



UNIVERSIDAD AUTÓNOMA CHAPINGO

POSGRADO EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA

MODELACIÓN DEL DESHIDRATADO DE PLÁTANO MEDIANTE
MODELOS AUTORREGRESIVOS EN UN SECADOR SOLAR TIPO
INVERNADERO APOYADO CON IOT

TESIS QUE COMO REQUISITO PARCIAL PARA OBTENER EL
GRADO DE:

**MAESTRO EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA**

PRESENTA:

BALTAZAR LÓPEZ VELASCO

BAJO LA SUPERVISIÓN DE:

DR. AGUSTÍN RUIZ GARCÍA



APROBADA



Chapingo, México. Noviembre de 2023.

MODELACIÓN DEL DESHIDRATADO DE PLÁTANO MEDIANTE MODELOS
AUTORREGRESIVOS EN UN SECADOR SOLAR TIPO INVERNADERO
APOYADO CON IOT

Tesis realizada por Baltazar López Velasco bajo la dirección del Comité Asesor
indicado, aprobada por el mismo y aceptada como requisito parcial para obtener
el grado de:

MAESTRO EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA

DIRECTOR:



DR. AGUSTÍN RUIZ GARCÍA

ASESOR:



DR. ÁNGEL GARDUÑO GARCÍA

ASESOR:



DR. CARLOS ALBERTO VILLASEÑOR PEREA

CONTENIDO

1	INTRODUCCIÓN GENERAL	1
1.1	Objetivo general	3
1.2	Objetivos particulares.....	4
1.3	Estructura de la tesis	4
1.4	Literatura citada	4
2	REVISIÓN DE LITERATURA.....	7
2.1	Antecedentes.....	7
2.2	Clasificación de los sistemas de secado solar	9
2.3	Secador solar tipo invernadero	11
2.4	Secado de plátano	14
2.5	Estructura e identificación de modelos ARX y NARX.....	18
2.6	Modelos ARX y NARX usados para modelar el proceso de secado en productos agrícolas.....	21
2.7	La internet de las cosas (IoT).....	25
2.7.1	Aplicaciones de IoT en la agricultura	25
2.7.2	Monitoreo basado en IoT en secadores de productos agrícolas.....	28
2.8	Literatura citada	32

3	MONITOREO DEL AMBIENTE APOYADO EN IOT Y PREDICCIÓN DEL CONTENIDO DE HUMEDAD DE PLÁTANO EN UN SECADOR SOLAR TIPO INVERNADERO	41
3.1	Resumen	41
3.2	Introducción	42
3.3	Materiales y Métodos	44
3.3.1	Descripción del secador solar	44
3.3.2	Experimento de deshidratado	44
3.3.3	Medición del color y dulzura.....	45
3.3.4	Estructura del sistema de monitoreo.....	46
3.3.5	Mediciones y sistema de registro de datos	51
3.3.6	Modelado del contenido de humedad del producto	53
3.4	Discusión y análisis de resultados.....	54
3.4.1	Evolución de las variables ambientales	54
3.4.2	Contenido de humedad del plátano	59
3.4.3	Propiedades del plátano deshidratado.....	60
3.4.4	Desempeño del sistema de monitoreo.....	61
3.4.5	Modelación del contenido de humedad del producto	63
3.5	Conclusiones.....	65
3.6	Referencias.....	66
4	PREDICCIÓN MEDIANTE MODELOS AUTORREGRESIVOS DE LA TEMPERATURA DEL AIRE Y EL CONTENIDO DE HUMEDAD DE PLÁTANO DURANTE EL DESHIDRATADO	69
4.1	Resumen	69

4.2	Introducción	70
4.3	Materiales y métodos.....	71
4.3.1	Experimentos de deshidratado con producto	72
4.3.2	Mediciones y sistema de registro de datos	72
4.3.3	Estructura de los modelos autorregresivos con entradas exógenas.....	74
4.3.4	Selección de las variables de entrada.....	76
4.3.5	Identificación y construcción de los modelos autorregresivos.....	76
4.4	Resultados y discusión	79
4.4.1	Variables de entrada a los modelos	79
4.4.2	Mejores modelos autorregresivos con entradas exógenas	80
4.4.3	Análisis de rendimiento de predicción de los modelos ARX	85
4.4.4	Mejores redes no lineales autorregresivas con entradas exógenas	88
4.4.5	Análisis del rendimiento de predicción de los modelos NARX	91
4.5	Conclusiones.....	95
4.6	Bibliografía	96
5	CONCLUSIONES GENERALES.....	100

ÍNDICE DE CUADROS

Cuadro 2-1. Características físicas y químicas del plátano seco (Ferreira & Freitas 2019).....	17
Cuadro 2-2. Trabajos previos sobre monitoreo basado en IoT en secadores de productos agrícolas.....	28
Cuadro 3-1. Características de los sensores del sistema de monitoreo.	48
Cuadro 3-2. Lista de componentes electrónicos del sistema de monitoreo.	48
Cuadro 3-3. Contenido de azúcar y variaciones de color del plátano dominico fresco y deshidratado.....	61
Cuadro 3-4. Mejores modelos ARX identificados en línea obtenidos para predecir el contenido de humedad del plátano durante el experimento uno.....	63
Cuadro 3-5. Estadísticos de evaluación del modelo ARX identificado en línea para predecir el contenido de humedad del plátano.	65
Cuadro 4-1. Mejores modelos ARX obtenidos para predecir la T_a un paso hacia adelante con 50% de información para estimación y 50% para validación.....	79
Cuadro 4-2. Mejores modelos ARX obtenidos para predecir el M_{wb} un paso hacia adelante con 50% de información para estimación y 50% para validación.....	79
Cuadro 4-3. Modelos ARX obtenidos para predecir la T_a con la T_{amb} y la RH_{amb} como variables de entrada, para diferentes proporciones de datos para estimación y validación.	80
Cuadro 4-4. Modelos ARX obtenidos para predecir el M_{wb} con VPD_{amb} y W_s como variables de entrada ($marx_{out}$), para diferentes proporciones de datos para estimación y validación.	81
Cuadro 4-5. Modelos ARX obtenidos para predecir el M_{wb} con VPD y T_f como variables de entrada ($marx_{in}$), para diferentes proporciones de datos para estimación y validación.	81

Cuadro 4-6. Redes NARX obtenidas para predecir la T_a con la T_{amb} y la RH_{amb} como variables de entrada, para diferentes proporciones de datos para entrenamiento y evaluación.	89
Cuadro 4-7. Redes NARX obtenidas para predecir la T_a con la T_{amb} , RH_{amb} y t_{ext} como variables de entrada, para diferentes proporciones de datos para entrenamiento y evaluación.	89
Cuadro 4-8. Redes NARX obtenidas para predecir el M_{wb} con VPD_{amb} y W_s como variables de entrada ($marx_{out}$), para diferentes proporciones de datos para estimación y validación.	90
Cuadro 4-9. Redes NARX obtenidas para predecir el M_{wb} con VPD_{amb} , W_s y t_{ext} como variables de entrada ($marx_{out}$), para diferentes proporciones de datos para estimación y validación.	90
Cuadro 4-10. Redes NARX obtenidas para predecir el M_{wb} con VPD y T_f como variables de entrada ($marx_{in}$), para diferentes proporciones de datos para estimación y validación.	91
Cuadro 4-11. Redes NARX obtenidas para predecir el M_{wb} con VPD , T_f y t_{ext} como variables de entrada ($marx_{in}$), para diferentes proporciones de datos para estimación y validación.	91

ÍNDICE DE FIGURAS

Figura 2-1. Velocidad de reacción de los diferentes microorganismos y procesos en los productos agrícolas en función de la actividad del agua (Adaptado de Labuza, 1977).	8
Figura 2-2. Clasificación de los sistemas de secado solar (Adaptado de Madhankumar, Viswanathan, Taipabu, & Wu, 2023).	9
Figura 2-3. Secado solar a la intemperie, (a) Arroz, (b) Pescado (Janjai & Bala, 2012).	10
Figura 2-4. Vista pictórica de un secador solar tipo invernadero de (a) Convección natural (Ahmad & Prakash, 2019), (b) Convección forzada y (c) Híbrido (Ahmad et al., 2022).	12
Figura 2-5. Clasificación de los sistemas de secado solar tipo invernadero.	13
Figura 2-6. Secador solar tipo invernadero de forma parabólica con cubierta de policarbonato y piso de concreto (Janjai et al., 2009).	13
Figura 2-7. Secado de plátano a la intemperie (Udomkun et al., 2020).	15
Figura 2-8. Secado de plátano en el interior de un secador solar tipo invernadero con cubierta de policarbonato (Udomkun et al., 2020).	15
Figura 2-9. Secado de plátano verde para la producción de harina mediante secado de ventana de refracción, (a) Rodajas de plátano de frescas, (b) Rodajas de plátano secas, (c) Harina de plátano (Padhi, Murakonda, & Dwivedi, 2022).	16
Figura 2-10. (a) Secado de chips (Singh, Sarkar, & Sahoo, 2020) y (b) muestras enteras de plátano (Kreetachat et al., 2023).	16
Figura 2-11. Ejemplo de productos de plátano secado al sol disponibles en el mercado (Udomkun et al., 2020).	18
Figura 2-12. Procedimiento de identificación de modelos ARX y NARX (adaptado de Zulkeflee, Rohman, Sata, & Aziz, 2021).	19

Figura 2-13. Secador solar doméstico (Aumporn <i>et al.</i> , 2021a).....	22
Figura 2-14. Secador solar tipo invernadero (Aumporn <i>et al.</i> , 2021b)	22
Figura 2-15. Horno de secado al vacío (Pilario, Ching, Calapatia, & Culaba 2022)	23
Figura 2-16. Esquema del secador por aspersión (Poozesh & Cousin 2022)...	23
Figura 2-17. Diagrama de la estructura mecánica del secador de granos (Li & Chen 2020)	24
Figura 2-18. Arquitectura IoT en la agricultura (Zhang, Dabipi, & Brown, 2018)	27
Figura 2-19. Tecnología de transmisión de datos comúnmente utilizada en IoT agrícola (adaptado de Xu, Gua, & Tian, 2022).	27
Figura 3-1. a) Secador solar parabólico tipo invernadero y b) deshidratado de plátano dominico.....	45
Figura 3-2. Funcionamiento del sistema de sensores diseñado para el monitoreo de un secador solar.	47
Figura 3-3. Arquitectura del módulo de adquisición de datos del sistema monitoreo.....	49
Figura 3-4. Arquitectura del módulo de comunicación del sistema de monitoreo.	50
Figura 3-5. Módulo de alimentación del sistema de monitoreo.....	51
Figura 3-6. Distribución de los sensores de medición para la temperatura (T_a), humedad relativa (RH), temperatura de referencia (T_{ref}) y humedad relativa de referencia (HR_{ref}) del aire dentro del secador, muestras del producto (M), señal de encendido y apagado de los extractores (t_{ext}), radiación global (R_g), temperatura (T_{amb}) y humedad relativa (HR_{amb}) del aire exterior	52
Figura 3-7. Radiación solar global (R_g) durante los experimentos de secado de plátano dominico. (a) Experimento uno, (b) experimento dos y (c) experimento tres.....	55

Figura 3-8. Temperatura en el interior (T_a) y exterior (T_{amb}) del secador solar durante el deshidratado de plátano. (a) Experimento uno, (b) experimento dos y (c) experimento tres.	57
Figura 3-9. Humedad relativa en el interior (RH) y exterior (RH_{amb}) del secador solar durante el deshidratado de plátano. (a) Experimento uno, (b) experimento dos y (c) experimento tres.	59
Figura 3-10. Variación del contenido de humedad del plátano dominico en el interior del sistema secador solar tipo invernadero. (a) Experimento uno, (b) experimento dos, (c) experimento tres.	60
Figura 3-11. Interfaz móvil del sistema de monitoreo.	62
Figura 3-12. Visualización gráfica del comportamiento de (a) temperatura y (b) humedad del aire en la interfaz móvil.	63
Figura 3-13. Contenido de humedad del plátano medido y predicho un paso hacia adelante con el modelo ARX. (a) Experimento uno, (b) experimento dos, (c) experimento tres.	64
Figura 4-1. a) Secador solar parabólico tipo invernadero y b) deshidratado de plátano dominico.	72
Figura 4-2. Distribución de los sensores de medición para la temperatura del suelo (T_f), temperatura (T_a) y humedad del aire (RH) dentro del secador, muestras del producto (M), señal de encendido y apagado de los extractores (t_{ext}), temperatura (T_{amb}) y humedad del aire (RH_{amb}), velocidad (W_s) y dirección del viento (W_d) del clima exterior.	73
Figura 4-3. Comparación del valor de T_a medido y predicho un paso hacia adelante mediante modelos ARX con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada.	86
Figura 4-4. Función de correlación entre las entradas y la salida del modelo ARX para predecir T_a con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada.	86

Figura 4-5. Comparación del valor de M_{wb} medido y predicho un paso hacia adelante mediante modelos ARX con entradas medidas en el exterior ($marx_{out}$) e interior ($marx_{in}$), respectivamente.	88
Figura 4-6. Función de correlación entre las entradas y la salida del (a) $marx_{out}$ y (b) $marx_{in}$ considerando a la señal de control.	88
Figura 4-7. Comparación del valor de T_a medido y predicho un paso hacia adelante mediante la red NARX con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada.	92
Figura 4-8. Análisis del rendimiento de la red NARX para predecir T_a con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada, a) correlación de la salida, b) correlación de las entradas.	92
Figura 4-9. Comparación del valor de M_{wb} medido y predicho un paso hacia adelante mediante redes NARX, a) con entradas medidas en el exterior ($marx_{out}$) considerando a la t_{ext} y b) con entradas medidas en el interior ($marx_{in}$) considerando a la t_{ext}	94
Figura 4-10. Análisis del rendimiento de los modelos $marx_{out}$ y $marx_{in}$ para predecir M_{wb} considerando a la t_{ext} como entrada, a), c) correlación de la salida y b), d) correlación de las entradas.	95

DEDICATORIAS

A mis queridos padres Misael y Maricela que me brindaron sus palabras de aliento en cada momento de mi vida, son la razón que me impulsa a seguir adelante para cumplir cada uno de mis objetivos

A mis queridas hermanas Verónica y Monserrat, por su apoyo y cariño en los momentos importantes de mi vida,

A mis amigos, que no podría mencionar a cada uno de ellos, por brindarme su amistad incondicional durante mi estancia en Chapingo.

AGRADECIMIENTOS

A la Universidad Autónoma Chapingo por brindarme la oportunidad y los medios necesarios para llevar a cabo mi formación profesional.

Al programa de posgrado en Ingeniería Agrícola y Uso Integral del Agua por permitirme la oportunidad de ampliar y mejorar mis conocimientos profesionales.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por la beca otorgada para la realización de mis estudios de maestría.


Al Dr. Agustín Ruiz García por dirigir la presente tesis, por su amistad, consejos, apoyo y contribuciones a mi formación profesional.

Al Dr. Ángel Garduño García por su amistad, apoyo, por el tiempo dedicado a la revisión y sus valiosas aportaciones a la presente.

Al Dr. Carlos Alberto Villaseñor Perea por su apoyo, por sus valiosas observaciones realizadas al presente trabajo.

A todas aquellas personas que de manera desinteresada me brindaron su apoyo en la realización de este trabajo.

DATOS BIOGRÁFICOS



Datos personales

Nombre:	Baltazar López Velasco
Fecha de nacimiento	20 de julio de 1998
Lugar de nacimiento	San Miguel Tulancingo, Oaxaca.
Profesión	Ing. Mecánico Agrícola
No. Cédula	12868439
Correo	baltazarlv@outlook.com

Desarrollo académico

Bachillerato	Preparatoria Agrícola Universidad Autónoma Chapingo
Licenciatura	Ingeniería Mecánica Agrícola Universidad Autónoma Chapingo

RESUMEN GENERAL

MODELACIÓN DEL DESHIDRATADO DE PLÁTANO MEDIANTE MODELOS AUTORREGRESIVOS EN UN SECADOR SOLAR TIPO INVERNADERO APOYADO CON IOT

La modernización del proceso de secado permitirá la disminución del desperdicio de productos agrícolas y la reducción de la contaminación ambiental. El objetivo de este estudio fue el diseño de un sistema de monitoreo basado en la internet de las cosas (IoT), de la temperatura (T_a) y humedad relativa del aire (RH) para un secador solar. El sistema desarrollado está compuesto por un módulo de adquisición de datos, que recopila datos de T_a , RH y el tiempo de encendido y apagado de los extractores del secador; un módulo de comunicación, que transmite información de T_a y RH a través de los protocolos LoRa y Wifi a ThingSpeak para el monitoreo en un dispositivo móvil; y un módulo de alimentación, que suministra energía eléctrica al sistema usando energía solar. El funcionamiento del sistema IoT fue evaluado en tres experimentos de secado de plátano dominico (*Musa paradisiaca* var *sapientum*) durante los cuales el desempeño del sistema fue satisfactorio, permitiendo al usuario visualizar de manera gráfica en una interfaz web y móvil el comportamiento de T_a y RH . Los datos medidos por el sistema se emplearon para identificar en línea modelos autorregresivos con variables exógenas (ARX), para predecir un paso hacia adelante el contenido de humedad del plátano (M_{wb}). Adicionalmente, se identificaron modelos ARX lineales y no lineales (NARX) para predecir M_{wb} y T_a . Se consideraron dos casos para las entradas: medidas en el exterior y medidas en interior del secador. Los modelos obtenidos predijeron de forma satisfactoria el comportamiento de M_{wb} y T_a , de acuerdo con el coeficiente de determinación, error cuadrático medio y error absoluto medio. Se logró reducir el contenido de humedad de los plátanos hasta un 19.84% base húmeda (w.b.) en un periodo de cuatro días y en un 20.03% w.b. durante cinco días en presencia de lluvias.

Palabras clave: *Musa paradisiaca* var *sapientum*, Internet de las Cosas, protocolo LoRa, Arduino, identificación de sistemas.

Tesis de Maestría en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua (IAUIA),
Universidad Autónoma Chapingo
Autor: Baltazar López Velasco
Director: Dr. Agustín Ruíz García

ABSTRACT

MODELING OF BANANA DEHYDRATION USING AUTOREGRESSIVE MODELS IN A GREENHOUSE TYPE SOLAR DRYER SUPPORTED WITH IOT

The modernization of the drying process will allow the reduction of waste of agricultural products and the reduction of environmental pollution. The objective of this study was the design of a monitoring system based on the Internet of Things (IoT), temperature (T_a) and relative air humidity (RH) for a solar dryer. The developed system is composed of a data acquisition module, which collects data on T_a , RH and the on/off time of the dryer extractors; a communication module, which transmits T_a and RH information via LoRa and Wifi protocols to ThingSpeak platform for monitoring on a mobile device; and a power module, which supplies electrical energy to the system using solar energy. The operation of the IoT system was evaluated in three dominican banana (*Musa paradisiaca* var *sapientum*) drying experiments during which the performance of the system was satisfactory, allowing the user to graphically visualize the behavior of T_a and RH in a web and mobile interface. The data measured by the system were used to identify online autoregressive models with exogenous variables (ARX), to predict one step ahead the moisture content of banana (M_{wb}). Additionally, ARX and nonlinear ARX (NARX) models were identified to predict M_{wb} and T_a . Two cases were considered for the inputs: measurements outside and measurements inside the dryer. The models obtained satisfactorily predicted the behavior of M_{wb} and T_a , according to the coefficient of determination, mean square error and mean absolute error. It was possible to reduce the moisture content of the bananas to 19.84% wet basis (w.b.) in a period of four days and to 20.03% w.b. for five days with the presence of rain.

Keywords: *Musa paradisiaca* var *sapientum*, Internet of Things, LoRa protocol, Arduino, system identification.

Master's Thesis in Engineering, Postgraduate in Agricultural Engineering and Integrated Use of Water (IAUIA), Chapingo Autonomous University

Author: Baltazar López Velasco

Major Professor: Dr. Agustín Ruíz García

1 INTRODUCCIÓN GENERAL

La población mundial de 7700 millones en 2020 se está expandiendo y se prevé que aumente en alrededor de 2000 millones en los próximos 30 años (Olimid & Olimid, 2019). Esto traerá varios desafíos en torno a la sostenibilidad global y, además de la energía y el agua, el suministro y la seguridad alimentaria serán los principales desafíos para la sociedad. Para lograr el equilibrio adecuado entre la oferta y la demanda mundial futura de alimentos, es necesario reducir las pérdidas posteriores a la cosecha. Los países en desarrollo como México sufren pérdidas significativas en los productos agrícolas, debido al almacenamiento y procesamiento inadecuados (Abdulmalek, Assadi, Al-Kayiem, & Gitan, 2018). De acuerdo con Ahmadi *et al.* (2021), al disminuir las pérdidas en los productos agrícolas, se puede satisfacer la demanda prevista de alimentos sin la sobre explotación de los recursos naturales.

El plátano es la fruta tropical más cultivada en México y actualmente una de las más consumidas en el país, su consumo per cápita es de 14.4 kg al año (SADER, 2023). Las principales variedades que se producen son: Dominico, Valery, Pera, Tabasco, Morado, Manzano y Macho. Es una fruta rica en carbohidratos, fibras dietéticas, vitaminas A, B1, B2 y C, minerales, compuestos fenólicos y antioxidantes. No obstante, es un producto altamente perecedero propenso a un alto deterioro durante su almacenamiento y también sensible a condiciones de refrigeración, por lo que se desperdicia el 53.76% su producción total en México FAO (2015).

