

UNIVERSIDAD NACIONAL

SISTEMA DE ESTUDIOS DE POSGRADO

MAESTRÍA EN AGRICULTURA ECOLÓGICA

Implementación de un modelo matemático de secado en poscosecha de cacao (*Theobroma cacao*), acoplado a un sistema de aprendizaje automático, que permita establecer una metodología de secado, aplicable en fincas de pequeña y mediana escala.

German Eduardo Zárate-Montero

Heredia, Junio 2024

Tesis sometida a consideración del Tribunal Examinador del Posgrado en Agricultura Ecológica de la Escuela de Ciencias Agrarias, para optar por el grado de *Magíster Scientiae* en Agricultura Ecológica.

**Implementación de un modelo matemático de secado en poscosecha de cacao (*Theobroma cacao*),
acoplado a un sistema de aprendizaje automático, que permita establecer una metodología de secado,
aplicable en fincas de pequeña y mediana escala.**

German Eduardo Zárate-Montero

Tesis presentada para optar al grado de *Magíster Scientiae* en Agricultura Ecológica. Cumple con los requisitos establecidos por el Sistema de Estudios de Posgrado de la Universidad Nacional, Heredia, Costa Rica.

MIEMBROS DEL TRIBUNAL EXAMINADOR

[M.Sc. Randall Gutiérrez Vargas /Dra. Damaris Castro García /Dr. Jorge Herrera Murillo/ Dr. José Vega Baudrit /Dr. Greivin Rodríguez Calderón/ Dra. Rocío Castillo Cedeño] Representante del Consejo Central de Posgrado

Ph.D. Martha Orozco Aceves

Coordinadora Maestría en Agricultura Ecológica

Ph.D. Carlos Eduardo Hernández Aguirre

Tutor de tesis

M.Sc. Alejandra Mencía Guevara

Miembro del Comité Asesor

M.Sc. Gerald Torrentes Espinoza

Miembro del Comité Asesor

German Eduardo Zárate Montero

Sustentante

Descriptores

Deshidratación, Poscosecha, Theobroma cacao, Red neuronal artificial, Predictor de humedad.

Resumen

El objetivo de la presente investigación fue determinar un modelo matemático descriptivo de la operación de secado en poscosecha de cacao (*Theobroma cacao*) acoplado a un sistema de aprendizaje automático, alimentado por datos experimentales. Lo anterior permitió desarrollar una metodología de dicha operación, que considera el efecto del cambio de temperatura, para que sea aplicable a pequeñas y medianas fincas productoras de cacao. La presente investigación constituye un aporte valioso, ya que una gran mayoría de modelos fenomenológicos existentes se enfocan en operaciones de secado en ambiente controlado; temperatura y humedad constante, sin embargo, la realidad de la operación en las fincas productoras de cacao medianas y pequeñas en la región, donde la operación poscosecha se realiza de manera artesanal, es que la temperatura no es constante durante el proceso y está influida por los cambios en el clima. Más aún, en muchos de estos lugares la cosecha suele darse en los meses de mayores precipitaciones como setiembre y octubre, por lo que se pueden tener pérdidas asociadas a la formación de moho por exceso de humedad y secado deficiente.

Es por esto que se propone construir una herramienta web, que permita predecir el pH y la humedad interna de la semilla de cacao, en cualquier parte de la operación, de manera que la persona productora pueda tomar decisiones basadas en la predicción. Para esto se implementó una red neuronal de aprendizaje, programada en Python3, con la librería Scikit-learn 1.4.1, la cual implementa una forma de aprendizaje de retroalimentación hacia atrás (back propagation) soportado por algoritmos de optimización (Descenso Estocástico de Gradiente, Adam, entre otros), en la que se asignan “pesos” a cada iteración de aprendizaje, asociados a una función de pérdida, la cual permite la optimización de la predicción por medio de minimizar la función de pérdida. Uno de los módulos de la librería Scikit-learn 1.4.1 conocido como MLPRegressor, utiliza como métricas al error cuadrado medio, para medir la desviación del valor predicho y el valor real en una serie de mediciones, además usa coeficiente de determinación R^2 , que representa la varianza entre un conjunto de salidas, siendo 0 el valor ideal para el error cuadrado medio y 1 para el coeficiente de determinación.

Para construir la herramienta se realizó una búsqueda exhaustiva de modelos fenomenológicos de secado en poscosecha de cacao, de los cuales se opta por adaptar el modelo de deshidratación isotérmica de alimentos propuestos por Adrover (2020), como acelerador de convergencia. Esto se debe a que la cantidad de datos experimentales no es suficiente para lograr que la herramienta prediga siempre el resul-

tado en el intervalo de convergencia, en una cantidad de iteraciones razonable. Por otra parte, los datos experimentales de pH interno, humedad interna inicial del grano, dimensiones promedio de la semilla, temperatura ambiente inicial, humedad ambiental inicial, que son las entradas del sistema, se toman durante los meses de junio a diciembre de 2023 en la finca experimental Santa Lucía de la escuela de Ciencias Agrarias de la Universidad Nacional. Se realizaron 6 ensayos de operación poscosecha, en la que se simularon las condiciones de campo similares a las que se se tienen en las fincas, lo que permitió definir un intervalo de convergencia para poder determinar el grado de exactitud de la predicción.

Se obtuvo de la integración de los datos experimentales con la función de aprendizaje, un error cuadrado medio de 153 y un coeficiente de determinación de 0,82, lo cual implica que es necesario aumentar la cantidad de datos experimentales, para que el algoritmo de aprendizaje pueda brindar resultados en el intervalo de convergencia en pocas iteraciones. Es por esto que el protocolo poscosecha que se propone, implica que la persona productora ingrese a la interfaz del predictor vía web y entrene la herramienta con datos experimentales reales de su finca, para que luego pueda realizar predicciones y tomar decisiones con respecto al resultado predicho.

Se recomienda para futuras retroalimentaciones del sistema que los datos experimentales sean realizados en intervalos continuos regulares (por ejemplo día a día, sin saltos), para que la herramienta de aprendizaje pueda aprender con mayor detalle la ruta de convergencia. También se recomienda incluir la variable genética del cacao como entrada del sistema, para aumentar la exactitud del cálculo predicho.

Abstract

The objective of the present research was to determine a descriptive mathematical model of the post-harvest drying operation of cocoa (*Theobroma cacao*) coupled with a machine learning system, fed by experimental data. The above allowed the development of a methodology of the post-harvest operation, which considers the effect of temperature change, so that it is applicable to small and medium-sized cocoa producing farms. The present research constitutes a valuable contribution, since a large majority of existing phenomenological models focus on drying operations in a controlled environment; constant temperature and humidity, however, the reality of the operation on medium and small-sized cocoa producing farms in the region, where the post-harvest operation is carried out in a artisanal way, is that the temperature is not constant during the process and is influenced by changes in the climate. Furthermore, in many of these places, the harvest usually occurs in the months of highest rainfall such as September and October, so there can be losses associated with the formation of mold due to excess moisture and poor drying.

This is why it is proposed to build a web tool that allows predicting the pH and internal moisture of the cocoa seed, at any point of the operation, so that the producer can make decisions based on the prediction. For this, a neural learning network was implemented, programmed in Python3, with the Scikit-learn 1.4.1 library, which implements a form of back propagation learning supported by optimization algorithms (Stochastic Gradient Descent, Adam, among others), in which “weights” are assigned to each learning iteration, associated with a loss function, which allows the optimization of the prediction by minimizing the loss function. One of the modules of the Scikit-learn 1.4.1 library known as MLPRegressor, uses the mean squared error (MSE) as a metric to measure the deviation of the predicted value and the actual value in a series of measurements, and also uses the coefficient of determination R^2 , which represents the variance between a set of outputs, with 0 being the ideal value for the mean squared error and 1 for the coefficient of determination.

To build the tool, an exhaustive search was carried out of phenomenological models of post-harvest drying of cocoa, of which it is decided to adapt the model of isotropic food dehydration proposed by Adrover (2020), as a convergence accelerator. This is because the amount of experimental data is not sufficient to allow the tool to always predict the result in the convergence interval, in a reasonable number of iterations. On the other hand, the experimental data on internal pH, initial internal moisture of the grain, average seed dimensions, initial ambient temperature, initial ambient humidity, which are the inputs of the system, are

taken during the months of June to December 2023 at the experimental farm Santa Lucía of the School of Agricultural Sciences of the National University. Six post-harvest operation tests were carried out, in which field conditions similar to those of the farms were simulated, which allowed defining a convergence interval to determine the degree of accuracy of the prediction.

From the integration of the experimental data with the learning function, a mean squared error of 153 and a coefficient of determination of 0.82 were obtained, which implies that it is necessary to increase the amount of experimental data, so that the learning algorithm can provide results in the convergence interval in few iterations. This is why the proposed post-harvest protocol implies that the producer enters the web-based predictor interface and trains the tool with real experimental data from their farm, so that they can then make predictions and make decisions based on the predicted result.

It is recommended for future feedback of the system that the experimental data be carried out at regular continuous intervals (for example, day by day, without gaps), so that the learning tool can learn in more detail the convergence path. It is also recommended to include the genetic variable of the cocoa as an input to the system, to increase the accuracy of the predicted calculation.

Agradecimiento

A Luis Zárate Montero por el gran apoyo. A Solvo.

A Carlos Hernández, Alejandra Mencia, Gerald Torrentes y Marta Orozco.

A Edgar Bermúdez y José Sanchez, estudiantes de la escuela de Ciencias Agrarias de la UNA.

A estudiantes y profesionales de LABCIAGRO: Paola Arguedas, María José, Angélica, Janet, Philippe, Cintia, Sebastián.

A las estudiantes de pasantía: Dominika, Harat y Ana.

A Jose Mario Núñez y Miguel Castillo del laboratorio de Nutrición Animal de la escuela de Ciencias Agrarias

A todo el personal administrativo y técnico de la finca experimental de Santa Lucía. A Mauricio Arias.

Al personal técnico de los laboratorios de la escuela de Física. A David Barrantes de la escuela de Química.

A Adriana Arciniegas, investigadora del CATIE.

A doña Sole y a Diego.

Dedicatoria

A mis ancestros y ancestras que utilizaron el cacao en este continente.

En memoria de las abuelas Carmen y Marta, las bisabuelas Elisa, Rosalía, Josefa María.

En memoria de German, abuelos Modesto y José M, los bisabuelos Tano, Pánfilo, Rafael y Manuel.

En memoria de Gloriana María.

Índice

	Página
I Introducción	1
Problema	2
Justificación	5
Objetivo General	6
II Marco teórico	8
Beneficiado de cacao	8
Cosecha, quebrado y extracción	9
Traslado al lecho de fermentación	9
Fermentación	9
Determinación del punto final de la fermentación	11
Secado	11
Modelos Fenomenológicos	12
Modelo de frontera móvil para deshidratación isotérmica del alimentos	13
Disminución del volumen de la semilla	14
Descripción del proceso de Difusión (ecuación de transporte de masa	16
Ecuaciones diferenciales sobre la operación de secado, tomando en cuenta el efecto de la difusión	18
Ecuación para el caso de distribución uniforme de agua al evaporarse sin efecto de contrac- ción de la semilla	19

Ecuación para el caso de distribución no uniforme de agua al evaporarse y sin efecto de contracción del grano	20
Ecuación para el caso de distribución no uniforme de agua al evaporarse y además efecto de contracción del grano	20
Herramienta de aprendizaje automático	21
Funciones para acelerar la convergencia del resultado en intervalo esperado	25
Modelo de Brusselator	26
Motor de aprendizaje del predictor de condiciones finales en poscosecha de cacao	27
III Metodología, métodos y técnicas	28
Procedimiento metodológico	28
Determinación de las variables de entrenamiento	29
Preparación de las muestras para fermentación- secado	30
Condiciones de fermentación y secado	30
Descripción de los análisis	31
Determinación de humedad interna del cotiledón y obtención de la curva de calibración por difusividad	31
Medición de las dimensiones de la semilla (ajuste de la tasa de deshidratación adimensional debida a la contracción del grano)	32
Determinación de pH de cotiledones	32
Determinación de humedad externa (pulpa-cáscara)	33
Determinación de humedad externa (pulpa-cáscara)	33
Recolección de datos experimentales	33
Procesamiento de los datos y construcción del motor de aprendizaje	34
Configuración de la interfaz del predictor de condiciones finales en poscosecha de cacao	35
Entradas	36
Salidas	37
IV Resultados y Discusión	39
Construcción de la red neuronal	39
Procesamiento de datos obtenidos experimentalmente	39

Funciones de entrenamiento	39
Definición de los intervalos de convergencia	43
Integración de los datos experimentales a la red neuronal (entrenamiento)	44
Comparación entre el resultado predicho por la red neuronal y los datos experimentales	45
Protocolo poscosecha para reducir pérdidas por fermentación inadecuada y manejo deficiente del secado en clima tropical húmedo	46
Entrenamiento del sistema para una finca	46
Uso del Predictor de condiciones finales en poscosecha de cacao	47
V Conclusiones y Recomendaciones	52
VI Bibliografía	54
VII Anexos	62
Anexo 1: Descripción de los ensayos realizados realizados	63
Anexo 2: Memoria gráfica de la parte experimental	67

Índice de tablas

Tablas	Páginas
1 Ensayos realizados en la Finca Experimental de la Escuela de Ciencias Agrarias en Santa Lucía de Barva.	34
2 Métricas del módulo MLPRegressor para el entrenamiento de la red neuronal.	45

Índice de figuras

Figuras	Páginas
1 Dificultades enfrentadas por pequeños y medianos productores para el procesamiento del cacao.	6
2 Representación del sistema de fermentación de cajas (figura de la izquierda) y del método de Rohan (figura de derecha).	10
3 Determinación de las dimensiones del grano de cacao (Adrover et al., 2020)	14
4 Secuencia metodológica empleada para la construcción del predictor de humedad.	29
5 Ejemplo de la estructura un perceptrón multicapa, unidad básica de la red neuronal (predictor de humedad interna).	36
6 Variación de la humedad interna y el pH interno Variación de la humedad interna y el pH interno en poscosecha de cacao.	40
7 Variación de la temperatura (°C) y humedad relativa en la pulpa-cáscara en poscosecha de cacao.	42
8 Ploteo de las variables de entrenamiento determinadas experimentalmente. Determinación de los intervalos de convergencia inicial para entradas y salidas.	44
9 Resultado de la integración de los datos experimentales en el motor de aprendizaje (entrenamiento de la red).	45
10 Interfaz del predictor de condiciones finales en poscosecha de cacao.	48
11 Resultado de la consulta al predictor de condiciones finales en poscosecha de cacao.	49
12 Retrolimentación al predictor de condiciones finales en poscosecha de cacao.	49

13	Acondicionamiento de los cajones y fermentación.	67
14	Prueba de corte, presecado y secado.	68
15	Instrumentos de medición.	69

Nomenclatura

λ_0	Espesor de la cáscara-pulpa: mm.
ρ_{aire}	Densidad del aire: kg/m ³ .
ρ_s	Densidad de la pulpa: kg/m ³ .
ρ_w	Densidad de agua: kg/ m ³ .
φ_0	Fracción de volumen de agua: Adimensional.
a_0	Dimensión inicial de una semilla de cacao (Largo): mm.
b_0	Dimensión inicial de una semilla de cacao (ancho): mm.
Bi_m	Número másico de Biot: adimensional.
c_0	Dimensión inicial de una semilla de cacao (altura): mm.
D	Coefficiente de difusividad: m ² /s.
h_m	Coefficiente de transferencia de masa: m/s.
J	Tasa de deshidratación: (1/h).
J_d	Tasa de deshidratación adimensional.
K_{eq}	Coefficiente de reparto: adimensional.
L_r	longitud característica de referencia: mm.
M_0	Masa inicial de cacao (semilla y pulpa) : kg.

- M_0^{core} Masa inicial del cotiledón: kg.
- M_0^{shell} Masa inicial de la pulpa: kg.
- M_d Masa total de cacao seco: kg.
- M_d^{core} Masa de la semilla seca: kg.
- M_d^{shell} Masa de la pulpa seca : kg.
- R_a Radio geométrico aritmético: mm.
- R_{eq} Radio equivalente: mm.
- R_g Radio geométrico promedio: mm.
- R_s Radio promedio cuadrado: mm.
- V_0 Volúmen Inicial: mm³.
- x Entradas al sistema de aprendizaje.
- X_0 Humedad inicial de cacao (semilla y pulpa): kg agua/kg base seca.
- X_0^{core} Humedad inicial de la semilla: kg agua/kg base seca.
- X_{eq} Humedad equivalente: kg agua/kg base seca.
- X_r Tasa de humedad: adimensional.
- y Salidas del sistema de aprendizaje.

Capítulo I

Introducción

El manejo poscosecha o beneficiado de cacao es un proceso en el que las semillas son removidas del fruto maduro, fermentadas y secadas adecuadamente, para lograr que un lote de cacao presente las características óptimas de calidad en cuanto a propiedades organolépticas, cantidad de metabolitos en el grano (Aguilar, 2017) e inocuidad (Obakior, 1975). Esto con la intención de poder vender el producto a precio competitivo en el mercado regional e internacional, asegurando calidad y homogenización (Herrera et al., 2016).

La operación poscosecha inicia con la remoción de semillas de la fruta (Estrada et al., 2011), las cuales se someten a un proceso de fermentación, que específicamente se da en la pulpa que rodea las semillas. La fermentación influye directamente en el color y el sabor de las semillas y por lo tanto en la calidad del producto final (Nigam & Singh, 2014). Al tratarse de un proceso microbiano, las condiciones iniciales de pH, los cambios en el contenido de azúcar, la concentración de oxígeno y la humedad influyen en la etapa de fermentación realizada principalmente por levaduras (Medina et al., 2009).

Luego de la fermentación de las semillas, la operación poscosecha continúa con el secado de las mismas, cuya función es reducir el contenido de humedad y ácido acético, para evitar el deterioro del grano debido al crecimiento de bacterias, levaduras, moho y descenso del pH (Aguilar, 2017). La operación de secado puede realizarse mediante dos métodos: secado natural (con mayor frecuencia usado por pequeños y medianos productores), cuando los granos de cacao se extienden sobre un soporte y se exponen directamente al sol, o secado por convección artificial (predominante en producción a gran escala), en el que los granos de cacao se exponen a un flujo de aire con velocidad, temperatura y humedad controladas (Tinoco y Ospina, 2016).

A nivel regional las condiciones de operación del beneficiado en las fincas agroecológicas pequeñas y medianas, carecen de equipo tecnológico para realizar el secado a temperatura controlada por convección de aire, por lo que la mayoría de estas fincas, realizan el secado de manera artesanal, es decir, sin control

de temperatura (SEPSA, 2017; Álvarez, 2016), por lo que la fluctuación en la temperatura de día y de noche, produce variaciones en la cantidad de días necesarios para que las semillas alcancen la humedad requerida para finalizar el secado. Otro factor que dificulta el secado y almacenamiento es la inestabilidad del clima en las zonas en las que se cultiva cacao, las cuales se caracterizan por abundantes lluvias y una humedad relativa que varía entre 70 % a 80 %. Esto disminuye la velocidad de secado y aumenta las posibilidades de formación de hongos y microorganismos indeseados en la semilla (Ortiz de Bertorelli et al., 2009).

Debido a que a la mayoría de fincas agroecológicas pequeñas y medianas, no disponen de equipo para controlar la temperatura y la humedad, se hace necesario construir una herramienta que permita tener control sobre el proceso y que sea de fácil acceso (Cortés et al., 2011., Ortiz de Bertorelli et al., 2009). Es por eso que en esta investigación se propone crear un protocolo poscosecha para pequeños y medianos productores agroecológicos, basado en la implementación de una herramienta de predicción de condiciones finales de producto. Esta herramienta es un software que acopla el modelo de deshidratación isotérmica de frontera móvil propuesto por Adrover et al., (2020), con un sistema de “machine learning” que permite contemplar la variación de humedad y temperatura (Gonçalves, 2017).

Problema

El cultivo de cacao ha desempeñado un papel económico relevante para pequeños agricultores en zonas rurales de África, Latinoamérica y Asia (Acebo, 2016). El cultivo comercial de este producto puede asegurar los ingresos necesarios para adquirir alimentos, lo cual es particularmente relevante en regiones donde la seguridad alimentaria ha representado un desafío (Medina et al., 2009).

De acuerdo con datos de la Organización Mundial del Cacao (ICCO) para 2013, África es el principal productor de cacao a nivel mundial, América Latina se ubica como el segundo mayor productor, siendo Brasil y Ecuador los principales productores. La Industria cacaotera a nivel global se caracteriza por tener naturaleza cíclica y porque aproximadamente el 90 % de la producción mundial la realizan pequeños agricultores, mientras que el procesamiento de la semilla seca para uso industrial se realiza en los países que importan cacao (Acebo, 2016).

