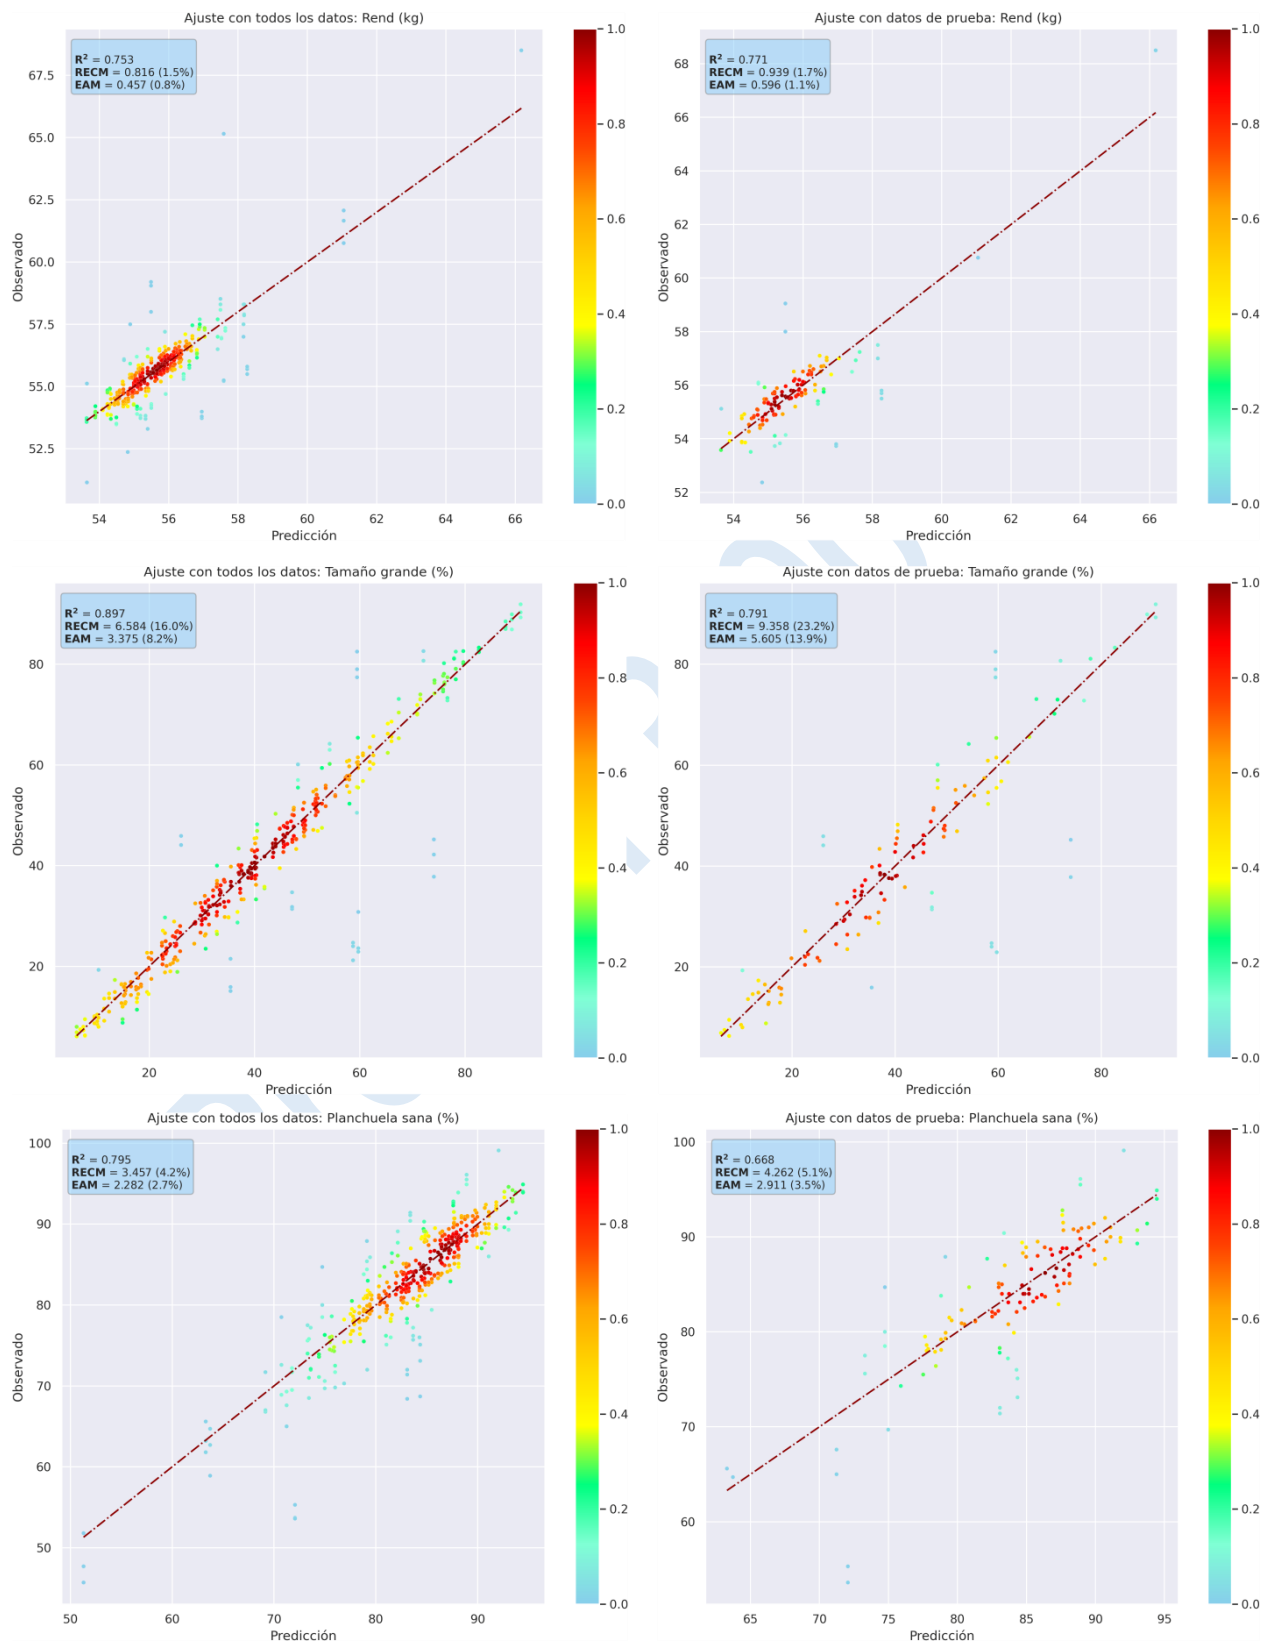
Figura 4. Historial del entrenamiento de la red neuronal para el rendimiento del café pergamino-oro