El secado es la técnica de conservación más utilizada de productos agrícolas como el plátano, que prolonga su vida útil al reducir la actividad del agua, reduce el costo de transporte y facilita el almacenamiento (Srinivasan, Rabha, & Muthukumar, 2021). Sin embargo, diversas investigaciones han demostrado que el secado es un gasto importante de energía, pues representa del 12 al 15% del consumo total de energía agrícola mundial (Catorze *et al.*, 2022). Además, se ha estimado que consume de 6 a 30 veces más energía que el enfriamiento y la

congelación (Machala, Tan, Poletayev, Khan, & Benson, 2022). Como resultado, depender de la energía fósil para la demanda de calor en el secado dará como resultado emisiones significativas de carbono a la atmósfera (Ndukwu *et al.*, 2023). Por lo tanto, es fundamental pasar de secadores de energía fósil a fuentes de energía limpia (Chowdhury *et al.*, 2020).

La tecnología de secado solar es una de las alternativas prometedoras, ya que utiliza la energía de la radiación solar que es una fuente de energía abundante, libre, limpia y renovable (Kumar & Layek, 2019). En particular, el secador solar tipo invernadero tiene un gran potencial, ya que puede ser usado a escala industrial debido a su capacidad de procesamiento (Garduño-García, López-Cruz, & Ruiz-García, 2017).

Por otra parte, el plátano contiene una gran cantidad de agua y nutrientes, que pueden perderse durante su secado. Por lo que, se necesitan modelos matemáticos que nos ayuden a comprender el proceso de secado y mejorar la calidad de los plátanos secos. Sin embargo, el secado es un proceso complicado, no lineal y dinámico. A menudo, los mecanismos básicos de transferencia de calor y masa son difíciles de comprender (Sun, Zhang, Mujumdar, & Yang, 2019). Por ello, usar técnicas matemáticas, estadísticas, numéricas y analíticas para determinar la relación entre la entrada y la salida del proceso de secado es engorroso o incluso imposible (Aghbashlo, Mobli, Rafiee, & Madadlou, 2012).

Sin embargo, existen modelos empíricos como son los modelos autorregresivos dinámicos con entradas exógenas que son fáciles de generar, ya que se basan en relaciones de datos de entrada y salida medidos con fines de identificación (Hamidane *et al.*, 2023). En particular, los modelos autorregresivos con entradas exógenas (ARX) y las redes neuronales autorregresivas no lineales con entradas exógenas (NARX), se han aplicado para modelar sistemas no lineales como los secadores solares (Ayala-Solares, Wei, & Billings, 2019). Estos modelos pueden emplearse como base para el diseño de controladores basados en modelos.

Por otro lado, de acuerdo con Dadhaneeya, Nema, y Arora (2023) y Chen, Zhang, Xu, Sun, y Mujumdar (2020), hoy en día la correcta modelación de los sistemas de secado solar y su integración con las nuevas tecnologías de la información, como la internet de las cosas y las redes de sensores inalámbricos, darán paso a la obtención de técnicas de deshidratado sostenibles e inteligentes que permitan monitorear y controlar el proceso de secado para producir frutas y verduras secas de alta calidad. Esto debido a que en la actualidad se espera que los productos deshidratados no solo sean nutritivos y sabrosos, si no también seguros; además, también se desea que sean de buena calidad y tengan una vida de anaquel larga (Ping, Wang, Ma, & Du, 2018).

La internet de las cosas (IoT) es considerada una revolución tecnológica que posibilita que la internet alcance el mundo real de los objetos físicos, convirtiendo objetos comunes en “cosas inteligentes” conectadas a la nube (Popa *et al.*, 2019). Además, permite el monitoreo remotamente del estado de las variables que intervienen en el secado, como lo son: la humedad y la temperatura en las diferentes cámaras del secador, la humedad y la temperatura ambiental y el peso del producto (Aumporn, Wattan, Pattarapanitchai, Sangsan, & Janjai, 2021). Por lo que, se considera necesario implementar este tipo de tecnologías que nos permitan automatizar el proceso de secado y aprovechar la facilidad de adquisición de datos que nos posibilitan, para llevar a cabo la modelación de los sistemas de secado mediante modelos precisos contruidos a partir de datos, que nos permitan controlar y optimizar el proceso de secado de los productos agrícolas, para garantizar la obtención de productos deshidratados de calidad y eficientizar el uso de energía.

1.1 Objetivo general

Modelar el proceso de secado de plátano mediante modelos autorregresivos en un secador solar tipo invernadero, equipado con un sistema de monitoreo basado en internet de las cosas.

1.2 Objetivos particulares

- Desarrollar e instalar un sistema de monitoreo basado en IoT en un secador solar tipo invernadero y evaluar su desempeño durante el secado de plátano dominico (*Musa paradisiaca* var *sapientum*).
- Identificar un modelo autorregresivo con entradas exógenas (ARX) y un modelo autorregresivo no lineal con entradas exógenas (NARX), para predecir la temperatura del aire y el contenido de humedad en muestras de plátano durante su deshidratado en un secador solar tipo invernadero.

1.3 Estructura de la tesis

El documento de tesis se compone de cuatro capítulos en los cuales se abordan las aportaciones de este trabajo de investigación. En el capítulo dos se presenta una revisión del estado del arte sobre la modelación matemática mediante modelos autorregresivos en secadores de productos agrícolas y de sistemas de monitoreo basados en IoT que se han desarrollado para estos secadores. En el capítulo tres se presentan los resultados del diseño y evaluación a través de experimentos de secado de plátano dominico del sistema de monitoreo basado en IoT que se implementó en el secador solar tipo invernadero. Los datos experimentales recopilados por el sistema IoT se usaron para realizar la predicción del contenido de humedad del producto mediante modelos ARX identificados en línea. Finalmente, en el capítulo cuatro se presenta el proceso de identificación de modelos dinámicos ARX y NARX para la predicción de la temperatura del aire y el contenido de humedad en muestras de plátano.

1.4 Literatura citada

- Abdulmalek, S. H., Assadi, M. K., Al-Kayiem, H. H., & Gitan, A. A. (2018). A comparative analysis on the uniformity enhancement methods of solar thermal drying. *Energy*, 148, 1103-1115. doi: <https://doi.org/10.1016/j.energy.2018.01.060>
- Aghbashlo, M., Mobli, H., Rafiee, S., & Madadlou, A. (2012). The use of artificial neural network to predict exergetic performance of spray drying process: A

- preliminary study. *Computers and Electronics in Agriculture*, 88, 32-43. doi: <https://doi.org/10.1016/j.compag.2012.06.007>
- Ahmadi, A., Das, B., Ehyaei, M. A., Esmaeilion, F., Assad, M. E., Jamali, D. H., . . . Safari, S. (2021). Energy, exergy, and techno-economic performance analyses of solar dryers for agro products: A comprehensive review. *Solar Energy*, 228, 349-373. doi: <https://doi.org/10.1016/j.solener.2021.09.060>
- Aumporn, O., Wattan, R., Pattarapanitchai, S., Sangsan, M., & Janjai, S. (2021). Study of Large-scale Solar Dryers Equipped with Monitoring and Control Systems for Banana Drying. *Journal of Renewable Energy and Smart Grid Technology*, 16(2), 1-16.
- Ayala-Solares, J. R., Wei, H. L., & Billings, S. A. (2019). A novel logistic-NARX model as a classifier for dynamic binary classification. *Neural Computing and Applications*, 31, 11-25. doi: <https://doi.org/10.1007/s00521-017-2976-x>
- Catorze, C., Tavares, A. P., Cardão, P., Castro, A., Silva, M. E., Ferreira, D. W., Brás, I. (2022). Study of a solar energy drying system—Energy savings and effect in dried food quality. *Energy Reports*, 8, 392-398. doi: <https://doi.org/10.1016/j.egy.2022.01.070>
- Chen, J., Zhang, M., Xu, B., Sun, J., & Mujumdar, A. S. (2020). Artificial intelligence assisted technologies for controlling the drying of fruits and vegetables using physical fields: A review. *Trends in Food Science & Technology*, 105, 251-260. doi: <https://doi.org/10.1016/j.tifs.2020.08.015>
- Chowdhury, T., Chowdhury, H., Chowdhury, P., Sait, S. M., Paul, A., Ahamed, J. U., & Saidur, R. (2020). A case study to application of exergy-based indicators to address the sustainability of Bangladesh residential sector. *Sustainable Energy Technologies and Assessments*, 37, doi: <https://doi.org/10.1016/j.seta.2019.100615>
- Dadhaneeya, H., Nema, P. K., & Arora, V. K. (2023). Internet of things in food processing and its potential in industry 4.0 era: A review. *Trends in Food Science & Technology*. doi: <https://doi.org/10.1016/j.tifs.2023.07.006>
- FAO. (2015). Pérdidas y desperdicios de alimentos en América Latina y el Caribe. Organización para la Alimentación y la Agricultura. Retrieved Julio 13, 2023, from https://www.fao.org/fileadmin/user_upload/FAO-countries/Argentina/docs/2do_Boletin_P____D_en_ALC_avances_en_Arentina.pdf
- Garduño-García, Á., López-Cruz, I. L., & Ruiz-García, A. (2017). Mathematical modeling of greenhouse solar dryers with natural and forced convection for agricultural products: state of the art. *Ingeniería agrícola y biosistemas*, 9(1), 19-36. doi: <http://dx.doi.org/10.5154/r.inagbi.2017.02.004>

- Hamidane, H., Faiz, S. E., Rkik, I., Khayat, M. E., Guerbaoui, M., Ed-Dahhak, A., & Lachhab, A. (2023). Constrained temperature and relative humidity predictive control: Agricultural greenhouse case of study. *Information Processing in Agriculture*. doi: <https://doi.org/10.1016/j.inpa.2023.04.003>
- Kumar, A., & Layek, A. (2019). Thermo-hydraulic performance of roughened solar air heater by design of experiment and meta-heuristic approach. *Thermal Science and Engineering Progress*, 10, 92-102. doi: <https://doi.org/10.1016/j.tsep.2019.01.011>
- Machala, M. L., Tan, F. L., Poletayev, A., Khan, M. I., & Benson, S. M. (2022). Overcoming barriers to solar dryer adoption and the promise of multi-seasonal use in India. *Energy for Sustainable Development*, 68, 18-28. doi: <https://doi.org/10.1016/j.esd.2022.02.001>
- Ndukwu, M. C., Okon, B. B., Abam, F. I., Lamrani, B., Bekkioui, N., Wu, H., Ehiem, J. C. (2023). Energy and exergy analysis of solar dryer with triple air passage direction collector powered by a wind generator. *International Journal of Energy and Environmental Engineering*, 14, 63–77. doi: <https://doi.org/10.1007/s40095-022-00502-8>
- Olimid, A. P., & Olimid, D. A. (2019). *Societal Challenges, Population Trends and Human Security: Evidence from the Public Governance within the United Nations Publications (2015-2019)*. Editura Universitaria Craiova.
- Ping, H., Wang, J., Ma, Z., & Du, Y. (2018). Mini-review of application of IoT technology in monitoring agricultural products quality and safety. *International Journal of Agricultural and Biological Engineering*, 11(5), 35-45.
- Popa, A., Hnatiuc, M., Paun, M., Geman, O., Hemanth, D. J., Dorcea, D., Ghita, S. (2019). An intelligent IoT-based food quality monitoring approach using low-cost sensors. *Symmetry*, 11(3), 374. doi: <https://doi.org/10.3390/sym11030374>
- SADER. (2023, Agosto 25). Aumentó 2.9 por ciento producción de plátano mexicano en 2020. Retrieved from Secretaría de Agricultura y Desarrollo Rural: <https://www.gob.mx/agricultura/prensa/aumento-2-9-por-ciento-produccion-de-platano-mexicano-en-2020?idiom=es>
- Srinivasan, G., Rabha, D. K., & Muthukumar, P. (2021). A review on solar dryers integrated with thermal energy storage units for drying agricultural and food products. *Solar Energy*, 229, 22-38. doi: <https://doi.org/10.1016/j.solener.2021.07.075>
- Sun, Q., Zhang, M., Mujumdar, A. S., & Yang, P. (2019). Combined LF-NMR and Artificial Intelligence for Continuous Real-Time Monitoring of Carrot in Microwave Vacuum Drying. *Food and Bioprocess Technology*, 12, 551–562. doi: <https://doi.org/10.1007/s11947-018-2231-1>

2 REVISIÓN DE LITERATURA

2.1 Antecedentes

Los productos agrícolas como frutas y verduras contienen nutrientes esenciales, fibra dietética, vitaminas y una variedad de micronutrientes necesarios para una vida saludable. Sin embargo, están disponibles poco tiempo después de su cosecha, pues son altamente perecederos (Pu & Sun, 2017). El rápido deterioro en los productos agrícolas se debe principalmente al crecimiento microbiano relacionado con la humedad, lo que hace que los alimentos no sean aptos para el consumo humano, provocando enfermedades. La tasa de crecimiento microbiano depende de una variedad de factores, como el pH, la temperatura y la actividad de agua (a_w) (Zambrano, Dutta, Mercer, MacLean, & Touchie, 2019).

La actividad de agua (a_w) es de gran importancia para la conservación de los alimentos, ya que es una medida y un criterio del crecimiento de microorganismos y probablemente de la liberación de toxinas, del desarrollo del pardeamiento enzimático y no enzimático, etc. Para cada alimento o producto agrícola, existe un límite de actividad por debajo del cual los microorganismos dejan de crecer (Babalís, Papanicolaou, & Belessiotis, 2017). Esta actividad se puede definir mediante la siguiente ecuación;

$$a_w = \left(\frac{p_w}{p_w^*} \right)_T \quad (1)$$

donde: p_w (Pa) es la presión parcial del vapor de agua del producto húmedo, p_w^* (Pa) es la presión parcial del agua pura en saturación, T (°C) es la temperatura a la que se calculan las presiones de vapor, a_w , (adim) es la actividad de agua.

Cuando a_w está por debajo de 0.8 la mayoría de los tipos de bacterias no puede crecer, mientras que los mohos y las levaduras no pueden crecer cuando a_w está por debajo de 0.7; por lo que si se desea evitar el deterioro de los productos agrícolas, a_w debe ser inferior a 0.6, como se muestra en la Figura 2-1.




Figura 2-1. Velocidad de reacción de los diferentes microorganismos y procesos en los productos agrícolas en función de la actividad del agua (Adaptado de Labuza, 1977).

En los países en desarrollo, el almacenamiento seguro de los productos agrícolas con un alto contenido de humedad se dificulta debido a las altas temperaturas ambientales y, a menudo, por las instalaciones inadecuadas de refrigeración y almacenamiento. Por lo tanto, es común secar los productos agrícolas para reducir su desperdicio. El secado reduce el contenido de humedad y la actividad de agua, lo que aumenta la vida útil del producto (Ogawa & Adachi, 2014).

El secado con tecnología de secado solar está ganando popularidad debido a su disponibilidad, menor costo de mantenimiento, confiabilidad y por ser amigable con el medio ambiente (Ismail, Yunus, & Hashim, 2021). El secado solar calienta y elimina la humedad de los productos agrícolas mientras conserva sus nutrientes y calidad. Los procesos generales implican la transferencia de calor por radiación de la luz solar directa, por convección de la atmósfera al producto húmedo, por conducción desde la superficie del producto al interior del producto y/o por conducción desde las bandejas de secado dentro de la cámara de secado que están en contacto con los productos (Kamarulzaman, Hasanuzzaman, & Rahim, 2021). Se han desarrollado y estudiado numerosos secadores solares en todo el mundo de diferentes tamaños, formas y tipos de cubiertas. En la literatura se

pueden encontrar hasta 500 tipos de secadores, de los cuales 100 están disponibles comercialmente (Mujumdar & Law, 2010).

2.2 Clasificación de los sistemas de secado solar

De acuerdo con Mohana *et al.* (2020), los sistemas de secado solar se pueden clasificar con base en el diseño, el material de construcción, la forma de las estructuras, los sistemas de respaldo de energía y las unidades auxiliares de calefacción, de los cuales se han utilizado varias variantes de secadores solares para deshidratar alimentos. En la Figura 2-2 se muestra la clasificación de los sistemas de secado solar en base al aprovechamiento de los recursos solares.




Figura 2-2. Clasificación de los sistemas de secado solar (Adaptado de Madhankumar, Viswanathan, Taipabu, & Wu, 2023).

El secado solar al aire libre o a la intemperie, utiliza la energía de la radiación solar para calentar directamente el material. El producto se extiende sobre grandes superficies exteriores en el suelo o en bandejas y se deja secar hasta lograr el contenido de humedad deseado (Figura 2-3). Existen varias limitaciones asociadas con esta técnica tales como condiciones de operación no controladas (temperatura, humedad y velocidad del aire) y condiciones climáticas (radiaciones solares directas, tormentas de viento, lluvia, polvo y suciedad), interferencia externa de pájaros, animales, insectos, roedores, etc.



Figura 2-3. Secado solar a la intemperie, (a) Arroz, (b) Pescado (Janjai & Bala, 2012)

Por otro lado, en el secado solar controlado los secadores se pueden clasificar de acuerdo con el movimiento del aire en su interior, como secadores solares pasivos y activos (Mohana *et al.*, 2020). En los secadores solares de modo pasivo, la circulación del aire se produce naturalmente por la fuerza de flotación o debido a las diferencias de presión o por una combinación (khadraoui, Hamdi, Kooli, & Kooli, 2019). Mientras que en los secadores solares activos, se utilizan ventiladores o extractores para facilitar el flujo de aire dentro de la cámara de secado, mejorando la transferencia de calor al producto (Kamarulzaman, Hasanuzzaman, & Rahim, 2021).

Otra forma importante de clasificar los secadores solares es de acuerdo con la incidencia de la radiación solar sobre el producto, como secadores solares directos, indirectos y de modo mixto (Kamarulzaman, Hasanuzzaman, & Rahim, 2021). En los secadores solares tipo directo, el producto a secar se mantiene en

el interior de la cámara de secado donde queda expuesto a la radiación solar transmitida a través de una cubierta transparente. Esta cubierta puede ser de diferentes materiales como: vidrio, plástico y policarbonato (Sontakke & Salve, 2015). Por el contrario, en los secadores solares tipo indirecto, el aire atmosférico se calienta en un colector de aire solar y luego este aire caliente se mueve hacia la cámara de secado, donde los productos se mantienen secos y el aire caliente toma un porcentaje de humedad de los productos de secado y finalmente, sale de la cámara de secado a través de la chimenea. A la combinación del secador solar de tipo directo e indirecto se denomina secador solar de modo mixto (Kumar & Singh, 2020).

Por último, debido a que para el secado de los productos agrícolas se requiere aire caliente en un rango de temperatura de 45 °C a 60 °C, actualmente a los sistemas de secado solar se les está acoplando una unidad de almacenamiento de energía térmica que se puede utilizar para calentar el aire cuando la energía solar no está disponible. Existen varias formas de almacenar energía en varias fuentes, incluyendo mecánica, eléctrica, química y térmica. La energía térmica puede almacenarse como calor sensible o como calor latente (Suresh *et al.*, 2023; Abueluor, Amin, Abuelnour, & Younis, 2023).

2.3 Secador solar tipo invernadero

El secador solar tipo invernadero es uno de los sistemas más novedosos en el sector de los secadores solares (Taki, Rohani, Soheili-Fard, & Abdeslahi, 2018). Se usa principalmente para secar productos agrícolas a gran escala, debido a que es muy sencillo de construir y más barato que otros tipos de secadores (Mani & Natesan, 2021), sus paredes y techo están contruidos de materiales transparentes como el vidrio, plástico o policarbonato, como medio para permitir que la radiación de onda corta ingrese mientras obstaculiza parcialmente las radiaciones de onda larga salientes. Los materiales, que están dispuestos en bandejas de contenedores adecuadas dentro de las paredes del secador, están expuestos a estas radiaciones de onda corta. Los productos frescos pierden la

humedad contenida en ellos a través del mecanismo de convección (Patil & Rajendra, 2016).

Según Chauhan y Kumar (2016) existen tres tipos de secadores tipo invernadero que se clasifican en función del aire que circula dentro de la cámara de secado: de convección natural, convección forzada e híbridos (Figura 2-4).




Figura 2-4. Vista pictórica de un secador solar tipo invernadero de (a) Convección natural (Ahmad & Prakash, 2019), (b) Convección forzada y (c) Híbrido (Ahmad *et al.*, 2022).

El-Mesery, El-Seesy, Hu, y Li, (2022) presentan una clasificación más amplia de los secadores solares tipo invernadero en base a la forma de su estructura, el material de la cubierta, el material del piso y el flujo de aire dentro de la cámara de secado:




Figura 2-5. Clasificación de los sistemas de secado solar tipo invernadero.

Uno de los diseños de secadores tipo invernadero más estudiados son los de techo parabólico con cubierta de policarbonato, piso de concreto y convección forzada (Figura 2-6), cuya principal ventaja de este diseño es la capacidad de alcanzar altas temperaturas al concentrar mayor cantidad de rayos solares en centro geométrico de la parábola. Su diseño está desarrollado principalmente para climas tropicales, puede soportar altas cargas de viento y el piso de concreto le permite almacenar energía que puede usar para continuar con el proceso de secado cuando el sol se oculta (Janjai *et al.*, 2009).



Figura 2-6. Secador solar tipo invernadero de forma parabólica con cubierta de policarbonato y piso de concreto (Janjai *et al.*, 2009).