A pesar de la importancia del cultivo existen pocos intentos de desarrollar tecnologías que ayuden a los pequeños agricultores a lograr un mejor y más eficiente procesamiento, la estandarización del proceso poscosecha es difícil de lograr, ya que no todos los productores cuentan con los mismos recursos (Aguilar,

2017; Anggraini, 2021; Aramburo, 2017), para poder controlar la operación poscosecha de manera óptima. Esto ha devenido que existan pocos modelos de predicción de calidad final de la semilla en poscosecha que puedan ser aplicados con éxito en las condiciones de operación de fincas artesanales donde se realiza secado al sol. Este método de secado implica la variación de la temperatura y humedad durante el día y la noche, lo que dificulta la precisión de los algoritmos de predicción (Adrover et al., 2019; Alean, 2011; Moreno et al., 2018).

Los algoritmos de predicción de la calidad final son modelos matemáticos que describen y relacionan procesos físicos, químicos, biológicos, entre otros (Gonçalves, 2017). Estos pueden aportar al productor información clave para tomar decisiones sobre el proceso, que le permitan obtener la calidad óptima de las semillas secas, así como el tiempo estimado en el que se espera que la semilla tenga entre 6 % y 7 % de humedad, el cual se considera el valor óptimo para finalizar la etapa de secado (Ortiz de Bertorelli, 2009). A pesar de la relevancia de la etapa poscosecha en el cultivo de cacao, ya que determina aspectos como el sabor y astringencia en el producto final (Moreno et al., 2018), existen pocos intentos de construir modelos matemáticos de la fermentación que abarquen todos los aspectos que influyen el proceso (Gil et al., 2019) y que como es el caso, que sea aplicable a las condiciones no controladas de temperatura y humedad, a las que se enfrentan los pequeños productores (Dzelagha et al., 2020).

Los modelos existentes se enfocan en etapas particulares posteriores a la fermentación, como en la cinética del secado isotérmico (Adrover et al., 2020., Chinenye et al., 2010), restringidos a la interacción secuencial de comunidades microbianas mediante el análisis de flujo metabólico (Adler, 2013), enfoques cinéticos que no incluyen la dinámica en la población microbiana apropiadamente (Alean, 2011), o incluso un modelo que describe ampliamente el comportamiento de los microorganismos a nivel bioquímico pero sin enlazar con todas las condiciones externas posibles (Moreno et al., 2018). Las razones de esto son múltiples, entre ellas, la falta de control sobre el proceso de fermentación en sí mismo, así como la complejidad de analizar las interacciones de las comunidades microbianas asociadas con los procesos de difusión de masa y calor, y especialmente cuando la temperatura de la fermentación y del secado no es controlada (Papalexandratou et al., 2011).

Con base en lo anterior, es posible indicar que para desarrollar un modelo predictivo de la humedad final de la semilla de cacao aplicable a pequeños y medianos productores, es importante tomar en cuenta que la temperatura y la humedad no son constantes en el proceso, lo cual aumenta el nivel de complejidad del algoritmo de predicción de la humedad final del grano (Alean, 2011., Anggraini, 2021., Treybal, 2020). A

nivel de producción esto se debe a la falta de control de las variables que determinan el proceso , ya que es difícil identificar los parámetros cruciales y las variables clave requeridas para la formulación de un modelo apropiado (Moreno et al., 2018).

La fermentación de cacao inicia en el momento en que el fruto es cortado, aumenta la velocidad de fermentación cuando las semillas entran en contacto con el aire, lo que hace imposible almacenar la semilla en baba para su posterior fermentación más allá de 48 horas - 54 horas. Esto implica que el sitio donde se cultiva y el lugar donde se realiza la fermentación y secado, deben estar relativamente cerca (Teneda-Llerena, 2016). A diferencia de la mayoría de los otros procesos de fermentación de alimentos, la etapa poscosecha de cacao, no está estandarizada entre productores con características similares, ya que se cuenta con una gran diversidad de técnicas y dispositivos usados por los productores, por ejemplo montículos, cajas, cestas, bandejas, sacos y plataformas para realizar la fermentación (Ayestas et al., 2014).

Debido a las razones antes expuestas, con la presente investigación se busca determinar un modelo matemático que permita establecer una metodología estandarizada de secado en el tratamiento poscosecha de cacao (*Theobroma cacao*) que pueda ser aplicada en el contexto heterogéneo de las fincas productoras de cacao agroecológico, lo que incluye regiones geográficas distintas y diferentes condiciones de humedad y temperatura inicial. Para esto se propone el desarrollo de un ejercicio de simulación del diseño de proceso de tratamiento de secado en poscosecha, por medio de la elaboración de un modelo matemático de frontera móvil para deshidratación de alimentos basado en las ecuaciones propuestas por Adrover y Brasiello (2020), acoplado a un sistema de aprendizaje automático (machine learning). Esto con el objetivo de procesar cada caso registrado en el sistema y relacionarlo con la humedad del lugar, temperatura, etc., de manera que bajo las condiciones dadas la aplicación realice predicciones sobre la calidad de un lote de cacao (humedad final, tamaño del grano, etc.) (Cortés et al., 2011).

Cabe destacar que la herramienta de aprendizaje automático considera el efecto de las condiciones no controladas de temperatura, por medio de aprendizaje del comportamiento de los datos experimentales para condiciones dadas (Riza et al., 2023). Adicionalmente uno de los algoritmos que constituyen la herramienta de aprendizaje llamado “back-propagation” permite obtener resultados más exactos y precisos en cada predicción, conforme se incrementa la información alimentada por los usuarios en el tiempo. (Angraini, 2021., Cunha et al., 2022; Tan et al., 2019).

Para efectos de delimitación del alcance de la investigación, el modelo matemático propuesto contempla principalmente la etapa de secado, como primer insumo para una investigación más amplia. Por

efectos de tiempo y complejidad del análisis, las interacciones microbianas no serán analizadas en profundidad, si no que se contemplará al fenómeno de difusión y su relación con los cambios de las variables como temperatura y humedad.

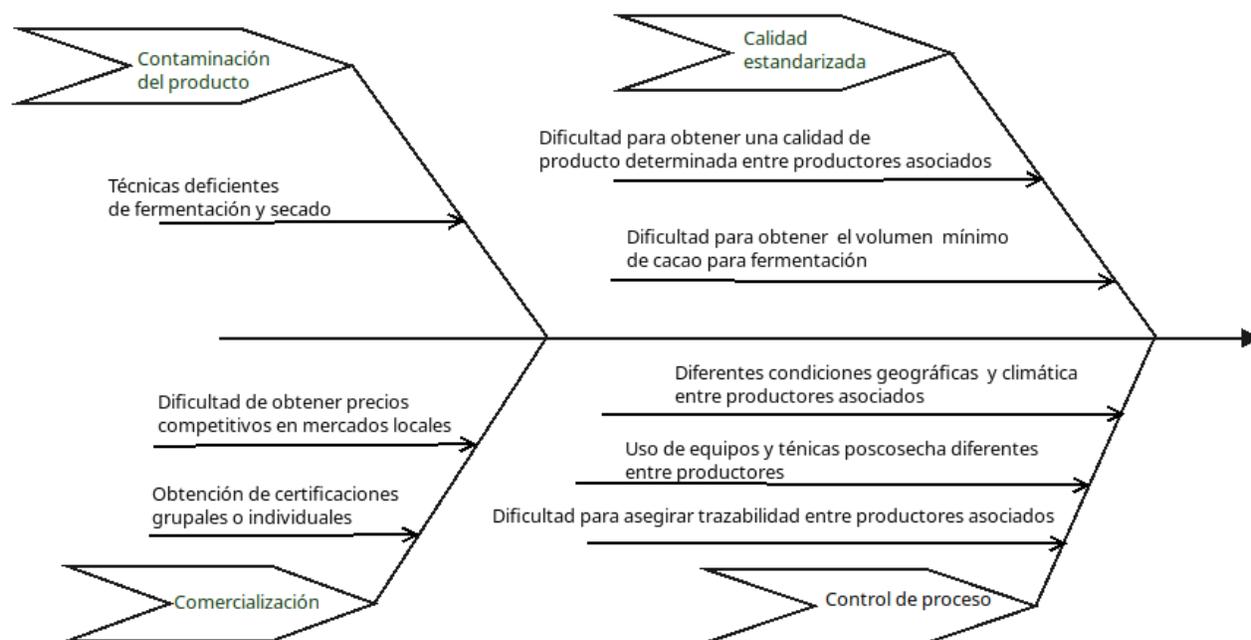
Justificación

Un problema serio que al que se enfrentan los exportadores de cacao en grano es la aparición de moho y la brotación que ocurren durante las etapas de “fermentación-secado al sol” de las semillas, especialmente durante la temporada de lluvias. Esto generó que se avanzara en la implementación de técnicas que evitaran la formación de moho y otros organismos indeseables que ahora conocemos como tratamiento poscosecha de cacao (Obakior, 1975).

Esta ha sido una situación complicada para los procesadores nacionales de cacao incluyendo a productores agroecológicos, ya que las zonas productoras; zona norte y Caribe (IICA, 2017), presentan condiciones ambientales (precipitaciones anuales entre 1500 mm y 3000 mm, temperaturas promedio de 20° C a 30° C, altitud de 0 a 900 msn), propicias para promover altas humedades relativas, 70 % a 80 %; lo cual dificulta el secado y el almacenamiento del grano, (Ayestas et al., 2014) y aumenta la proliferación de una vasta diversidad de microorganismos. Esto se agrava debido a que los dos periodos de cosecha de cacao en Costa Rica coinciden con la época lluviosa: mayo y octubre (Cubero, 1990).

Lo reportado concuerda con los hallazgos en Nicaragua y Costa Rica por Ayestas et al. (2014) y SEP-SA (2017). En ambos países, la mayoría de los productores agroecológicos entrevistados mencionaron tener dificultades con las actividades de fermentación y secado. Además, argumentaron no contar con las herramientas y técnicas necesarias para medir la temperatura y evaluar las características externas e internas de las semillas durante las pruebas de corte en el proceso de fermentación. Otro punto importante es que, debido al bajo volumen de acopio y fermentación, no logran alcanzar la temperatura requerida para una fermentación adecuada, lo cual afecta negativamente la calidad de la semilla (Figura 1).

Figura 1. Dificultades enfrentadas por pequeños y medianos productores para el procesamiento del cacao.



Nota. Elaboración propia (2024).

Lo anterior tiene implicaciones en otros aspectos relacionados con la producción, ya que la variabilidad de calidades de cacao, debido a la heterogeneidad del proceso de fermentación por la diversidad de condiciones ambientales, dificulta la obtención de certificaciones grupales en agricultura orgánica, Fair Trade, u otras certificaciones para las cooperativas de productores de cacao, ya que deben realizar enormes esfuerzos económicos y organizativos (Jacobi et al., 2014; Medina, 2009). Poner a disposición de los productores de cacao una herramienta que permita controlar el proceso de secado y fermentación en el contexto de alta humedad ambiental, permitiría obtener mayores rendimientos y optar por ingresar a nuevos mercados (CAOBISCO/AEC/FCC, 2015; Guerrero, 2007 ; Zea et al., 2017).

Objetivo General

Objetivo General

Determinar un modelo matemático descriptivo de la operación de secado en poscosecha de cacao (*Theobroma cacao*) acoplado a un sistema de aprendizaje automático, alimentado por datos experimentales, que permita desarrollar una metodología de dicha operación, que considere el efecto del cambio de

temperatura, para que sea aplicable a pequeñas y medianas fincas productoras de cacao.

Objetivos Específicos

- Proponer y simular un modelo matemático a partir de revisión bibliográfica que parametrize el proceso de secado en el tratamiento poscosecha de cacao, con el fin de predecir las condiciones finales del secado a partir de las condiciones iniciales.
- Comparar el resultado de la simulación del modelo propuesto con el resultado experimental de secado de cacao en el laboratorio, para las mismas condiciones iniciales.
- Proponer una metodología de poscosecha de cacao basada en los resultados obtenidos en el laboratorio.

Capítulo II

Marco teórico

El árbol del cacao, cuyo nombre científico es *Theobroma cacao* L., pertenece a la familia Malvácea. El término “*Theobroma*” proviene del griego y significa “alimento de los dioses”, mientras que “*cacao*” deriva del nahua “*cacáhua*”. El cacao es la materia prima principal para la fabricación del chocolate (Tinoco et al., 2010).

De acuerdo con Herrera (2016), la clasificación tradicional de variedades de árboles de cacao implica al cacao Criollo, Forastero, Trinitario y CCN51; sin embargo, esta clasificación no toma en cuenta los recursos genéticos específicos de cada variedad, por lo que resulta insuficiente para describir a todas las variedades (Motamayor et al., 2008). Debido a lo anterior el mismo autor y demás colaboradores, plantearon una nueva clasificación basada en el germoplasma como patrón de diferenciación, con lo cual se establecen 10 clusters genéticos o grupos mayores. Estos son Marañón, Curaray, Criollo, Iquitos, Nanay, Contamana, Amelonado, Purús, Nacional and Guiana.

En el caso de Costa Rica, un trabajo de investigación desarrollado por el CATIE en 2007, y que contó con 15 años de estudios previo, dió el inicio a la distribución en Centroamérica de 6 clones sobresalientes de alto rendimiento y tolerancia a la moniliasis (Philiph et al., 2012), algunos de estos con capacidad productiva de más de 2000 kg/ha* año de cacao seco, estos son: CATIE R-1 (VERDE), CATIE R-4 (ROJO), CATIE R-6 (AMARILLO), ICS-95 (NEGRO), CC-137 (BLANCO) Y PMCT-58 (AZUL) (Chacón, 2019). De los anteriores, los clones que mayor producción y rendimiento son: CATIE R-4 (ROJO), CATIE R-6(AMARILLO) (Philiph et al., 2012).

Beneficiado de cacao

De acuerdo con Ayestas et al., (2016), el tratamiento poscosecha o beneficiado es la operación crítica del proceso de producción de cacao y por lo tanto también es crítica en la elaboración de Chocolate (Álvarez et al., 2010). El acondicionamiento de las semillas de cacao se lleva cabo después de ser ex-

traídas del fruto, luego son depositadas en dispositivos especiales y en condiciones apropiadas para que las transformaciones físicas, químicas y microbiológicas mejoren su calidad y conservación. El Beneficiado (poscosecha) consta de las siguientes etapas principales (Ayestas et al., 2016; Estrada et al., 2011).

Cosecha, quebrado y extracción

La cosecha requiere ser efectuada a intervalos regulares de 10 días a 15 días y en ningún caso exceder de las tres semanas (Umaña, 2013). Comúnmente, el quebrado de las mazorcas se realiza utilizando un mazo de madera o el lomo de un machete, mientras que la extracción del cacao en baba se lleva a cabo manualmente. No obstante, también existen máquinas quebradoras-despulpadoras automatizadas que pueden realizar estas tareas (Ayestas et al., 2016).

Traslado al lecho de fermentación

Después de cortados los frutos con machetes o cuchillos desinfectados, se tiene un máximo de 48 horas, en las que se puede mantener el cacao en fruto sin perder sus características; y luego de que extraen las semilla se cuenta con 6 horas para iniciar el proceso de fermentación (Aguilar, 2017).

Fermentación

Durante el procesamiento post-cosecha del cacao, los principales productos finales de la descomposición de los sustratos de la pulpa (glucosa, fructosa y ácido cítrico) por parte de las levaduras, las bacterias del ácido láctico (LAB) y las bacterias del ácido acético (AAB) son el etanol, el ácido láctico, el manitol y/o el ácido acético (Papalexandratou et al., 2011). Entre las especies bacterianas dominantes en la fermentación reportadas en la literatura se encuentran: *Lactobacillus fermentum* y *Acetobacter pasteurianus* (Papalexandratou et al., 2011), *Lactobacillus plantarum*, *Acetobacter tropicalis* (Camu et al., 2007), entre otros.

Durante esta etapa, el mucílago que cubre las semillas y que tiene un alto contenido de azúcar, se va separando del cotiledón por procesos difusivos (Ayestas et al., 2016). También en esta etapa, se previene la

germinación del embrión al aumentar la temperatura del cacao y la producción de ácido acético, lo que a su vez conduce al desarrollo del sabor y el aroma del producto final. (Ureña, Sandoval, 2021). A continuación se describen dos de los métodos más usados (Figura 2).

El método Rohan (1960), descrito por Umaña (2013); Ureña, Sandoval (2021); en el que los granos se colocan en una serie de bandejas apiladas, cada una con dimensiones aproximadas de 120 cm, por 80 cm, por 10 cm, y una capacidad aproximada de 70 kilogramos de cacao húmedo por bandeja (Figura 2). El método de caja, implica realizar la fermentación en cajones de madera con dimensiones variables que dependen de la cantidad a fermentar, pero basado en el hecho de que un cajón de un metro cúbico de volumen, puede contener de 800 kg a 850 kg de cacao (Umaña, 2013) (Figura 2). Algunas maderas no convencionales, que son usadas para crear cajones de fermentación, son laurel, pino, guayacán blanco (Erazo-Solórzano et al., 2021).

Figura 2. Representación del sistema de fermentación de cajas (figura de la izquierda) y del método de Rohan (figura de derecha).



Nota. Elaboración propia (2024).

Durante el proceso de fermentación, la masa de cacao se voltea a las 24, 48, 72, 96 y 120 horas después de que ha comenzado el proceso, con el fin de separar el lixiviado de la masa en fermentación (Álvarez et al., 2010).

Determinación del punto final de la fermentación

La información reportada en la literatura, difiere en cantidad de días de fermentación y secado de un autor a otro; por ejemplo, Álvarez et al., (2010), mencionan que el proceso de fermentación en cajas dura cinco días y el secado cinco días para las condiciones meteorológicas de Curiepe, Venezuela. Sin embargo, en otras zonas geográficas el tiempo de poscosecha podría variar, por ejemplo bajo las condiciones climáticas de Bahía, Brasil; lugar en el que Papalexandratou et al., (2011) utilizaron seis días para fermentación en cajas (Método Rohan, 1960), pero con dimensiones diferentes: 1,2 metros por 1,2 metros por 1,0 metros. En el manual elaborado por la Sede Costarricense del IICA, se menciona que el tiempo de fermentación recomendado es 5 días a 6 días (Arvelo et al., 2017).

La determinación de calidad de los granos fermentados se relaciona con la cocción del cotiledón observado en el color del mismo, el día final de fermentación, por lo que un indicador de fermentación incompleta, es la presencia de cotiledones de colores violáceos y pizarrosos (Ortiz de Bertorelli et al., 2009; Rohan, 1964). Como la cantidad de masa de fermentación influye en la temperatura de la fermentación, es necesario aplicar la prueba de corte (Ortiz de Bertorelli et al., 2009; Baker et al., 1994). La prueba de corte está regulada en Costa Rica por la norma nacional INTE 23-02-04-09: "Cacao y productos derivados del cacao", en la cual se toma una muestra de 100 gramos de granos procesados en un intervalo de tiempo determinado (Rivera et al., 2012), y se clasifican según tamaño, integridad, presencia de hongos, porcentaje de humedad y estados de fermentación (Álvarez, 2016).

Secado

Secado es una operación unitaria en la que un componente volátil dentro de una sustancia con componentes menos volátiles que este, abandona la masa original por evaporación (Treybal, 2000). Un tipo de secado común en procesamiento de alimentos es la deshidratación, que se da cuando el compuesto volátil es agua (Tinoco y Ospina, 2010). En la etapa del secado de la operación poscosecha de cacao, no solo el agua sale del grano, sino que también lo hace el ácido acético y el ácido láctico, lo que provoca disminución de la acidez del cacao (Moreno et al., 2018). Este proceso debe realizarse de tal manera que se obtenga un contenido de humedad de aproximadamente el 7 % (Deus et al., 2018; Dzelagha, 2020). El secado realizado después de la fermentación, produce la disminución del amargor, la astringencia y la acidez de las semillas de cacao al final de la poscosecha (Barrientos et al., 2019).

Con respecto a poscosecha de cacao realizada de forma artesanal o tradicional (productores medianos y pequeños principalmente), el secado debe realizarse de forma suave, para que el ácido acético no se encapsule en el interior del cotiledón, en los primeros días de secado.

El encapsulamiento del ácido acético produce una nota ácida en el sabor final y también hace que la semilla adquiera forma de hojuela, esto disminuye la percepción de calidad (Castillo-Orozco, 2023). Sin embargo es importante que el secado no sea demasiado lento, por que entonces se podría favorecer la formación de moho (Adewumi et al., 2016).