En las figuras 5 se muestra la bondad de ajuste para las variables estimadas, y en el Cuadro 3 un resumen de las métricas de ajuste. Como puede apreciarse en las figuras 5 y en el Cuadro 3,

en general, se tuvo un buen ajuste con valor de los coeficientes de determinación (R^2) de un rango

Pronaii 319069

0.72 a 0.90 con todos los datos y de 0.62 a 0.79 con los datos de prueba.






Figura 5. Ajustes con todos los datos y los datos de prueba

Como puede apreciarse en las figuras 5, no existe un sobreajuste evidente, la diferencia entre los valores de métrica de ajuste para los datos de entrenamiento y validación se deben a lo reducido del conjunto de datos y la existencia de datos atípicos que generan errores grandes. Esta situación provoca un desbalance en las muestras.

Cuadro 3. Resumen de los resultados del ajuste de las redes

Variable	Todos los datos				
	R ²	RECM	RECM (%)	EAM	EAM (%)
Rendimiento (kg)	0.753	0.816	1.15	0.457	0.8
Tamaño grande (%)	0.897	6.584	16.0	3.375	8.2
Planchuela sana (%)	0.795	3.457	4.2	2.282	2.7
Frutos vanos (%)	0.854	1.209	24.6	0.321	6.5
	Datos de Prueba				
	R ²	RECM	RECM (%)	EAM	EAM (%)
	0.771	0.939	1.7	0.596	1.1
	0.791	9.358	23.2	5.605	13.9
	0.668	4.262	5.1	2.911	3.5
	0.620	1.808	37.2	0.623	12.8

Existe un compromiso entre el rendimiento de un modelo y su interpretabilidad (entendiendo rendimiento como la precisión del modelo en sus predicciones). Existen modelos, como por ejemplo los modelos lineales simples, o algunos basados en árboles, que pueden explicar fácilmente las decisiones tomadas para llegar a una predicción en particular, pero es posible que se necesite sacrificar el rendimiento del modelo, puesto que no siempre es posible obtener los mejores resultados. Modelos más complejos como las redes neuronales y los de aprendizaje profundo a menudo producen un mejor rendimiento, pero se perciben como modelos de caja negra, puesto que es extremadamente difícil explicar cómo el modelo podría estar tomando las decisiones.