Este tipo de secador tiene varias capacidades de carga para secar frutas y verduras. Hay cuatro tamaños estándar, a saber, tamaño pequeño (capacidad de carga de 100-300 kg de frutas o verduras), tamaño mediano (capacidad de carga de 400-600 kg), tamaño grande (capacidad de carga de 1000-1200 kg) y tamaño extragrande (capacidad de carga de 1500-1700 kg). La selección del tamaño del secador depende de la cantidad de producto a secar (Aumporn, Wattan, Pattarapanitchai, Sangsan, & Janjai, 2021c).

En los últimos años, los desarrollos en secadores solares tipo invernadero se han centrado principalmente en la mejora de la eficiencia de secado, la utilización eficaz de la energía solar disponible y la reducción del período de secado (Mishra, Verma, Chowdhury, & Dwivedi, 2021). Según Mani y Natesan (2021) muchos investigadores mejoran el rendimiento térmico de estos sistemas mediante la incorporación de diversas técnicas, como el aislamiento de la pared norte, la reflexión de la pared norte, la base absorbente pintada de negro, la modificación del techo, el almacenamiento de energía, etc.

2.4 Secado de plátano

El plátano (*Musa paradisiaca* L.) es un fruto altamente nutritivo que incluye grandes contenidos de fibra, minerales como potasio, almidón, carbohidratos y polisacáridos, vitaminas como B6 y C, y antioxidantes como carotenoides y pectina, entre otros fitonutrientes (Al-Dairi, Pathare, Al-Yahyai, Jayasuriya, & Al-Attabi, 2023). Sin embargo, es un fruto perecedero, las pérdidas poscosecha durante toda la cadena de suministro alcanzan hasta un 40%, debido a técnicas inadecuadas utilizadas por los productores en la cosecha, así como a un manejo poscosecha inadecuado (Hasan *et al.*, 2019). Las principales razones de las pérdidas son la maduración excesiva, las magulladuras y la compresión, que provocan daños mecánicos (Abedi & Takhar, 2021). El secado se considera el mejor método de conservación de la pulpa de plátano a través del cual se pueden desarrollar subproductos como snacks y harina (Petikirige, Karim, & Millar, 2022). El secado de plátano se realiza principalmente a la intemperie (Figura 2-7), donde

la calidad del producto se ve afectada debido a la exposición directa al sol, contaminación por polvo, lluvia, suciedad e infestación de insectos y animales.



Figura 2-7. Secado de plátano a la intemperie (Udomkun *et al.*, 2020).

De acuerdo con Aumporn *et al.* (2021c) las limitaciones del secado de plátano a la intemperie se pueden resolver mediante el uso de secadores solares tipo invernadero que ofrecen protección contra la contaminación y los animales, disminuyen el tiempo de secado y mejoran la calidad del producto, para lo cual se emplean comúnmente los de tamaño grande con una capacidad de carga de 1200 kg de plátanos pelados (Figura 2-8).



Figura 2-8. Secado de plátano en el interior de un secador solar tipo invernadero con cubierta de policarbonato (Udomkun *et al.*, 2020).

Uno de los productos de gran interés es la harina de plátano verde, la cual tiene una alta demanda debido a su uso en la elaboración de productos alimentarios como galletas, pastas, bebidas fermentadas, etc. y a los beneficios en la salud humana que trae su consumo (Dhull *et al.*, 2020). El proceso de secado para la producción de harina de plátano verde consiste en secar, como una capa fina,

rodajas de plátano sin madurar con o sin pretratamiento, una vez finalizado el proceso de secado se realiza la molienda del producto (Figura 2-9).




Figura 2-9. Secado de plátano verde para la producción de harina mediante secado de ventana de refracción, (a) Rodajas de plátano de frescas, (b) Rodajas de plátano secas, (c) Harina de plátano (Padhi, Murakonda, & Dwivedi, 2022).

Sin embargo, el secado del plátano se realiza mayormente para la producción de snacks, ya que no es necesario realizar más procesos de transformación posteriores al secado. Además, es un producto con buena aceptación sensorial, que se puede emplear exitosamente para su comercialización (Ferreira & Freitas, 2019). Se deshidrata comúnmente en rodajas para producir chips (Figura 2-10a) o el fruto entero (Figura 2-10b).



Figura 2-10. (a) Secado de chips (Singh, Sarkar, & Sahoo, 2020) y (b) muestras enteras de plátano (Kreetachat *et al.*, 2023).

Es importante mencionar que, antes del proceso de secado del plátano, se realizan pretratamientos a las muestras que consisten en sumergirlas en

soluciones de materiales como: metabisulfito del sodio, ácido cítrico, ácido ascórbico y mucilago de semilla de membrillo (Milani, Jouki, & Rabbani, 2020; Granella, Bechlin, & Christ, 2022), con la finalidad de obtener muestras secas con buen aspecto y que mantengan la mayor cantidad posible de sus propiedades fisicoquímicas.

Finalmente, para evaluar la calidad del plátano deshidratado se realizan análisis de sus propiedades fisicoquímicas, tales como el contenido de humedad, la actividad de agua, el contenido de azúcar reductor y total, su acidez, textura y color (Macedo, Vimercati, Araújo, Saraiva, & Teixeira, 2020). Un ejemplo de uso de pretratamientos y evaluación de la calidad del plátano deshidratado es el estudio realizado por Ferreira & Freitas (2019), quienes secaron muestras de plátano sin pretratamiento (T1) y pretratadas con metabisulfito de sodio (T2) y una combinación de ácido cítrico con ácido ascórbico (T3). Al final del secado, caracterizaron las muestras de acuerdo con el contenido de humedad, su acidez, el contenido de sólidos solubles, pH, actividad de agua, parámetros de color, textura (Cuadro 2-1) y mediante un análisis sensorial de su aceptación e intención de compra por parte de los consumidores.

Cuadro 2-1. Características físicas y químicas del plátano seco (Ferreira & Freitas 2019)

Análisis	Tratamientos		
	T1	T2	T3
Humedad final (%)	19.32 ^b	17.39 ^b	24.58 ^a
pH	3.88±0.01 ^a	3.67±0.02 ^a	3.18±0.07 ^b
TTA (g ácido málico/100g)	0.67±0.07 ^b	1.23±0.06 ^{a^b}	1.72±0.10 ^a
TSS	38±0.01 ^b	57±0.05 ^a	54±0.02 ^a
TSS/TTA	56.69±0.17 ^a	46.35±0.22 ^a	31.40±0.09 ^b
Actividad de agua (a _w)	0.675±0.004 ^{n.s.}	0.664±0.007 ^{n.s.}	0.685±0.001 ^{n.s.}

Las medias seguidas de letras mostraron una diferencia significativa ($p \leq 0.05$) mediante la prueba de medias de Tukey. TTA: Acidez titulable total. TSS: Sólidos solubles totales. n.s: no significativo.

Como resultado de los esfuerzos por mejorar la calidad de los frutos de plátano deshidratado, hoy en día podemos encontrar disponible en el mercado productos de plátano deshidratado en diferentes presentaciones (Figura 2-11).



Figura 2-11. Ejemplo de productos de plátano secado al sol disponibles en el mercado (Udomkun *et al.*, 2020).

2.5 Estructura e identificación de modelos ARX y NARX

Dentro del marco de la técnica de identificación de sistemas se encuentran: los modelos de respuesta de impulso finito (FIR), autorregresivos con entradas exógenas (ARX), media móvil autorregresiva con entradas exógenas (ARMAX), Box-Jenkins (BJ), error de salida (OE) y sus versiones no lineales, los modelos de respuesta de impulso finito no lineales (NFIR), redes neuronales autorregresivas no lineales con entradas exógenas (NARX), media móvil autorregresiva no lineal con entradas exógenas (NARMAX), Box-Jenkins no lineal (NBJ), error de salida no lineal (NOE) (Singh, Manju, Rukkumani, & Srinivasan, 2022).

En particular, los modelos ARX y NARX se han aplicado preferentemente para manejar diversos problemas de modelado basados en datos debido a su facilidad de cálculo y estructura simple, que permite interpretar fácilmente los modelos resultantes (Ayala-Solares, Wei, & Billings, 2019). En la Figura 2-12 se muestran los procedimientos de identificación de los modelos ARX y NARX.




Figura 2-12. Procedimiento de identificación de modelos ARX y NARX (adaptado de Zulkeflee, Rohman, Sata, & Aziz, 2021).

Un modelo ARX de entrada y salida única (SISO) se describe mediante una ecuación lineal en diferencias (Keesman, 2011; Ljung, 1998).

$$y(t) + a_1y(t - 1) + \dots + a_nay(t - na) = b_1u(t - nk) + \dots + b_nbu(t - nb - nk + 1) + e(t) \quad (2)$$

donde: $y(t)$ es la salida del modelo para $t = t, t - 1, \dots, t - na$, $u(t)$ es la entrada del modelo para $t = t - nk, t - nk - 1, \dots, t - nk - nb + 1$, na es el número de pasos de tiempo de la salida, nb es el número de pasos de tiempo de la entrada, nk es el retardo de la entrada con respecto a la salida y $e(t)$ es ruido blanco asociado con la variable de salida.

En la mayoría de los casos de modelación se requiere predecir una variable de respuesta a partir de un conjunto de variables de entrada, por lo que se debe utilizar un modelo ARX de entradas múltiples y salida única (MISO). Según Rachad, Nsiri, y Bensassi (2015) la estructura general del modelo ARX MISO es:

$$A(q^{-1})y(t - n) = q^{-d}B_1(q^{-1})u_1(t - n) + \dots + q^{-d}B_i(q^{-1})u_i(t - n) + e(t) \quad (3)$$

donde, q^{-1} representa al operador de retraso, $A(q^{-1})$ y $B(q^{-1})$ son los polinomios que representan la dinámica general del sistema y se definen como:

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na} \quad (4)$$

$$B_i(q^{-1}) = b_0 + \dots + b_{nb}q^{-nb} \quad (5)$$

Por otro lado, el modelo NARX es una extensión del modelo ARX que describe la no linealidad en los procesos dinámicos con mayor precisión y este dado por la ecuación (6):

$$y(t) = f(y(t - 1), y(t - 2), \dots, y(t - n_y), u(t - 1), u(t - 2), \dots, u(t - n_u)) + e(t) \quad (6)$$

donde n_y y n_u es el número de retardos en la salida y entrada, respectivamente y $e(t)$ es denominado el error de predicción en el tiempo t , se modela como una variable aleatoria proveniente de la realización de un proceso de ruido blanco gaussiano de media cero y varianza σ , y que representa la incertidumbre del modelo y el ruido asociado a los datos experimentales.

El predictor asociado de este tipo de modelos esta dado por:

$$\hat{y}(t) = \phi(y(t - 1), y(t - 2), \dots, y(t - n_y), u(t - 1), u(t - 2), \dots, u(t - n_u)) \quad (7)$$

donde, $\hat{y}$ es la predicción de la variable autorregresiva y , realizada a partir de la información experimental obtenida y de la variable de entrada u en tiempos anteriores $t - 1, t - 2, \dots$ considerando la función no lineal ϕ .

La validación de los modelos se realiza mediante la bondad de ajuste que puede ser determinada mediante diferentes estadísticos y el análisis de residuales, que nos ayuda a seleccionar el modelo con la estructura más simple y cuyos valores de entrada y salida no están correlacionados.

2.6 Modelos ARX y NARX usados para modelar el proceso de secado en productos agrícolas.

El secado es un proceso tedioso, que necesita monitoreo y control dinámico durante la operación. Se sabe que su control es vital en la industria del secado. Sin embargo, es esencial modelar el proceso en el interior de los sistemas de secado antes de realizar su control (Singh, Manju, Rukkumani, & Srinivasan, 2022).

Existen varios estudios realizados sobre modelación del secado de productos agrícolas (Janjai *et al.*, 2009; Ratti & Mujumdar, 1997). Los métodos de modelado incluyen modelos mecanicistas y el modelado con modelos autorregresivos como ARX, NARX y otras variantes de estos (Aumporn, Janjai, Khunkaeo, & Bala, 2021a; Li & Chen, 2020). Los modelos autorregresivos tienen la ventaja de basarse únicamente en datos experimentales, pero requieren menos cantidad de datos, en comparación con otros métodos similares y se emplean comúnmente para el diseño de controladores.

Recientemente Aumporn *et al.* (2021a) compararon los resultados de un estudio experimental de secado de plátano con un estudio de modelado ARX, sobre el rendimiento de un secador solar de escala doméstica (Figura 2-13). El modelo ARX predijo de forma adecuada el contenido de humedad de las muestras de plátano durante su proceso de secado.

Aumporn, Pankaew, Chanpen, y Janjai (2021b) realizaron el modelado mediante modelos ARX de un secador solar tipo invernadero con cubierta de policarbonato anti-UV equipado con un sistema de control para el secado de láminas de caucho (Figura 2-14). Midieron el rendimiento del modelo en base a la diferencia media cuadrática relativa (rRMSD) y la diferencia media de sesgo relativa (rMBD). Encontraron que el modelo predice correctamente el contenido de humedad de las láminas de caucho secadas en este secador, obtuvieron valores de rRMSD igual a 9.8% y un rMBD de 0.5%.



Figura 2-13. Secador solar doméstico (Aumporn *et al.*, 2021a)



Figura 2-14. Secador solar tipo invernadero (Aumporn *et al.*, 2021b)

Zhou *et al.* (2018), a través de la comparación de varias estructuras de modelos, encontraron que el modelo autorregresivo basado en red neuronal de función de base radial con función base de tipo cubica (Cubic-RBF-ARX) puede representar adecuadamente las características globales del proceso de secado de tabaco en la etapa de cabeza o cola. El modelo fue empleado para diseñar conjuntos de variables de entrada de configuración óptima para implementar un control óptimo del proceso de secado. De manera similar, Yuan, Ding, y Hou (2018) propusieron predecir el contenido de humedad en tabaco picado usando un modelo ARX con una red neuronal wavelet basado en la teoría de identificación de sistemas.

Zhou y Wang (2018) construyeron modelos ARX para predicción del contenido de humedad de equilibrio (EMC) y temperatura de secado durante el secado de madera. A partir del modelo encontrado, realizaron el diseño de un controlador de modo deslizante, validando la efectividad de la estrategia de control mediante simulaciones y experimentos. Igualmente, en otro estudio Zhou y Wang (2019) construyeron un modelo ARX de segundo orden para describir el proceso de secado de madera, que se utilizó posteriormente para la construcción de un sistema de control de temperatura de bulbo seco y el EMC.

Pilario, Ching, Calapatia, y Culaba (2022) demostraron que los modelos autorregresivos de proceso gaussiano (GPAR), son predictores precisos del

contenido de humedad de microalgas (*Chlorococcum infusionum*) en secado al vacío (Figura 2-15). Específicamente, un tipo de GPAR llamado GP-ARX logró un RMSE de 0.6770 en predicción de un paso hacia adelante, también demostró ser superior a una red neuronal NARX.

Poozesh y Cousin (2022) derivaron un modelo ARX a partir de modelos cinéticos de automatización y de gota única, de los procesos de transferencia de calor y masa durante secado por aspersión (Figura 2-16), con la finalidad de conectar variables de entrada y salida para construir un modelo de control predictivo (MPC) que controle el proceso de secado. Asimismo, Poozesh, Karam, Akafuah, y Wang (2021) obtuvieron un 93% y 90% de ajuste en la predicción de temperatura y contenido de humedad con un modelo ARX en un secador por aspersión a escala de laboratorio.




Figura 2-15. Horno de secado al vacío (Pilario, Ching, Calapatia, & Culaba 2022)




Figura 2-16. Esquema del secador por aspersión (Poozesh & Cousin 2022)

Li y Chen, (2020), desarrollaron un modelo NARX para predecir el contenido de humedad en granos para un secador de granos real (Figura 2-17), el modelo tuvo un rendimiento de MSE = 0.0043 y MSE = 0.0231 durante su entrenamiento y validación, respectivamente. Finalmente, los modelos NARX también han demostrado ser adecuados para predecir el contenido de húmeda en secado por

aspersión (Abdullah, Taip, Kamal, & Rahman, 2020) y el contenido de humedad de equilibrio en hongos (Argyropoulos & Paraforos, 2022).




Figura 2-17. Diagrama de la estructura mecánica del secador de granos (Li & Chen 2020)

Los modelos ARX y NARX han demostrado ser adecuados para describir el proceso de secado en diferentes sistemas. Sin embargo, han sido poco empleados en secadores solares, por lo que todavía hay gran oportunidad de estudio de la aplicación de estos modelos en secadores solares, donde la radiación incidente domina el comportamiento del secador. En estos sistemas la variabilidad de la radiación debida a perturbaciones ambientales, como la lluvia, la estación o la hora del día, hace que el de secado de productos agrícolas en su interior sea un proceso dinámico y no lineal difícil de describir. Por lo que, el uso de modelos basados en leyes físicas es un desafío, además de la dificultad de emplearlos para el diseño de controladores. En contraste con estos, los modelos ARX y NARX son fáciles de generar y se pueden usar como base para el diseño de dispositivos de control, ya que se generan a través de datos experimentales mediante técnicas de identificación de sistemas. Debido a la importancia de investigar el proceso de secado y el rendimiento en diferentes condiciones, se vuelve indispensable probar modelos ARX y NARX con diferentes estructuras y parámetros matemáticos.

2.7 La internet de las cosas (IoT)

La Internet de las cosas (IoT), a veces denominada "Internet de los objetos", es un concepto nuevo que se relaciona con la interoperabilidad de los objetos y su capacidad para acceder e intercambiar información sobre ellos mismos a través de Internet. Esencialmente, la integración de la IoT es una tecnología de vanguardia que puede tener un gran impacto positivo en la agricultura, ya que puede proporcionar una gestión eficiente de los recursos y una mayor producción al facilitar el almacenamiento, la gestión, el acceso y la difusión de la información (Symeonaki, Arvanitis, & Piromalis, 2019).

2.7.1 Aplicaciones de IoT en la agricultura

Internet agrícola de las cosas se refiere a una red en la que los componentes físicos, como animales y plantas, elementos ambientales, herramientas de producción y varios "objetos" virtuales en el sistema agrícola, están conectados a Internet a través de equipos de percepción de información agrícola bajo ciertos protocolos para realizar el intercambio de información y la comunicación. Tiene la intención de realizar la identificación inteligente, posicionamiento, seguimiento, monitoreo y gestión de objetos y procesos agrícolas. La interconexión "hombre-máquina-cosas" del IoT agrícola puede ayudar a los humanos a reconocer, administrar y controlar varios elementos, procesos y sistemas agrícolas de una manera más refinada y dinámica. También puede mejorar en gran medida la comprensión humana de las partes esenciales de la vida de los animales y plantas agrícolas, ayudar con la capacidad de controlar sistemas agrícolas complejos y asistir en el manejo de emergencias agrícolas (Xu, Gua, & Tian, 2022).

Las soluciones agrícolas de IoT consisten en múltiples aplicaciones de monitoreo, control y rastreo que miden varios tipos de variables como monitoreo del aire, monitoreo de temperatura, monitoreo de humedad, monitoreo del suelo, monitoreo del agua, fertilización, control de plagas, control de iluminación y rastreo de ubicación. El enfoque principal de cada aplicación agrícola de IoT con

respecto a sus dominios (monitoreo, control y seguimiento) es el siguiente: monitoreo y control de riego (16%), agricultura de precisión (16%), monitoreo de suelos (13%), monitoreo de temperatura (12%), monitoreo de humedad (11%), monitoreo y seguimiento de animales (11 %), monitoreo y control del agua (7%), monitoreo de enfermedades (5%), monitoreo del aire (5%) y monitoreo de fertilización (4%) (Farooq, Riaz, Abid, Umer, & Zikria, 2020).

Como se puede observar en la Figura 2-18, el modelo de IoT agrícola tiene tres capas básicas. La parte inferior es la capa de adquisición de datos, en la que los datos ambientales de cultivos se recopilan a través de sensores o dispositivos de detección remota, y luego se cargan en el almacenamiento en la nube a través de internet. La segunda capa es la capa de funciones de computación en la nube, en ella se realiza el filtrado y procesamiento de los datos mediante herramientas de análisis para obtener información abstracta. Luego, la información procesada se convertirá en conocimiento esencial mediante herramientas de minería de datos y aprendizaje automático. Con la consideración de factores específicos, como la condición del suelo, el patrón de fertilización, el estado del cultivo, la situación climática y ambiental, etc., el conocimiento derivado en el último paso se utilizará para la toma de decisiones. Mientras tanto, esta capa también proporciona servicios de visualización y presentación de datos para el acceso de los usuarios. En última instancia, la capa superior es el control de todas las operaciones agrícolas, incluida la siembra, el riego, la fertilización y la cosecha. Las operaciones correspondientes se implementan con dispositivos agrícolas, máquinas, vehículos y sistemas de riego basados en decisiones o mapas índice generados en la nube durante la última etapa. Los comandos de control relacionados se transmitirán a través de la puerta de enlace de Internet a los sistemas agrícolas (Zhang, Dabipi, & Brown, 2018).




Figura 2-18. Arquitectura IoT en la agricultura (Zhang, Dabipi, & Brown, 2018)

La transmisión de datos es una parte vital de IoT agrícola. En la Figura 2-19 se muestra la tecnología de transmisión de datos comúnmente utilizada en IoT agrícola. La tecnología de comunicación no debe usarse al azar al transmitir información, sino que debe seleccionarse de acuerdo con las características específicas del proyecto (Xu, Gua, & Tian, 2022).




Figura 2-19. Tecnología de transmisión de datos comúnmente utilizada en IoT agrícola (adaptado de Xu, Gua, & Tian, 2022).