Modelos Fenomenológicos

Los modelos fenomenológicos buscan establecer relaciones matemáticas que reflejen la naturaleza multidisciplinaria de los procesos reales, integrando las diferentes propiedades y variables que influyen en el comportamiento del sistema (Cortés et al., 2011; Herman et al., 2018). Estos se clasifican como microscópicos y macroscópicos. Los modelos macroscópicos no contienen gradientes espaciales y la única variable independiente es el tiempo. Sin embargo, este tipo de modelos no brindan información con respecto al comportamiento interno del sistema (Alean, 2011).

Los modelos microscópicos resultan del planteamiento de las ecuaciones de balance de masa y/o energía, deducida a partir de un elemento diferencial de volumen a través del cual se efectúa el transporte correspondiente, a este elemento se le llama gradiente (Adrover, 2020). Este tipo de modelos, se clasifican como modelos de transferencia simultánea de masa, calor y momentum, modelos basados en la termodinámica de los procesos irreversibles, modelos difusivos y modelos cinéticos (Alean, 2011; Hii et al., 2013).

Independientemente del tipo de modelo elegido, en los últimos años se ha tratado de tener en cuenta otras especies químicas diferentes al agua que influyen en las características organolépticas (sabor, entre ellas) (Rojas et al., 2020). Una de las maneras de hacerlo es contemplando algunos ácidos, especialmente el ácido acético presente en la semilla (Moreno et al., 2018).

Modelo de frontera móvil para deshidratación isotérmica del alimentos

El modelo de frontera móvil para deshidratación isotérmica de alimentos permite estimar el efecto de la difusión de agua en la etapa de deshidratación y relacionarla con la calidad final de la semilla seca (Adrover et al., 2019). El planteamiento metodológico del modelo permite analizar y caracterizar la cinética de deshidratación y contracción de los granos fermentados de cacao, a partir de los datos experimentales reportados. El modelo de frontera móvil de Adrover et al., (2019), ya se aplicó correctamente para describir la cinética de deshidratación y contracción de diferentes materiales alimenticios y diferentes formas de muestra, por ejemplo, berenjena cilíndrica y muestras discoidales, rodajas de chayote, palitos de papa, entre otros (Adrover et al., 2019). Desde la formalidad de la modelización de procesos, se puede mencionar que en la construcción del modelo de frontera móvil, Adrover et al., (2019) se basó en las siguientes suposiciones propuestas inicialmente por Herman et al., (2018).

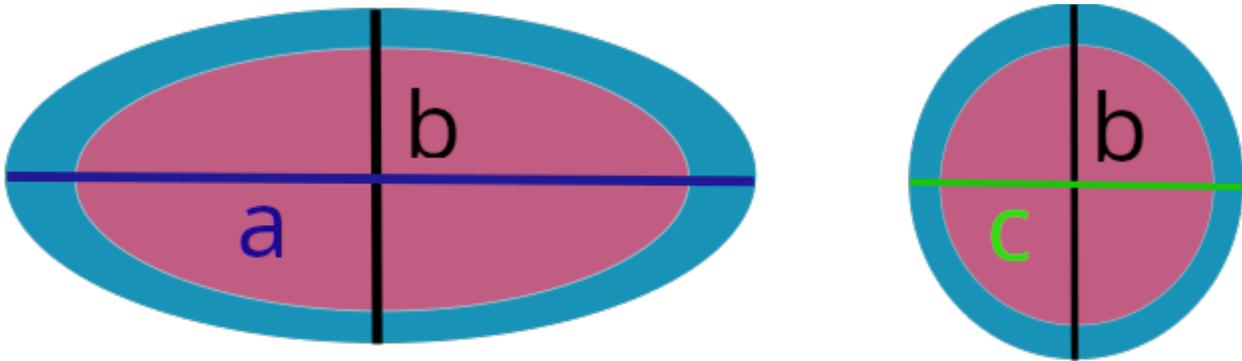
El agua se distribuye heterogéneamente en una semilla de cacao fresco; su concentración es mayor en el cáscara que en el núcleo, por lo tanto, la velocidad de secado de una semilla se puede dividir en dos fases; primero ocurre la fase de deshidratación rápida inicial de la cáscara en la etapas de escurrimiento y presecado, seguida de la fase de deshidratación lenta del cotiledón en la etapa de fermentación y secado (Adrover et al., 2019; Adrover et al., 2020; Herman et al., 2018). Los fenómenos de transporte de masa externo controlan la primera fase, mientras que los fenómenos de transporte de masa interno controlan la segunda (Adrover et al., 2020).

Con respecto a la características geométricas necesarias para parametrizar el fenómeno de difusión en la semilla, se toma en cuenta que la semilla de cacao suele tener forma elipsoidal y la estructura interna consta de un núcleo central rodeado por una cáscara delgada, que representa aproximadamente el 20 % de la masa total de la semilla (Adrover et al., 2019; Adrover et al., 2020). El contenido de agua en el núcleo y la cáscara puede ser muy diferente de una semilla a otra, lo cual puede tener influencia en la cinética de deshidratación, que se acompaña de una reducción moderada del volumen (encogimiento), alrededor del 30 % del volumen inicial (Hii et al, 2013).

Disminución del volumen de la semilla

El modelo de frontera móvil se aplica a semillas elipsoidales en tres dimensiones (Figura 2), tomando en cuenta los siguientes tres aspectos: 1) que la semilla cuenta con una estructura interna (cotiledón y cáscara), 2) la falta de uniformidad del contenido de agua inicial y 3) la contracción del volumen con el fin de aproximar con precisión el proceso de deshidratación en dos fases de las semillas de cacao, según lo observado por Herman et al., (2018), y aplicado por Adrover et al., (2020). Los principales parámetros morfológicos y físicos de una semilla de cacao promedio son: la longitud inicial de los tres principales ejes a_0, b_0, c_0 , el espesor inicial de la cáscara λ_0 , la cual está representada por la franja de color celeste en la Figura 2.

Figura 3. Determinación de las dimensiones del grano de cacao (Adrover et al., 2020)



Nota. Elaboración propia (2024).

Tanto los parámetros de ejes iniciales como el contenido de humedad total inicial X_0 pueden ser determinados experimentalmente y están relacionadas con las ecuaciones 1, 2, 3 y 4, éstas se muestran a continuación (Adrover et al., 2020; Herman et al., 2018).

$$X_0^{core} = \frac{M_0^{core} - M_d^{core}}{M_d^{core} + M_d^{shell}} \quad (1)$$

$$M_d = M_d^{core} + M_d^{shell} \quad (2)$$

Donde:

X_0^{core} : es el contenido de humedad inicial del cotiledón ($kg_{agua}/kg_{base-seca}$).

M_d : es la masa de cacao seca total (kg).

M_d^{core} : es la masa seca del cotiledón (kg).

M_d^{shell} : es la masa seca de la cáscara (kg).

$$M_0 = M_0^{core} + M_0^{shell} \quad (3)$$

Donde:

M_0 : es la masa de cacao al inicio de fermentación (masa húmeda) (kg).

M_0^{shell} : es la masa inicial de la cáscara (kg).

M_0^{core} : es la masa inicial del cotiledón (kg).

La fracción volumen de agua inicial φ_0 (promediada sobre toda la semilla, es decir, el núcleo y la cáscara) dentro de la semilla de cacao, se puede estimar de la siguiente manera (Herman et al., 2019; Adrover et al., 2020).

$$\varphi_0 = \frac{M_0 - M_d}{\rho_w V_0} = \frac{M_0}{\rho_w V_0} \frac{X_0}{1 + X_0} \quad (4)$$

Donde:

V_0 : es el volumen inicial de la semilla (m^3).

ρ_w : es la densidad del agua (kg/m^3).

Otro de los parámetros necesarios para construir el modelo es el Radio equivalente, el cual es una estimación del radio que tendría una semilla de cacao si este tuviera forma esférica. Esta estimación se realiza mediante las siguiente ecuaciones (Adrover et al., 2019).

$$R_{eq} = \frac{1}{3} (R_g + R_a + R_s) \quad (5)$$

$$R_g = \frac{1}{2} \sqrt[3]{abc} \quad (6)$$

$$R_a = \frac{1}{6} (a + b + c) \quad (7)$$

$$R_s = \frac{1}{2} \sqrt{\frac{ab + bc + ac}{3}} \quad (8)$$

Donde:

R_g : es el radio geométrico promedio (mm).

R_a : es el radio geométrico aritmético (mm).

R_s : es el radio promedio cuadrado (mm).

Del desarrollo de las expresiones anteriores es posible obtener una ecuación que relaciona las dimensiones iniciales de la semilla (a_0, b_0, c_0) (Herman et al. 2018). Por lo tanto, el radio equivalente R_{eq} se puede obtener de la siguiente forma (ecuación 9):

$$R_{eq} = 3 \frac{(\pi/6) a_0 b_0 c_0}{4\pi \left(\frac{a^p + b^p + c^p}{3} \right)^{\frac{1}{p}}} \quad (9)$$

De acuerdo con Adrover et al., 2020, p es aproximadamente 1,605.

Descripción del proceso de Difusión (ecuación de transporte de masa)

El fenómeno de la difusión se refiere al desplazamiento de un soluto a través de una sustancia, por medio de un gradiente de concentración como fuerza motriz (Treybal, 2000). La ecuación de transporte de masa permite parametrizar el proceso de difusión, ya que describe la trayectoria del espacio-tiempo, de tal forma que define la concentración puntual de agua $c_w(x, t)$ dentro de la semilla, cuyo volumen $V(t)$ y la superficie $S(t)$ en estado transitorio. La siguiente ecuación representa la contracción local a través de la velocidad de contracción puntual $v(x)$ (Adrover et al., 2019).

$$\frac{\partial c_w(x, t)}{\partial t} + \nabla \cdot (v(x) \cdot c_w(x, t)) = -\nabla \cdot J = \nabla \cdot (D \nabla c_w(x, t)), x \in V(t) \quad (10)$$

Donde

$c_w(x, t)$: es la concentración de masa de agua.

J : es la tasa de deshidratación (h^{-1}).

$\nabla \cdot (cv)$: es un término convectivo asociado de la contracción de la semilla.

Del desarrollo de la ecuación 10 se obtiene el número másico de Biot Bi_m , el cual es un indicador de la velocidad de deshidratación de la semilla (Herman et al., 2019) y se puede calcular de la siguiente forma (ecuación 11).

$$Bi_m = \frac{h_m L_r}{D} K_{eq} \frac{\rho_{air}}{\rho_s} \quad (11)$$

Donde:

h_m : es el coeficiente de transferencia de masa (m/s).

ρ_{aire} : es la densidad del aire en base seca ($kg_{aireseco}/m^3$).

ρ_s : es la densidad de la pulpa ($kg/m^3_{producto}$).

D : es el coeficiente de difusividad (m^2/s).

K_{eq} : es la relación de reparto del agua entre las fases gaseosa y sólida en condiciones de equilibrio (*adimensional*).

L_r : es la Longitud característica (mm).

Las condiciones iniciales son: $\tilde{V}(0) = \tilde{V}_0$, $\tilde{S}(0) = \tilde{S}_0$ y $\varphi(\tilde{x}, 0) = \varphi_0(\tilde{x})$ (Adrover et al., 2020; Herman et al., 2018). Con este modelo se determinan tres aspectos de los que se obtienen las relaciones que se muestran en los resultados (Adrover et al., 2020; Herman et al., 2018):

a) La influencia de la forma elipsoidal en la cinética de deshidratación en el caso más simple de una distribución de agua inicial uniforme, cuando $\varphi_0(x) = constante$ y en ausencia de contracción, es decir $\alpha(\varphi) = 0$. La tasa de deshidratación cuando la distribución inicial de agua es uniforme se representa de la siguiente forma (ecuación 12):

$$J_d = \frac{-dX_r}{dt} = \frac{DY_0^2}{R_{eq}^2} X_r \quad (12)$$

Donde:

J_d : es la tasa de deshidratación (*adimensional*).

X_r : es la tasa de humedad (*adimensional*).

X : es la humedad en cualquier instante ($kg_{agua}/kg_{base-seca}$).

X_0 : es la humedad inicial ($kg_{agua}/kg_{base-seca}$).

X_{eq} : es la humedad equivalente ($kg_{agua}/kg_{base-seca}$).

X_{eq} , se determina por medio de una ecuación empírica, que calcula la tasa de humedad X_r (este parámetro se calcula mediante el proceso descrito en la metodología). Por lo tanto X_r se representa de la siguiente forma :

$$X_r = \frac{X - X_{eq}}{X_0 - X_{eq}} \quad (13)$$

Por lo tanto al sustituir la ecuación 13 en la ecuación 12 se obtiene la ecuación 14, la cual se muestra a continuación:

$$J_d = \frac{-dX_r}{dt} = \frac{DY_0^2}{R_{eq}^2} \frac{X - X_{eq}}{X_0 - X_{eq}} \quad (14)$$

b) La influencia de la distribución inicial de agua de manera no uniforme, cuando $\varphi_0(\tilde{x}) = \varphi_0^{core}$ para

$\tilde{x} \in \tilde{V}^{core}$ y $\varphi_0(x) = \varphi_0^{shell}$ para $x \in \tilde{V}^{shell}$, en la tasa de deshidratación (ausencia de contracción), $\alpha(\varphi) = 0$.

La tasa de deshidratación para distribución inicial no uniforme de agua y sin efecto de la contracción, es equivalente al caso en el que la distribución es uniforme y sin contracción. Lo anterior fue determinado experimentalmente por Adrover et al. (2020).

c) La influencia en la tasa de deshidratación, del factor de contracción constante $\alpha(\varphi) = \alpha_0$. Distribución inicial no uniforme de agua y efecto de la contracción

La implicación del factor de contracción se puede apreciar mediante la siguiente curva de calibración lineal de forma que Υ es la raíz positiva más pequeña de la ecuación 15 (Adrover et al., 2019). Para calcular el parámetro $\tilde{B}i_m^{eq}$ se utiliza la ecuación 16.

$$\Upsilon \cot(\Upsilon) + \tilde{B}i_m^{eq} - 1 = 0 \quad (15)$$

$$\tilde{B}i_m^{eq} = \tilde{B}i_m \left(\frac{\tilde{R}_{eq}}{L_r} \right) = \tilde{B}i_m \left(\frac{R_{eq}}{L_r} \right) \left(\frac{V_{eq}}{V_r} \right)^{\frac{1}{3}} \quad (16)$$

Donde:

$\tilde{B}i_m$: es número másico de Biot cuando hay contracción del grano (donde valores altos de $\tilde{B}i_m$ representan tasas mayores de transferencia de masa).

L_r : es la longitud específica (mm).

\tilde{R}_{eq} : es el radio equivalente cuando hay contracción del grano (mm).

V_r : es el volumen característico del grano (mm³).

V_{eq} : es la volumen equivalente si un grano tuviera forma esférica (mm³) (Adrover et al., 2020).

Ecuaciones diferenciales sobre la operación de secado, tomando en cuenta el efecto de la difusión

A partir de las expresiones de velocidad de deshidratación V_1 (ecuación 17) y V_2 (ecuación 18), la expresión que describe la tasa de deshidratación adimensional J_d (ecuación 12), se logra obtener una expresión intermedia (ecuación 19), que relaciona la tasa de deshidratación X_r , a través de la expresión que muestra el decaimiento del contenido de humedad con respecto al tiempo $d \left[\frac{X}{X_0} \right]$, y la tasa de deshidratación adimensional J_d . Esta expresión matemática es el punto de partida, para obtener una expresión que

permita evaluar las condiciones que competen a la deshidratación de la semilla. La distribución uniforme y no uniforme del agua, sin contracción de la semilla (predominante en la fermentación) se puede representar por la ecuación 17.

$$V_1 = J_d = \frac{-dX_r}{dt} = \frac{DY_0^2}{R_{eq}^2} X_r \quad (17)$$

La distribución no uniforme del agua con contracción de la semilla (predominante en el secado) se representa por la ecuación 18.

$$V_2 = J_d = \tilde{Y}_0^2 \left[\frac{L_r}{R_{eq}} \right]^2 \left[\frac{V_{eq}}{V_0} \right]^{\frac{-2}{3}} X_r \quad (18)$$

La siguiente ecuación diferencial es la expresión general de la tasa de deshidratación, la cual representa la cantidad de agua que abandona la semilla en un instante determinado (Adrover et al., 2020).

$$j_d = \frac{-dX_r}{dt} = \frac{-d}{dt} \left[\frac{X - X_{eq}}{X_0 - X_{eq}} \right] = \frac{d \left[\frac{X}{X_0} \right]}{dt} \frac{-1}{1 - \frac{X_{eq}}{X_0}} \quad (19)$$

La ecuación anterior se puede expresar en términos de $d \left[\frac{X}{X_0} \right]$ (ecuación 20), utilizando la expresión que muestra el decaimiento del contenido de humedad con respecto al tiempo, los coeficientes de esta ecuación pueden ser determinados experimentalmente por medio de la ecuación 21, en este caso se mide la humedad en intervalos durante el secado, y de la expresión polinómica que sea ajustable se obtienen los coeficientes que resuelven la ecuación (Adrover et al., 2020).

$$\frac{d \left[\frac{X}{X_0} \right]}{dt} = \frac{J_d \left[1 - \frac{X_{eq}}{X_0} \right]}{-1} \quad (20)$$

$$\frac{X(t)}{X_0} = a_0 + a_1 e^{-b_1 t} + a_2 e^{-b_2 t} + [1 - a_0 - a_1 - a_2] e^{-b_3 t} \quad (21)$$

Ecuación para el caso de distribución uniforme de agua al evaporarse sin efecto de contracción de la semilla

Reacomodando y evaluando la tasa de deshidratación para el caso de distribución uniforme de agua sin contracción (ecuación 2.17) en la ecuación 2.20, se obtiene el decaimiento de humedad en la semilla

(ecuación 2.22). Esta ecuación relaciona el decaimiento de la humedad de la semilla $d \left[\frac{X}{X_0} \right]$ con la tasa de humedad X_r , el radio equivalente R_{eq} , el factor (γ) y el coeficiente de difusión D .

$$\frac{d \left[\frac{X}{X_0} \right]}{dt} = \left[\frac{D\tilde{\gamma}_0^2}{R_{eq}^2} \right] \left[\frac{X_{eq}}{X_0} - 1 \right] \left[\frac{X - X_{eq}}{X_0 - X_{eq}} \right] \quad (22)$$

La velocidad de deshidratación representada por la expresión anterior coincide con la etapa de fermentación anaeróbica al inicio de la poscosecha (Koua et al., 2019), en la cual el flujo difusivo de azúcares y otros compuestos de la pulpa tiene dirección hacia al interior de la semilla (Adrover et al, 2019).

Ecuación para el caso de distribución no uniforme de agua al evaporarse y sin efecto de contracción del grano

De acuerdo con los experimentos de Adrover et al., (2019, 2020), en ausencia de contracción, la relación es lineal de la tasa de deshidratación J_d frente a X_r , (para valores pequeños de X_r e intervalos de deshidratación largos, como en el caso de la fermentación espontánea y secado al sol), es similar tanto para distribución no uniforme de agua como para distribución uniforme, por lo que la ecuación 22 aplica para ambos casos. Este escenario corresponde con la etapa de fermentación aeróbica, donde la concentración del agua no es uniforme en el cotiledón y la velocidad de deshidratación es lenta, por lo que no hay contracción de la semilla (Herman et al., 2019).

Ecuación para el caso de distribución no uniforme de agua al evaporarse y además efecto de contracción del grano

Reacomodando para expresar la ecuación en términos de $\frac{d \left(\frac{X}{X_0} \right)}{dt}$ y evaluando la tasa de deshidratación para el caso de distribución no uniforme de agua al evaporarse y con efecto de contracción del grano (ecuación 18) se obtiene la siguiente expresión:

$$\frac{d \left(\frac{X}{X_0} \right)}{dt} = \tilde{\gamma}_0^2 \left(\frac{L_r}{R_{eq}} \right)^2 \left(\frac{V_{eq}}{V_0} \right)^{-\frac{2}{3}} \left(\frac{X - X_{eq}}{X_0 - X_{eq}} \right) \left(\frac{X_{eq}}{X_0} - 1 \right) \quad (23)$$

La ecuación 23 es una expresión diferencial que describe la pérdida de humedad para la semilla en contracción en función del tiempo y corresponde con la etapa de secado (Obando-Ulloa et al., 2019). La velocidad de deshidratación tiene un impacto en la contracción de la semilla, se conoce que si la velocidad

de deshidratación al inicio del secado es alta y constante, la semilla tendrá mayor contracción (Herman et., 2019; Koua et al., 2019).