La capacidad de interpretar correctamente el resultado de un modelo de predicción es extremadamente importante. Genera una confianza adecuada en el usuario, proporciona información sobre cómo se puede mejorar un modelo y respalda la comprensión del proceso que se está modelando (Samek y Müller, 2019).

Para resolver el problema de interpretabilidad de los modelos de aprendizaje automático o profundo, se utilizan técnicas de análisis post-hoc para explicar sus predicciones. Entre estas técnicas se encuentra el modelo SHAP (SHapley Additive exPlanations, Lundberg y Lee, 2017), el cual es un método de interpretación de modelos basado en el Valor de Shapley de la Teoría de Juegos.

Los valores de Shapley están fundamentados en la teoría de la utilidad esperada, la cual establece que si los axiomas de Von Neumann-Morgenstern son satisfechos, entonces los individuos se comportan como si estuvieran tratando de maximizar la utilidad esperada. Por lo

tanto hereda ciertas suposiciones inherentes: (a) La utilidad es objetiva y transferible, (b) Los juegos son asuntos cooperativos y (c) Los juegos, cumpliendo (a) y (b), están adecuadamente representados por sus funciones características (Shapley, 1953). Por lo que se definen axiomas en los que la utilidad en un juego, se reparte entre los jugadores en función de sus características. SHAP se utiliza para explicar la importancia de cada variable (medida como el cambio promedio en la predicción del modelo cuando varía el valor de la variable) en una predicción concreta.

SHAP utiliza una combinación de líneas de base, funciones de importancia local y el Teorema de Valor de Shapley para calcular la importancia de cada variable en una predicción individual:

- Se calculan los valores de Shapley, donde las variables independientes se interpretan como jugadores que colaboran para recibir la *utilidad*.
- Los valores de Shapley se corresponden con la contribución de cada variable a la predicción del modelo.
- La *utilidad* es la predicción concreta realizada por el modelo menos el valor promedio de todas las predicciones.
- Los jugadores se “reparten” esta *utilidad* en función de su contribución, y este reparto viene calculado por los valores de Shapley y refleja la importancia de cada variable.

Esto se entiende mejor si se analiza la Figura 6, la cual muestra una gráfica de cascada de la predicción del rendimiento pergamino-oro para un punto dado. En la figura se aprecia que el valor esperado del rendimiento $E[f(x)]$, es igual a 55.744 kg (promedio del rendimiento), mientras que la predicción para ese punto en particular, $f(x)$, es de 56.32 kg. Los valores de Shapley representan la contribución de cada variable para obtener $f(x)-E[f(x)]$.








Figura 6. Gráfica de cascada para una predicción de rendimiento de café pergamino-oro

La biblioteca SHAP permite estimar estos valores al realizar permutaciones en las variables del modelo para un punto de predicción dado. Genera una gran variedad de gráficas de gran utilidad para la interpretación del efecto de las variables en la predicción del modelo. Es importante resaltar que estos valores representan la *importancia de cada variable en el modelo*, no en la realidad, ya que correlación no implica causalidad. Las relaciones causa-efecto se deben analizar al establecer las variables independientes.

Una de las gráficas permite establecer la importancia media de cada variable en la predicción del modelo, esto lo hace al calcular el promedio del valor absoluto de los valores de Shapley, que modificamos para que presentara la contribución promedio de cada variable en las predicciones de manera porcentual.

Otra gráfica de importancia para la interpretabilidad, es la de enjambre, en la que se presentan los puntos de los valores Shapley para todas las variables. Los puntos se dibujan con una rampa de color que indica la magnitud de la variable, que varía del mínimo de color azul al rojo oscuro para el valor máximo. Esto es importante para la interpretación del efecto de las variables en la predicción del modelo, ya que permite identificar relaciones directas, si los colores van de azul a rojo de izquierda a derecha, e inversas, si los colores van de rojo a azul.

En la Figura 7. se presenta el conjunto de gráficas de importancia e impacto de cada variable en la predicción de las variables dependientes.