Finalmente, es importante mencionar que los dispositivos sensores para aplicaciones agrícolas están especialmente diseñados para operar en entornos abiertos, en la naturaleza, en el suelo, el agua y el aire para medir y recopilar parámetros ambientales que afectan a la producción, como los nutrientes del suelo, la humedad, la temperatura, etc. Esto debido a que las soluciones agrícolas inteligentes son operaciones agrícolas que a menudo se implementan en grandes tierras de cultivo, al aire libre, por lo que los dispositivos que respaldan las soluciones necesitan algunas características únicas, como la capacidad de soportar los efectos del clima, la humedad y la inestabilidad de la temperatura a lo largo de su ciclo de vida útil (Quy *et al.*, 2022).

2.7.2 Monitoreo basado en IoT en secadores de productos agrícolas

La tecnología IoT hace que el monitoreo de los productos agrícolas sea más fácil, automático, efectivo y en tiempo-real, mejora enormemente la calidad y seguridad de los productos agrícolas. El establecimiento y la aplicación de un sistema de seguridad y calidad de productos agrícolas basado en la tecnología IoT proporciona todo el proceso de seguimiento y supervisión de productos agrícolas y satisface las necesidades de productos agrícolas seguros y de alta calidad (Ping, Wang, Ma, & Du, 2018).

En el Cuadro 2-2 se muestra un resumen de las investigaciones realizadas sobre monitoreo basado en IoT en deshidratadores de productos agrícolas, indicando un resumen del trabajo realizado y la referencia de este.

Cuadro 2-2. Trabajos previos sobre monitoreo basado en IoT en secadores de productos agrícolas.

No.	Autor/es	Año	Trabajo realizado
1	Spagnuolo <i>et al.</i>	2023	Construyeron un sistema de monitoreo capaz de soportar altas temperaturas para supervisar

No.	Autor/es	Año	Trabajo realizado
			temperatura y humedad relativa en tiempo real dentro de hornos de secado industrial.
2	Sharma <i>et al.</i>	2022	Instalaron un sistema de monitoreo y control en un secador solar tipo indirecto, que proporciona datos de temperatura y humedad relativa. El sistema se encarga del encendido de los extractores con los que regula las condiciones en el interior de la cámara de secado.
3	Patil <i>et al.</i>	2022	Diseñaron un sistema de monitoreo y control para un secador de plátano, con la finalidad de seguir y administrar el rendimiento del secador de forma remota.
4	Choosumrong <i>et al.</i>	2023	Propusieron un sistema basado en IoT para monitorear temperatura y humedad relativa durante el deshidratado de plátano en un secador parabólico de efecto invernadero.
5	Mishra <i>et al.</i>	2023	Evaluaron un sistema de monitoreo y control basado en IoT en un secador, que operó de manera efectiva, proporcionó datos confiables sobre el clima en el interior de secador y emitió las alarmas apropiadas en los casos de emergencia.
6	Alvinika <i>et al.</i>	2021	Usaron un sistema de monitoreo basado en IoT para recolectar datos de temperatura y humedad relativa durante el secado de pescado, que

No.	Autor/es	Año	Trabajo realizado
			utilizaron para el diseño de un controlador de lógica difusa.
7	Pramono <i>et al.</i>	2022	Estudiaron un sistema de monitoreo del contenido de humedad en hojas de moringa durante su secado en un secador tipo invernadero, el sistema permite monitorear el proceso de forma remota.
8	Varela-Aldás <i>et al.</i>	2023	Crearon un sistema de monitoreo de temperatura a través de un navegador web, el cual se puede aplicar en hornos de secado, pasteurización, almacenamiento, etc.
9	Murali <i>et al.</i>	2022	Diseñaron y evaluaron un sistema de alerta móvil que permite monitorear la pérdida de peso, contenido de humedad y grado de secado mediante mensajes de texto del secado de camarón en un secador solar tipo túnel
10	Hananda <i>et al.</i>	2023	Implementaron un sistema IoT en un secador solar tipo invernadero capaz de monitorear y regular la temperatura, humedad relativa y velocidad del viento, a través del accionamiento de un extractor de aire, un calentador y un deshumidificador.
11	Furtado <i>et al.</i>	2022	Construyeron un sistema de secado automático de bajo costo y probaron su efectividad en el proceso de secado de granos de cacao, utilizaron un método artificial de secado por

No.	Autor/es	Año	Trabajo realizado
			convección forzada en lecho fijo, en comparación con el lecho móvil.
12	Catania <i>et al.</i>	2020	Diseñaron un sistema de control y monitoreo en tiempo real de bajo costo para el proceso de secado de hierbas aromáticas y evaluaron la eficacia del secado en la comunidad microbiana asociada con las hierbas estudiadas (salvia y laurel).
13	Vengsungnle <i>et al.</i>	2020	Probaron un secador solar de efecto invernadero equipado con un sistema de control automático de circuito cerrado. Su sistema consta de seis termopares utilizados para medir la temperatura del aire interior y exterior, transmisores de humedad para medir la humedad interior y exterior y el peso del producto durante el secado dentro del secador se mide y registra con una celda de carga.
14	Aumporn <i>et al.</i>	2021c	Aplicaron un sistema de IoT en 18 secadores tipo invernadero de gran escala. Los secadores fueron equipados con sistemas que permitieron monitorear a distancia la temperatura y humedad relativa del aire de secado, el peso e imágenes del proceso de secado de plátano a través de un teléfono móvil.

Los sistemas IoT diseñados e implementados en secadores de productos agrícolas, han demostrado ser capaces de monitorear y controlar de forma remota el estado de las variables que intervienen en el secado, como son la

temperatura y humedad de aire dentro de las cámaras de secado y el peso del producto. Sin embargo, las aplicaciones que se han realizado aún son limitadas, todavía existe la necesidad de investigación que involucre nuevos diseños de sistemas IoT, que utilicen sensores precisos, sistemas de alimentación con energías renovables, protocolos de comunicación de gran alcance como LoRa, etc. Esta necesidad se justifica debido a que la mayoría de los secadores solares se encuentran instalados en zonas remotas, donde no se tiene acceso a energía eléctrica, ni conexión a internet o red telefónica. De esta forma se podrá explorar e incursionar en las ventajas y oportunidades que ofrecen las nuevas tecnologías como la IoT participando así en la cuarta revolución industrial.

2.8 Literatura citada

- Abdullah, Z., Taip, F. S., Kamal, S. M., & Rahman, R. Z. (2020). Nonlinear Model-Based Inferential Control of Moisture Content of Spray Dried Coconut Milk. *Foods*, 9(9), 1177. doi:<https://doi.org/10.3390/foods9091177>
- Abedi, F. M., & Takhar, P. S. (2021). Stress relaxation properties of bananas during drying. *Journal of Texture Studies*, 53(1), 146-156. doi:<https://doi.org/10.1111/jtxs.12637>
- Abueluor, A. A., Amin, M. T., Abuelnour, M. A., & Younis, O. (2023). A comprehensive review of solar dryers incorporated with phase change materials for enhanced drying efficiency. *Journal of Energy Storage*, 72, 108425. doi:<https://doi.org/10.1016/j.est.2023.108425>
- Ahmad, A., & Prakash, O. (2019). Thermal analysis of north wall insulated greenhouse dryer at different bed conditions operating under natural convection mode. *Environmental Progress & Sustainable Energy*, 38(6), e13257. doi:<https://doi.org/10.1002/ep.13257>
- Ahmad, A., Prakash, O., Kumar, A., Chatterjee, R., Sharma, S., Kumar, V., . . . Eldin, E. M. (2022). A Comprehensive State-of-the-Art Review on the Recent Developments in Greenhouse Drying. *Energies*, 15(24), 9493. doi:<https://doi.org/10.3390/en15249493>
- Al-Dairi, M., Pathare, P. B., Al-Yahyai, R., Jayasuriya, H., & Al-Attabi, Z. (2023). Postharvest quality, technologies, and strategies to reduce losses along the supply chain of banana: A review. *Trends in Food Science & Technology*, 134, 177-191. doi:<https://doi.org/10.1016/j.tifs.2023.03.003>

- Alvinika, Y., Setyohadi, D. B., & Sulistyoningih, M. (2021). IoT-Based Monitoring and Design of Automatic Fish Drying Equipment Using Fuzzy Logic. IOP Conference Series: Earth and Environmental Science. 704, pág. 012042. Yogyakarta, Indonesia: IOP. doi:10.1088/1755-1315/704/1/012042
- Argyropoulos, D., & Paraforos, D. S. (2022). Predicting equilibrium moisture content of mushrooms by NARX neural network and first order kinetic modelling approaches. IFAC-PapersOnLine, 55(32), 241-246. doi:https://doi.org/10.1016/j.ifacol.2022.11.146
- Aumporn, O., Janjai, S., Khunkaeo, T., & Bala, B. K. (2021a). Development of a Household Scale Solar Dryer: Performance Evaluation and ARX Modeling. Journal of Renewable Energy and Smart Grid Technology, 16(1), 1-11.
- Aumporn, O., Pankaew, P., Chanpen, N., & Janjai, S. (2021b). Experimental performance and auto-regressive with eXogenous Input (ARX) modelling of an anti-uv polycarbonate sheet-covered solar dryer equipped with a control system for drying Para rubber sheets. Journal of Renewable Energy and Smart Grid Technology, 16(2), 68-80.
- Aumporn, O., Wattan, R., Pattarapanitchai, S., Sangsan, M., & Janjai, S. (2021c). Study of Large-scale Solar Dryers Equipped with Monitoring and Control Systems for Banana Drying. Journal of Renewable Energy and Smart Grid Technology, 16(2), 1-16.
- Ayala-Solares, J. R., Wei, H. L., & Billings, S. A. (2019). A novel logistic-NARX model as a classifier for dynamic binary classification. Neural Computing and Applications, 31, 11-25. doi:https://doi.org/10.1007/s00521-017-2976-x
- Babalis, S., Papanicolaou, E., & Belessiotis, V. (2017). Fundamental Mathematical Relations of Solar Drying Systems. En O. Prakash, & A. Kumar, Solar Drying Technology Concept, Design, Testing, Modeling, Economics, and Environment (págs. 89–175). Singapore: Springer. doi:https://doi.org/10.1007/978-981-10-3833-4_4
- Catania, P., Gaglio, R., Orlando, S., Settanni, L., & Vallone, M. (2020). Design and implementation of a smart system to control aromatic herb dehydration process. Agriculture, 10(8), 332. doi:https://doi.org/10.3390/agriculture10080332
- Chauhan, P. S., & Kumar, A. (2016). Heat transfer analysis of north wall insulated greenhouse dryer under natural convection mode. Energy, 118, 1264-1274. doi:https://doi.org/10.1016/j.energy.2016.11.00
- Choosumrong, S., Hataitara, R., Panumonwatee, G., Raghavan, V., Nualsri, C., Phasinam, T., & Phasinam, K. (2023). Development of IoT based smart monitor and control system using MQTT protocol and Node-RED for

- parabolic greenhouse solar drying. *International Journal of Information Technology*, 15, 2089–2098. doi:<https://doi.org/10.1007/s41870-023-01237-3>
- Dhull, S. B., Malik, T., Kaur, R., Kumar, P., Kaushal, N., & Singh, A. (2020). Banana Starch: Properties Illustration and Food Applications—A Review. *Starch*, 73(1-2), 2000085. doi: <https://doi.org/10.1002/star.202000085>
- EL-Mesery, H. S., EL-Seesy, A. I., Hu, Z., & Li, Y. (2022). Recent developments in solar drying technology of food and agricultural products: A review. *Renewable and Sustainable Energy Reviews*, 157, 112070. doi:<https://doi.org/10.1016/j.rser.2021.112070>
- Farooq, M. S., Riaz, S., Abid, A., Umer, T., & Zikria, Y. B. (2020). Role of IoT Technology in Agriculture: A Systematic Literature Review. *Electronics*, 9(2), 319. doi:<https://doi.org/10.3390/electronics9020319>
- Ferreira, T. H., & Freitas, M. L. (2019). Production, physical, chemical and sensory evaluation of dried banana (*Musa Cavendish*). *Emirates Journal of Food and Agriculture*, 31(2), 102-108. doi:10.9755/ejfa.2019.v31.i2.1912
- Furtado, W. V., Vaz Junior, O. A., Veras, A. A., de Sá, H. H., & Henrique, A. M. (2022). Low-cost automation for artificial drying of cocoa beans: A case study in the Amazon. *Drying Technology*, 40(1), 42-49. doi:<https://doi.org/10.1080/07373937.2020.1767644>
- Granella, S. J., Bechlin, T. R., & Christ, D. (2022). Moisture diffusion by the fractional-time model in convective drying with ultrasound-ethanol pretreatment of banana slices. *Innovative Food Science and Emerging Technologies*, 76, 102933. doi:<https://doi.org/10.1016/j.ifset.2022.102933>
- Hananda, N., Kamul, A., Harito, C., Djuana, E., Elwirehardja, G. N., Pardamean, B., Pasang, T. (2023). Solar drying in Indonesia and its development: a review and implementation. *The 6th International Conference on Eco Engineering Development 2022 (ICEED 2022)* (p. 012084). IOP Conference Series: Earth and Environmental Science. doi:10.1088/1755-1315/1169/1/012084
- Hasan, M. U., Malik, A. U., Ali, S., Imtiaz, A., Munir, A., Amjad, W., & Anwar, R. (2019). Modern drying techniques in fruits and vegetables to overcome postharvest losses: A review. *Journal of Food Processing and Preservation*, 43(12), e14280. doi: <https://doi.org/10.1111/jfpp.14280>
- Ismail, M. I., Yunus, N. A., & Hashim, H. (2021). Integration of solar heating systems for low-temperature heat demand in food processing industry – A review. *Renewable and Sustainable Energy Reviews*, 147, 111192. doi:<https://doi.org/10.1016/j.rser.2021.111192>

- Janjai, S., & Bala, B. K. (2012). Solar Drying Technology. *Food Engineering Reviews*, 4, 16–54. doi:<https://doi.org/10.1007/s12393-011-9044-6>
- Janjai, S., Lamlert, N., Intawee, P., Mahayothee, B., Bala, B. K., Nagle, M., & Müller, J. (2009). Experimental and simulated performance of a PV-ventilated solar greenhouse dryer for drying of peeled longan and banana. *Solar Energy*, 83(9), 1550-1565. doi:<https://doi.org/10.1016/j.solener.2009.05.003>
- Kamarulzaman, A., Hasanuzzaman, M., & Rahim, N. A. (2021). Global advancement of solar drying technologies and its future prospects: A review. *Solar Energy*, 221, 559-582. doi:<https://doi.org/10.1016/j.solener.2021.04.056>
- Keesman, K. J. (2011). *System Identification: An Introduction*. London: Springer. doi:10.1007/978-0-85729-522-4
- khadraoui, A. E., Hamdi, I., Kooli, K., & Kooli, A. (2019). Drying of red pepper slices in a solar greenhouse dryer and under open sun: Experimental and mathematical investigations. *Innovative Food Science and Emerging Technologies*, 52, 262-270. doi:<https://doi.org/10.1016/j.ifset.2019.01.001>
- Kreetachat, T., Imman, S., Suwannahong, K., Wongcharee, S., Muangthong-on, T., & Suriyachai, N. (2023). Dataset on the optimization by response surface methodology for dried banana products using greenhouse solar drying in Thailand. *Data in Brief*, 109370. doi:<https://doi.org/10.1016/j.dib.2023.109370>
- Kumar, P., & Singh, D. (2020). Advanced technologies and performance investigations of solar dryers: A review. *Renewable Energy Focus*, 35, 148-158. doi:<https://doi.org/10.1016/j.ref.2020.10.003>
- Labuza, T. P. (1977). THE PROPERTIES OF WATER IN RELATIONSHIP TO WATER BINDING IN FOODS: A REVIEW. *Journal of Food Processing and Preservation*, 1(2), 167-190. doi:<https://doi.org/10.1111/j.1745-4549.1977.tb00321.x>
- Li, H., & Chen, S. (2020). A neural-network-based model predictive control scheme for grain dryers. *Drying Technology*, 38(8), 1079-1091. doi:10.1080/07373937.2019.1611598
- Ljung, L. (1998). *System Identification*. En A. Procházka, J. Uhlíř, P. Rayner, & N. Kingsbury, *Signal Analysis and Prediction* (págs. 163-173). Boston: Birhiuser. doi:https://doi.org/10.1007/978-1-4612-1768-8_11
- Macedo, L. L., Vimercati, W. C., Araújo, C. d., Saraiva, S. H., & Teixeira, L. J. (2020). Effect of drying air temperature on drying kinetics and

- physicochemical characteristics of dried banana. *Journal of Food Process Engineering*, 43(9), e13451. doi:<https://doi.org/10.1111/jfpe.13451>
- Madhankumar, S., Viswanathan, K., Taipabu, M. I., & Wu, W. (2023). A review on the latest developments in solar dryer technologies for food drying process. *Sustainable Energy Technologies and Assessments*, 58, 103298. doi:<https://doi.org/10.1016/j.seta.2023.103298>
- Mani, P., & Natesan, V. T. (2021). Experimental investigation of drying characteristics of lima beans with passive and active mode greenhouse solar dryers. *Journal of Food Process Engineering*, 44(5), e13667. doi:<https://doi.org/10.1111/jfpe.13667>
- Milani, A., Jouki, M., & Rabbani, M. (2020). Production and characterization of freeze-dried banana slices pretreated with ascorbic acid and quince seed mucilage: Physical and functional properties. *Food Science & Nutrition*, 8(7), 3768-3776. doi:<https://doi.org/10.1002/fsn3.1666>
- Mishra, N., Jain, S. K., Agrawal, N., Jain, N. K., Wadhawan, N., & Panwar, N. L. (2023). Development of drying system by using internet of things for food quality monitoring and controlling. *Energy Nexus*, 11, 100219. doi:<https://doi.org/10.1016/j.nexus.2023.100219>
- Mishra, S., Verma, S., Chowdhury, S., & Dwivedi, G. (2021). Analysis of recent developments in greenhouse dryer on various parameters- a review. *Materials Today: Proceedings*, 38, 371-377. doi:<https://doi.org/10.1016/j.matpr.2020.07.429>
- Mohana, Y., Mohanapriya, R., Anukiruthika, T., Yoha, K. S., Moses, J. A., & Anandharamakrishnan, C. (2020). Solar dryers for food applications: Concepts, designs, and recent advances. *Solar Energy*, 208, 321-344. doi:<https://doi.org/10.1016/j.solener.2020.07.098>
- Mujumdar, A. S., & Law, C. L. (2010). Drying Technology: Trends and Applications in Postharvest Processing. *Food and Bioprocess Technology*, 3, pages843–852. doi:10.1007/s11947-010-0353-1
- Murali, S., Alfiya, P. V., Delfiya, D. A., Harikrishnan, S., Kunjulakshmi, S., & Samuel, M. P. (2022). Performance evaluation of PV powered solar tunnel dryer integrated with a mobile alert system for shrimp drying. *Solar Energy*, 240, 246-257. doi:<https://doi.org/10.1016/j.solener.2022.05.028>
- Ogawa, T., & Adachi, S. (2014). Measurement of Moisture Profiles in Pasta During Rehydration Based on Image Processing. *Food and Bioprocess Technology*, 7, 1465–1471. doi:10.1007/s11947-013-1156-y
- Padhi, S., Murakonda, S., & Dwivedi, M. (2022). Investigation of drying characteristics and nutritional retention of unripe green banana flour by

- refractance window drying technology using statistical approach. *Journal of Food Measurement and Characterization*, 16, 2375–2385. doi:<https://doi.org/10.1007/s11694-022-01349-7>
- Patil, P. S., Pangavhane, D. R., Shekhawat, S. P., Deshmukh, D. S., & Deshmukh, M. S. (2022). Development of an iot-based solar banana dryer monitoring and control system. *International Journal of Mechanical Engineering*, 7(1), 4745-4752.
- Patil, R., & Gawandeb, R. (2016). A review on solar tunnel greenhouse drying system. *Renewable and Sustainable Energy Reviews*, 56, 196-214. doi:<https://doi.org/10.1016/j.rser.2015.11.057>
- Petikirige, J., Karim, A., & Millar, G. (2022). Effect of drying techniques on quality and sensory properties of tropical fruits. *International Journal of Food Science and Technology*, 57(11), 6963-6979. doi:<https://doi.org/10.1111/ijfs.16043>
- Pilario, K. E., Ching, P. M., Calapatia, A. M., & Culaba, A. B. (2022). Predicting Drying Curves in Algal Biorefineries using Gaussian Process Autoregressive Models. *Digital Chemical Engineering*, 4, 100036. doi:<https://doi.org/10.1016/j.dche.2022.100036>
- Ping, H., Wang, J., Ma, Z., & Du, Y. (2018). Mini-review of application of IoT technology in monitoring agricultural products quality and safety. *International Journal of Agricultural and Biological Engineering*, 11(5), 35-45.
- Poozesh, S., & Cousin, C. A. (2022). Integrating a dynamic multiscale drying model into a closed loop control strategy for laboratory spray dryer. *Drying Technology*, 40(11), 2308-2320. doi:[10.1080/07373937.2021.1934692](https://doi.org/10.1080/07373937.2021.1934692)
- Poozesh, S., Karam, M., Akafuah, N., & Wang, Y. (2021). Integrating a model predictive control into a spray dryer simulator for a closed-loop control strategy. *International Journal of Heat and Mass Transfer*, 170, 121010. doi:<https://doi.org/10.1016/j.ijheatmasstransfer.2021.121010>
- Pramono, E. K., Taufan, A., Novrinaldi, Putra, S. A., Karim, M. A., Haryanto, A., & Kuala, S. I. (2022). Performance Tests of Loadcell as Real-Time Moisture Content Sensor: Case Study Moringa Oleifera Leaves Drying. *IOP Conference Series: Earth and Environmental Science*. 1024, p. 012018. Bogor, Indonesia: IOP. doi:[10.1088/1755-1315/1024/1/012018](https://doi.org/10.1088/1755-1315/1024/1/012018)
- Pu, Y.-Y., & Sun, D.-W. (2017). Combined hot-air and microwave-vacuum drying for improving drying uniformity of mango slices based on hyperspectral imaging visualisation of moisture content distribution. *Biosystems Engineering*, 156, 108-119. doi:<https://doi.org/10.1016/j.biosystemseng.2017.01.006>