Herramienta de aprendizaje automático

El aprendizaje automático (Machine Learning) alude a la habilidad de un sistema para obtener e incorporar conocimiento mediante el procesamiento de datos experimentales a gran escala (Russel, 2018). También se refiere a la capacidad de simular procesos a través de ajustar nuevos conocimientos dados por las condiciones propias del sistema o entorno, en lugar de ser programado previamente para dar una sola respuesta a unas condiciones dadas (Cunha et al., 2022).

La Red Neuronal Artificial (Artificial Neural Network: ANN) es una de las principales herramientas utilizadas en el aprendizaje automático, la cual simula la estructura neuronal de la corteza cerebral de los mamíferos, pero en una escala básica (Anggraini, 2021). En la forma más básica de las Redes Neuronales Artificiales (ANN), los efectos de las conexiones sinápticas se representan mediante "pesos" que modulan el impacto de las señales de entrada, y la propiedad no lineal de las neuronas se simboliza a través de una función de transferencia (Tan et al., 2019). Posteriormente, la activación de la neurona se calcula como la suma ponderada de las señales de entrada, transformada por la función de transferencia. Cuando la información se propaga hacia atrás para que la red funcione efectivamente como un sistema de computación autoprogramable y retroalimentado, se le conoce como backpropagation (Gonçalves, 2017). De los estudios realizados en el tema, se sabe que ANN es útil en el reconocimiento de patrones, la predicción de la vida útil, la discriminación de calidad y la clasificación en la industria alimentaria (Tan et al., 2019). La unidad básica de ANN es la neurona, la cual puede verse como un dispositivo o unidad lógica como muchas entradas y muchas salidas. La red neuronal completa tiene dos modos de operación: entrenamiento y uso. En la parte de entrenamiento se puede utilizar información experimental, así como el uso de algoritmos que permitan utilizar los resultados bajo condiciones ideales (modelo de deshidratación isotérmico de Adrover et al., 2020), como punto de partida para la aproximación del sistema en condiciones reales (sistema caótico oscilatorio) (Olofintuyi et al., 2023; Tronci et al., 2016). Algunas de las ventajas de implementar una red neuronal de aprendizaje se muestran a continuación:

Aprendizaje adaptativo: capacidad de aprender a realizar tareas basadas en datos experimentales.

Esta funcionalidad es central en la investigación, ya que en las fincas en las que el proceso de poscosecha de cacao, se lleva a cabo de forma artesanal, no es común contar con ambientes controlados térmicamente (Ayestas et al., 2014), lo cual dificulta la predicción de la humedad debido a que el sistema, al interactuar con las condiciones ambientales, sigue un comportamiento caótico (Calvo et al., 2021). También se destaca el hecho que en la etapa de fermentación, predomina el mecanismo cinético de reacción compleja, influido por muchos factores (Schwan, 2014; Papalexandratou, 2011), el cual se puede representar como un sistema caótico por el método de Brusselator (Gonçalves, 2017; Tronci et al., 2003).

Autoorganización: la red neuronal artificial puede crear su propia forma de organizar o representar la información que recibe durante el tiempo de aprendizaje, lo cual es útil cuando se pretende predecir modelos caóticos u oscilatorios (Tronci et al., 2016).

Operación en tiempo real: con el uso de dispositivos hardware diseñados para este fin, los cálculos de red neuronal artificial se pueden realizar en paralelo y mostrar un resultado en el instante de la consulta (Tronci et al., 2016). Esta opción es útil para realizar control de proceso, o sea poder tomar decisiones, de acuerdo con las condiciones esperadas, lo que permitiría a los productores, reducir las pérdidas por contaminación o sobrefermentación (McDowel, 2024).

Tolerancia a fallas a través de codificación redundante: si bien la destrucción parcial de una red conlleva a la disminución del desempeño de la herramienta, algunas de las capacidades de la red pueden preservarse incluso con daños significativos (Adewumi, 2016; Olofintuyi et al., 2023; Tronci et al., 2016).

La red neuronal opera en dos modos: el modo de entrenamiento y el modo de uso. Durante el modo de entrenamiento, la red puede ser entrenada para responder o no responder a patrones de entrada específicos (Adewumi, 2016). En el modo de uso, cuando se presenta un patrón de entrada previamente enseñado, la salida asociada a dicho patrón se convierte en la salida actual de la neurona. (Olofintuyi et al., 2023; Tronci et al., 2016).

Para estos efectos una red neuronal, se puede definir como un sistema computacional que consiste en una composición de funciones $f^{(i)}$, que toma valores de entrada x y retorna valores de salida y , y además está inspirado en la redes neuronales biológicas (Bonde et al., 2020).

Una regla de aprendizaje es un algoritmo para actualizar los pesos de una red con el fin de lograr minimizar una función de error asociada con la red, también denominada función objetivo o de pérdida representada como L (Ernst, 2016).

Redes de retroalimentación (Feedforward): El objetivo de una red feedforward es aproximar algu-

na función $f^{(i)}$ basada en el conjunto de entrenamiento de entradas x , en este caso el sistema debe clasificar las entradas en dos categorías de manera que la función sea $y = f(x, \theta)$, donde θ el vector que permite obtener la mejor aproximación de la función $f^{(i)}$ (Ruder, 2016).

La red consta de capas de neuronas, donde a cada neurona se le asigna una activación que se calcula utilizando el peso de salida de la capa anterior. Entre las neuronas en la capa i e $i + 1$ tienen conexiones con “pesos” asociados, los cuales forman parte de los parámetros θ que se adaptan durante el aprendizaje proceso. También se añade un sesgo a la activación de cada neurona, y estos son la segunda parte de los parámetros θ de la red (Bonde et al., 2020).

Entrenamiento de Redes Neuronales: Se basa en adaptar los parámetros θ de tal manera que estos valores tiendan a aproximar la función con cierta precisión (Ruder, 2016). Para el efecto de clasificación de puntos que compete, se parte de un conjunto de N ejemplos de entrenamiento $x^{(i)}$ con las salidas correspondientes $y^{(i)}$ previamente dados. La red usará esto para calcular una salida $\hat{y}^{(i)} \in [0, 1]$. Para medir el rendimiento de la red utiliza la función de pérdida, la cual alcanza un valor alto si la red está funcionando deficientemente. De lo contrario, alcanza un valor bajo (Bonde, 2020).

Propagación hacia atrás (Backpropagation): Para el cálculo del gradiente de la función de pérdida se utiliza el algoritmo conocido como “Backpropagation”, el cual es útil cuando se tienen una gran cantidad de parámetros en la red neuronal, ya que calcular el gradiente analíticamente se vuelve inviable. El algoritmo compara las salida actuales y las salidas anteriores, asignado un peso que se representa a través de los parámetros θ . La solución del algoritmo es un conjunto de valores que minimizan la función de pérdida L . (Ernst, 2016; Adewuni, 2016)

Descenso de Gradiente Estocástico (SGD): Es un algoritmo para encontrar el mínimo de una función de pérdida. Se basa en el hecho que la gradiente de una función siempre apunta en la dirección de máximo aumento, por lo que moviéndose en la dirección opuesta del gradiente se puede lograr una mejora en el valor de la función de pérdida (Bonde, et al., 2020).

El descenso de gradiente estocástico (SGD) realiza actualizaciones de los parámetros θ para cada ejemplo de entrenamiento $x^{(i)}$ y etiqueta $y^{(i)}$, lo cual resulta en actualizaciones frecuentes con una alta variación, lo que acota la funciones objetivo que tienen alta fluctuación (Ruder, 2016).

Algoritmo de optimización de gradiente: Se utiliza el algoritmo como ADAM: estimación del momento adaptativo (Adaptive Moment Estimation), el cual calcula las tasas de aprendizaje adaptativo para cada parámetro; además de almacenar y mantener un promedio de gradientes cuadrados anteriores que

decae exponencialmente (Ruder, 2016).

El algoritmo ADAM es un método de optimización de primer orden para funciones estocásticas que se basan en estimaciones adaptativas de momentos de primer y segundo orden. (Ruder, 2016). El momento (Momentum) es un método que ayuda a acelerar la convergencia de SGD en la dirección relevante y amortiguar las fluctuaciones. Lo hace sumando una fracción γ (Fracción de momentum) al vector actualizado, de manera que el resultado del actual es el valor inicial de la siguiente iteración (Bonde et al., 2020; Ruder, 2016).

Modelo de aprendizaje integrado: Librería scikit-learn 1.4.1: Python 3, es un lenguaje de programación particularmente útil para resolver un ejercicio de machine learning, esto debido a que su funcionamiento modular le permite integrar librerías especializadas en operaciones matemáticas de alto nivel, tal es el caso de la librería Scikit-learn 1.4.1. Las herramientas pertinentes de esta librería se presentan a continuación:

Multi-layer Perceptron (MLP): El perceptrón multicapa (MLP) es un algoritmo que aprende una función $f(\cdot) : R^m \rightarrow R^o$, y que mapea desde un espacio de dimensión m a uno de dimensión o , a través del entrenamiento en un conjunto de datos. A diferencia de la regresión logística, el MLP puede tener una o más capas no lineales intermedias, conocidas como capas ocultas, entre la capa de entrada y la de salida. Esto le permite aprender a aproximar funciones no lineales para tareas de clasificación o regresión, a partir de un conjunto de características $X = x_1, x_2 \dots x_m$, y un objetivo y (Pedregosa et al., 2024).

Las principales ventajas del Perceptrón Multicapa (MLP) incluyen su capacidad para aprender modelos no lineales y adaptarse en tiempo real (aprendizaje en línea) (Olofintuyi et al., 2023). Sin embargo, las redes MLP con capas ocultas también presentan algunas desventajas. En particular, tienen una función de pérdida no convexa, lo que significa que pueden existir múltiples mínimos locales. Como resultado, diferentes inicializaciones de los pesos aleatorios pueden conducir a precisiones de validación variables. Además, los MLP requieren ajustar una serie de hiperparámetros, como el número de neuronas y capas ocultas, así como el número de iteraciones. Finalmente, estos modelos también son sensibles al escalado de las variables de entrada (Pedregosa et al., 2024).

Clasificación: MLPClassifier utiliza un Perceptrón Multicapa (MLP) que aprende mediante el algoritmo de retropropagación (Backpropagation) (Pedregosa et al., 2024). Durante el entrenamiento, el MLP recibe dos conjuntos de datos: la matriz X , que contiene las muestras de entrenamiento representadas como vectores de características de punto flotante con dimensiones (n_samples, n_features), y la matriz y ,

que almacena las etiquetas de clase correspondientes a cada muestra de tamaño ($n_samples$) (Pedregosa et al., 2024).

Regresión: MLPRegressor utiliza un Perceptrón Multicapa (MLP) que aprende mediante el algoritmo de retropropagación, pero a diferencia de MLPClassifier, no utiliza ninguna función de activación en la capa de salida (Pedregosa et al., 2024). Esto se puede ver como el uso de la función de identidad como función de activación en la salida. Como resultado, el modelo minimiza el error cuadrático y produce un conjunto de valores continuos como salida, lo que lo convierte en un modelo de regresión en lugar de clasificación.

La clase MLPRegressor utiliza dos métricas para evaluar el desempeño del modelo durante el entrenamiento: el coeficiente de determinación R^2 y el error cuadrático medio (MSE) (Olofintuyi et al., 2023). La función `"mean_squared_error"` calcula el MSE, que es una métrica de riesgo que representa el valor esperado del error o pérdida cuadrática. Por otro lado, la función `"r2_score"` calcula el coeficiente de determinación, comúnmente denotado como R^2 , el cual indica la razón de la varianza de los valores de salida `"y"`, que es explicada por las variables independientes en el modelo. Esto permite que a través de la proporción de varianza, se realicen predicciones precisas en muestras incógnitas. El valor máximo posible de R^2 es 1.0, lo que indica un ajuste perfecto del modelo. Sin embargo, el coeficiente de determinación también puede tomar valores negativos, lo cual significa que el modelo es aleatoriamente peor (Pedregosa et al., 2024).

Funciones para acelerar la convergencia del resultado en intervalo esperado

Una de las desventajas del sistema de aprendizaje propuesto es que este necesita una gran cantidad de datos en entrenamiento para hacer que la función converja en el intervalo deseado, por lo que el entrenamiento puede ser un proceso demasiado lento para efectos prácticos en una investigación (Adewumi, 2016). Debido a esto se recurre a utilizar funciones de convergencia que aceleren el proceso de iteración y permitan que con los datos recolectados en el campo y las funciones de convergencia se logren predicciones dentro del intervalo de confianza.

Modelo de Adrover et al. (2020).

La función para acelerar la convergencia utilizada fue el modelo deshidratación isotérmica de Adrover et al. (2020), la cual se utiliza para generar datos de humedad interna, en el caso de la presente investigación. Los datos generados de humedad interna se pueden tomar como resultados en condiciones ideales (temperatura constante) que funcionan como punto de partida para la iteración de la función de predicción. Por lo tanto la comparación entre los resultados ideales y los de la función de predicción pueden brindar una medida de la desviación de la idealidad en la condiciones reales (temperatura interna variable). Esta medida de desviación se puede representar como un peso que influye en los nodos o capas escondidas de aprendizaje en el algoritmo.

Modelo de Brusselator

Como función para acelerar la convergencia de la humedad externa al grano (pulpa o cáscara), se propone una versión particular de la función dinámica conocida como modelo oscilatorio de Brusselator. Este modelo ha sido aplicado en fenómenos regidos por variaciones aleatorias, como por ejemplo la reacción de autocatálisis o fermentación espontánea (McDowell, 2008).

Una de las versiones del modelo de Brusselator, puede ser representada con el siguiente sistema no lineal de ecuaciones diferenciales (ecuaciones 24 y 25):

$$\frac{dy_1}{dt} = p_1 - (1 + p_2)y_1 + y_1^2 y_2 + p_3 \cos(wt) \quad (24)$$

$$\frac{dy_2}{dt} = p_2 y_1 - y_1^2 y_2 \quad (25)$$

Donde todos los parámetros y variables son adimensionales (Tronci et al., 2003):

$$p_1 = 2:00$$

$$p_2 = 5:4$$

$$p_3 = 0:265$$

$$w = 2:85$$

Esta es una versión del sistema clásico que funciona para aproximar sistemas caóticos, como por ejemplo: reacciones autocatalizadas, relaciones climáticas, entre muchas otras (Tronci et al., 2003).

Las ecuaciones diferenciales 24 y 25 y sus respectivos parámetros son implementadas para acele-

rar la convergencia de la humedad externa en el intervalo esperado, y al igual que el modelo de Adrover, permite disminuir la cantidad de iteraciones necesarias para que la función de pérdida tienda a un mínimo (Bonde, 2020). Cabe destacar que la función de pérdida en el sistema está establecida por el módulo ML-PreRegressor y no es necesario programarla, ya que el módulo la trae incorporada como parte del algoritmo base (Pedregosa et al., 2024).

Motor de aprendizaje del predictor de condiciones finales en poscosecha de cacao

El motor de aprendizaje automático para el predictor de condiciones finales en poscosecha de cacao (Humedad interna de la semilla, pH y volumen promedio de las semilla), está compuesto por el algoritmo Perceptrón Multicapa (MLP) de la librería Scikit-learn 1.4.1 (Python 3), más dos funciones aceleradoras de convergencia: el modelo deshidratación isotérmica de Adrover et al. (2020) y el modelo oscilatorio Brusselator.

Capítulo III

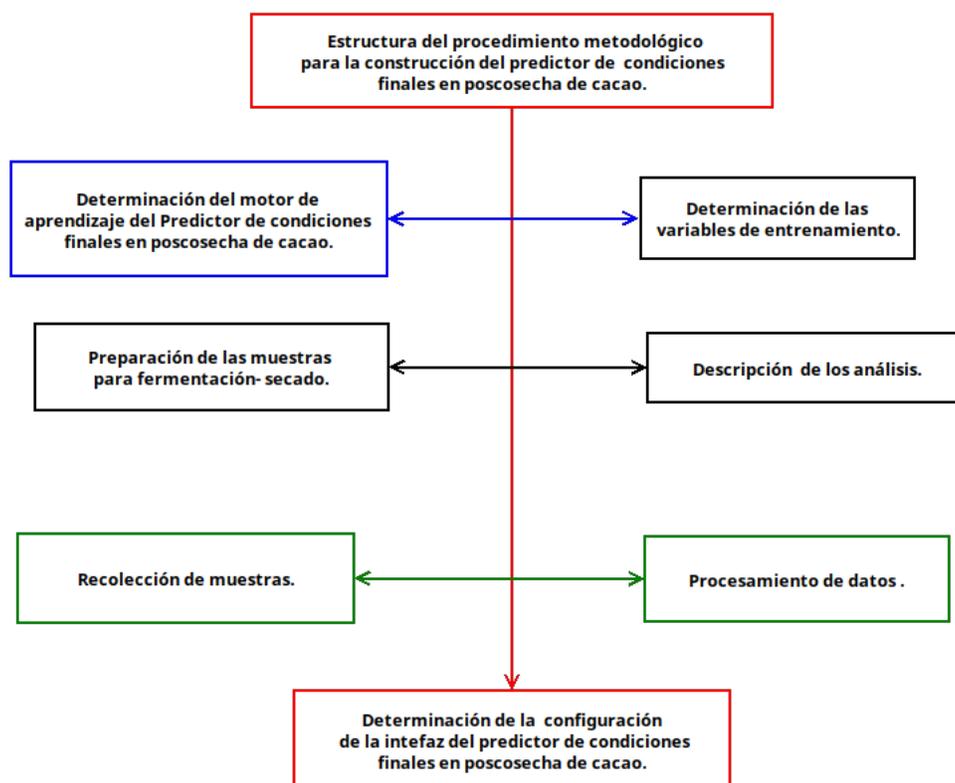
Metodología, métodos y técnicas

Procedimiento metodológico

El procedimiento metodológico consistió en la construcción e implementación de un sistema automatizado que permite la predicción de la humedad en poscosecha en cualquier instante (predictor de humedad). Para esto se utiliza una red neuronal (ANN) bajo el algoritmo Backpropagation optimizado por el algoritmo ADAM (Pedregosa et al., 2011), alimentada por datos experimentales en campo, reforzado por dos modelos generadores de datos que facilitan la convergencia de las predicciones en el intervalo deseado. El primer algoritmo es el modelo automático de frontera móvil para deshidratación isotérmica de alimentos (Adrover et al., 2020) y el segundo el modelo cinético conocido como Brusselator (McDowel, 2008; Tronci et al., 2016), el cual describe la cinética de reacciones autocatalíticas oscilatorias, tal como es el caso de la fermentación de cacao (Gonçalves, 2017).

Para ampliar la comprensión sobre la estructura metodológica empleada, se presenta la Figura 4, en la cual se mencionan las etapas que conforman la metodología para construir el predictor de humedad. Estas etapas serán abordadas a lo largo del presente capítulo, con excepción de la determinación del motor de aprendizaje del Predictor de condiciones finales en poscosecha de cacao, que fue abordado en el marco teórico.

Figura 4. Secuencia metodológica empleada para la construcción del predictor de humedad.



Nota. Elaboración propia (2024).

Determinación de las variables de entrenamiento

Una vez que se determinó la configuración del motor de aprendizaje del predictor de condiciones finales en poscosecha de cacao, se establecieron las variables de entrenamiento del mismo. Las variables de entrenamiento son los parámetros físicos y químicos, que se determinaron de forma experimental realizando varios ensayos de fermentación de cacao, lo cual se abordará posteriormente. Estos datos contribuyen a definir los límites del intervalo de convergencia (Olofinty et al., 2023). Las variables de entrenamiento fueron elegidas, de acuerdo con la disponibilidad logística y de instrumentos con la que se contó. Se llevaron a cabo 6 ensayos no simultáneos. El cacao utilizado proviene de la colección del CATIE. A continuación se muestran algunas consideraciones sobre cada variable, que fueron tomadas en cuenta en la elección de las mismas.

- Humedad interna del cotiledón: el proceso de secado culmina cuando la humedad de la semilla es de 6-7 % (Deus et al., 2018).
- pH: el día número 6 de la etapa poscosecha se espera obtener el valor de pH, más bajo posible, debido a la formación de ácido acético y láctico principalmente (Schwan et al., 2014). Y a partir de ese día, se espera que el pH comience a aumentar hasta un máximo el día 12.
- Temperatura en la pulpa y/o cáscara: se espera que el alcance su valor más alto en la etapa de fermentación (Pelaez et al., 2016).
- Masa: las mediciones de masa al inicio y al final permiten obtener la cantidad de agua desalojada de la semilla (Herman, 2018).
- Dimensiones: la medición de la dimensiones finales e iniciales, permite obtener el volumen de contracción de la semilla en toda la operación (Adrover et al., 2020).
- Humedad externa (pulpa-cáscara): influye en la velocidad de deshidratación (Ayestas et al., 2016) y en la dirección del flujo difusivo (Castillo-Orozco, 2023; Koua et al., 2019).