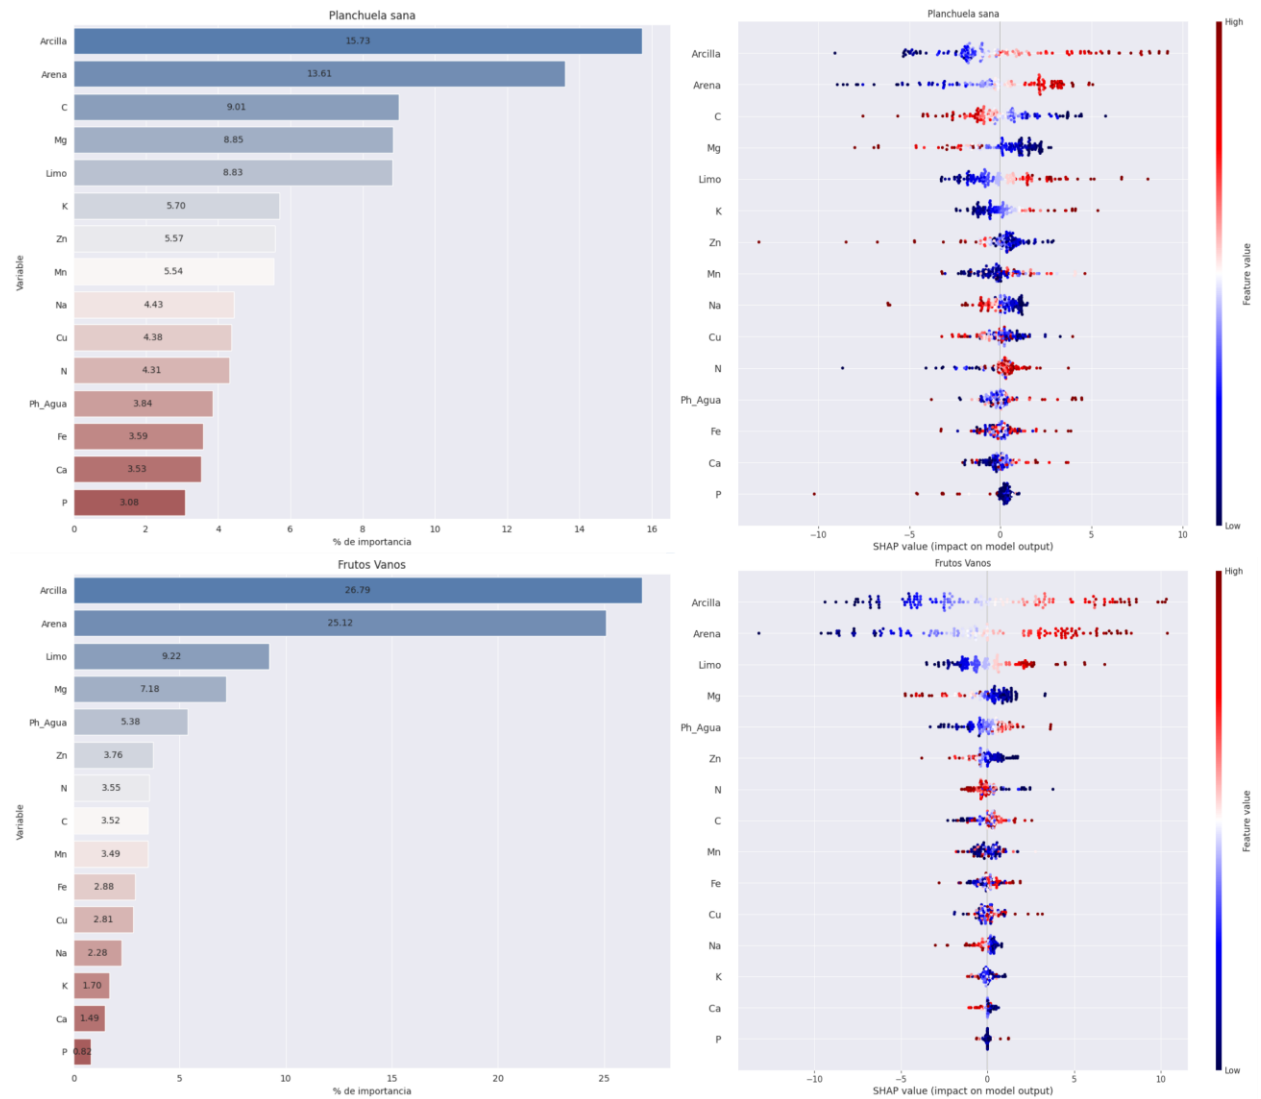


Figura 7. Importancia e impacto de las variables independientes en la predicción de los modelos

De este conjunto de gráficas se puede inferir, por ejemplo, que para el caso del rendimiento, la textura juega un papel importante en el modelo, mientras que para el tamaño del grano tipo europeo, el contenido de carbono tiene una relación inversa, mientras que el contenido del nitrógeno y el contenido de arena tienen una relación directa.