- Quy, V. K., Hau, N. V., Anh, D. V., Quy, N. N., Ban, N. T., Lanza, S., . . . Muzirafuti, A. (2022). IoT-Enabled Smart Agriculture: Architecture, Applications, and Challenges. *Applied Sciences*, 12(7), 3396. doi:<https://doi.org/10.3390/app12073396>
- Rachad, S., Nsiri, B., & Bensassi, B. (2015). System Identification of Inventory System Using ARX and ARMAX Models. *International Journal of Control and Automation*, 8(12), 283-294. doi:<http://dx.doi.org/10.14257/ijca.2015.8.12.26>
- Ratti, C., & Mujumdar, A. S. (1997). Solar drying of foods: Modeling and numerical simulation. *Solar Energy*, 60(3-4), 151-157. doi:[https://doi.org/10.1016/S0038-092X\(97\)00002-9](https://doi.org/10.1016/S0038-092X(97)00002-9)
- Sharma, B. B., Gupta, G., Vaidya, P., Basheer, S., Memon, F. H., & Thakur, R. N. (2022). Internet of Things-Based Crop Classification Model Using Deep Learning for Indirect Solar Drying. *Wireless Communications and Mobile Computing*, 2022, 1-11. doi:<https://doi.org/10.1155/2022/1455216>
- Singh, A. B., Manju, P., Rukkumani, V., & Srinivasan, K. (2022). Comparative Analysis of MRAC and IMC Adaptive Control Modes for an Industrial Dryer. En E. G. V, & A. Fethi, *Energy and Exergy for Sustainable and Clean Environment, Volume 1. Green Energy and Technology* (Vol. 1, págs. 475-486). Singapore: Springer. doi:https://doi.org/10.1007/978-981-16-8278-0_31
- Singh, A., Sarkar, J., & Sahoo, R. R. (2020). Experimental performance analysis of novel indirect-expansion solar-infrared assisted heat pump dryer for agricultural products. *Solar Energy*, 206, 907-917. doi:<https://doi.org/10.1016/j.solener.2020.06.065>
- Sontakke, M. S., & Salve, S. P. (2015). Solar Drying Technologies: A review. *International Refereed Journal of Engineering and Science (IRJES)*, 4(4), 29-35.
- Spagnuolo, A., Vetromile, C., Masiello, A., De Santo, G., Suriano, M., Mercuri, G., Di Cicco, M. R. (2023). Industrial Drying of Fruit and Vegetable Products: Customized Smart Monitoring and Analytical Characterization of Process Variables in the OTTORTO Project. *Processes*, 11(6), 1635. doi:<https://doi.org/10.3390/pr11061635>
- Suresh, B. V., Shireesha, Y., Kishore, T. S., Dwivedi, G., Haghighi, A. T., & Patro, E. R. (2023). Natural energy materials and storage systems for solar dryers: State of the art. *Solar Energy Materials and Solar Cells*, 255, 112276. doi:<https://doi.org/10.1016/j.solmat.2023.112276>

- Symeonaki, E. G., Arvanitis, K. G., & Piromalis, D. D. (2019). Cloud Computing for IoT Applications in Climate-Smart Agriculture: A Review on the Trends and Challenges Toward Sustainability. En A. Theodoridis, A. Ragkos, & M. Salampasis, *Innovative Approaches and Applications for Sustainable Rural Development 8th International Conference, HAICTA 2017, Chania, Crete, Greece, September 21–24, 2017, Selected Papers* (págs. 147-167). Springer Earth System Sciences. doi:https://doi.org/10.1007/978-3-030-02312-6_9
- Taki, M., Rohani, A., Soheili-Fard, F., & Abdeslahi, A. (2018). Assessment of energy consumption and modeling of output energy for wheat production by neural network (MLP and RBF) and Gaussian process regression (GPR) models. *Journal of Cleaner Production*, 172, 3028-3041. doi:<https://doi.org/10.1016/j.jclepro.2017.11.107>
- Udomkun, P., Romuli, S., Schock, S., Mahayothee, B., Sartas, M., Wossen, T., . . . Müller, J. (2020). Review of solar dryers for agricultural products in Asia and Africa: An innovation landscape approach. *Journal of Environmental Management*, 268, 110730. doi:<https://doi.org/10.1016/j.jenvman.2020.110730>
- Varela-Aldás, J., Escudero, P., & Casa, S. (2023). IoT-Based System for Web Monitoring of Thermal Processes. In C. Stephanidis, M. Antona, S. Ntoa, & G. Salvendy, *HCI International 2023 Posters 25th International Conference on Human-Computer Interaction, HCII 2023 Copenhagen, Denmark, July 23–28, 2023 Proceedings, Part IV* (pp. 549–553). Springer. doi:https://doi.org/10.1007/978-3-031-36001-5_71
- Vengsungnle, P., Jongpluempiti, J., Srichat, A., Wiriyasart, S., & Naphon, P. (2020). Thermal performance of the photovoltaic–ventilated mixed mode greenhouse solar dryer with automatic closed loop control for Ganoderma drying. *Case Studies in Thermal Engineering*, 21, 100659. doi:<https://doi.org/10.1016/j.csite.2020.100659>
- Xu, J., Gao, B., & Tian, G. (2022). Review of agricultural IoT technology. *Artificial Intelligence in Agriculture*, 6, 10-22. doi:<https://doi.org/10.1016/j.aiia.2022.01.001>
- Yuan, C., Ding, X., & Hou, R. (2018). Prediction Method for Moisture Content in Dried Cut Tobacco Based on Combination Model of WNN and ARX. 2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD) (págs. 155-160). Huangshan, China: IEEE. doi:10.1109/FSKD.2018.8687157
- Zambrano, M. V., Dutta, B., Mercer, D. G., MacLean, H. L., & Touchie, M. F. (2019). Assessment of moisture content measurement methods of dried food products in small-scale operations in developing countries: A review.

Trends in Food Science & Technology, 88, 484-496.
doi:<https://doi.org/10.1016/j.tifs.2019.04.006>

- Zhang, L., Dabipi, I. K., & Brown, W. L. (2018). Internet of Things Applications for Agriculture. En Q. F. Hassan, Internet of Things A to Z: Technologies and Applications (págs. 507-528). Hoboken, New Jersey: John Wiley & Sons. doi:<https://doi.org/10.1002/9781119456735.ch18>
- Zhou, F., Peng, H., Ruan, W., Wang, D., Liu, M., Gu, Y., & Li, L. (2018). Cubic-RBF-ARX modeling and model-based optimal setting control in head and tail stages of cut tobacco drying process. Neural Computing and Applications, 30, 1039–1053. doi:<https://doi.org/10.1007/s00521-016-2735-4>
- Zhou, Z., & Wang, K. (2018). Sliding mode controller design for wood drying process. Wood Science and Technology, 52, 1039-1048. doi:<https://doi.org/10.1007/s00226-018-1006-1>
- Zhou, Z., & Wang, K. (2019). RBF-based sliding mode control method for lumber drying system. Wood and fiber science, 51(3), 1-9. doi:<https://doi.org/10.22382/wfs-2019-028>
- Zulkeflee, S. A., Rohman, F. S., Sata, S. S., & Aziz, N. (2021). Autoregressive exogenous input modelling for lipase catalysed esterification process. Mathematics and Computers in Simulation, 182, 325-339. doi:<https://doi.org/10.1016/j.matcom.2020.11.006>

3 MONITOREO DEL AMBIENTE APOYADO EN IOT Y PREDICCIÓN DEL CONTENIDO DE HUMEDAD DE PLÁTANO EN UN SECADOR SOLAR TIPO INVERNADERO

3.1 Resumen

La modernización del proceso de secado permitirá la disminución del desperdicio de los productos agrícolas y la reducción de la contaminación ambiental. El objetivo de este estudio fue el diseño de un sistema de monitoreo basado en la internet de las cosas (IoT), de la temperatura y humedad relativa para un secador solar. El sistema desarrollado está compuesto por un módulo de adquisición de datos: que recopila datos de la temperatura (T_a), humedad relativa (RH) del aire y el tiempo de encendido y apagado de los extractores del secador, un módulo de comunicación: que transmite información de T_a y RH a través de LoRa y Wifi a ThingSpeak para el monitoreo en un dispositivo móvil, y un módulo de alimentación: que suministra por energía solar la corriente eléctrica para la operación del sistema. El funcionamiento del sistema de monitoreo IoT fue evaluado en tres experimentos de secado de plátano dominico (*Musa paradisiaca* var *sapientum*), durante los cuales el desempeño del sistema fue satisfactorio permitiendo al usuario visualizar de manera gráfica en una interfaz web y móvil el comportamiento de la T_a y RH en el interior del secador. Los datos medidos por el sistema se emplearon para predecir el contenido de humedad del plátano con un modelo autorregresivo con variables exógenas (ARX) identificado en línea. El modelo matemático obtenido predijo de forma adecuada el comportamiento del contenido de humedad con una buena bondad de ajuste, con valores de $R^2 = 0.99$, $MSE = 1.29 \times 10^{-5}$ y $MAE = -5.03 \times 10^{-6}$. El secador solar permitió reducir el contenido de humedad de los plátanos hasta un 19.84 % w.b. en un periodo de 4 días y en un 20.03% w.b. durante 5 días en presencia de lluvias.

Palabras clave: *Musa paradisiaca* var *sapientum*, protocolo LoRa, ThingSpeak, modelo ARX, gradiente conjugado.

3.2 Introducción

El plátano (*Musa* spp.) es una fruta tropical, rica en carbohidratos, fibras dietéticas, ciertas vitaminas, minerales, compuestos fenólicos y antioxidantes. Como resultado, el consumo del plátano está asociado con beneficios para la salud y la disminución del riesgo de enfermedades. Estas características hacen de esta fruta una de las más consumidas en el mundo (Khoozani, Birch, & Bekhit, 2019; Sidhu & Zafar, 2018). Sin embargo, debido a su alto contenido de humedad, el plátano es un fruto perecedero y está sujeto a un rápido deterioro después de la cosecha. Para reducir su contenido de humedad y en consecuencia prolongar su vida útil, se han utilizado diferentes técnicas de secado (Seyedabadi, Khojastehpour, & Abbaspour-Fard, 2017). Generalmente, el secado del plátano se realiza a la intemperie resultando en frutos secos de mala calidad debido a la contaminación por insectos, polvo y lluvia. Además, la energía solar se utiliza de manera ineficiente (Nabnean & Nimnuan, 2020). Para resolver estos problemas, se ha propuesto el uso de sistemas de secado solar de tipo invernadero que ofrecen un proceso de secado rápido, eficiente e higiénico y amigables con el medio ambiente (Pankaew, Aumporn, Janjai, Mundpookhiew, & Bala, 2019).

El rápido aumento de la población mundial, el agotamiento de los recursos, las pérdidas de alimentos debido al deterioro, etc., han generado la necesidad de la implementación de tecnologías novedosas para la modernización de procesos agrícolas como el secado (Quy *et al.*, 2022; Maroli, Narwane, & Gardas, 2021). La integración de las metodologías de secado sostenible con las últimas tecnologías de la información como la internet de las cosas (IoT) y las redes de sensores inalámbricos, puede conducir a la modernización de este proceso, que tendrá como resultado la disminución del desperdicio de los productos agrícolas y la reducción de la contaminación ambiental (Raj *et al.*, 2021; Rehman *et al.*, 2022).

La IoT es un campo emergente que permite un monitoreo del proceso de deshidratado eficiente y confiable (Popa *et al.*, 2019). En la actualidad, se han

desarrollado sistemas inteligentes basados en IoT para realizar el monitoreo del proceso de secado. Catania, Gaglio, Orlando, Settanni y Vallone (2020) diseñaron un sistema de control y monitoreo de bajo costo para el proceso de secado de hierbas aromáticas en un secador de gabinete. El prototipo del sistema está basado en una placa Arduino Mega 2560, nueve celdas de carga Siemens 7MH5102-1PD00 y un sensor de temperatura y humedad relativa DHT22. Los datos adquiridos por los sensores se transmitieron a través de Wi-Fi a una cuenta de ThingSpeak para monitorear el proceso de secado en tiempo real. Los resultados experimentales mostraron que el sistema es adecuado para monitorear la pérdida de humedad. Aumporn, Wattan, Pattarapanitchai, Sangsan y Janjai (2021c) evaluaron un sistema de IoT en 18 secadores tipo invernadero de gran escala. Los secadores fueron equipados con sistemas de monitoreo y control que permitieron monitorear a distancia la temperatura y humedad relativa del aire interior del secador, el peso e imágenes del proceso de secado de plátano a través de un teléfono móvil.

Por otro lado, para el diseño de algoritmos de control en sistemas de secado solar los modelos autorregresivos con variables exógenas (ARX), han demostrado ser útiles para predecir el comportamiento del contenido de humedad en plátano (Aumporn, Janjai, Khunkaeo, & Bala. 2021a) y hojas de caucho (Aumporn, Pankaew, Chanpen, & Janjai, 2021b).

Por lo anterior, el objetivo de este estudio fue desarrollar un sistema apoyado en la IoT para el monitoreo de la temperatura y humedad relativa en el proceso de secado de plátano en un secador solar tipo invernadero. Adicionalmente, con los datos obtenidos del sistema de monitoreo identificar en línea un modelo ARX para predecir un paso hacia adelante el contenido de humedad del producto.

3.3 Materiales y Métodos

3.3.1 Descripción del secador solar

Las pruebas de secado de plátano dominico (*Musa paradisiaca* var. *sapientum*) se llevaron a cabo en un secador solar tipo invernadero de forma parabólica (Figura 3-1a) con dimensiones de 10 x 9 m de base y 3.5 m de altura. El sistema está construido de acero galvanizado, cuenta con piso de concreto reforzado, cubierta de policarbonato de doble pared de 0.006 m de espesor y con protección contra rayos UV. En la parte frontal cuenta con dos entradas de aire cada una con 0.3 x 1.5 m y en la pared trasera tiene instalados dos extractores con capacidad de 9,435 m³ h⁻¹ cada uno, accionados mediante motores monofásicos de 0.5 HP (373 W), empleados para controlar el flujo de aire en el interior del secador.

3.3.2 Experimento de deshidratado

Los plátanos utilizados en los tres experimentos de secado realizados el 11, 18 y 26 de marzo de 2023 presentaban un grado de maduración entre 6 y 7 de acuerdo con la escala estándar Von Loesecke (CEAGESP, 2006). Para los experimentos, los plátanos se pelaron y extendieron como una capa delgada sobre las mesas de secado en el interior del secador (Figura 3-1b). En el sistema de control se estableció que la temperatura del aire no excediera 50°C, temperatura máxima recomendada para el deshidratado de plátano (Nimnuan & Nabnean, 2022). Durante las pruebas, en la noche las muestras se guardaron en bolsas selladas herméticamente con la finalidad de que no ganaran o perdieran humedad, y se concluyeron los experimentos cuando el producto alcanzó un peso aproximadamente constante.




Figura 3-1. a) Secador solar parabólico tipo invernadero y b) deshidratado de plátano dominico.

3.3.3 Medición del color y dulzura

El color de las muestras de plátano frescas y secas se midieron con un espectrofotómetro de esfera (X-Rite Modelo SP60 Series). Este instrumento define el color en términos de los valores L^* , a^* y b^* de las propiedades de cromaticidad de la Comisión Internacional de Iluminación (CIE). El valor L^* se utiliza para indicar luminosidad ($L^* = 100$ para blanco) y oscuridad ($L^* = 0$ para negro), a^* describe la intensidad de color rojo ($a^* > 0$) y de color verde ($a^* < 0$), b^* describe la intensidad de color amarillo ($b^* > 0$) y de color azul ($b^* < 0$). Se eligieron los sistemas $L^*a^*b^*$ y $L^*a^*h^*$ porque son los más utilizados en la evaluación de alimentos secos y ampliamente aceptados en toda la industria agrícola para evaluar la calidad visual de los productos (Nabnean & Nimnuan, 2020).

El espectrofotómetro fue calibrado con una placa de referencia blanca y negra al comienzo de las mediciones. Para cada muestra, se realizaron tres mediciones en el centro del fruto. A partir de las coordenadas L^* , a^* , b^* , el ángulo de matiz (h) se calculó con la ecuación (López-Camelo & Gómez, 2004):

$$h = \begin{cases} \tan^{-1}\left(\frac{b^*}{a^*}\right), & \text{cuando } a^* > 0 \\ 180^\circ + \tan^{-1}\left(\frac{b^*}{a^*}\right), & \text{cuando } a^* < 0 \end{cases} \quad (1)$$

Los valores de h varían de 0° (rojo puro), 90° (amarillo puro), 180° (verde puro) a

270° (azul puro) (Macedo, da Silva Araújo, Vimercati, Saraiva, & Teixeira, 2019; Vimercati *et al.*, 2020). Croma (C^*) que indica la intensidad del color o la saturación se define como (López-Camelo & Gómez, 2004):

$$C^* = (a^{*2} + b^{*2})^{1/2} \quad (2)$$

El cambio de color total (ΔE) entre el plátano fresco y seco se calculó con la ecuación siguiente (Maskan, 2001):

$$\Delta E = [(L^* - L_{ref}^*)^2 + (a^* - a_{ref}^*)^2 + (b^* - b_{ref}^*)^2]^{1/2} \quad (3)$$

donde L_{ref}^* , a_{ref}^* y b_{ref}^* son las propiedades de luminosidad e intensidad de color de las muestras frescas; y L^* , a^* y b^* son las propiedades de luminosidad e intensidad de color de las muestras secas.

El contenido de sólidos solubles totales (SST) de las muestras de plátano frescas y secas se determinó utilizando un refractómetro Atago modelo PAL-1.

3.3.4 Estructura del sistema de monitoreo

El sistema se basa en sensores para monitorear en tiempo real la temperatura T_a (°C) y humedad relativa RH (%) en la cámara de secado, y el tiempo de encendido y apagado de los extractores t_{ext} (s). El sistema de monitoreo consta de tres módulos: adquisición de datos, comunicación y alimentación (Figura 3-2). Las características de los sensores y componentes electrónicos usados en la construcción del sistema de monitoreo se muestran en el Cuadro 3-1 y Cuadro 3-2, respectivamente.




Figura 3-2. Funcionamiento del sistema de sensores diseñado para el monitoreo de un secador solar.

Cuadro 3-1. Características de los sensores del sistema de monitoreo.

Sensor	Rango de operación	Resolución	Precisión	Voltaje de operación
BME680	-40° a +85°C 0 a 100%	±1°C ±3%	0.01°C 0.008%	3 a 5 V
SCT-013	20% a 100 % A		1%	≤ 660V

Cuadro 3-2. Lista de componentes electrónicos del sistema de monitoreo.

Descripción	Cantidad	Modelo	Fabricante
Placa microcontroladora	2	MEGA 2560 R3	ARDUINO
	1	UNO	ARDUINO
Tarjeta de comunicación	2	TTGO LORA 32	LILYGO
Reloj en tiempo real	2	DS3231	MAXIM INTEGRATED
Tarjeta microSD	2	74LVC125A	NEXPERIA
Convertidor analógico/digital	1	ADS1115	TEXAS INSTRUMENTS
Pantalla LCD	1	020N004L	VISHAY
monocromática	1	MD1602I	SURENOO
El circuito integrado I2C	1	PCF8574	TEXAS INSTRUMENTS
Fotocelda solar	1	50 Wp	GENÉRICO
batería recargable	1	31T	MS BATTERY
	1	PWM 30A	KIMISS
Regulador de voltaje	1	STEP DOWN 4 PUERTOS	GENÉRICO

El módulo de adquisición de datos fue dividido en dos partes. En la primera parte (Figura 3-3, Parte I) se encuentran cuatro sensores BME680, el Arduino Mega secundario que se encarga de la lectura de dos sensores BME680 y enviar los datos al Arduino Mega primario. Este último realiza la lectura de los dos sensores BME680 restantes; a continuación, lee el módulo RTC y registra e imprime los datos de temperatura y humedad relativa, con la fecha y hora en la tarjeta SD y en el Display LCD, respectivamente. Finalmente, el Arduino Mega primario se comunica con la placa LilyGO TTGO notificándole el valor promedio de temperatura y humedad relativa de los cuatro sensores BME680.

La segunda parte (Figura 3-3, Parte II) se encarga del registro del tiempo de encendido y apagado de los extractores a través de la lectura del consumo de corriente. Para el monitoreo del consumo de energía se utiliza el sensor STC-013 conectado a una tarjeta ADS1115, que convierte la señal analógica proporcionada por el sensor a una señal digital que es recibida e interpretada por el Arduino UNO, que a continuación lee el RTC y guarda e imprime el evento de encendido y apagado con la estampa de tiempo en la SD y LCD, respectivamente.




Figura 3-3. Arquitectura del módulo de adquisición de datos del sistema monitoreo.