Preparación de las muestras para fermentación- secado

Las mazorcas de la colección del CATIE se recolectaron y se abrieron manualmente en los campos con machetes limpios. Se limpiaron y se prepararon los cajones de fermentación o fermentadores, los cuales tenían 60 cm por lado y 10 cm de espesor. Antes de colocar la muestra en los fermentadores, se agregó una cama de hojas de plátano como inóculo microbiano. Esta es una práctica utilizada ampliamente en el campo (Ureña y Sandoval, 2021). En cada uno de los cajones se depositó 70 kg de cacao de la colección.

Condiciones de fermentación y secado

El inicio de la fermentación se realiza antes de 24 horas de haber abierto los frutos de cacao. Esta etapa duró entre 6 días y 7 días. Después de finalizada la etapa de fermentación, el día número 7 (8 en un caso) de la etapa poscosecha inicia el presecado realizado en cajas Rohan de laurel. La condición de

operación que caracteriza el ensayo es la variación de la temperatura durante todo el proceso. El presecado dura 24 horas, luego continúa la etapa de secado al sol, en la cual el cacao se extiende en cajas Rohan en los ensayos del 1 al 4. Los ensayos 5 y 6 se realizan en invernadero, donde el cacao se extiende sobre malla de invernadero.

Descripción de los análisis

Como se menciona previamente las variables descritas a continuación tuvieron el objetivo de dotar de datos de aprendizaje del algoritmo. Los análisis que se describen a continuación se realizaron para construir una función generadora de valores teóricos de entrenamiento, necesaria para dotar de datos de aprendizaje al algoritmo de machine learning. Los datos obtenidos para diferentes condiciones de temperatura, humedad, altura y dimensiones de semilla, cumplen la función de blanco reactivo con respecto a una muestra dada a tales condiciones.

Determinación de humedad interna del cotiledón y obtención de la curva de calibración por difusividad

La humedad en cualquier instante se determina por medio del método ISO 2291-1972E, utilizado por Stevenson (1990) en su manual para análisis de cacao en laboratorio. En este método se lleva una muestra de 25 g de cacao a una estufa a 130 °C por 16 horas, luego se determina la masa restante y por diferencia se obtiene humedad en g de agua/g de cacao seco.

La medición de humedad por día, brinda la información requerida para obtener la curva de calibración que toma en cuenta el efecto de la difusividad del agua en la tasa de humedad X_r . La determinación de la curva de calibración permite encontrar los coeficientes de la ecuación 26, a partir de medir diferentes valores de humedad absoluta tomada en intervalos de tiempo definido (días) durante la fermentación y secado de la muestra (Adrover et al., 2020).

$$\frac{X(t)}{X_0} = a_0 + a_1 e^{-b_1 t} + a_2 e^{-b_2 t} + (1 - a_0 - a_1 - a_2) e^{-b_3 t} \quad (26)$$

La tasa de humedad se relaciona con la ecuación 26 mediante la siguiente expresión (ecuación 27) obtenida experimentalmente a partir de la ecuación 2.13.

$$X_r = \frac{\frac{X(t)}{X_0} - a_0}{1 - a_0} \quad (27)$$

El análisis se lleva a cabo en laboratorio. La variable independiente es el tiempo (t). La variable dependiente es la humedad en tiempo (t), la variable de respuesta es la tasa de deshidratación $\left(\frac{x(t)}{x_0}\right)$. Las condiciones de Operación son: $T_0(K)$, $P_0(atm)$, $X_0(kg_{agua}/kg_{aireseco})$. Y los materiales y equipos son: estufa, balanza granataria, termómetro, cronómetro y beakers.

Medición de las dimensiones de la semilla (ajuste de la tasa de deshidratación adimensional debida a la contracción del grano)

La medición de las dimensiones de la semilla al inicio y al final del proceso, permite determinar el término que relaciona al factor de contracción Υ , en la operación de secado. Por lo tanto, se determinan las dimensiones promedio (R_{eq} , V_{eq}) de una muestra representativa de granos de cacao, para obtener Υ de la ecuación 28:

$$\Upsilon \cot(\Upsilon) + \tilde{B}i_m^{eq} - 1 = 0 \quad (28)$$

En la cual:

$\tilde{B}i_m^{eq}$: es número másico de Biot cuando hay contracción del grano.

L_r : es la longitud específica (mm).

\tilde{R}_{eq} : es el radio equivalente cuando hay contracción del grano (mm).

V_r : es el volumen característico del grano (mm^3).

V_{eq} : es el volumen equivalente si un grano tuviera forma esférica (mm^3) (Adrover et al., 2020).

Las dimensiones promedio mencionadas son obtenidas a partir de medir con un vernier los parámetros a_0 , b_0 , c_0 de 15 semillas (Figura 2) una muestra por día, durante los 6 ensayos de fermentación-secado (cuadro 1) y con esto usar la ecuación 9 para calcular R_{eq} y V_{eq} . Los valores de L_r y V_r son obtenidos de la literatura correspondiente (Adrover et al., 2020).

Determinación de pH de cotiledones

Se tomó una muestra de 25 g de cacao en baba (fermentación) y con cáscara (secado) a partir del día 1 y hasta el último día de secado. Se trituró la muestra sin llegar a contextura de pasta y se diluyó con una cantidad conocida de agua, luego de reposar unos minutos se midió el pH, con un pH-metro de electrodo marca Jenway (Stevenson et al., 1990).

Determinación de humedad externa (pulpa-cáscara)

Se utilizó un dataloger MDL. 40550 Data Logger de Flash link, el cual fue programado para tomar datos cada 30 minutos durante la fermentación y secado. El dispositivo reporta los datos de humedad en términos de porcentaje de humedad relativa.

Determinación de humedad externa (pulpa-cáscara)

Se utilizó un dataloger MDL. 40550 Data Logger de Flash link, el cual fue programado para tomar datos cada 30 minutos durante fermentación y secado, el dispositivo reporta los datos de temperatura en grados Celsius. Para los ensayos 4 y 5, se utilizó una termocupla Omega de 8 canales, mediciones en grados Celsius cada 2 minutos.

Recolección de datos experimentales

Para la recolección de datos se realizaron 6 ensayos de fermentación-secado de cacao entre el 26 de junio de 2023 y el 6 de diciembre de 2023. En algunos ensayos se adicionaron aditivos (zinc, aminoácidos) al cacao para capturar el efecto de estos. Todos los ensayos fueron realizados en la finca experimental Santa Lucía de la Escuela de Ciencias Agrarias en Barva de Heredia. El cuadro 1 presenta un resumen de dichos ensayos. Debido a que el problema a solucionar se relaciona con el manejo de poscosecha en condiciones de campo, cada ensayo aporta condiciones particulares, que permiten tener un escenario similar al que se enfrentan los productores en campo, particularmente en lugares como Upala y Zona Norte en Costa Rica, donde las condiciones de humedad son muy altas.

Tabla 1. Ensayos realizados en la Finca Experimental de la Escuela de Ciencias Agrarias en Santa Lucía de Barva.

Número de ensayo	Fecha de inicio y final	Análisis realizados
1	26 de junio al de 10 de julio 2023	Humedad interna
2	13 de julio al de 28 de julio 2023	pH interno, humedad interna, dimensiones, humedad externa, temperatura externa
3	26 de julio al 10 de agosto 2023	pH interno, humedad interna, dimensiones, humedad externa, temperatura externa
4	04 al 20 de octubre 2023	pH interno, humedad interna, dimensiones
5	02 al 20 de noviembre de 2023	pH interno, humedad interna, dimensiones, humedad externa, temperatura externa, temperatura ambiente
6	20 de noviembre al 6 de diciembre 2023	pH interno, humedad interna, dimensiones, humedad externa, temperatura externa, temperatura ambiente

Nota. Elaboración propia (2024).

Procesamiento de los datos y construcción del motor de aprendizaje

Para programar y entrenar el motor de aprendizaje del predictor de condiciones finales en poscosecha de cacao se utilizaron los datos experimentales recolectados. También se hizo uso del lenguaje de programación Python3, desde la plataforma Jupyter Lab para realizar los gráficos de la parte experimental, la programación del modelo de Adover (2020) y el modelo Brusselator. Algunas de las librerías utilizadas son: numpy, seaborn, matplotlib, sympy, scipy, entre otros. La programación de la red neuronal se realizó también en Python3, pero desde la plataforma pyCharm, en este caso se utilizó la librería Scikit-learn 1.4.1. (Pedregosa et al., 2024).

Esta librería posee el módulo MLPRegressor el cual brinda las métricas para determinar el grado de aprendizaje o grado de aproximación al valor esperado, por medio de la estimación del error cuadrado medio y el coeficiente de determinación. El error cuadrado medio (MSE) es una medida de la exactitud

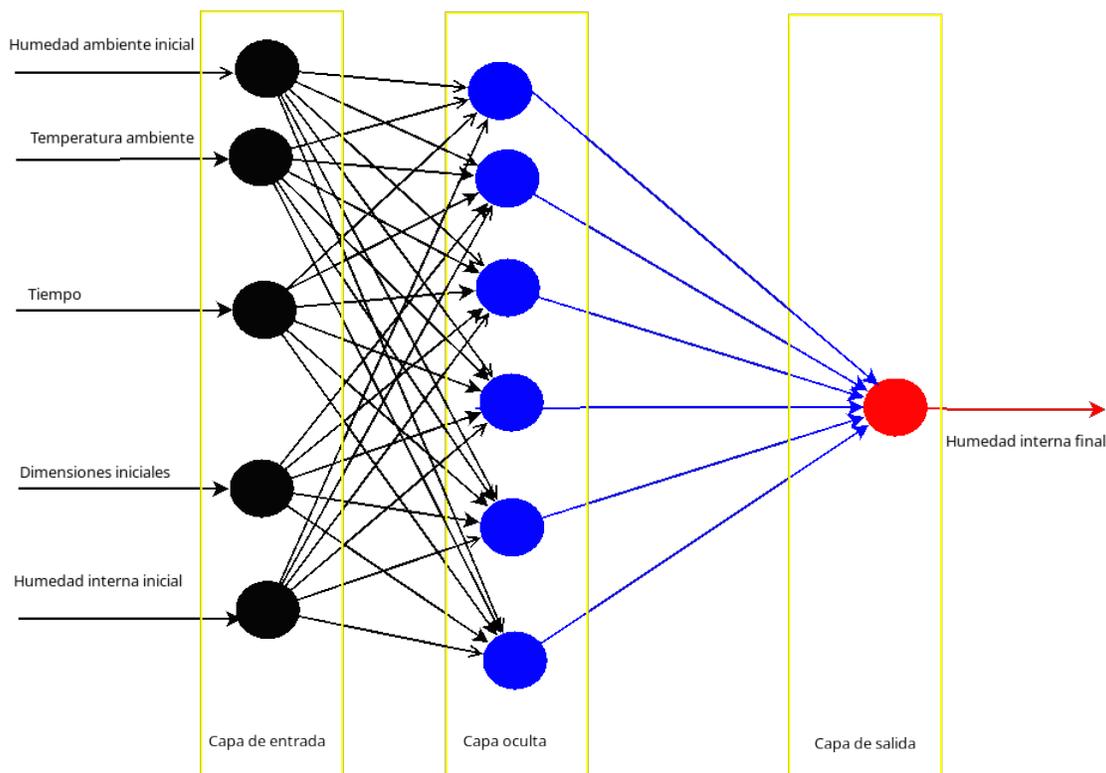
del resultado, mientras que el coeficiente de determinación R^2 es una medida de precisión de los datos (Pedregosa et al., 2024).

Configuración de la interfaz del predictor de condiciones finales en poscosecha de cacao

La interfaz o ventana que ve el usuario del predictor de condiciones finales en poscosecha de cacao, consiste en un formulario de entrada en la plataforma web, con los datos aportados por el usuario y un formulario de salida, el cual muestra el resultado de la consulta. Para establecer la información que se muestra en la interfaz (plataforma web), es necesario establecer los campos que el usuario debe completar en el formulario que se muestra en la plataforma del predictor para obtener uno o más resultados, en este caso, a esos datos se les conoce como entradas (Ruder, 2016). Las salidas son los resultados que muestra la plataforma del predictor luego de que procesara los datos de entrada (Bonde, 2020).

La red neuronal implementada parte de una unidad básica conocida como perceptrón multicapa. Un ejemplo aplicado al caso en estudio se muestra en la Figura 5, en esta se puede apreciar que la capa de entrada, representa los datos que se deben aportar al sistema para que la neurona devuelva un resultado o capa de salida. Tanto los parámetros de la capa de entrada (humedad ambiente inicial, temperatura ambiente, tiempo, dimensiones iniciales y humedad interna inicial) como el parámetro de salida de la Figura 5 (humedad interna final), fueron determinados experimentalmente tal y como se describió anteriormente. La neurona completa se compone de varias unidades básicas interrelacionadas, pero por la complejidad de elaborar la imagen resultante, se decidió mostrar solo la unidad relacionada con humedad interna final de la semilla (Pedregosa et al., 2024).

Figura 5. Ejemplo de la estructura un perceptrón multicapa, unidad básica de la red neuronal (predicador de humedad interna).



Nota. Elaboración propia (2024).

Las variables de entrada y de salida fueron seleccionadas por utilidad para el cumplimiento del modelo y por disponibilidad de equipo y materiales para realizar los análisis. A continuación se detallan las consideraciones que se tomaron en cuenta para elegir estas variables de entrada y salida:

Entradas

La capa de entrada al sistema para la etapa de entrenamiento puede representarse como $x^{(i)}$, estas se iteran en la composición de funciones $f^{(i)}$ para dar la capa de salida $y^{(i)}$ (Bonde et al., 2020). Para el desarrollo del predictor de humedad en poscosecha de cacao se utilizaron las siguiente entradas:

1. Tiempo: es la variable independiente del modelo y se trabaja en horas, por facilidad de convergencia con las ecuaciones de Adrover y Brusselator (Tronci, 2003), ya que si el tiempo se expresa en segundos, algunas funciones pueden tender a infinito (Sundnes, 2023), por ejemplo una función exponencial como en el caso del modelo de deshidratación isotérmica de Adrover (2020).

2. Dimensiones promedio: se midieron las dimensiones a_0, b_0, c_0 en los ensayos del 3 al 6, aproximadamente 15 veces por muestra, se obtiene el promedio y con esto se estima el volumen final esperado. Debido a que todos los ensayos se realizaron con cacao perteneciente a la colección del CATIE, lo cual es una mezcla indeterminada de diversas variedades; es posible partir de un amplio intervalo de probabilidad que irá siendo reducido a medida que se vaya dando el aprendizaje en la herramienta (Olofintuyi, 2023).
3. Humedad interna inicial: Parámetro de partida en la función, se conoce que la humedad inicial del cacao en baba se encuentra entre 62 y 58% aproximadamente (Tinoco y Ospina, 2010).
4. Temperatura ambiente: es una condición inicial para la función de aprendizaje. La temperatura hace variar los coeficientes de transferencia de masa, los cuales influyen directamente en la velocidad de deshidratación (Castillo-Orozco et al., 2023), por lo que la temperatura ambiente de inicio, influye en el resultado predictivo.
5. Intervalo climático promedio: parámetro de aprendizaje que relaciona la zona geográfica donde se realiza la poscosecha.

Salidas

La capa de salida está compuesta por los siguientes parámetros $y^{(i)}$. Los cuales pueden ser la respuesta a la evaluación de las entradas en la red neuronal, o servir como punto de partida para el aprendizaje, de manera que para un conjunto de entradas $x^{(i)}$ específicas, existan salidas $y^{(i)}$ ya conocidas, que permitan acotar la función de pérdida L (Bonde, 2020; Adewumi et al., 2016). Las salidas se enumeran a continuación.

1. Humedad Interna: Es la salida principal del sistema, ya que el proceso de poscosecha finaliza cuando la humedad interna se encuentra entre 6 y 7 % de humedad relativa (Deus et al., 2018; Raju, 2019). Por lo tanto la evolución en el tiempo de este parámetro es fundamental para el aprendizaje de la función.
2. pH: es un indicador de calidad del proceso, ya que valores atípicos podrían indicar formación de sustancias indeseables o que la fermentación no se llevó a cabo de manera correcta (Moreno-Zambrano, 2018). Con respecto al comportamiento del pH se parte que el día número 6 de la etapa poscosecha

se espera obtener el valor de pH, más bajo posible, debido a la formación de ácido acético y láctico principalmente (Schwan et al., 2014). Y a partir de ese día, se espera que el pH comience a aumentar hasta un máximo el día 12.

3. Volumen final: Se estima a partir de las dimensiones iniciales, y está relacionado con la cantidad de agua y sólidos volátiles que salen de la semilla en el proceso (Adrover, 2019).

Capítulo IV

Resultados y Discusión

Construcción de la red neuronal

Debido a que la revisión bibliográfica implica la consulta a una gran cantidad de modelos y algoritmos, estos suelen presentar diferencias entre las notaciones usadas por cada autor, por lo que para efectos de comprensión, en este estudio se utiliza la notación empleada en el modelo de deshidratación isotérmica de Adrover et al. (2020).

Procesamiento de datos obtenidos experimentalmente

Los resultados de todos los análisis realizados fueron clasificados por tipo y almacenados en una base de datos, la cual se acondicionó para que el predictor de condiciones finales en poscosecha de cacao, pueda consultar esta base de datos cada vez, que se le realiza una iteración. Además también se programó para que cada vez que el usuario agregue datos experimentales, el predictor aprenda un nuevo resultado confiable, este se agregue a la base de datos existente y pueda ser tomado en cuenta en futuras consultas (Olofintuyi et al., 2023).

Funciones de entrenamiento

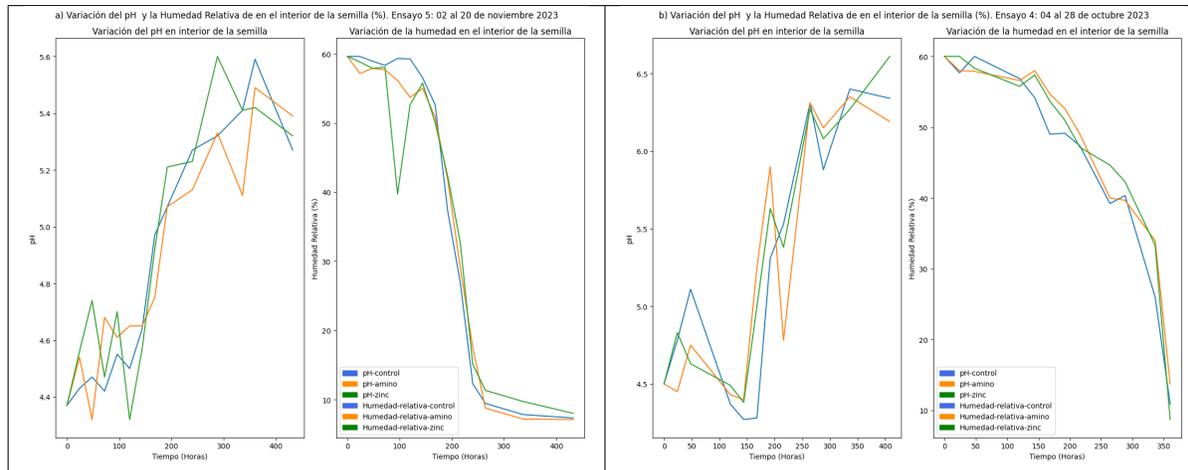
El modelo de deshidratación isotérmica de Adrover (2020), parte de la determinación de la curva de calibración de humedad (Figura 4.1), con la que se pueden obtener valores experimentales de x_{eq} , sin embargo, para los efectos de esta investigación, estas curvas de calibración actúan como funciones de entrenamiento con las que se contruye la base de datos, por lo tanto el análisis de los valores de x_{eq} realizado por Adrover et al. (2020), no es pertinente en esta investigación.

Cabe resaltar que el modelo de deshidratación isotérmica de Adrover (2020) es aplicable para condiciones controladas, específicamente temperatura constante. Sin embargo, lo anterior no representa la

realidad del proceso realizado por los pequeños y medianos productores, donde la temperatura se ve afectada directamente por las condiciones climáticas de la zona, y su comportamiento es caótico (Aramburo, 2017). No obstante, resulta de gran utilidad en este caso como generador de escenarios ideales, los cuales permiten reducir las iteraciones de la red neuronal, ya que la cantidad de datos experimentales obtenidos en los 6 ensayos, es poca con respecto a los requerimientos, en cuanto a cantidad de datos del modelo de aprendizaje que se está implementando. Esto hace que la convergencia del resultado aprendido dentro del intervalo esperado sea lenta y se necesiten muchas iteraciones. Por esta razón se planteó la utilización de este modelo como acelerador de convergencia acoplado a la red neuronal.