CONCLUSIONES

Los análisis realizados para los atributos físicos del rendimiento café pergamino a oro, tamaño del grano preparación europea, frutos vanos y planchuela sana mostraron resultados aceptables para todos los datos (R^2 de 0.75 a 0.89) por lo que las redes neuronales de aprendizaje profundo pueden usarse en forma confiable y robusta. Para cada atributo físico analizado, las redes neuronales muestran configuraciones diferentes, enfatizando las diferentes interacciones entre las variables fisicoquímicas existentes, mostrando flexibilidad en los ajustes para un conjunto fijo de variables fisicoquímicas, a diferencia del uso de recomendaciones de fertilidad de los suelos (Carbajal, 1984; Sadeghian, 2008; Bedoya y Salazar, 2014).

REFERENCIAS BIBLIOGRÁFICAS

- Abadi, M., A., P. Agarwal, E. Barham, Z. Brevdo, C. Chen, G.S. Citro, A. Corrado, J. Davis, M. Dean, S. Devin, I.J. Ghemawat, A. Goodfellow, G. Harp, M. Irving, Y. Isard, R. Jia, L. Józefowicz, M. Kaiser, J. Kudlur, D. Levenberg, R. Mane, S. Monga, D.G. Moore, C. Murray, M. Olah, J. Schuster, B. Shlens, I. Steiner, K. Sutskever, P.A. Talwar, V. Tucker, V. Vanhoucke, F.B. Vasudevan, O. Viegas, P. Vinyals, M. Warden, M. Wattenberg, M. Wicke, Y. Yu and X. Zheng. 2015. TensorFlow: Large-scale machine learning on heterogeneous distributed systems. ArXiv preprint: arxiv.org/abs/1603.04467.
- Bedoya, M. y R. Salazar. 2014. Optimización del uso de fertilizantes para el cultivo de café. *Revista Mexicana de Ciencias Agrícolas* 8:1433-1439
- Bertrand, B., P. Vaast, E. Alpizar, H. Etienne, F. Davrieux and P. Charmetant. 2006. Comparison of bean biochemical composition and beverage quality of Arabica hybrids involving Sudanese-Ethiopian origins with traditional varieties at various elevations in Central America. *Tree Physiology* 26:1239-1248
- 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.
- Carbajal, J.F. 1984. *Cafeto, cultivo y fertilización*. Segunda Edición. Instituto Internacional de la Potasa. Bema, Suiza 251 p.
- Cheng, B., A. Furtado, H.E. Smyth and R.J. Henry. 2016. Influence of genotype and environment on coffee quality. *Trends in Food Science and Technology* 57:20-30