El valor promedio de la T_a y RH de las lecturas proporcionadas por los cuatro sensores BME680 se enviaron cada 10 segundos mediante los protocolos de comunicación de LoRa y Wifi a la plataforma ThingSpeak, que permite visualizar los datos en tiempo real a través de una interfaz web y móvil. Para realizar esta acción, se implementó un servidor local donde interactúan dos placas LilyGO TTGO con el módulo de adquisición de datos como se muestra en la Figura 3-4.

Las placas LilyGO TTGO se configuraron para trabajar en la frecuencia de banda 915 MHz con un ancho de banda de 125 kHz y un factor de propagación (SF) igual a 12 para lograr una comunicación inalámbrica de largo alcance, con alta

resistencia a interferencias y una eficiencia espectral mejorada. Se optó por esta configuración, donde la velocidad de transmisión de datos es secundaria frente a la necesidad de una combinación robusta y de larga distancia, permitiendo así la transmisión de los datos a una velocidad de 156 bps a 1.14 km de distancia del secador donde el dispositivo LilyGO TTGO receptor (Figura 3-4) se conectó con un router WiFi para transmitir la información a ThingSpeak.

El módulo de alimentación (Figura 3-5) suministra 4.2 Wh de energía eléctrica al sistema de monitoreo usando energía solar. Se compone de una celda fotovoltaica de 50 Wp, conectada a un controlador de carga PWM encargado de mantener cargada la batería y suministrar corriente al módulo Step Down, cuyos puertos se utilizaron para alimentar a los tres Arduinos y al módulo emisor LilyGO TTGO.




Figura 3-4. Arquitectura del módulo de comunicación del sistema de monitoreo.




Figura 3-5. Módulo de alimentación del sistema de monitoreo.

3.3.5 Mediciones y sistema de registro de datos

Los puntos de medición durante los experimentos se distribuyeron en el secador (Figura 3-6). La temperatura del aire T_a (°C) y humedad relativa RH (%) por encima de las muestras se monitorearon con los sensores BME680. Las señales generadas por los sensores se almacenaron cada diez segundos y después fueron procesadas para obtener la T_a y RH cada minuto. Adicionalmente, se emplearon dos sensores de temperatura y humedad relativa HygroVUE 10 (Campbell Scientific) como sensores de referencia para evaluar el desempeño de los sensores BME680. Los sensores se protegieron de la radiación solar con un tubo de PVC de 0.5 m de longitud recubierto de aluminio (Erell, Leal, & Maldonado, 2005). La radiación solar global R_g ($W m^{-2}$), la temperatura T_{amb} (°C) y humedad relativa RH_{amb} (%) del ambiente exterior se registraron cada minuto con una estación meteorológica HOBO U30 (Onset Computer Corporation, EE. UU.). El tiempo de encendido y apagado de los extractores (t_{ext}) se registró cada 5 segundos, el cual fue procesado para obtener una señal en porcentaje de encendido y apagado de los extractores por minuto.




Figura 3-6. Distribución de los sensores de medición para la temperatura (T_a), humedad relativa (RH), temperatura de referencia (T_{ref}) y humedad relativa de referencia (RH_{ref}) del aire dentro del secador, muestras del producto (M), señal de encendido y apagado de los extractores (t_{ext}), radiación global (R_g), temperatura (T_{amb}) y humedad relativa (RH_{amb}) del aire exterior.

La pérdida de peso del producto en el tiempo se registró en cuatro muestras en el secador (M_1 , M_2 , M_3 , M_4) (Figura 3-6), que se pesaron en intervalos de 0.5 h utilizando una balanza digital VE-1000 con una precisión de ± 0.01 g (Microscopios VELAB). Los experimentos comenzaron con el registro del peso inicial de cada una de las muestras. Al finalizar, el porcentaje de materia seca en las muestras se determinó mediante el método de la estufa, el cual consiste en deshidratar la muestra a 105°C durante 24 h.

El contenido de humedad en base húmeda M_{wb} (%) durante el proceso de secado, se determinó a partir del peso de las muestras en el tiempo y la materia seca final con la siguiente ecuación:

$$\% M_{wb} = \left(\frac{W_0 - W_d}{W_0} \right) \cdot 100 \quad (4)$$

donde W_0 es el peso de la muestra húmeda (kg) y W_d es el peso de la muestra seca (kg).

3.3.6 Modelado del contenido de humedad del producto

Los datos obtenidos de los experimentos se utilizaron para predecir el contenido de humedad de los plátanos mediante modelos autorregresivos con entradas exógenas (ARX). El modelo ARX implementado es un modelo de múltiples entradas y salida única (MISO), que de acuerdo con Montoya-Ríos, García-Mañas, Guzmán, y Rodríguez (2020) se puede representar matemáticamente en tiempo discreto mediante la siguiente expresión:

$$A(z)y(t) = \sum_{i=1}^{nu} B_i(z) \cdot u_i(t - nk_i) + e(t) \quad (5)$$

donde y es la salida, u_i son las entradas, e es el ruido blanco, nu es el número total de entradas y nk_i es el número de muestras correspondientes a cada retardo de tiempo de entrada. $A(z)$ y $B_i(z)$ son polinomios con la siguiente estructura:

$$A(z) = 1 + a_1 \cdot z^{-1} + \dots + a_{na} \cdot z^{-na} \quad (6)$$

$$B_i(z) = b_{0_i} + b_{1_i} \cdot z^{-1} + \dots + b_{nb_i} \cdot z^{-nb_i} \quad (7)$$

donde na y nb son el orden para los polinomios A y B , respectivamente; a y b son los coeficientes por determinar en el procedimiento de identificación.


Los coeficientes de los polinomios $A(z)$ y $B_i(z)$ de los modelos ARX en el primer experimento se inicializaron de forma aleatoria, y los coeficientes finales obtenidos se emplearon para inicializar la predicción del contenido de humedad en las muestras de plátano del segundo y tercer experimento. La estimación de los parámetros se realizó mediante los algoritmos para la estimación en línea: factor de olvido (λ) variado de 0.98 a 0.995, filtro de Kalman y gradiente normalizado, disponibles en la caja de herramientas de identificación de sistemas de Matlab. Los órdenes de los modelos se variaron de 1 a 3 manteniéndolos homogéneos.

Las variables de entrada para los modelos ARX fueron las variables proporcionadas por el sistema IoT: T_a , RH y t_{ext} ; y como salida el contenido de humedad del producto (M_{wb}). Los valores de M_{wb} con intervalos de muestreo de un minuto usado en el modelo se obtuvieron mediante una interpolación lineal de los datos medidos cada 30 minutos. Las estadísticas de ajuste utilizadas para evaluar el desempeño de los modelos identificados fueron: el coeficiente de determinación (R^2), el error medio absoluto (MAE) y el error cuadrático medio (MSE) (Chicco, Warrens, & Jurman, 2021).

3.4 Discusión y análisis de resultados

3.4.1 Evolución de las variables ambientales

La radiación solar global durante las pruebas de secado realizadas se muestra en la Figura 3-7. Como puede observarse, en la mayoría de los días se tuvo presencia de nubes y lluvia por las tardes. En general, se obtuvieron picos máximos de radiación por arriba de los 1000 W m^{-2} , con un pico máximo de 1026.9 W m^{-2} , 1018.9 W m^{-2} y 1053.1 W m^{-2} en el primer día del experimento uno, segundo día del experimento dos y quinto día del tercer experimento, respectivamente.







Figura 3-7. Radiación solar global (R_g) durante los experimentos de secado de plátano dominico. (a) Experimento uno, (b) experimento dos y (c) experimento tres.

La temperatura en el interior del secador fluctuó debido a la variación en la radiación solar global; por las tardes, en donde hubo mayor nubosidad y presencia de lluvia se observa que la temperatura disminuyó drásticamente (Figura 3-8). Además, se observó que la temperatura del aire dentro de la cámara

de secado fue superior a la temperatura del aire del ambiente debido al efecto invernadero. En la Figura 3-8 se puede observar que la temperatura se mantuvo por debajo de los 50° la mayor parte del tiempo durante los experimentos, solo en algunos instantes el sistema de control no funcionó correctamente, por ello, se observan temperaturas superiores a los 50 °C. Para los días 20 y 21 de marzo, en donde no hubo presencia de nubosidad, la temperatura en el interior del secador alcanzó los 50° a las 9:30 h y esta comenzó a disminuir hasta las 17:30 h dando un total de 8 h efectivas de secado.








Figura 3-8. Temperatura en el interior (T_a) y exterior (T_{amb}) del secador solar durante el deshidratado de plátano. (a) Experimento uno, (b) experimento dos y (c) experimento tres.

En todos los experimentos, la humedad relativa dentro del secador fue menor a la humedad relativa del ambiente (Figura 3-9). Esto se debió principalmente a que la temperatura de secado fue mayor respecto a la temperatura ambiente. Esto confirma que la humedad relativa dentro del secador tiene potencial para un secado más rápido, en comparación con el secado natural a la intemperie, donde se obtendrá una baja velocidad de secado si se tiene una humedad relativa alta. Los resultados obtenidos en estos experimentos son similares a los reportados por Janjai, Intawee, Kaewkiew, Sritus, y Khamvongsa (2011), quienes deshidrataron plátano en un secador solar tipo invernadero de forma parabólica con cubierta de policarbonato.






Figura 3-9. Humedad relativa en el interior (RH) y exterior (RH_{amb}) del secador solar durante el deshidratado de plátano. (a) Experimento uno, (b) experimento dos y (c) experimento tres.

3.4.2 Contenido de humedad del plátano

La disminución del contenido de humedad de las muestras durante los experimentos fue similar y únicamente en el experimento tres se incrementó en un día el tiempo de secado, debido al aumento en la humedad relativa dentro del secador provocado por la infiltración de humedad debido a la lluvia (Figura 10). El contenido de humedad de los plátanos se redujo de un 70% a un 20% w.b., humedad que está dentro del estándar adoptado para el plátano seco de 20 a 25% (Batista, Cardoso, Godoy, & Evangelista-Barreto, 2014; Macedo *et al.*, 2019). Aumporn *et al.* (2021c) reportaron resultados similares durante el secado de plátano en 18 secadores tipo invernadero con control de la temperatura. Sin embargo, la pérdida del contenido de humedad fue menor a lo reportado por Aumporn *et al.* (2021a), quienes durante el deshidrato de plátano en un secador solar de uso doméstico redujeron su contenido de humedad inicial de 69% hasta

un contenido final de 13% w.b.




Figura 3-10. Variación del contenido de humedad del plátano dominico en el interior del sistema secador solar tipo invernadero. (a) Experimento uno, (b) experimento dos, (c) experimento tres.

3.4.3 Propiedades del plátano deshidratado

Los resultados de la medición del color del plátano se muestran en la Cuadro 3-3. Contenido de azúcar y variaciones de color del plátano dominico fresco y deshidratado.. El color del plátano fresco cambió de un color amarillo a rojo-amarillo después del proceso de secado. Los valores de los índices de color del plátano deshidratado indican que es color marrón dorado oscuro. Nabnean y

Nimnuan (2020) obtuvieron este mismo color en rodajas de plátano deshidratadas en un secador solar doméstico de convección forzada. El cambio de color promedio del plátano deshidratado para los tres experimentos fue 27.94, que indica que hay una diferencia apreciable en el plátano deshidratado respecto a las muestras frescas. Por otro lado, se observó un incremento en la concentración de azúcar en los tres experimentos, lo cual concuerda con lo obtenido por Ferreira y Freitas (2019) quienes reportaron un aumento en la concentración de azúcar del plátano deshidratado respecto a muestras frescas.

Cuadro 3-3. Contenido de azúcar y variaciones de color del plátano dominico fresco y deshidratado.

Experimento	Estado del plátano	Valor de color						Contenido de azúcar (°Brix)
		L^*	a^*	b^*	C^*	h	ΔE	
1	Fresco	76.23	3.41	30.56	30.74	83.63		9.00
	Deshidratado	55.56	4.32	15.42	16.01	74.35	25.63	10.49
2	Fresco	75.08	3.67	35.19	35.38	84.05		16.36
	Deshidratado	52.31	5.74	15.98	16.97	70.24	29.86	19.16
3	Fresco	74.96	2.93	32.40	32.53	84.83		14.02
	Deshidratado	52.10	5.49	15.85	16.77	70.90	28.33	25.99

3.4.4 Desempeño del sistema de monitoreo

Los datos de T_a y RH adquiridos continuamente por el sistema de monitoreo durante el proceso de secado se muestran de manera gráfica a través de la plataforma ThinSpeak. En la Figura 3-11 se muestra la interfaz móvil a través de la cual el usuario puede monitorear los datos del clima en el interior del secador; así mismo permite visualizar los datos en gráficas que se actualizan en línea (Figura 3-12). Estos resultados confirman que el sistema de monitoreo fue capaz de recopilar y mostrar las variables del clima interior a través de una computadora y un teléfono móvil conectados a Internet. Además, ThingSpeak generó una base de datos en Exel (.csv) que permite el análisis de la información después del experimento o en tiempo real al soportar código de Matlab. El protocolo de comunicación de LoRa permitió enviar los datos desde la ubicación del secador, donde no se cuenta con conexión a internet, a un sitio con acceso a una red de

internet localizada a 1.14 km de distancia. El sistema de monitoreo tiene la ventaja de funcionar con energía solar, por lo cual, puede ser instalado en sistemas de secado solar localizados en zonas remotas donde no se tenga acceso a una red eléctrica y sin acceso a internet.

Por otro lado, se obtuvieron valores de R^2 de 0.995 y 0.977 entre las mediciones de temperatura y humedad relativa con los sensores BME680 y las mediciones de los sensores HygroVUE 10 (datos no mostrados), lo que indica que las mediciones realizadas por los sensores del sistema IoT son confiables.





Figura 3-11. Interfaz móvil del sistema de monitoreo.






Figura 3-12. Visualización gráfica del comportamiento de (a) temperatura y (b) humedad del aire en la interfaz móvil.

3.4.5 Modelación del contenido de humedad del producto

En el Cuadro 3-4 se muestran para el experimento uno los mejores modelos ARX identificados en línea para predecir un paso hacia adelante el contenido de humedad del plátano durante su deshidratado. De acuerdo con la R^2 , MSE y MAE , el mejor modelo que predice el contenido de humedad en el producto es el identificado con el método de gradiente conjugado normalizado, con estructura: $na = 2$, $nb = [2 \ 2 \ 2]$ y $nk = [2 \ 2 \ 2]$. En la Figura 3-13 se muestra la evolución del contenido de humedad del plátano medido y predicho con el modelo ARX para los tres experimentos. Como se observa, el modelo identificado predice de manera precisa el comportamiento del contenido de humedad del producto durante los tres experimentos.

Cuadro 3-4. Mejores modelos ARX identificados en línea obtenidos para predecir el contenido de humedad del plátano durante el experimento uno.

Algoritmo de estimación	na	nb	nk	R^2	MSE	MAE
Factor de olvido $\lambda = 0.995$	2	2 2 2	2 2 2	0.99	2.16×10^{-5}	4.03×10^{-4}
Factor de olvido $\lambda = 0.99$	2	2 2 2	2 2 2	0.99	2.22×10^{-5}	-4.25×10^{-5}
Factor de olvido $\lambda = 0.99$	3	3 3 3	3 3 3	0.99	2.34×10^{-5}	-4.06×10^{-5}
Filtro de Kalman	2	2 2 2	2 2 2	0.99	1.33×10^{-5}	-2.83×10^{-5}
Filtro de Kalman	3	3 3 3	3 3 3	0.99	1.37×10^{-5}	-1.95×10^{-5}
Filtro de Kalman	1	1 1 1	1 1 1	0.99	1.08×10^{-4}	1.08×10^{-4}
Gradiente normalizado	2	2 2 2	2 2 2	0.99	1.29×10^{-5}	-5.03×10^{-6}
Gradiente normalizado	3	3 3 3	3 3 3	0.99	1.29×10^{-5}	-4.97×10^{-6}
Gradiente normalizado	1	1 1 1	1 1 1	0.99	9.02×10^{-2}	-3.15×10^{-3}

na : número de retrasos de la variable de salida. nb : número de retrasos para las variables de entrada. nk : retardo entre las variables de entrada y salida. R^2 : coeficiente de determinación. MSE : error cuadrático medio. MAE : error absoluto medio.






Figura 3-13. Contenido de humedad del plátano medido y predicho un paso hacia adelante con el modelo ARX. (a) Experimento uno, (b) experimento dos, (c) experimento tres.

El modelo identificado predice de manera precisa el contenido de humedad del producto en los experimentos dos y tres, de acuerdo con las estadísticas R^2 , MSE y MAE (Cuadro 3-5). El modelo ARX identificado en combinación con el sistema de monitoreo basado en IoT, permite realizar la predicción en línea del contenido de humedad del producto. Estos resultados concuerdan con los obtenidos por Aumporn *et al.* (2021a), quienes predijeron de forma adecuada el contenido de humedad de muestras de plátano con un modelo ARX en un secador solar de uso doméstico. Los modelos ARX también se han empleado para predecir de forma efectiva el contenido de humedad en láminas de caucho durante su deshidratado en un secador solar tipo invernadero (Aumporn *et al.*, 2021b).

Cuadro 3-5. Estadísticos de evaluación del modelo ARX identificado en línea para predecir el contenido de humedad del plátano.

Experimento	R^2	MSE	MAE
2	0.99	1.81×10^{-4}	-7.83×10^{-6}
3	0.99	3.24×10^{-5}	-4.78×10^{-6}

3.5 Conclusiones

El sistema de monitoreo apoyado en IoT permitió al usuario monitorear de forma remota el comportamiento de la temperatura y humedad relativa, a través de una interfaz web y móvil durante el proceso de secado de plátano en el interior de un sistema de secado solar tipo invernadero. La combinación del protocolo de comunicación de LoRa y la alimentación con energía solar permitió instalar el sistema de monitoreo en un secador solar localizado en un sitio sin acceso a internet. El plátano deshidratado obtuvo un color visualmente no atractivo (marrón dorado oscuro) y una mayor concentración de azúcar respecto al plátano fresco, su contenido de humedad estuvo en el rango comercial y se alcanzó en un tiempo similar a lo reportado en la literatura. El modelo ARX identificado en línea para predecir un paso hacia adelante el contenido de humedad del plátano durante su deshidratado fue de bajo orden y preciso de acuerdo con las estadísticas R^2 , MSE y MAE . Al ser un modelo que estima sus parámetros en

línea, no es necesario recalibrarlo periódicamente en cada proceso de deshidratado por las variaciones del sistema. Finalmente, a futuro se incluirá en el sistema una balanza electrónica para la medición del contenido de humedad del producto, mismo que será de utilidad para un manejo más eficiente del proceso de secado. El modelo ARX identificado en combinación con el sistema de monitoreo basado en IoT y la medición del peso del producto, permitirá la predicción en línea del contenido de humedad del producto.

3.6 Referencias

- Aumporn, O., Janjai, S., Khunkaeo, T., & Bala, B. K. (2021a). Development of a household scale solar dryer: Performance, evaluation and ARX modeling. *Journal of Renewable Energy and Smart Grid Technology*, 16(1), 1-11.
- Aumporn, O., Pankaew, P., Chanpen, N., & Janjai, S. (2021b). Experimental performance and Auto-Regressive with eXogenous Input (ARX) modelling of an anti-UV polycarbonate sheet-covered solar dryer equipped with a control system for drying para rubber sheets. *Journal of Renewable Energy and Smart Grid Technology*, 16(2), 68-80.
- Aumporn, O., Wattan, R., Pattarapanitchai, S., Sangsan, M., & Janjai, S. (2021c). Study of large-scale solar dryers equipped with monitoring and control systems for banana drying. *Journal of Renewable Energy and Smart Grid Technology*, 16(2), 1-16.
- Batista, D. d., Cardoso, R. L., Godoy, R. C., & Evangelista-Barreto, N. S. (2014). Stability physical-chemical and microbiological of organic dehydrated banana. *Ciência Rural*, 44(10), 1886-1892. doi: <http://dx.doi.org/10.1590/0103-8478cr20130442>
- Catania, P., Gaglio, R., Orlando, S., Settanni, L., & Vallone, M. (2020). Design and implementation of a smart system to control aromatic herb dehydration process. *Agriculture*, 10(8), 332. doi: <https://doi.org/10.3390/agriculture10080332>
- CEAGESP. (2006). PBMH & PIF – Programa Brasileiro para a Modernização da Horticultura & Produção Integrada de Frutas. (S. P. CEAGESP, Ed.) Recuperado el 18 de Junio de 2023, de Normas de Classificação de Banana N° 29: <https://ceagesp.gov.br/wp-content/uploads/2015/07/banana.pdf>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623.