Otra de las funciones de entrenamiento es la curva de pH en función del tiempo, la cual se muestra en la figura 6, acompañada de la curva de humedad relativa, tanto para el ensayo 5 (Figura. 6a) como a para el ensayo 4 (Figura. 6b). De esta figura, se puede notar un cierto patrón en las curvas de pH, que obedece a la actividad microbiológica (Moreno-Zambrano; 2018), la cual aumenta levemente en las primeras 48 horas y luego comienza a descender conforme predomina la formación de ácido acético (Schwan et al., 2014).

Figura 6. Variación de la humedad interna y el pH interno Variación de la humedad interna y el pH interno en poscosecha de cacao.



Nota. Elaboración propia (2024).

Cabe destacar que el cacao procesado obtenido en el ensayo 5, fue llevado a chocolatería y en general el equipo de trabajo se mostró satisfecho con la calidad obtenida el día del empaque. En el caso del ensayo 4, la muestra se contaminó con moho, por lo que la Figura 6, se contruyó para hacer notar que, obtener valores de pH mayores a 6 en la parte final del secado, puede convertirse en un indicador de un secado deficiente y por lo tanto se recomienda profundizar en el tema para futuras publicaciones (Ayestas

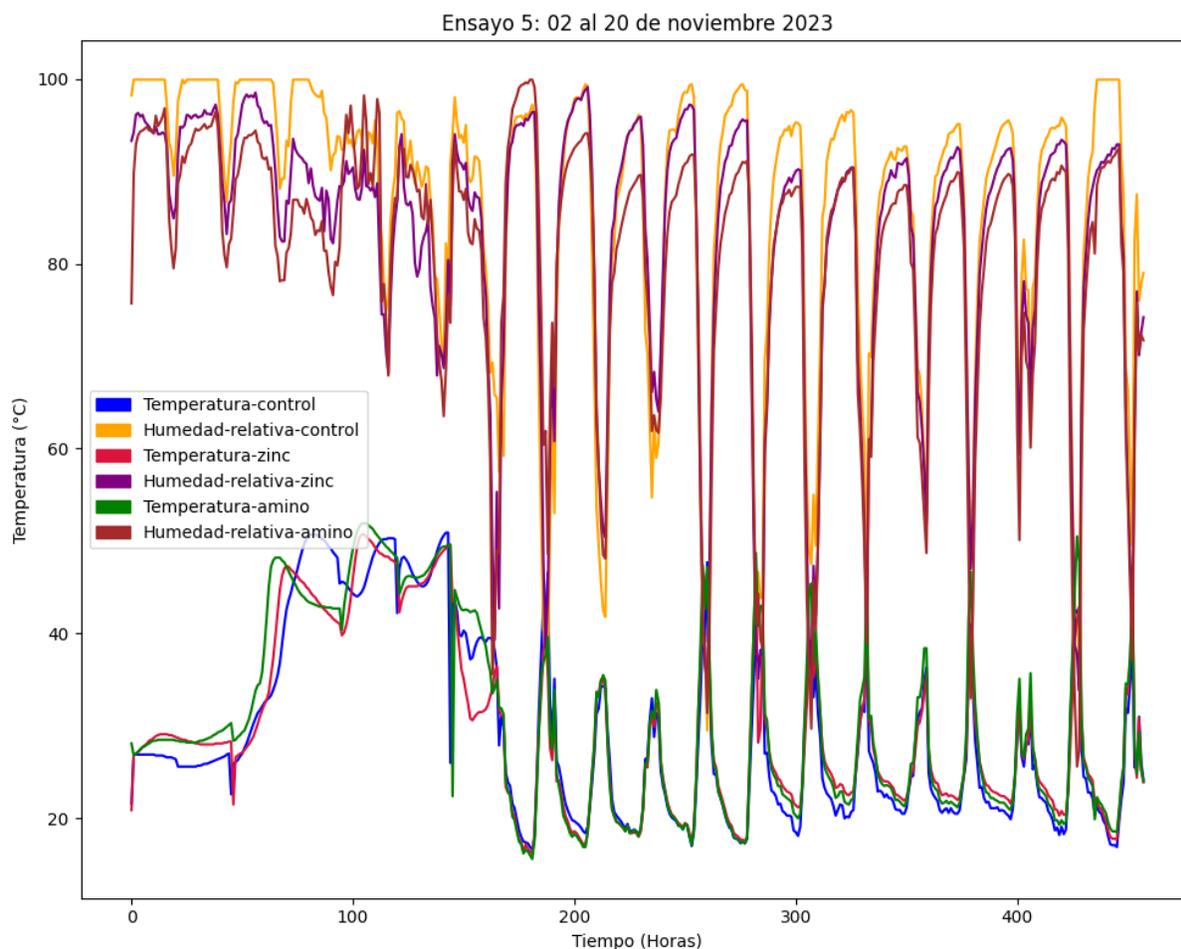
et al., 2016).

Otro indicador puede notarse en las curvas de variación de humedad interna, en las que se aprecia que las curvas del ensayo 5, presentan un descenso exponencial pronunciado en la parte de secado, el cual tiene una forma similar a una isoterma (Adrover et al., 2020), mientras que en el caso del ensayo 4, presenta un descenso de humedad mucho mas lento en la parte de secado.

En toda la etapa de secado, pero especialmente en la parte de secado suave, es imprescindible dar movimiento constante de los granos y extender la masa de cacao de manera que disminuya el contacto entre granos para que no se peguen, esta operación colabora con la disminución de humedad y evita la formación de moho (Calvo et al; 2021). Sin embargo, en el ensayo 4 (Figura 6b) esto no se realizó de manera correcta, por lo que apunta a ser una de las causas de la formación de moho en este ensayo (Deus et al., 2018).

La tercera relación de entrenamiento usada fue la representación de la evolución de la humedad en la pulpa y cáscara con respecto al tiempo. A este gráfico (Figura 7) se le agregó también la variación de la temperatura de pulpa y la cáscara contra el tiempo, lo que permitió que junto a la información obtenida en la figura 6, se puedan establecer las siguientes observaciones:

Figura 7. Variación de la temperatura (°C) y humedad relativa en la pulpa-cáscara en poscosecha de cacao.



Nota. Elaboración propia (2024).

De 48 horas a 120 horas se da la fermentación aeróbica, por lo tanto se espera y se aprecia en la Figura 4.2, que cuando la temperatura tiende a aumentar por el avance de una reacción exotérmica (Koua et al., 2019), la humedad en la pulpa tiende a disminuir.

El flujo difusivo en la etapa de secado debe tener una dirección de adentro de la semilla hacia afuera de ésta, para garantizar que el agua y algunos compuestos volátiles salgan de la semilla (Dzelagha et al., 2024). No obstante, en el ensayo 4 se notó que la humedad interna medida en algunos días consecutivos, se mantenía prácticamente constante. Esto puede implicar que en algunos momentos del día, la dirección de flujo difusivo sea de afuera hacia adentro, esto aumenta los días de secado y las posibilidades de contaminación con moho (Deus et al., 2018).

La información de la figura 4.2, puede ayudar a seleccionar el momento adecuado del día para

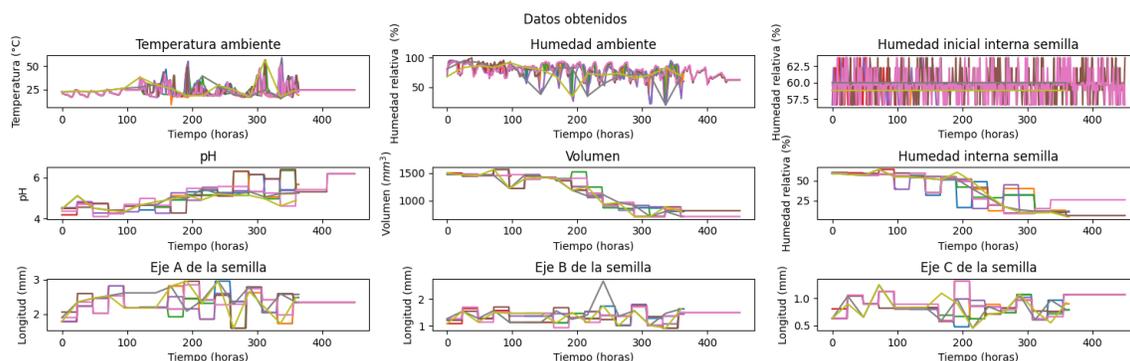
empacar el cacao, por lo que se aprecia que cuando la temperatura de la cáscara es la máxima durante el secado, la humedad de la cáscara es mínima. Esto sucedió en horas de 10 am a 12:30 pm, momento en el que la temperatura del día alcanza un máximo debido a la influencia del sol. Por lo tanto se establece que este intervalo del día, es el adecuado para empacar, ya que si en la tarde llueve, la humedad en la cáscara aumenta, lo que podría generar que la humedad interna también aumente, y el producto termine con una humedad de empaque mayor a la esperada (Kyi et al., 2014; Koua et al., 2019).

Definición de los intervalos de convergencia

Los intervalos de convergencia de la red neuronal son las salidas del sistema en el ámbito de resultados esperados y definido por los resultados experimentales realizados para este fin (Adewumi et al., 2016). El funcionamiento de la red neuronal permite que se pueda alimentar al sistema con datos experimentales reales, que ajusten el resultado de la predicción. Esto permite que la red neuronal aprenda un camino o posibilidad que tomará en cuenta en las siguientes predicciones, con cada resultado aprendido sobre datos reales, el sistema irá ajustando la función de pérdida de manera que la diferencia entre el resultado predicho por la herramienta y el resultado experimental obtenido tienda a ser cero cuando la base de datos posea suficientes entradas para que el aprendizaje sea efectivo (Bonde et al., 2020). Para esa cantidad de datos, se utilizan el coeficiente de determinación R^2 y el error cuadrado medio (MSE), las condiciones son: $R^2 \rightarrow 1$ y $MSE \rightarrow 0$ (Pedregoza et al., 2024).

Luego de que se recolectan los datos experimentales, se crea con estos una matriz para cada variable, definida como el intervalo de convergencia de los resultados experimentales. Estos se pueden apreciar gráficamente en la figura 8. La red neuronal está programada para que se use este intervalo, como límite de aceptación de 70 % de los datos de entrenamiento (Olofintuyi, 2023), por lo que cada vez que una predicción se salga del intervalo de convergencia, es necesario retroalimentar con un valor experimental para que el sistema aprenda el camino de convergencia según las condiciones y de ser necesario ajustar el intervalo de convergencia para las condiciones dadas (Adewumi et al., 2016; Anggraini et al., 2021). Al conjunto de algoritmos de aprendizaje se le conoce como motor de aprendizaje (Tamayo et al, 2024; Tronci et al., 2003).

Figura 8. Ploteo de las variables de entrenamiento determinadas experimentalmente. Determinación de los intervalos de convergencia inicial para entradas y salidas.



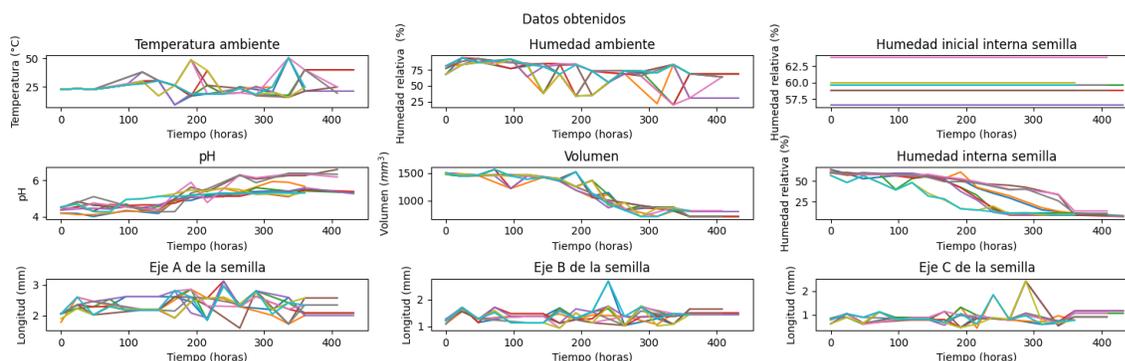
Nota. Elaboración propia (2024).

Tal y como se evidencia en la descripción de los ensayos, la recolección de datos no es uniforme, ya que la réplica de condiciones de campo implica en ocasiones, imprevistos como lluvia, frente frío, alta nubosidad, imposibilidades logísticas, disponibilidad de los operadores, entre otras. Esto ocasiona que aumente la variabilidad de la predicción, que podría verse reflejado en las métricas obtenidas (Adewumi et al., 2016).

Integración de los datos experimentales a la red neuronal (entrenamiento)

El 70 % del conjunto de datos se utilizó para entrenamiento, mientras que el 30 % restante se utilizó para realizar pruebas de verificación, dicho de otra forma primero se entrenó al motor de aprendizaje (Figura 9) y luego se comprobó que los resultados predichos se encuentran dentro del intervalo de convergencia. Esta proporción es recomendada tanto por el creador de la librería Scikit-learn 1.4.1 (Pedregosa et al., 2024), como por Olofintuyi et al., (2023), en Owo, Nigeria. Estos investigadores validaron el arreglo: 70 % / 30 %, por medio de una serie de experimentos que analizan la eficiencia de los modelos predictivos estudiados. Algunos de los indicadores de eficiencia utilizados son: error medio absoluto, error cuadrado medio, entre otros (Olofintuyi et al., 2023).

Figura 9. Resultado de la integración de los datos experimentales en el motor de aprendizaje (entrenamiento de la red).



Nota. Elaboración propia (2024).

Comparación entre el resultado predicho por la red neuronal y los datos experimentales

El error cuadrado medio (MSE por sus siglas en inglés) estima la desviación total entre los valores predichos y los valores reales, por lo que puede considerarse como un parámetro para determinar exactitud. El coeficiente de determinación R^2 , muestra el grado de correlación de los datos, por lo que puede considerarse como un indicador de precisión de los mismos (Pedregosa et al., 2024).

MLPRegressor brinda dos tipos de métricas al realizar una iteración. El error cuadrado medio de la red neuronal después de ingresar los datos experimentales al sistema y de realizar más de 10 iteraciones en búsqueda del mejor escenario, se obtiene que es 153 (Cuadro 2). Esto implica que es necesario alimentar al sistema con mayor cantidad de datos experimentales para que el error cuadrado medio de la función de pérdida disminuya, siendo que el valor deseado de este parámetro es cero. En cuanto al coeficiente de determinación R^2 , el resultado fue 0,82 (Cuadro 2), lo que reafirma la aseveración de que es necesario alimentar la base de datos para tener predicciones más acertadas (Olofintuyi et al., 2023).

Tabla 2. Métricas del módulo MLPRegressor para el entrenamiento de la red neuronal.

Métricas	Resultado obtenido
Error cuadrado medio (MSE)	153
Coficiente de determinación (R^2)	0,82

Nota. Elaboración propia (2024).

Sin embargo, para efectos de esta investigación el resultado se considera positivo, ya que se logra obtener resultados de predicción en el ámbito esperado (convergencia del resultado), a pesar de contar con pocos datos de entrenamiento. Esto implica que los algoritmos aceleradores de convergencia influyen en el resultado predicho, por lo tanto cumplen su función (Adewumi, 2016).

Se recomienda para futuros trabajos sobre modelos predictivos en poscosecha de cacao, incluir en el modelo de aprendizaje, la información sobre la variación genética de las semillas utilizadas (Arguedas et al., 2024), no solo para aumentar el tamaño de la base datos, sino porque la variabilidad genética influye en la características físicas y microbiológicas del cacao (Adewumi, 2009; Motamayor et al., 2008).

Protocolo poscosecha para reducir pérdidas por fermentación inadecuada y manejo deficiente del secado en clima tropical húmedo

El objetivo de este instructivo es brindar a investigadores y productores de cacao de fincas de pequeña y mediana escala, un protocolo para reducir pérdidas por fermentación inadecuada y manejo deficiente del secado en clima tropical húmedo, mediante el uso de una calculadora para predecir de humedad interna de la semilla, pH y volúmen final para cualquier instante del proceso.

Entrenamiento del sistema para una finca

Para las etapas iniciales de uso de la herramienta, cuando su uso no es masivo, se recomienda entrenar la herramienta para las condiciones específicas de la finca, por lo que es necesario para esta etapa contar con los instrumentos necesarios para medir las variables para retroalimentar al sistema, se listan los siguientes:

Vernier para medir dimensiones de las semillas. Las medidas de los granos oscilan entre 5 mm y 40 mm.

Termómetro, datalogger o termocupla para medir temperatura.

Estufa u horno en el que se pueda secar muestras de cacao (en baba y en almendras) a 130° C por 16 horas, para determinar humedad interna de la semilla.

pH-metro, para uso correcto, se debe elegir un lugar específico y no mover el aparato. Se debe

calibrar una vez al iniciar cada sesión de toma de muestra de cacao en baba o cuando se sospeche de que la medición se sale de los parámetros esperados. Debido a que la matriz cacao en baba se suele adherir a las superficies y es de difícil limpieza, se debe lavar el electrodo con alcohol y luego con agua destilada después de cada corrida.

Balanza granataria, se recomienda también elegir un lugar estable para su colocación y no moverla de ser posible, evitar corrientes de aire en el sitio de medición. Se mide la masa de caco de una muestra por diferencia, por lo que primero se mide el recipiente seco, luego el recipiente con la muestra fresca, luego se coloca en la estufa por 16 horas a 130 °C, y se deja enfriar hasta alcanzar temperatura ambiente. No medir masa en caliente, ya que se distorsiona el resultado. Alcanzada la temperatura ambiente se mide la masa del recipiente más la muestra seca. Se obtiene la masa seca, de la resta de la masa del recipiente con muestra seca menos la masa del recipiente vacío. La cantidad de agua (y compuestos volátiles) liberada se obtiene de la resta de masa del recipiente con muestra húmeda, menos la masa del recipiente con muestra seca. La humedad absoluta se forma del cociente entre el agua liberada y la masa seca. Para obtener la humedad relativa se divide la humedad absoluta entre el valor de humedad absoluta más 1 y el resultado se multiplica por 100 (Himmelblau et al., 2004).

Con respecto a la medición de pH pueden utilizarse también cintas medidoras, pero no van a dar un resultado numérico, solo un intervalo en el que se encuentra el dato, lo es cual es útil para verificar si el pH se encuentra en el ámbito esperado, pero no para retroalimentar al sistema. Por otro lado, se recomienda el uso de balanza granataria y no analítica, se debe al elevado costo de la balanza analítica con respecto a la granataria y al hecho de que manejar una balanza analítica en condiciones de campo es disminuye la vida útil del aparato.

Uso del Predictor de condiciones finales en poscosecha de cacao

La persona productora que vaya a usar el sistema, debe tener disponible una computadora con un navegador de internet instalado, se recomienda Mozilla Firefox o Google Chrome. La url de acceso se solicita a los desarrolladores del sistema (correo: german.zarate.montero@gmail.com).

Cuando se ingrese al sistema aparece un formulario (Figura 10) en el que se deben llenar los campos con las longitudes de grano, la temperatura ambiente al momento de realizar la predicción, humedad del ambiente en ese momento, humedad interna inicial del grano y el intervalo de temperatura promedio para

la zona geográfica, para un tiempo que va de 0 horas a 420 horas (el sistema no tiene datos después de las 420 horas).

Figura 10. Interfaz del predictor de condiciones finales en poscosecha de cacao.

Nota. Elaboración propia (2024).

Luego de ingresar los datos y dar click en el botón de predicción, el productor obtiene un resultado en la derecha de la pantalla (Figura 11). Si se cuenta con resultados experimentales, la persona productora puede entrenar al sistema dando click en el botón de retroalimentación, y esto desplegará un formulario donde se ingresan los datos correspondientes (Figura 12).

Figura 11. Resultado de la consulta al predictor de condiciones finales en poscosecha de cacao.