- DaMatta, F.M., P.C. Ronchi, M. Maestri and S.R. Barros. 2007. Ecophysiology of coffee growth and production. *Brazilian Journal of Plant Physiology* 19:485-510
- Escamilla, E. 2012. La Calidad del café orgánico en México. Factores ambientales, genéticos, agrónomos y sociales. Editorial Academica Española ISBN-10:9783848457342 380 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
- Escamilla, E., O. Ruiz, A. Zamarripa y V.A. González. 2015. Calidad en variedades de café orgánico en tres regiones de México. *Revista de Geografía Agrícola* 55:45-55
- Escamilla, E. y C. Landeros. 2016. Cafes diferenciados y de especialidad. CENACAFE. Huatusco, Veracruz 54 p.
- Hein, L. and F. Gatzweiler. 2005. The economic value of coffee (*Coffea arabica*) genetic resources. *Ecological Economics* 60:176-185
- Kathurima, C.W., B.M. Gichimu, G.M. Kenji, S.M. Muhoho and R. Boulanger. 2009. Evaluation of beverage quality and green bean physical characteristics of selected Arabica coffee genotypes in Kenya. *African Journal of Food Science* 3:365-371
- Kingma, D. P. and J. Ba. 2014. Adam: A method for stochastic optimization. ArXiv preprint: <https://arxiv.org/abs/1412.6980>
- Samek, W. and K.R. Müller, K.-R. 2019. Towards explainable artificial intelligence. In W. Samek, G. Montavon, A. Vedaldi, L. K. Hansen and K.-R. Müller (eds.). *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*. doi:10.1007/978-3-030-28954-6_1 pp. 5-22
- 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
- López-García, F.J., E. Escamilla-Prado, A. Zamarripa-Colmenero y J.G. Cruz-Castillo. 2016. Producción y calidad en variedades de café (*Coffea arabica* L.) en Veracruz, México. *Rev. Fitotec. Mex.* 39:297-304
- López-García, F.J., J.G. Cruz-Castillo y E. Escamilla-Prado. 2021. Variedades de *Coffea arabica* L. con manejo orgánico en Oaxaca. *Acta Agrícola y Pecuaria* doi:10.30973/aap/2021.7.0071000
- Lundberg, S. M., S.-I. Lee. 2017. A Unified approach to interpreting model predictions. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan and R. Garnett (eds.), *Advances in Neural Information Processing Systems* 30 pp. 4765–4774. <http://papers.nips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions.pdf>
- Morales, E.I. y M.A. Bolaños. 2022. Producción de café de alta calidad como estrategia de sustentabilidad para los sistemas socioecológicos de café bajo sombra. *Boletín Informativo CONACYT-PMC-UAEM-UACJ-PNUD-INIFAP* 4 p. https://pmcarbono.org/pmc/proyectos/Resiliencia_estabilidad_socieologica_cafeticaultura_mexicana_bajo_sombra.php

- Pérez, P., J.G. Partida y D. Martínez. 2005. Determinación de las subdenominaciones de origen del Café Veracruz (estudio preliminar). *Revista Geografía Agrícola* 35:35-56
- Pérez-Portilla, E., S. Bonilla-Cruz, J.A.M. Hernández-Solabac y J.G. Partida-Sedas. 2011. Estrategia de mejoramiento de la producción cafetalera de la organización Campesinos Ecológicos de la Sierra Madre de Chiapas: caracterización de la bebida de café. *Revista de Geografía Agrícola* 46-47:7-18
- Rosas, J. 2006. Diagnostico de la fertilidad de los suelos con manejo orgánico y su efecto sobre la calidad física y sensorial del café (*Coffea arabica* L.) en cinco regiones de México. Tesis profesional. Departamento de Suelos, Universidad Autónoma Chapingo. Chapingo, México. 104 p.
- Rosas, J., E. Escamilla y O. Ruiz. 2008. Relación de los nutrimentos del suelo con las características físicas y sensoriales del café orgánico. *Terra Latinoamericana* 26:375-384
- Sadeghian, S. 2008. Fertilidad del suelo y nutrición del café en Colombia. *Boletín Técnico* No. 32. CENICAFE Colombia 45 p.
- Santoyo, V., S. Díaz, E. Escamilla y J.D. Robledo. 1996. Factores agronómicos y calidad del café. México. Universidad Autónoma Chapingo/Confederación de Productores de Café 21 p.
- Shapley, L.S. 1953. A value for n-person games. In: H.W. Kuhn and A.W. Tucker, (eds). *Contributions to the Theory of Games, volume II Annals of Mathematical Studies* 28:307–317. Princeton University Press.
- Sosa, M, E. Escamilla and S. Díaz. 2004. Organic coffee. In: J.E. Wintgens (ed). *Coffee: Growing, Processing, Sustainable Production. A Guide Book for growers, processors, traders and researchers*. Wiley-VCH Verlag KgaA. Weinheim, Germany pp. 339-354
- UACH-INCAFECH-CONACYT. 2018. Informe del proyecto: Diseño, construcción, equipamiento y puesta en marcha de un centro estatal de innovación y transferencia de tecnología para el desarrollo de la caficultura chiapaneca (Clave 2580). Resultados de la caracterización del potencial productivo de los cafetales en las 13 regiones de Chiapas. Universidad Autónoma Chapingo, Instituto del Café de Chiapas y Consejo Nacional de Ciencia y Tecnología. Tuxtla Gutiérrez, Chiapas 289 p.
- Wintgens, J.N. 2004. Factors influencing the quality of green coffee. In: J.N. Wintgens (ed) *Coffee: Gowing, Processing, Susrainable Production*. Weinhein. Wiley-VCH pp. 789-809