- Erell, E., Leal, V., & Maldonado, E. (2005). Measurement of air temperature in the presence of a large radiant flux: An assessment of passively ventilated thermometer screens. *Boundary-Layer Meteorology*, 114, 205-231. doi: <https://doi.org/10.1007/s10546-004-8946-8>
- Ferreira, T. H., & Freitas, M. L. (2019). Production, physical, chemical and sensory evaluation of dried banana (*Musa Cavendish*). *Emirates Journal of Food and Agriculture*, 31(2), 102-108. doi:10.9755/ejfa.2019.v31.i2.1912
- Janjai, S., Intawee, P., Kaewkiew, J., Sritus, C., & Khamvongsa, V. (2011). A large-scale solar greenhouse dryer using polycarbonate cover: Modeling and testing in a tropical environment of Lao People's Democratic Republic. *Renewable Energy*, 36(3), 1053-1062. doi: <https://doi.org/10.1016/j.renene.2010.09.008>
- Khoozani, A. A., Birch, J., & Bekhit, A. E.-D. (2019). Production, application and health effects of banana pulp and peel flour in the food industry. *Journal of Food Science and Technology*, 56, 548-559. doi: <https://doi.org/10.1007/s13197-018-03562-z>
- López-Camelo, A. F., & Gómez, P. A. (2004). Comparison of color indexes for tomato ripening. *Horticultura Brasileira*, 22(3), 534-537. doi: <https://doi.org/10.1590/S0102-05362004000300006>
- Macedo, L. L., da Silva Araújo, C., Vimercati, W. C., Saraiva, S. H., & Teixeira, L. J. Q. (2019). Evaluation of different bleaching methods applied to yacon. *Journal of Food Process Engineering*, 42(7), e13276. doi: <https://doi.org/10.1111/jfpe.13276>
- Maroli, A., Narwane, V. S., & Gardas, B. B. (2021). Applications of IoT for achieving sustainability in agricultural sector: A comprehensive review. *Journal of Environmental Management*, 298, 113488. doi: <https://doi.org/10.1016/j.jenvman.2021.113488>
- Maskan, M. (2001). Kinetics of colour change of kiwifruits during hot air and microwave drying. *Journal of Food Engineering*, 48(2), 169-175. doi: [https://doi.org/10.1016/S0260-8774\(00\)00154-0](https://doi.org/10.1016/S0260-8774(00)00154-0)
- Montoya-Ríos, A. P., García-Mañas, F., Guzmán, J. L., & Rodríguez, F. (2020). Simple tuning rules for feedforward compensators applied to greenhouse daytime temperature control using natural ventilation. *Agronomy*, 10(9), 1327. doi:10.3390/agronomy10091327
- Nabnean, S., & Nimnuan, P. (2020). Experimental performance of direct forced convection household solar dryer for drying banana. *Case Studies in Thermal Engineering*, 22, 100787. doi: <https://doi.org/10.1016/j.cste.2020.100787>

<https://doi.org/10.1016/j.csite.2020.100787>

- Nimnuan, P., & Nabnean, S. (2022). Improvement of the Thepsatri Rajabhat-type household solar dryer. *Journal of Energy Systems*, 6(4), 573-582. doi:10.30521/jes.1148625
- Pankaew, P., Aumporn, O., Janjai, S., Mundpookhiew, T., & Bala, B. K. (2019). Performance of parabolic greenhouse solar dryer equipped with rice husk burning system for banana drying. *Journal of Renewable Energy and Smart Grid Technology*, 14(1), 52-65. Obtenido de <https://ph01.tci-thaijo.org/index.php/RAST/article/view/151682>
- Popa, A., Hnatiuc, M., Paun, M., Geman, O., Hemanth, D. J., Dorcea, D., . . . Ghita, S. (2019). An intelligent IoT-based food quality monitoring approach using low-cost sensors. *Symmetry*, 11(3), 374. doi: <https://doi.org/10.3390/sym11030374>
- Quy, V. K., Hau, N. V., Anh, D. V., Quy, N. N., Ban, N. T., Lanza, S., . . . Muzirafuti, A. (2022). IoT-Enabled Smart Agriculture: Architecture, Applications, and Challenges. *Applied Sciences*, 12(7), 3396. doi: <https://doi.org/10.3390/app12073396>
- Raj, M., Gupta, S., Chamola, V., Elhence, A., Garg, T., Atiquzzaman, M., & Niyato, D. (2021). A survey on the role of Internet of Things for adopting and promoting Agriculture 4.0. *Journal of Network and Computer Applications*, 157, 103107. doi: <https://doi.org/10.1016/j.jnca.2021.103107>
- Rehman, A., Saba, T., Kashif, M., Fati, S. M., Bahaj, S. A., & Chaudhry, H. (2022). A Revisit of Internet of Things Technologies for Monitoring and Control Strategies in Smart Agriculture. *Agronomy*, 12(1), 127. doi: <https://doi.org/10.3390/agronomy12010127>
- Seyedabadi, E., Khojastehpour, M., & Abbaspour-Fard, M. H. (2017). Convective drying simulation of banana slabs considering non-isotropic shrinkage using FEM with the arbitrary Lagrangian–Eulerian method. *International Journal of Food Properties*, 20(sup1), S36–S49. doi: <https://doi.org/10.1080/10942912.2017.1288134>
- Sidhu, J. S., & Zafar, T. A. (2018). Bioactive compounds in banana fruits and their health benefits. *Food Quality and Safety*, 2(4), 183–188. doi:10.1093/fqsafe/fyy019
- Vimercati, W. C., da Silva Araújo, C., Macedo, L. L., Fonseca, H. C., Guimarães, J. S., de Abreu, L. R., & Pinto, S. M. (2020). Physicochemical, rheological, microbiological and sensory properties of newly developed coffee flavored kefir. *LWT*, 123, 109069. doi: <https://doi.org/10.1016/j.lwt.2020.109069>

4 PREDICCIÓN MEDIANTE MODELOS AUTORREGRESIVOS DE LA TEMPERATURA DEL AIRE Y EL CONTENIDO DE HUMEDAD DE PLÁTANO DURANTE EL DESHIDRATADO

4.1 Resumen

El objetivo de esta investigación fue aplicar la metodología de identificación de sistemas para obtener modelos autorregresivos con entradas exógenas (ARX) y redes autorregresivas no lineales con entradas exógenas (NARX). para predecir un paso hacia adelante la temperatura del aire (T_a) y contenido de humedad de plátano dominico (M_{wb}) durante el deshidratado en un secador solar tipo invernadero. Para la T_a se utilizaron como entradas variables medidas en el exterior del secador y para M_{wb} se consideraron dos casos: 1) entradas medidas en el exterior y 2) entradas medidas en el interior. Con base en el error de predicción final de Akaike, el criterio de información de Akaike normalizado y el porcentaje de ajuste para T_a , el mejor modelo se obtuvo al utilizar como variables de entrada a la temperatura y humedad relativa del aire exterior. Para M_{wb} en el primer caso el mejor modelo se obtuvo al utilizar como entradas al déficit de presión de vapor y velocidad del viento exterior y para el segundo caso el déficit de presión de vapor y la temperatura del piso interior. Los modelos ARX y NARX evaluados tuvieron una precisión en predicción con un paso hacia adelante mayor del 90% de ajuste entre lo predicho y lo medido. Cuando a los modelos obtenidos se agrega como entrada la señal de tiempo de encendido y apagado de los extractores (t_{ext}), el porcentaje de ajuste no mejora, aun así, es necesario considerar como entrada el t_{ext} pues los extractores son los actuadores que se usarán en el controlador automático para regular la T_a . Los modelos obtenidos predicen de manera satisfactoria la T_a y el M_{wb} , y se pueden utilizar para el diseño de un controlador automático para el control y manejo del proceso de secado de plátano dominico.

Palabras clave: *Musa paradisiaca* variedad *sapientum*, modelos autorregresivos, secado solar, identificación de sistemas.

4.2 Introducción

Las técnicas de deshidratado de los productos agrícolas se han fomentado con la finalidad de reducir las pérdidas poscosecha, facilitar el almacenamiento y transporte, así como asegurar la disponibilidad (Hasan *et al.*, 2019). El secado solar a la intemperie es el método más antiguo que se ha utilizado para este propósito (Pragati & Preeti, 2014). Los principales inconvenientes de este método son el largo tiempo de secado, la dependencia del clima y la contaminación por polvo, lluvia, viento, plagas y roedores (El Hage, Herez, Ramadan, Bazzi, & Khaled, 2018; Singh, Shrivastava, & Kumar, 2018), lo que genera productos de mala calidad y una pérdida de ingresos a los agricultores.

Los secadores solares tipo invernadero permiten superar estos problemas (Hamdi *et al.*, 2018; Azaizia, Kooli, Elkhadraoui, Hamdi, & Guizani, 2017), y se han vuelto populares debido al uso de energía renovable, la capacidad de control, el tamaño, la reducción de la contaminación del producto y la posibilidad del uso en ubicaciones remotas (Tiwari, 2016; Patil & Gawande, 2016). En la actualidad, se espera que las técnicas de secado aporten ventajas como mayor eficiencia energética, mejor calidad del producto, reducción de costos y menor impacto ambiental (Calín-Sánchez *et al.*, 2020). Por lo cual, los sistemas de secado solar deben diseñarse de forma adecuada para cumplir con los requisitos particulares de secado de los productos agrícolas y para brindar un rendimiento óptimo. Según Nemzer, Vargas, Xia, Sintara y Feng (2018), la eficiencia energética, la calidad de los alimentos y el tiempo de secado son los principales parámetros que deben optimizarse en los sistemas de secado.

El modelado matemático es una herramienta útil para optimizar los parámetros de secado y mejorar el rendimiento de los sistemas de secado en varios modos de operación (Chauhan, Kumar, & Gupta, 2017). Por esto, se necesitan modelos matemáticos que ayuden a comprender el proceso de secado y mejorar la calidad de los productos secos. Sin embargo, el secado es un proceso complejo, no lineal y dinámico (Sun, Zhang, Mujumdar, & Yang, 2019), durante el cual el contenido de humedad es difícil medir en tiempo real debido a la baja confiabilidad de los

dispositivos de medición, así como a la consideración de los problemas de higiene del producto alimenticio. Por estos factores, la temperatura de secado ha sido ampliamente seleccionada para ser estudiada, ya que se correlaciona directamente con el contenido de humedad de los productos (Maas *et al.*, 2011). Debido a estas correlaciones presentes en las variables medidas, existe la posibilidad de utilizar modelos de secado con componentes autorregresivos para capturar mejor los comportamientos dinámicos (Pilario, Ching, Calapatia, & Culaba, 2022).

Los modelos autorregresivos con entradas exógenas (ARX) y los modelos autorregresivos no lineales con entradas exógenas (NARX), pueden construirse a través de relaciones de datos experimentales mediante técnicas de identificación de parámetros y han demostrado ser adecuados para predecir el contenido de humedad (Aumporn, Janjai, Khunkaeo, & Bala, 2021a; Aumporn, Pankaew, Chanpen, & Janjai, 2021b; Zhou *et al.*, 2018; Li & Chen, 2020; Abdullah, Taip, Kamal, & Rahman, 2020) y la temperatura del aire (Castañeda-Miranda & Castaño, 2017; Montoya-Ríos, García-Mañas, Guzmán, & Rodríguez, 2020; Gao, *et al.*, 2023; Jung, Kim, Jhin, Kim, & Park, 2020) en sistemas de secado e invernaderos. Por lo anterior, el objetivo de este estudio fue modelar mediante modelos ARX y NARX la temperatura del aire y contenido de humedad de plátano durante su secado en un secador solar tipo invernadero. El propósito del modelo para temperatura es que sirva de base para el diseño de un controlador de la temperatura y del modelo de humedad para el manejo del proceso de deshidratado de plátano.

4.3 Materiales y métodos

Los experimentos de secado se llevaron a cabo en un secador solar tipo invernadero de forma parabólica con dimensiones de 10 x 9 m de base y 3.5 m de altura (Figura 4-1a). El sistema está construido de acero galvanizado, cuenta con piso de concreto reforzado, cubierta de policarbonato de doble pared de 0.006 m de espesor y con protección contra rayos UV. En la parte frontal cuenta con dos entradas de aire cada una con 0.3 x 1.5 m y en la pared trasera tiene

instalados dos extractores con capacidad de $9,435 \text{ m}^3 \text{ h}^{-1}$ cada uno, accionados mediante motores monofásicos de 0.5 HP (373 W), empleados para controlar el flujo de aire en el interior del secador.

4.3.1 Experimentos de deshidratado con producto

Se realizaron tres experimentos de secado de plátano dominico (Figura 4-1b), los días 11, 18 y 26 de marzo de 2023 comenzando a las 07:00 h y concluyendo cuando el producto alcanzo un peso constante. En todos los casos se introdujeron 150 kg de producto al secador, los frutos de plátano se colocaron como una capa fina sobre las mesas de secado y la temperatura del aire dentro del secador se configuró para que no superara los 50°C , que es la temperatura recomendada para el secado de plátano (Nimnuan & Nabnean, 2022). Los experimentos se realizaron con la finalidad de obtener datos para modelar el contenido de humedad de los plátanos y la temperatura del aire en el interior del secador mediante modelos ARX y NARX.




Figura 4-1. a) Secador solar parabólico tipo invernadero y b) deshidratado de plátano dominico.

4.3.2 Mediciones y sistema de registro de datos

Las variables climáticas en el interior del secador fueron medidas como se describe a continuación (Figura 4-2). La temperatura T_a ($^\circ\text{C}$) y humedad relativa RH (%) con sensores bme680 (Bosch Sensortec, precisión $\pm 1^\circ\text{C}$ y $\pm 3\%$, rango de -40° a $+85^\circ\text{C}$ y de 0 a 100%) colocados por arriba de las muestras y protegidos de la radiación solar mediante tubos horizontales de 0.5 m de longitud recubiertos

de aluminio (Erell, Leal, & Maldonado, 2005). La temperatura del suelo T_f ($^{\circ}\text{C}$) se midió con termopares tipo T (Onset Computer, EE. UU.; precisión $\pm 0.6^{\circ}\text{C}$, resolución 0.022°C , y rango de -260° a 400°C). La radiación solar global R_g (W m^{-2}), la temperatura T_{amb} ($^{\circ}\text{C}$), humedad relativa RH_{amb} (%), velocidad W_s (m s^{-1}) y dirección del viento W_d ($^{\circ}$) en ambiente exterior se registraron cada minuto con una estación meteorológica HOBO U30 (Onset Computer Corporation, EE. UU.). El tiempo de encendido y apagado de los extractores (t_{ext} , señal de control) se registró cada 5 segundos, el cual fue procesado para obtener una señal en porcentaje de encendido y apagado de los extractores por minuto.




Figura 4-2. Distribución de los sensores de medición para la temperatura del suelo (T_f), temperatura (T_a) y humedad del aire (RH) dentro del secador, muestras del producto (M), señal de encendido y apagado de los extractores (t_{ext}), temperatura (T_{amb}) y humedad del aire (RH_{amb}), velocidad (W_s) y dirección del viento (W_d) del clima exterior.

La pérdida de peso del producto en el tiempo se registró en cuatro muestras en el secador (M_1 , M_2 , M_3 , M_4) (Figura 4-2), que se pesaron en intervalos de 0.5 h

utilizando una balanza digital VE-1000 con una precisión de ± 0.01 g (Microscopios VELAB). Los experimentos comenzaron con el registro del peso inicial de cada una de las muestras. Al finalizar, el porcentaje de materia seca en las muestras se determinó mediante el método de la estufa, el cual consiste en deshidratar la muestra a 105°C durante 24 h.

El contenido de humedad en base húmeda M_{wb} (%) durante el proceso de secado, se determinó a partir del peso de las muestras en el tiempo y la materia seca final con la siguiente ecuación:

$$\% M_{wb} = \left(\frac{W_0 - W_d}{W_0} \right) \cdot 100 \quad (1)$$

donde W_0 es el peso de la muestra húmeda (kg) y W_d es el peso de la muestra seca (kg).

4.3.3 Estructura de los modelos autorregresivos con entradas exógenas

Los modelos autorregresivos con entrada externa (ARX) son una familia de modelos matemáticos comúnmente usados para describir sistemas dinámicos. Un modelo ARX de entrada y salida única (SISO) se describe mediante la siguiente ecuación (Keesman, 2011; Ljung, 1998).

$$A(q)y(t) = B(q)u(t - nk) + e(t) \quad (2)$$

donde q representa al operador de retraso y $A(q)$ y $B(q)$ son los polinomios que representan la dinámica general del sistema y se definen como:

$$A(q) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na} \quad (3)$$

$$B(q) = b_1 + b_2q^{-1} + \dots + b_{nb}q^{-nb+1} \quad (4)$$

Los modelos para predecir la T_a y el M_{wb} con precisión requieren más de una entrada, por lo que se debe ajustar un modelo ARX SISO en un modelo ARX de entradas múltiples y salida única (MISO). Para modelos ARX MISO con nu entradas, nb y nk son vectores fila donde el i -ésimo elemento corresponde al

orden y retraso asociados con la i -ésima entrada del vector de columna $u(t)$. De manera similar, los coeficientes del polinomio B son vectores fila. La estructura ARX MISO viene dada por la siguiente ecuación:

$$A(q)y(t) = B_1(q)u_1(t - nk_1) + B_2(q)u_2(t - nk_2) + \dots + B_{nu}(q)u_{nu}(t - nk_{nu}) \quad (5)$$

La red autorregresiva no lineal con entradas exógenas (NARX) es una red dinámica recurrente, con conexiones de retroalimentación que incluyen varias capas de la red. El modelo NARX se basa en el modelo lineal ARX y está dado por la ecuación (6):

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) + e(t) \quad (6)$$

donde y es la señal de salida, u es la señal de entrada, n_u y n_y son el número de entradas y salidas retardadas, f función de mapeo no lineal, y $e(t)$ es el error de predicción en el tiempo t .

En la arquitectura estándar de la red NARX (en paralelo) la salida se retroalimenta a la entrada de la red neuronal de manera directa, por tanto, la salida predicha está dada por:

$$\hat{y}(t+1) = f(\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-n_y), u(t), u(t-1), \dots, u(t-n_u)) \quad (7)$$

donde $\hat{y}$ es la salida predicha por la red NARX.

En este estudio debido a que la salida real estaba disponible durante el entrenamiento de la red, se creó una arquitectura NARX serie-paralelo (ecuación 9), en la que se usa la salida medida en lugar de realimentar con la salida predicha:

$$\hat{y}(t+1) = f(y(t), y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)) \quad \dots\dots(8)$$

4.3.4 Selección de las variables de entrada

Las variables de entrada a los modelos ARX se seleccionaron para dos casos: 1) modelo con variables ambientales externas como entradas, 2) modelo con variables ambientales internas como entradas; en ambos casos, 50% de los datos experimentales se usaron para estimación y 50% para validación. Para elegir las variables de entrada a los modelos del caso 1) se hicieron combinaciones de dos variables de un total de cinco variables: T_{amb} , RH_{amb} , R_g , W_s , VPD_{amb} (déficit de presión de vapor del ambiente exterior), con la finalidad de obtener un modelo simple para predecir la temperatura del aire (T_a) y el contenido de humedad de los plátanos (M_{wb}) mediante condiciones ambientales externas. Para el caso 2) se buscó generar un modelo simple para la predicción del M_{wb} con variables medidas dentro del secador: T_a , T_f , RH , VPD (Déficit de presión de vapor en el interior del secador). En ambos casos, a la mejor combinación de variables de entrada obtenida se le agrego otra de las variables restantes, con la finalidad de mejorar la predicción del modelo. Finalmente, en ambos casos para la T_a se usó como entrada para los modelos la combinación de variables con la que se obtuvo mejor porcentaje de ajuste de predicción, agregando la variable de control (t_{ext}). Se usaron las mismas combinaciones de variables de entrada de los modelos ARX a las redes NARX, con la finalidad comparar la calidad de predicción.

4.3.5 Identificación y construcción de los modelos autorregresivos

Para estimar y validar los modelos ARX los conjuntos de datos fueron divididos 50%:50%, 60%:40%, 70%:30%, 80%:20%, 90%:10%, para estimación y validación, respectivamente. Se utilizó la caja de herramientas de identificación de sistemas (System Identification Toolbox) de Matlab para estimar y evaluar la estructura de los modelos. La selección de la estructura se realizó siguiendo la metodología de la guía de usuario del Toolbox, la cual consiste en los siguientes pasos:

Paso 1. Determinación de los retardos o tiempos muertos (nk), para cada una de las variables de entrada.

Paso 2. Búsqueda del número de pasos de tiempo de la salida (na) y de la entrada (nb), con una variación de 1 a 10 pasos.

Paso 3. Elección de la mejor estructura mediante el criterio de información de Akaike (AIC), el criterio de longitud mínima de descripción de Rissanen (MDL) y el error cuadrático medio normalizado (NRMSE).

$$AIC = \log(V) + \frac{2 \cdot d}{N}, N \gg d \quad (9)$$

$$MDL = V \left(1 + \frac{d \cdot \log(N)}{N} \right) \quad (10)$$

$$NRMSE = 100 \cdot \left(1 - \frac{\|Y_i - \hat{Y}_i\|}{\|Y_i - \bar{Y}_i\|} \right) \quad (11)$$

donde V es la función de pérdida, d es el número total de parámetros en la estructura en cuestión, N es el número de puntos de datos utilizados para la estimación, Y_i es el valor medido, $\hat{Y}_i$ es el valor simulado, $\bar{Y}_i$ es la media de los datos y $\|\cdot\|$ indica la norma dos de un vector.

Paso 4. Evaluación de los modelos mediante el error de predicción final de Akaike (FPE), el criterio de información de Akaike normalizado (nAIC), el porcentaje de ajuste en estimación y validación (NRMSE), así como el análisis residual para evaluar la calidad predictiva del modelo.

$$FPE = \det \left(\frac{1}{N} E^T E \right) \left(\frac{1 + \frac{n_p}{N}}{1 - \frac{n_p}{N}} \right) \quad (12)$$

$$nAIC = \log \left(\det \left(\frac{1}{N} E^T E \right) \right) + \frac{2 \cdot n_p}{N} \quad (13)$$

donde n_p es el número de parámetros libres en el modelo, N es el número de muestras en el conjunto de datos de estimación, E es la matriz $N \times n_y$ de errores de predicción, n_y es el número de canales de salida.