Predictor de cacao para un tiempo dado

Tiempo en horas:
 Hora en la cual se da la predicción de 1-432

Eje A (grano promedio):
 Eje longitudinal del grano inicial en milímetros

Eje B (grano promedio):
 Eje radial del grano inicial en milímetros

Eje C (grano promedio):
 Eje axial del grano inicial en milímetros

Temperatura ambiente:
 Temperatura ambiental inicial en grados Celsius

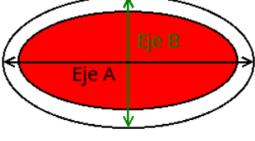
Humedad ambiente:
 Humedad ambiental porcentaje de humedad relativa

Humedad inicial grano:
 Humedad actual porcentaje de humedad relativa

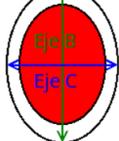
Temperatura promedio de la Zona Geográfica en grados Celsius:

Dimensiones de una semilla de Cacao

Vista Longitudinal



Vista Radial



Cáscara-pulpa
 Cotiledón

Resultado de Predicción

Tiempo: 24.0
 Humedad Relativa Interna: 59.19241045120354
 PH: 4.222904637388502
 Volumen: 821.9547509201159

El resultado obtenido no concuerda con los datos medidos:

La retroalimentación permite mejorar la predicción

Nota. Elaboración propia (2024).

Figura 12. Retrolimentación al predictor de condiciones finales en poscosecha de cacao.

Actualiza con datos medidos

Humedad relativa:
 PH:
 Volumen:

Datos de entrada

Fecha de registro: March 27, 2024, 5:04 p.m.
 Tiempo: 24.0
 Grano A: 26.0
 Grano B: 20.0
 Grano C: 11.0
 Temperatura Ambiente: 25.0
 Humedad Ambiente: 79.0
 Humedad Inicial Grano: 61.0
 Zona Geográfica: 25

Resultado de Predicción

Humedad Relativa: 59.283954711519876
 PH: 4.087138973512453
 Volumen: 863.48559661161

Nota. Elaboración propia (2024).

Si no es posible medir experimentalmente cada 24 horas, se recomienda medir en los días más críticos de proceso, por ejemplo, a las 0 h, 48 h, 120 h, 144 h, 168 h, 192 h y el día de empaque (se espera que sea a las 360 horas aproximadamente). Tomar en cuenta que el día de presecado (120 horas) y los dos días posteriores (144 y 168 horas), se realiza un secado suave, ya que es la estapa más crítica de secado por la posibilidad de formación de moho. Por lo que es fundamental extender el cacao procurando reducir el área de contacto entre grano y grano.

Se recomienda que las primeras veces que se use el sistema, se retrolimente con mediciones experimentales cada 24 horas incluyendo el tiempo cero, lo cual acelerará la convergencia del sistema para

esa finca y lugar geográfico específico. En este caso los campos para retroalimentar se aprecian en la figura 12 y corresponden con los valores de humedad Interna, pH y volumen para ese momento. Otro aspecto importante es que las mediciones experimentales, deben realizarse a la misma hora cada día.

Puntos críticos

- En el traslado y en las primeras horas de fermentación en los cajones, es importante permitir que se drene el líquido lixiviado de manera eficiente, ya que un exceso podría intervenir en la velocidad de fermentación y acelerar la formación de ácido acético en un momento no apto, y por lo tanto sobrefermentar el mosto (Pelaez et al., 2016).
- Cuando se inocula solo con hojas de plátano, sin tratamiento adicional, el volteo de la parte aeróbica de la fermentación puede realizarse cada 24 horas, pero cuando se aplican tratamientos con zinc, aminácidos o algún acelerante de la fermentación, se recomienda dar un lapso de 48 horas entre el primer y segundo volteo, para que no ocurra una sobrefermentación (Ayestas et al., 2016).
- Indispensable mover periódicamente los granos en la etapa de secado, especialmente las primeras horas, en las que es importante que la humedad superficial del grano disminuya rápidamente para que las posibilidades de formación de moho disminuyan, pero la humedad interna debe disminuir paulatinamente, para que no se encapsule el ácido acético (Arvelo et al. 2017).
- En el momento de recoger el cacao cuando ya se alcanza la humedad requerida, es importante tomar en cuenta la hora del día para empacar, se recomienda que se realice a la hora del día en el que la temperatura externa es mayor (entre 11 horas y 13 horas), lo cual implica que la humedad interna es menor, por lo que se minimiza la posibilidad de que el cacao se pudra en el empaque.
- Los granos de cacao con un pH de 5,0-5,5 producen un mayor potencial de aroma en comparación con un pH de 4,0-4,5 (Riza et al., 2023), por lo tanto se espera que el día final de secado el pH del cacao se encuentre en este intervalo.

Recomendaciones

Para la etapa de entrenamiento en la finca, se recomienda realizar la cantidad de ensayos de pos-cosecha con retroalimentación constante, que permitan obtener un resultado de predicción en el intervalo

de convergencia deseado (Olofintuyi et al., 2023). Dicho de otra forma si por ejemplo, se entrena al sistema con 10 ensayos, y luego se le realiza una predicción aleatoria en la que el resultado coincide con el intervalo de convergencia esperado y además las métricas (MSE y R^2) del sistema dan resultados más adecuados que los obtenidos en esta investigación, puede considerarse que el motor de aprendizaje, ya puede usarse para predecir. Es importante que cada vez que un resultado se salga del intervalo de convergencia, o el volumen y/o el pH muestre un resultado negativo, se retroalimente al sistema con la información experimental correcta, para que el motor de aprendizaje se autocorrija (Tamayo et al., 2024; Tan et al., 2019).

Una vez que el motor de aprendizaje haya sido entrenado en la finca, la persona productora puede elegir el tipo de consulta que le sea útil, eligiendo el tiempo al que desea obtener una predicción. Por ejemplo si un productor cosecha en época muy lluviosa (influencia de frentes fríos, entre otros), puede usar el predictor para determinar cuantos días tardará el cacao en alcanzar el 6 % a 7 % de humedad, o el pH que tiene en determinada parte del proceso. Estos datos puede ser útiles para tomar decisiones logísticas o correctivas (Adewumi et al., 2016).

Capítulo V

Conclusiones y Recomendaciones

Se implementa un predictor de condiciones finales (humedad interna, pH y volúmen de la semilla) en poscosecha de cacao. Este consiste en una red neuronal de aprendizaje con interfaz web, por medio de la librería Scikit-learn 1.4.1 del lenguaje de programación Python3, con la capacidad para realizar una predicciones, en el intervalo de 0 horas a 420 horas, a partir de condiciones basadas en resultados experimentales; de los cuales se utilizó el 70 % de los datos experimentales para entrenamiento y el 30 % para validación.

El predictor de condiciones finales en poscosecha de cacao, aborda la condición de que la temperatura sea variable en el proceso de poscosecha de cacao, por medio de aprendizaje automático. Esto hace que las predicciones de la herramienta sean aplicables a las fincas que realizan la poscosecha de cacao de manera artesanal o tradicional.

De la integración de los datos experimentales al modelo de aprendizaje, se obtiene que el error cuadrado medio es de 153, mientras que el coeficiente de determinación R^2 , es 0,82. Lo cual implica la necesidad de aumentar la cantidad de datos experimentales para obtener valores de error cuadrado medio, cercanos a cero y valores de R^2 cercanos a 1.

La utilización de funciones de convergencia (modelo de deshidratación isotérmica de Adrover et al., (2020) y el modelo Brusselator en este caso) en el modelo de aprendizaje, permite obtener resultados convergentes en pocas iteraciones, cuando se cuenta con una base de datos experimentales pequeña.

La salida principal del sistema predictor es la humedad interna de la semilla para cualquier instante del proceso poscosecha, sin embargo, salidas como pH, y volúmen pueden aportar información que ayude a corroborar que el resultado es correcto o a descartar el mismo.

Se propone un protocolo poscosecha para reducir pérdidas por fermentación inadecuada y manejo deficiente del secado de cacao en clima tropical húmedo, basado en el uso del predictor de humedad. Se establece que la persona productora o investigadora que use la herramienta, debe alimentar con datos

experimentales el sistema para que se ajuste a sus condiciones, y vaya obteniendo de forma paulatina, predicciones más acertadas y afines al lugar donde se realiza el experimento.

Para futuras retroalimentaciones del sistema se prefiere que la toma de datos experimentales sea realizada en intervalos continuos regulares (por ejemplo día a día, sin saltos) , para que la herramienta de aprendizaje pueda aprender con mayor detalle la ruta de convergencia.

Se recomienda para futuras investigaciones, crear una entrada más en el sistema que represente la variedad genética del lote para que la herramienta, tome en cuenta la genética del cacao y pueda brindar una predicción más exacta y precisa, conforme se van aumentando la cantidad de datos en el sistema.

Capítulo VI

Bibliografía

Acebo, M. (2016). *Estudios industriales y orientación estratégica para la toma de decisiones para la Industria de cacao*. Escuela Politécnica Del Litoral, 42.

Adewumi, I. (2009). *Using Genetic Algorithm for Solving Traveling Salesman Problem* [B.Sc Project Submitted to the Department of Industrial and Production Engineering. Faculty of Technology. University of Ibadan].

Adewumi, I., Orisaremi, K., Ajisegiri, G., & Oladipo, O. (2016). *Artificial Neural Networks Model: reliable forecasting tool in cocoa postharvest losses reduction*. *Journal of Agricultural Technology*, 12, 195–214. <https://www.researchgate.net/publication/298211864>

Adler, P., Bolten, C., Dohnt, K., Hansen, C., & Wittmann, C. (2013). *Core fluxome and metafluxome of lactic acid bacteria under simulated cocoa pulp fermentation conditions*. *Applied and Environmental Microbiology*, 79 (18), 5670–5681. <https://doi.org/10.1128/AEM.01483-13>

Anggraini, C., Putranto, A., Iqbal, Z., Firmanto, H., & Al Riza, D. (2021). *Preliminary study on development of cocoa beans fermentation level measurement based on computer vision and artificial intelligence*. In *IOP Conference Series: Earth and Environmental Science* (Vol. 924). IOP Publishing Ltd. <https://doi.org/10.1088/1755-1315/924/1/012019>

Aguilar, H. (2017). *Actividades de poscosecha para lograr cacao de calidad*. Infocacao, Septiembre (14), 8. http://www.fhia.org.hn/downloads/cacao_pdfs/infocacao/InfoCacao_No14_Sept_2017.pdf

Adrover, A., Brasiello, A., Ponso, G. (2019). *A moving boundary model for food isothermal drying and shrinkage: A shortcut numerical method for estimating the shrinkage factor*. *Journal of Food Engineering*, 244 (), 212–219. <https://doi:10.1016/j.jfoodeng.2018.09.030>

Adrover, A., & Brasiello, A. (2019). *A moving boundary model for food isothermal drying and shrinkage: One-dimensional versus two-dimensional approaches*. *Journal of Food Process Engineering*, 42 (6). <https://doi.org/10.1111/jfpe.13178>

Adrover, A., & Brasiello, A. (2020). 3-D Modeling of Dehydration Kinetics and Shrinkage of Ellipsoidal Fermented Amazonian Cocoa Beans. *Drying Kinetics and Quality Control in Food Processing. Processes*, 8 (2), 1–21. <https://doi.org/10.3390/pr8020150>

Alean, J. (2011). *Modelado y simulación del cacao secado con aire* [Tesis de grado presentado como requisito para optar por el título Maestría en Ingeniería Química. Escuela de Energía y procesos. Facultad de minas. Universidad Nacional de Colombia sede Medellín].

Álvarez, C., Tovar, L., García, H., Morillo, F., Sánchez, P., Girón, C., & De Farias, A. (2010). *Evaluación de la calidad comercial del grano de cacao (Theobroma cacao L.) usando dos tipos de fermentadores*. *Revista Científica UDO Agrícola*, 10 (1), 76–87.

Álvarez, D. (2016). *Diseño del Programa de Evaluación y Aprobación de Proveedores en la empresa Costa Rican Cocoa Products, como parte de la implementación del Sistema de Inocuidad, según el esquema de certificación FSSC 22000* [Informe de Práctica Dirigida presentado a la Escuela de Tecnología de Alimentos para optar por el grado de Licenciado en Ingeniería de Alimentos. Universidad de Costa Rica].

Aramburo, D. (2017). *Condiciones Productivas de Cacao de los Territorios Rurales de la Zona Norte y Caribe de Costa Rica*. IICA. <http://repositorio.iica.int/handle/11324/6460>

Arvelo et al., (2017). *Manual técnico del cultivo de cacao Buenas prácticas para América Latina*. I, Instituto Interamericano de Cooperación para la Agricultura (IICA). I. Edición M. Arvelo. IICA.

Ayestas, E., Vega-Jarquín, C., Torres, P., Lanzas, J., Orozco, L., y Astorga, C. (2014). *Puntos críticos del manejo poscosecha de cacao en Waslala, Nicaragua*. *La Calera*, 14 (22), 5–12. <https://doi.org/10.5377/calera.v14i22.2650>.

Barrientos, L. D. P., Oquendo, J. D. T., Garzón, M. A. G., & Álvarez, O. L. M. (2019). *Effect of the solar drying process on the sensory and chemical quality of cocoa (Theobroma cacao L.) cultivated in Antioquia, Colombia*. *Food Research International*, 115, 259–267. <https://doi.org/10.1016/j.foodres.2018.08.084>.

Baker, D. M., Tomlins, K. I., & Gay, C. (1994). *Survey of Ghanaian cocoa farmer fermentation practices and their influence on cocoa flavour*. *Food Chemistry*, 51 (4), 425–431.

Bonde, O., & Karlsson, L. (2020). *A Comparison of Selected Optimization Methods for Neural Networks*. <http://kth.diva-portal.org/smash/get/diva2:1438308/FULLTEXT01.pdf>

Calvo, A. M., Botina, B. L., García, M. C., Cardona, W. A., Montenegro, A. C., & Criollo, J. (2021). *Dynamics of cocoa fermentation and its effect on quality*. *Scientific Reports*, 11 (1). <https://doi.org/10.1038/s41598-021-95703-2>

Camu, N., Verbrugghe, K., Cleenwerck, I., Vandamme, P., Takrama, J., Vancanneyt, M. (2007). *Dynamics and biodiversity of populations of lactic acid bacteria and acetic acid bacteria involved in spontaneous heap fermentation of cocoa beans in Ghana*. *Appl. Environ. Microbiol.* 73, 1809–1824. <https://doi.org/10.1128/AEM.02189-06>

Camu, N., De Winter, T., Addo, S., Takrama, J., Bernaert, H., De Vuyst, L. (2008). *Fermentation of cocoa beans: influence of microbial activities and polyphenol concentrations on the flavour of chocolate*. *Journal of the Science of Food and Agriculture* (88): 2288-2297.

CAOBISCO/AEC/FCC. (2015). *Cacao en Grano: Requisitos de Calidad de la Industria del Chocolate y del Cacao*. *Revista Brasileira de Medicina* (Vol. 69, p. 110). [http://www.cocoaquality.eu/data/Cacao en Grano Requisitos de Calidad de la Industria Apr 2016_es.pdf](http://www.cocoaquality.eu/data/Cacao%20en%20Grano%20Requisitos%20de%20Calidad%20de%20la%20Industria%20Apr%202016_es.pdf)

Castillo-Orozco, E., Garavito, O., Saavedra, O., & Mantilla, D. (2023). *The Drying Kinetics and CFD Multidomain Model of Cocoa Bean Variety CCN51*. *Foods*, 12 (5). <https://doi.org/10.3390/foods12051082>

Chinenye, N. M., Ogunlowo, A. S., & Olukunle, O. J. (2010). *Cocoa bean (Theobroma cacao L.) drying kinetics*. *Chilean Journal of Agricultural Research*, 70 (4), 633–639. <https://doi.org/10.4067/s0718-58392010000400014>

Cortés, F. B., Chejne, F., & Rojano, B. (2011). *A new model for predicting sorption isotherm of water in foods*. *International Journal of Food Engineering*, 7 (2). <https://doi.org/10.2202/1556-3758.2254>

Cortés-Peña, Y., Kumar, D., Singh, V., & Guest, J. S. (2020). *BioSTEAM: A Fast and Flexible Platform for the Design, Simulation, and Techno-Economic Analysis of Biorefineries under Uncertainty*. *ACS Sustainable Chemistry and Engineering*, 8 (8), 3302–3310.

Cubero, E. (1990). *Indicadores químicos de la calidad del grano seco de cacao (Theobroma cacao L.) y su aplicación* [Proyecto de graduación para optar por el grado de Licenciatura en Tecnología de Alimentos, Carrera Interdisciplinaria en Tecnología].

Ctn, I. (2009). *Cacao y productos derivados del cacao — Cacao en grano — Clasificación y requisitos*. *INTECO*, 1 (506), 1–10.

Deus, V. L., De Cerqueira, E., Silva, M. B., Maciel, L. F., Miranda, L. C. R., Hirooka, E. Y., Soares, S. E., Da Silva, E. (2018). *Influence of drying methods on cocoa (Theobroma cacao L.): Antioxidant activity and presence of ochratoxin A*. *Food Science and Technology*, 38, 278–285. <https://doi.org/10.1590/fst.09917>

Díaz-Muñoz, C., Voorde, D. V. D., Comasio, A., Verce, M., Hernandez, C. E., Weckx, S., & Vuyst, L. D. (2021). *Curing of Cocoa Beans : Fine-Scale Monitoring of the Starter Cultures Applied and Metabolo-*

mics of the Fermentation and Drying Steps. *Frontiers in Microbiology*, 11, 3446. <https://doi.org/10.3389/fmicb.2020.616875>

Dzelagha, B. F., Ngwa, N. M., & Bup, D. N. (2020). *A review of cocoa drying technologies and the effect on bean quality parameters*. *International Journal of Food Science*. Hindawi Limited.

End, M.J., Dand, R. (2015). *Cocoa Beans: Chocolate and Cocoa Industry Quality Requirements*. Editor ECA-Caobisco-FCC Cocoa. ISBN: 978-2-9601817-2-2.

Erazo-Solórzano, C. et al. (2021). *De maderas no convencionales sobre la calidad física y sensorial del Licor de Cacao (Theobroma cacao L.)*. *Revista de Investigación Talentos*, 8 (2), 42–55.

Ernst, O. K. (2016). *Stochastic Gradient Descent Learning and the Backpropagation Algorithm*. Recuperado de: <https://isn.ucsd.edu/courses/beng260/2014/reports/Oliver%20Ernst/ernst.pdf>

Estrada, M., Romero, X., y Moreno, J. (2011). *Guía técnica del cultivo de cacao manejado con técnicas agroecológicas*. IICA. ISBN: 978-92-9248-732-4.

Gil, M., Jaramillo, Y., Bedoya, C., Llano, S. M., Gallego, V., Quijano, J., & Londono-Londono, J. (2019). *Chemometric approaches for postharvest quality tracing of cocoa: An efficient method to distinguish plant material origin*. *Heliyon*, 5 (5). Recuperado de: <https://doi.org/10.1016/j.heliyon.2019.e01650>

Gonçalves, C. (2017). *Quantum Neural Machine Learning - Backpropagation and Dynamics*. University of Lisbon, Institute of Social and Political Sciences. cgoncalves@iscsp.ulisboa.pt.

Guerrero, M. (2007). *Diagnóstico y propuesta de parámetros para la estandarización y homogenización del tratamiento poscosecha de cacao*. *Mef*, 3 (1), 78.

Herman, C., Spreutels, L., Turomzsa, N., Konagano, E.M., Haut, B. (2018). *Convective drying of fermented Amazonian cocoa beans (Theobroma cacao var. Forasteiro)*. *Experiments and mathematical modeling*. *Food and Bioproducts Processing*. Recuperado de: <https://doi.org/10.1016/j.fbp.2018.01.002>

Herman, C., Fauvieu, J., Haut B. (2019). *Evolution of the moisture content in the core and the shell of fermented Amazonian cocoa beans during drying*. In *Proceedings of the EuroDrying — 7th European Drying Conference*, Torino, Italy, 10–12 July 2019; 158–165.

Hernani, Hidayat, T., & Mulyawanti, I. (2019). *The Usage of Dried Starter for Re-Fermentation of Unfermented Cocoa Beans*. *IOP Conference Series: Earth and Environmental Science*, 309 (1). Recuperado de: <https://doi.org/10.1088/1755-1315/309/1/012061>

Herrera, C., Ospina, N. (2016). *Nibs de cacao orgánico para mercados verdes: Monografía. Programa Especialización en procesos industriales agroalimentarios*. Facultad de Tecnología. Universidad Tecnoló-

gica de Pereira.

Hii, C., Law, C., Law, M. (2013). *Simulation of heat and mass transfer of cocoa bean under stepwise drying conditions in a heat pump dryer*. Applied Thermal Engineering, 54, 264–271.

Himmelblau, D., & Riggs, J. (2004). *Basic principles _ calculations in chemical engineering*. Prentice-Hall, Ed.; 7th ed.

Jacobi, J., Schneider, M., Isabel, M., Mariscal, P., Huber, S., Weidmann, S., & Rist, S. (2014). *The contribution of organic cocoa production to the socio-ecological resilience in the context of climate change in the Alto Beni-La Paz*. Acta Nova, 6, 1683–0768.

Jalil, M., Osmail, A. (2008). *Polyphenols in cocoa and cocoa products: is there a link between antioxidant properties and health?*. Molecules (Basel, Switzerland), 13 (9), 2190-2219. PMID:18830150. <https://doi.org/10.3390/molecules13092190>

John, W., Kumari, N., Böttcher, N., Koffi, K., Grimbs, S., Vrancken, G., D'Souza R., Kuhner, N., Ullrich, M. (2016). *Aseptic artificial fermentation of cocoa beans can be fashioned to replicate the peptide profile of commercial cocoa bean fermentations*. Food Research International 89:764-772.

Kern, D. *Procesos de Transferencia de calor (1999)*. Trigésima primera reimpresión. CECSA. Compañía Editorial Continental de Mexico. ISBN 96826- 1040-0

Koua, B., Koffi, P., Gbaha, P. (2019). *Evolution of shrinkage, real density, porosity, heat and mass transfer coefficients during indirect solar drying of cocoa beans*. Journal of the Saudi Society of Agricultural Sciences, 18 (1), 72–82. <https://doi.org/10.1016/j.jssas.2017.01.002>

Kyi, T., Wan, D., Abu, M., Mohd, S., Abdul, H., & Meor, M. (2005). *The kinetics of polyphenol degradation during the drying of Malaysian cocoa beans*. International Journal of Food Science & Technology, 40 (3), 323-331.

McDowell, M. P. (2008). *Mathematical Modeling of the Brusselator*. Department of Aerospace and Mechanical Engineering. University of Notre Dame. <https://www3.nd.edu/~powers/mcdowell.pdf>

Medina, J. D. L. C., y Vargas, O. (2009). *CACAO: Operaciones Poscosecha*. Instituto Tecnológico de Veracruz, 1–78. <http://www.fao.org/3/a-au995s.pdf>

Moreno-Zambrano, M., Grimbs, S., Ullrich, M. S., & Hütt, M. T. (2018). *A mathematical model of cocoa bean fermentation*. Royal Society Open Science, 5 (10). <https://doi.org/10.1098/rsos.180964>

Motamayor, J. C., Lachenaud, P., da Silva E Mota, J. W., Loor, R., Kuhn, D. (2008). *Geographic and Genetic Population Differentiation of the Amazonian Chocolate Tree (Theobroma cacao L.)*. (10), 3311. <https://doi.org/10.1002/ajb.10000>

doi.org/10.1371/journal.pone.0003311

Muloiwa, M., Nyende-Byakika, S., Dinka, M. (2020). *Comparison of unstructured kinetic bacterial growth models*. South African Journal of Chemical Engineering, Volume 33, 2020, Pages 141-150, ISSN 1026-9185. <https://doi.org/10.1016/j.sajce.2020.07.006>

Nigam, P. S., & Singh, A. (2014). *Cocoa and Coffee Fermentations*. In Encyclopedia of Food Microbiology: Second Edition (pp. 485–492) Elsevier Inc. <https://doi.org/10.1016/B978-0-12-384730-0.00074-4>

Obando-Ulloa, J. M., y Guzmán Hernández, T. D. J. (2019). *La tecnología térmica solar aplicada al proceso de secado de cacao*. Programa de Doctorado en Ciencias Naturales para el Desarrollo (DOCINADE). ITCR. Boletín Investiga TEC.

Obiakor, E. (1975). *Experimental Evaluation of Mechanical Dehydration of Nigerian Cocoa Beans*. Nigerian Journal of Technology, 1.

Olofintuyi, S. S., Olajubu, E. A., & Olanike, D. (2023). *An ensemble deep learning approach for predicting cocoa yield*. Heliyon, 9 (4). <https://doi.org/10.1016/j.heliyon.2023.e15245>

Ortiz de Bertorelli, L., Graziani de Fariñas, L., y Rovedas L, Gervaise. (2009). *Influencia de varios factores sobre características del grano de cacao fermentado y secado al sol*. Agronomía Tropical, 59 (2), 119-127.

Papalexandratou, Z., Vrancken, G., Bruyne K., Vandamme, P., Vuyst, D. (2011). *Spontaneous organic cocoa bean box fermentations in Brazil are characterized by a restricted species diversity of lactic acid bacteria and acetic acid bacteria*. Food Microbiol. 28, 1326–1338. <https://doi:10.1016/j.fm.2011.06.003>

Pedregosa, F; Varoquaux, G; Gramfort; Michel, V; Thirion, B; Grisel, O; Blondel, M; Prettenhofer, P. (2011). *Scikit-learn: Machine Learning in Python*. Journal of Machine Learning Research 12, pp. 2825-2830. <https://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf>

Pedregosa, F; Varoquaux, G; Gramfort; Michel, V; Thirion, B; Grisel, O; Blondel, M; Prettenhofer, P. (Febrero 2024). *Scikit-learn: Machine Learning in Python*. Versión scikit-learn 1.4.1. <https://scikit-learn.org>

Pelaez, P., Guerra, S., Contreras, D. (2016). *Changes in physical and chemical characteristics of fermented cocoa (Theobroma cacao) beans with manual and semi-mechanized transfer, between fermentation boxes*. Scientia Agropecuaria, 07 (02), pp. 111–119. <https://doi.org/10.17268/sci.agropecu.2016.02.04>

Peña, C., Arango, R., y Restrepo, F. (2010). *Efecto de adición de iones hierro y zinc sobre la producción de etanol de dos cepas recombinantes de Saccharomyces cerevisiae* The effect of adding iron and zinc ions to ethanol production from two recombinant Saccharomyces cerevisiae strains. Revista Colombiana de

Biotecnología (Vol. 1).

Phillips-mora, W., Arciniegas-leal, A., Mata-quirós, A., Motamayor-arias, J. (2012). *Catálogo de clones de Cacao seleccionados por el CATIE*. Serie Técnico. Manual Técnico 105. CATIE. ISBN 978-9977-57-571-1

Quesada-Arguedas, P., Hernández-Aguirre, C., Vargas-Martínez, A., Mencía-Guevara, A. (2024). *Perfil de calidad de cacao utilizando Espectroscopía de Infrarrojo Cercano portable, desafíos para diferenciación geográfica*. Laboratorio de Calidad e Innovación Agroalimentaria (LABCIAGRO), Universidad Nacional.

Raju, R., Heyes, J., Archer, R., & Chen, Q. (2019). *Drying behaviour of fermented Fijian Theobroma cacao using dehumidified air*. In AIP Conference Proceedings (Vol. 2199). American Institute of Physics Inc. <https://doi.org/10.1063/1.5141279>

Rivera-Fernández, R. D., Barrera-Álvarez, A. E., Guzmán-Cedeño, Á. M., Medina-Quinteros, H. N., Casanova Ferrín, L. M., Peña Galeas, M. M., y Nivelá Morante, P. E. (2012). *Efecto del tipo y tiempo de fermentación en la calidad física y química del cacao (Theobroma cacao L.) tipo nacional*. Ciencia y Tecnología, 5 (1), 7-12.

Riza, D., Putranto, W., Iqbal, Z., Firmanto, H., & Anggraini, C. (2023). *Prediction of Fermentation Index and pH of Cocoa (Theobroma cacao L.) Beans Based on Color Features (Cut Test) and Partial Least Square Regression Model*. Food Science and Technology (United States), 11 (1), 54-62.

Rohan, T. (1960). *El beneficiado del cacao*. Organización de las Naciones Unidas para la Agricultura y la Alimentación, Roma.

Rojas-Rojas, K., Hernández-Aguirre, C. and Mencía-Guevara, A. (2021). *Transformaciones bioquímicas del cacao (Theobroma Cacao) durante un proceso de fermentación controlada*. Agronomía Costarricense, 45 (1), pp. 53-65. ISSN:0377-9424.

Ruder, S. (2016, September 15). *An overview of gradient descent optimization algorithms*. Ruder.io: A Blog about Natural Language Processing and Machine Learning. <http://arxiv.org/abs/1609.04747>

Russel, R. (2018). *Machine Learning. Guía paso a paso para implementar algoritmos de Machine Learning in python*. Manual. Editado por el autor.

Schwan, R. F., Pereira, G. V. de M., & Fleet, G. H. (2014). *Microbial activities during cocoa fermentation*. Cocoa and Coffee Fermentations, January 2014, 129-192. https://www.researchgate.net/publication/285267847_Microbial_activities_during_cocoa_fermentation

SEPSA. (2017). *Análisis de la actividad cacaotera costarricense y perspectivas de su reactivación* (p. 87). <http://www.mag.go.cr/bibliotecavirtual/E16-10869.pdf>

Stevenson, C. Corven, J. Villanueva, G. (1993). *Manual para análisis de Laboratorio*. Serie Publicaciones Misceláneas. Instituto Interamericano de Cooperación para la Agricultura (IICA). ISSN-0534-5391.

Sundnes, J. (2023). *Solving Ordinary Differential Equations in Python: Vol. I. Simula Research Laboratory*. https://sundnes.github.io/solving_odes_in_python/

Tamayo, L., Ferrancol, Z., & Romero, E. (2024). *A review of machine learning applications in Cacao Post-harvest management*. *International Journal of Science and Research Archive*, 11 (1), 1540 – 1550. <https://doi.org/10.30574/ijrsra.2024.11.1.0186>

Tan, J., Balasubramanian, B., Sukha, D., Ramkissoon, S., & Umaharan, P. (2019). *Sensing fermentation degree of cocoa (Theobroma cacao L.) beans by machine learning classification models based electronic nose system*. *Journal of Food Process Engineering*, 42 (6). <https://doi.org/10.1111/jfpe.13175>

Teneda Llerena, W. F. (2016). *Mejoramiento del Proceso de Fermentación del Cacao (Theobroma cacao L.) Variedad Nacional y Variedad CCN51 (I)*. Universidad Internacional de Andalucía. Servicio de Publicaciones.

Tinoco, H., y Ospina, D. Y. (2010). *Análisis del proceso de deshidratación de cacao para la disminución del tiempo de secado*. *Revista EIA*, 13, 53–63.

Treybal, R. E. (2000). *Operaciones de Transferencia de masa*. (2a. ed). McGraw-Hill International.

Tronci, S., Giona, M., & Baratti, R. (2003). *Reconstruction of chaotic time series by neural models: A case study*. *Neurocomputing*, 55 (3–4), 581–591. [https://doi.org/10.1016/S0925-2312\(03\)00394-1](https://doi.org/10.1016/S0925-2312(03)00394-1)

Umaña, M. (2013). *Anteproyecto de una planta de procesamiento para la elaboración de un producto tradicional y un producto funcional obtenido a partir del grano de cacao (theobroma cacao l.)* [Proyecto de graduación presentado a la Escuela de Ingeniería Agrícola como requisito parcial para optar por el grado de Licenciatura en Ingeniería Agrícola. Universidad de Costa Rica].

Ureña, M., y Sandoval, A. (2021). *Prototipo de fermentador portátil ecológico, optimización del proceso de fermentación*. Fontagro. https://fontagro.org/new/uploads/productos/16109_-_Producto_6.pdf

Zea Vallejo, Daniel Arturo. (2017, December 15). *Do intermediaries sweeten the deal? An inquiry into the activities of intermediaries and their effect on small and medium producers within the Cocoa Value Chain in Ecuador*. *Governance and Development Policy (GDP)*. <http://hdl.handle.net/2105/41801>

Capítulo VII

Anexos

Anexo 1: Descripción de los ensayos realizados realizados

A continuación se describen los detalles de cada ensayo durante experimental, a modo de bitácora de operación.

Ensayo 1: 26 de junio al de 10 de julio 2023

La fermentación se realizó en un cajón de laurel, con un espesor de 10 cm, al cual no se le aplicó tratamientos. Las primeras 48 horas de iniciada la fermentación predomina el mecanismo de fermentación anaeróbica (Schwan et al., 2014). De 48 a 144 horas predomina el mecanismo aeróbico (Teneda-Llerena, 2016), debido a que en esta etapa se realizan volteos cada 24 horas (Aguilar, 2017). De 144 a 168 horas se lleva el presecado, el cual consiste en reposo por un día en una superficie de madera sin exposición al sol (Aguilar, 2017). En la etapa de secado se utilizó una plataforma metálica existente, a la cual se le colocó un sarán para invernadero, para cubrir las partes metálicas. Se expuso al sol directo todos los días de esta etapa, de 5 horas a 6 horas por día, dependiendo de la disponibilidad para asistir a la finca. El cacao se guardó en las noches en un espacio techado para evitar que el rocío propio de la madrugada aumentara la humedad de las semilla. El primer ensayo tiene por objetivo, probar los instrumentos de medición en un ensayo real, para esto se utilizó un pH-metro de electrodo para tomar lectura de pH en la pulpa in-situ, sin embargo las condiciones de la finca resultaron no ser adecuadas para el tomar muestras in- situ con este instrumento, ya que el constante movimiento del aparato, produjo mediciones discortantes con la realidad del proceso, por lo que se tomó la desición tomar muestras de pH interno, pero en laboratorio.

Ensayo 2: 13 de julio al de 28 de julio 2023

Se utilizó el mismo cajón de fermentación, después de haber sido lavado solamente con agua y secado al sol (Aguilar, 2017). Como inóculo se utilizó las levaduras de las hojas de plátano de la finca (Ureña y Sandoval, 2021), de forma que se colocaron en forma de cama dentro del cajón. Luego se agregó el cacao en baba, se colocaron los electrodos para determinar temperatura y humedad externa, se terminó de cubrir la masa de cacaco con las hojas de plátano. Por último el cajón fue cerrado con tablas de madera de laurel. En las primeras 48 horas predomina la fermentación anaeróbica, no se realiza volteo. De 48 a 120 horas se lleva a cabo la fermentación aeróbica y se voltea cada 24 horas, hasta las 120 horas que da inicio la etapa de pre-secado. La etapa de secado inicia a las 144 horas de haber iniciado el proceso. En este caso se utilizó una

plataforma metálica existente, sobre la se colocó dos cajas de Rohan como base madera para secar sin que se afecte el sabor final del cacao (también se utilizaron dos cajones para poder extender el cacao y tener mayor área de exposición). La etapa de secado se prolongó por 8 días y durante este periodo la masa cacao tuvo una exposición de 4 a 6 horas de sol directo por día. Cabe aclarar que en la etapa de fermentación se tomó la masa total de cacao y en el etapa de secado, ésta se dividió en 2, por lo que los datos de las primeras 144 horas, son iguales para los dos conjuntos de datos.

Ensayo 3: 26 de julio al 10 de agosto 2023

Después de haber determinado empíricamente que los cajones de fermentación pueden conservar el calor hasta cierto punto y funcionar como aislante térmico, lo que permite que en las madrugadas la temperatura de fermentación no descienda hasta la temperatura ambiente y se permita la cocción del coctiledón de forma constante durante la etapa de fermentación aeróbica (Ureña y Sandoval, 2021); se realiza un tercer ensayo en el que se realiza otra prueba empírica para la selección de la técnica de secado. En caso se realiza la fermentación en un solo cajón, en el que al finalizar la etapa de fermentación aeróbica se separa el mosto en dos partes iguales. La primera parte del mosto se lavan la semillas hasta quitarles los restos de pulpa fermentada, luego se escurre y se deja presecando por 24 horas. La segunda parte del mosto se deja presecando sin lavar en un tablas de madera, tal y como se realizó en los ensayos 1 y 2.

Ensayo 4: 04 al 20 de octubre 2024

En este caso se fermentan 210 kilogramos de cacao, distribuido en en tres cajones de fermentación señalado de la siguiente forma: Control y dos tratamientos; Amino y zinc. Los lotes se pueden distinguir de la siguiente forma: Lote control, el cual fue solamente inóculado con las levaduras proporcionadas por las hojas de plátano. Lote Amino, al cual de se le aplicó además del recubrimiento del mosto con hojas de plátano, un inóculo enriquecido con aminoácidos . Por último el lote Zinc, el cual también fue recubirto con hojas de plátano dentro del cajón e inculado con una mezcla de aminoácido enriquecidos y zinc como nutrientes. También se utilizó la termocupla Omega con salida para 8 sensores, distribuidos de la siguiente manera: Lote control utiliza los sensores T7 y T8. El lote Amino, utiliza los sensores T4 y T3; el Lote Zinc utiliza los sensores T1 y T2 y los sensores T5 y T6 son utilizados para determinar la temperatura ambiente. A partir de este ensayo, los volteos de la etapa de fermentación aeróbica se realizaron cada 48 horas y no

cada 24 horas como se venía haciendo, por recomendación de productores de la Zona norte de Costa Rica. Hasta este punto el clima no había influido de manera negativa al proceso, sin embargo, una alta humedad relativa, acompañada de nubosidad intensa, producida por ondas tropicales típicas de la época, hicieron que el proceso de secado no fuese adecuado, hasta el momento consistía en sacar los cajones del invernadero en la mañana entre 4 y 5 horas de la mañana, e ingresar los cajones para protegerlos de la lluvia entre las 11 y 13 horas, lo cual implicaba esfuerzo físico excesivo, pocas horas de secado y un área de exposición al sol muy limitada, el secado se hizo en cajones Rohan, lo cual no permitió una buena distribución para secar. Estos factores favorecieron la formación de moho. También se presentó otro inconveniente; en la etapa de fermentación los datalogger y la termocupa pueden acumular una capa de sólidos provenientes de la pulpa en descomposición que actúa como aislante e interfiere con el valor real de temperatura. Por lo tanto para este ensayo no se pudo obtener datos de humedad y temperatura en la pulpa-cáscara. Sin embargo este ensayo deja valiosas experiencias para atender el objetivo fundamental del proyecto, fermentar y secar cacao cuando las condiciones climáticas son adversas. Por lo tanto en los siguientes 2 ensayos se utiliza un invernadero para llevar a cabo la etapa de secado y se tiene el cuidado de extender correctamente el cacao para favorecer el proceso eliminación de agua.

Ensayo 5. 02 al 20 de noviembre de 2023

Control y dos tratamientos. Para este ensayo predominaron las condiciones de nubosidad y humedad relativa altas al igual que en el ensayo 4, sin embargo de esa experiencia, se tomaron medidas como limpiar los sensores de los dataloggers cada vez que se realiza un volteo. En la etapa de fermentación aeróbica el volteo fue tomado cada 48 horas a partir del inicio de esta etapa. En este caso el resultado final de la poscosecha se consideró positivo, humedad cercana a 7 %, olor y sabor característico de un tratamiento correcto, por lo que este lote se envió a proceso de chocolatería. Entre los aspectos determinantes para la obtención de la calidad deseada, destaca el uso de invernadero para la etapa de secado, extensión del cacao sobre saranes para aumentar el área de exposición y agitación de las semillas en cada visita. Además se realizó un raleo preventivo constante, ante la primer sospecha (olor, aparición de puntos blancos, etc), por lo que fueron retirados del invernadero los granos que presentaron estas condiciones, lo que permitió que a pesar de el secado fue leve y muy extenso en días (12 días de secado), el resultado final fuese apropiado para chocolatería. Este escenario es importante por que emula una poscosecha exitosa en condiciones

extremas de humedad en el campo, lo cual permitirá en la presente investigación emitir recomendaciones para los productores que realicen poscosecha en estas condiciones (Adewumi et al., 2016).

Ensayo 6: del 20 de noviembre al 6 de diciembre 2024

El ensayo numero 6 fue realizado en colaboración con los estudiantes Edgar Bermúdez y José Sanchez , quienes realizan su proyecto graduación de licenciatura en la Universidad Nacional, carrera de Ciencias Agrarias. En este ensayo tambien se tuvo 3 días de fermentación aeróbica, con volteos de 48 horas. Debido a que el proceso de secado se dió una semana antes de la salida a receso institucional, se decidió detener el secado el 05 de diciembre, ya que el laboratorio de calidad e innovación agroalimentaria cesara sus actividades el 06 de diciembre. Como puede observarse en la figura 4.4, el 05 de diciembre aún no se había alcanzado el 7 % de humedad para considerarse seco, sin embargo la gráfica también muestra que de acuerdo a la experiencia de los otros ensayos y la tendencia de la grafica, el valor se iba a alcanzar en uno o dos más de secado. El sabor y el olor al día 5 de diciembre ya se percibia como óptimos. Los dos lotes fueron llevados a chocolatería, para producir licor de cacao.

Anexo 2: Memoria gráfica de la parte experimental

Figura 13. Acondicionamiento de los cajones y fermentación.



Nota. Elaboración propia (2024).

Figura 14. Prueba de corte, presecado y secado.



Nota. Elaboración propia (2024).

Figura 15. Instrumentos de medición.



Nota. Elaboración propia (2024).