Para construir las redes NARX, debido a que se tenían disponibles las salidas (T_a y M_{wb}) se usó una arquitectura en serie-paralelo con el conjunto de datos normalizado y dividido en 50%:50%, 60%:40%, 70%:30%, 80%:20%, 90%:10%, para entrenamiento y evaluación. Se buscaba desarrollar un modelo apropiado, sin sobre ajuste, junto con un bajo consumo computacional. Por ello, para determinar la estructura óptima de las redes, se realizaron una serie de pruebas de optimización: Se varió el número de retardos en las entradas y salidas (1 a 10 retrasos) y el número de neuronas en la capa oculta usando como límite inferior la regla de la pirámide geométrica y límite superior el teorema de Kolmogorov, considerando los cambios en los coeficientes de eficiencia (ecuación 14) y error medio absoluto (ecuación 15) continuamente observados hasta determinar el número óptimo de neuronas. Lo anterior se realizó utilizando el método de método Levenberg-Marquardt que tuvo un mejor desempeño respecto a la regularización bayesiana, el gradiente descendente y el gradiente descendente con momento. Finalmente, con la topología de red seleccionada se realizaron 150 entrenamientos mejorando la eficiencia (ecuación 14) en cada iteración.

Las estadísticas de ajuste utilizadas para evaluar el desempeño de las redes NARX fueron: la eficiencia (EF), el error medio absoluto (MAE) y NRMSE (ecuación 11).

$$EF = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (14)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - \hat{Y}_i| \quad (15)$$

donde Y_i es el valor medido, $\hat{Y}_i$ es el valor simulado, $\bar{Y}$ es la media de los datos y N es el número de mediciones.

4.4 Resultados y discusión

4.4.1 Variables de entrada a los modelos

En el Cuadro 4-1 y Cuadro 4-2 se muestran los resultados obtenidos al evaluar las parejas de variables de entrada medidas en el exterior e interior del secador, respectivamente.

Cuadro 4-1. Mejores modelos ARX obtenidos para predecir la T_a un paso hacia adelante con 50% de información para estimación y 50% para validación.

Variables de entrada	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)
<i>Caso 1: Variables de entrada medidas en el exterior</i>							
$T_{amb}: RH_{amb}$	9	5 2	0 0	0.0458	-3.0818	98.35	98.27
$T_{amb}: R_g$	9	4 1	0 0	0.0476	-3.0438	98.31	98.26
$R_g: VPD_{amb}$	9	1 5	0 0	0.0535	-2.9272	98.21	97.89
$R_g: W_s$	9	2 1	0 6	0.0591	-2.826	98.12	97.69
$T_{amb}: RH_{amb}: R_g$	9	4 3 2	1 0 0	0.0488	-3.0192	98.30	98.06
$T_{amb}: RH_{amb}: W_s$	10	5 2 3	0 0 0	0.0439	-3.1248	98.39	98.29

na : número de retrasos de la variable de salida, nb : número de retrasos en las variables de entrada, nk : retardo entre las variables de entrada y salida, FPE: error de predicción final de Akaike, AICn: Criterio de información de Akaike.

Cuadro 4-2. Mejores modelos ARX obtenidos para predecir el M_{wb} un paso hacia adelante con 50% de información para estimación y 50% para validación.

Variables de entrada	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)
<i>Caso 1: Variables de entrada medidas en el exterior</i>							
$T_{amb}: W_s$	2	3 3	0 1	0.2086	-1.5673	96.48	97.40
$T_{amb}: R_g$	2	3 2	0 1	0.2098	-1.5615	96.47	97.37
$VPD_{amb}: W_s$	1	2 3	0 0	0.2432	-1.4138	96.20	96.34
<i>Caso 2: Variables de entrada medidas en el interior</i>							
$RH: T_f$	9	10 9	0 0	0.1089	-2.2173	97.47	97.44
$T_a: RH$	8	5 10	1 0	0.0980	-2.3231	97.60	97.53
$VPD: T_f$	2	4 9	0 0	0.2767	-1.2849	95.96	95.90

El mejor modelo para predecir la T_a con base en la predicción final de Akaike, el criterio de información de Akaike normalizado y el porcentaje de ajuste, se obtiene al utilizar como variables de entrada a la T_{amb} y RH_{amb} (Cuadro 4-1),

mientras que la combinación: T_{amb} y R_g muestra un grado de ajuste similar (0.01 % menos de ajuste). Al agregar otra variable a la combinación T_{amb} y RH_{amb} la calidad predictiva no aumenta significativamente (0.02% más de ajuste al añadir a la R_g) (Cuadro 4-1).

Para predecir el M_{wb} en el caso de los modelos con variables de entrada medidas en el exterior, con base a los índices de evaluación FPE y AICn, el mejor modelo se obtiene al utilizar como variables de entrada el VPD_{amb} y la W_s . El porcentaje de ajuste fue mayor usando otras combinaciones de variables como: la T_{amb} y la W_s o la T_{amb} y la R_g ; sin embargo, estas no cumplieron con el análisis residual (datos no mostrados). Para el caso de los modelos con variables de entrada medidas en el interior, se encontró que usando como entradas el VPD y la T_f se obtiene el mejor porcentaje de ajuste y los valores mínimos del FPE y AICn (Cuadro 4-2).

4.4.2 Mejores modelos autorregresivos con entradas exógenas

En el Cuadro 4-3 se muestran los resultados de los modelos obtenidos con los diferentes conjuntos de datos para estimación y validación, para predecir la T_a usando como entradas la T_{amb} y la RH_{amb} . Para el caso de la predicción del M_{wb} en los Cuadros Cuadro 4-4 y Cuadro 4-5 se muestran las predicciones mediante variables externas ($marx_{out}$) e internas ($marx_{in}$), respectivamente.

Cuadro 4-3. Modelos ARX obtenidos para predecir la T_a con la T_{amb} y la RH_{amb} como variables de entrada, para diferentes proporciones de datos para estimación y validación.

Criterio	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)	Conjunto de datos
NRMSE	10	10 9	0 0	0.0454	-3.0917	98.35	98.27	50%:50%
AIC	9	10 2	0 0	0.0457	-3.0853	98.35	98.27	
MDL	9	5 2	0 0	0.0459	-3.0818	98.35	98.27	
NRMSE	10	10 2	0 0	0.0518	-2.9604	98.26	98.37	60%:40%
AIC	10	10 2	0 0	0.0518	-2.9604	98.26	98.37	
MDL	9	10 2	0 0	0.0518	-2.9606	98.26	98.37	
NRMSE	9	9 3	0 1	0.0529	-2.9401	98.24	98.49	70%:30%

Criterio	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)	Conjunto de datos
AIC	9	5 3	0 1	0.0530	-2.9365	98.24	98.49	80%:20%
MDL	9	4 3	0 1	0.0530	-2.9367	98.24	98.49	
NRMSE	9	9 3	0 1	0.0510	-2.9758	98.26	98.57	
AIC	9	8 3	0 1	0.0511	-2.9748	98.26	98.57	
MDL	9	5 3	0 1	0.0512	-2.9726	98.26	98.57	
NRMSE	9	8 2	0 1	0.0501	-2.9928	98.28	98.71	
AIC	9	5 2	0 1	0.0503	-2.9904	98.58	98.70	90%:10%
MDL	9	4 2	0 1	0.0503	-2.9896	98.28	98.70	

Cuadro 4-4. Modelos ARX obtenidos para predecir el M_{wb} con VPD_{amb} y W_s como variables de entrada ($marx_{out}$), para diferentes proporciones de datos para estimación y validación.

Criterio	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)	Conjunto de datos
NRMSE	1	2 9	0 0	0.2433	-1.4134	96.21	96.35	50%:50%
AIC	1	2 6	0 0	0.2432	-1.4138	96.21	96.35	
MDL	1	2 3	0 0	0.2432	-1.4138	96.20	96.34	
NRMSE	10	10 10	0 0	0.2096	-1.5624	96.84	96.05	60%:40%
AIC	1	2 9	0 0	0.2096	-1.5622	96.84	96.04	
MDL	1	2 3	0 0	0.2096	-1.5624	96.83	96.03	
NRMSE	10	1 1	0 1	0.4456	-0.8082	95.44	96.88	70%:30%
AIC	1	1 1	0 1	0.4442	-0.8113	95.44	99.88	
MDL	1	1 1	0 1	0.4442	-0.8113	95.44	99.88	
NRMSE	10	1 1	0 1	0.3897	-0.9421	95.5	99.73	80%:20%
AIC	1	1 1	0 1	0.3887	-0.9449	95.5	99.73	
MDL	1	1 1	0 1	0.3887	-0.9449	95.5	99.73	
NRMSE	10	1 1	0 1	0.3463	-1.0603	95.75	99.50	90%:10%
AIC	1	1 1	0 1	0.3454	-1.0627	95.75	99.49	
MDL	1	1 1	0 1	0.3454	-1.0627	95.75	99.49	

Cuadro 4-5. Modelos ARX obtenidos para predecir el M_{wb} con VPD y T_f como variables de entrada ($marx_{in}$), para diferentes proporciones de datos para estimación y validación.

Criterio	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)	Conjunto de datos
NRMSE	9	10 10	0 0	0.2766	1.28×10^4	95.97	95.91	50%:50%
AIC	3	8 9	0 0	0.2761	1.28×10^4	95.96	95.91	
MDL	2	4 9	0 0	0.2767	1.28×10^4	95.96	95.90	
NRMSE	9	10 9	0 0	0.2352	1.37×10^4	96.65	95.51	60%:40%

Criterio	na	nb	nk	FPE	nAIC	Ajuste en entrenamiento (%)	Ajuste en validación (%)	Conjunto de datos
AIC	3	8 9	0 0	0.2349	1.37×10^4	96.65	95.50	
MDL	3	4 9	0 0	0.2352	1.37×10^4	96.65	95.50	
NRMSE	1	1 1	0 0	0.4438	2.34×10^4	95.44	99.60	
AIC	1	1 1	0 0	0.4438	2.34×10^4	95.44	99.60	70%:30%
MDL	1	1 1	0 0	0.4438	2.34×10^4	95.44	99.60	
NRMSE	1	1 1	0 0	0.3884	2.49×10^4	95.50	99.00	
AIC	1	1 1	0 0	0.3884	2.49×10^4	95.50	99.00	80%:20%
MDL	1	1 1	0 0	0.3884	2.49×10^4	95.50	99.00	
NRMSE	1	1 1	0 0	0.3452	2.63×10^4	95.75	98.47	
AIC	1	1 1	0 0	0.3452	2.63×10^4	95.75	98.47	90%:10%
MDL	1	1 1	0 0	0.3452	2.63×10^4	95.75	98.47	

Para obtener el mejor modelo que prediga la T_a y el M_{wb} , se empleó un procedimiento de validación cruzada, que sirve para elegir el modelo que tenga el mejor ajuste, que cumpla con la verificación de los residuales y que además sea de bajo orden (Rivas-Pérez, Feliú-Batlle, & Salcedo-Hernández, 2021). Analizando los modelos obtenidos para predecir la T_a con los diferentes conjuntos de datos, la mayoría presentó un nivel de ajuste bueno que vario del 98.27% al 98.71% en validación. Por otro lado, los valores de FPE y AICn calculados son similares (Cuadro 4-3) y basándonos en la prueba de residuos los modelos que presentaron menor sobreajuste son los obtenidos con el conjunto de datos de 50%:50% (resultados no mostrados). De acuerdo con la teoría de control un modelo con una estructura simple en cuanto al orden es preferible a uno con una estructura compleja (Ljung, 1998), esto debido a que el comportamiento con respecto a un modelo de orden superior es similar y por consecuente se facilita el proceso de diseño de un sistema de control.

Por lo tanto, el mejor modelo ARX para predecir la T_a encontrado en esta investigación basándonos en la teoría de control, con variables de entrada T_{amb} y RH_{amb} tiene la estructura $na = 9$, $nb = [8 \ 2]$, $nk = [0 \ 0]$, que se presenta en la siguiente ecuación:

$$A(z)y(t) = B(z)u(t) + e(t) \quad (16)$$

donde:

$$A(z) = 1 - 1.929 z^{-1} + 1.414 z^{-2} - 0.4579 z^{-3} + 0.002276 z^{-4} - 0.008576 z^{-5} - 0.1369 z^{-6} + 0.03625 z^{-7} + 0.1697 z^{-8} - 0.09085 z^{-9} \quad (17)$$

$$B_1(z) = 0.6237 - 1.432 z^{-1} + 1.297 z^{-2} - 0.5409 z^{-3} + 0.04772 z^{-4} \quad (18)$$

$$B_2(z) = -0.0676 + 0.06805 z^{-1} \quad (19)$$

Las mejores estructuras de los modelos ARX para predecir M_{wb} se obtuvieron con el conjunto de datos 60%:40%, tanto para los modelos con variables de entrada VPD_{amb} y W_s medidas en el exterior ($na = 1$, $nb = [2 \ 3]$, $nk = [0 \ 0]$) como con entradas VPD y T_f medidas en el interior ($na = 3$, $nb = [4 \ 1]$, $nk = [0 \ 0]$) del secador. El modelo con variables de entrada medidas en el exterior es el siguiente,

$$A(z) = 1 - z^{-1} \quad (20)$$

$$B_1(z) = -0.01024 + 0.01027 z^{-1} \quad (21)$$

$$B_2(z) = 0.03113 - 0.06867 z^{-1} + 0.01393 z^{-2} \quad (22)$$

mientras que el modelo con variables de entrada medidas en el interior es el siguiente,

$$A(z) = 1 - 1.032 z^{-1} + 0.05277 z^{-2} - 0.02108 z^{-3} \quad (23)$$

$$B_1(z) = -0.0007393 + 0.001467 z^{-1} - 0.001212 z^{-2} + 0.0004847 z^{-3} \quad (24)$$

$$B_2(z) = -0.0007105 + 0.001442 z^{-1} - 0.00122 z^{-2} + 0.0004867 z^{-3} \quad (25)$$

Cuando al mejor modelo ARX obtenido anteriormente para predecir la T_a se incluye como variable de entrada a la señal de control, con base en el error de predicción final de Akaike, el criterio de información de Akaike normalizado y el porcentaje de ajuste (resultados no mostrados), el mejor modelo se obtiene con el conjunto de datos 50%: 50% con estructura $na = 9$, $nb = [5 \ 2 \ 10]$ y $nk =$

$[0 \ 0 \ 0]$, donde sus entradas son T_{amb} , RH_{qmb} y t_{ext} y sus coeficientes estimados son:

$$A(z) = 1 - 1.909 z^{-1} + 1.386 z^{-2} - 0.4583 z^{-3} - 0.005349 z^{-4} + 0.01039 z^{-5} - 0.1443 z^{-6} + 0.03726 z^{-7} + 0.1737 z^{-8} - 0.09117 z^{-9} \quad (26)$$

$$B_1(z) = 0.6221 - 1.424 z^{-1} + 1.291 z^{-2} - 0.5433 z^{-3} + 0.05051 z^{-4} \quad (27)$$

$$B_2(z) = -0.06713 + 0.06756 z^{-1} \quad (28)$$

$$B_3(z) = -0.2344 + 0.1062 z^{-1} + 0.002199 z^{-2} + 0.06995 z^{-3} - 0.0124 z^{-4} + 0.008965 z^{-5} + 0.06348 z^{-6} + 0.03512 z^{-7} - 0.001641 z^{-8} - 0.03721 z^{-9} \quad (29)$$

De igual forma, cuando a los dos mejores modelos ARX obtenidos anteriormente se incluye como variable de entrada a la señal de control, para predecir el M_{wb} mediante variables medidas en el exterior (VPD_{amb} , W_s y t_{ext}) y dentro del secador (VPD , T_f y t_{ext}) los mejores modelos tienen la estructura : $na = 1$, $nb = [2 \ 3 \ 1]$, $nk = [0 \ 0 \ 9]$ y $na = 3$, $nb = [4 \ 1 \ 1]$, $nk = [0 \ 0 \ 0]$, respectivamente; estimados con el conjunto de datos 60%:40%. Los coeficientes del modelo con entradas medidas en el exterior son:

$$A(z) = 1 - z^{-1} \quad (30)$$

$$B_1(z) = -0.01028 + 0.01029 z^{-1} \quad (31)$$

$$B_2(z) = 0.03124 - 0.06874 z^{-1} + 0.01415 z^{-2} \quad (32)$$

$$B_3(z) = 0.03613 z^{-9} \quad (33)$$

mientras que para el modelo con entradas medidas en el interior son:

$$A(z) = 1 - 1.031 z^{-1} + 0.05254 z^{-2} - 0.02099 z^{-3} \quad (34)$$

$$B_1(z) = -0.0007407 + 0.00147 z^{-1} - 0.001214 z^{-2} + 0.0004866 z^{-3} \quad (35)$$

$$B_2(z) = -0.001884 \quad (36)$$

$$B_3(z) = -0.08355 \quad (37)$$

4.4.3 Análisis de rendimiento de predicción de los modelos ARX

El modelo ARX con entradas: T_{amb} y RH_{amb} en fase de predicción de T_a con un paso hacia delante tiene un ajuste de 98.35% (grafica no mostrada). Castañeda-Miranda y Castaño (2017) obtuvieron un ajuste similar con valores de $R^2 = 0.9130$ y 0.9294 durante la predicción de la temperatura del aire en el interior de un invernadero en verano e invierno, respectivamente. Por otro lado, este resultado también es congruente con lo obtenido por Patil, Tantau y Salokhe (2008), quienes predijeron la temperatura en el interior de un invernadero tropical durante todo un año mediante variables ambientales. Del análisis residual y de coeficientes del modelo, se obtuvo que las funciones de correlación cruzada se encuentran dentro del intervalo de confianza del 99%, mientras que la autocorrelación de la salida sale del intervalo de confianza, aunque no es un valor significativo (menor de 0.2), por lo cual podría considerarse como un ruido blanco (datos no mostrados).

Cuando se agrega como variable de entrada a la t_{ext} al modelo ARX para predecir T_a (variables de entrada = T_{amb} , RH_{amb} , t_{ext}), se mejora la predicción en un 0.02% (Figura 4-3). Aunque el incremento en el porcentaje de ajuste es pequeño, es necesario considerar como entrada la t_{ext} , pues los extractores son los encargados de regular la temperatura del aire dentro del secador, lo que permite que el modelo pueda ser usado para el diseño de un controlador automático. Montoya-Ríos *et al.* (2020) diseñaron un controlador PI (Proporcional-Integral) para regular la temperatura del aire de un invernadero con ventilación natural a partir de un modelo ARX de alto orden.

Cuando se considera la t_{ext} en el modelo que predice la T_a se puede observar que no se cumple con la prueba de blancura, pues la función de autocorrelación residual sale del intervalo de confianza. De igual forma, en prueba de independencia se observa que existe correlación entre la t_{ext} y la T_a (Figura 4-4), lo que indica que el modelo puede mejorarse. Sin embargo, la autocorrelación

está por debajo de 0.2 por lo cual puede considerarse como un ruido blanco y decir que el modelo ha capturado la dinámica esencial del comportamiento de la T_a .




Figura 4-3. Comparación del valor de T_a medido y predicho un paso hacia adelante mediante modelos ARX con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada.




Figura 4-4. Función de correlación entre las entradas y la salida del modelo ARX para predecir T_a con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada.

El modelo ARX para predecir M_{wb} tiene un porcentaje del 96.34% y 96.90% para variables de entrada externas ($marx_{out}$) e internas ($marx_{in}$) sin considerar a la señal de control, respectivamente (figura no mostrada). Esto significa que los modelos predicen de manera satisfactoria el contenido de humedad de los plátanos dentro del secador un minuto hacia adelante. Anteriormente, los modelos ARX fueron utilizados con éxito por Aumporn *et al.* (2021a) para predecir el contenido de humedad en muestras de plátano durante su deshidratado en un secador solar con cubierta de policarbonato. También se han empleado para predecir el contenido de humedad en láminas de caucho (Aumporn *et al.*, 2021b) y en algas (Pilario *et al.*, 2022). Del análisis residual y de coeficientes de ambos modelos, se observó que las funciones de correlación cruzada de las entradas y la salida se mantienen dentro de los intervalos de confianza del 99% (graficas no mostradas), lo que indica que ambos modelos han capturado la dinámica esencial del comportamiento del contenido de humedad de las muestras de plátano dominico durante su deshidratado.

Para el caso de los modelos $marx_{out}$ y $marx_{in}$ para predecir M_{wb} considerando como entrada a la t_{ext} , ambos modelos predijeron de manera precisa el M_{wb} (Figura 4-5). Por lo cual, podrian aplicarse para predecir el rendimiento operativo y diseñar controladores para el proceso de secado. Como lo sugiere Zhou *et al.* (2018), usarlos para el diseño de conjuntos de variables de entrada de configuración óptima para la implementación de un control óptimo en un secador de tabaco.

En la Figura 4-6a y Figura 4-6b se muestran los residuos de ambos modelos ($marx_{out}$ y $marx_{in}$) considerando como entrada a la t_{ext} . En éstas se puede observar que las funciones de correlación de las entradas y la salida se mantiene dentro de los intervalos de confianza, lo que significa que se pueden usar ambos modelos para predecir el M_{wb} .




Figura 4-5. Comparación del valor de M_{wb} medido y predicho un paso hacia adelante mediante modelos ARX con entradas medidas en el exterior ($marx_{out}$) e interior ($marx_{in}$), respectivamente.




Figura 4-6. Función de correlación entre las entradas y la salida del (a) $marx_{out}$ y (b) $marx_{in}$ considerando a la señal de control.

4.4.4 Mejores redes no lineales autorregresivas con entradas exógenas

Para el caso de los modelos de red neuronal autorregresiva no lineal con entrada externa (NARX) desarrollados para predecir la T_a y el M_{wb} , los estadísticos indican que el número óptimo de neuronas en la capa oculta es cinco para todos los casos (resultados no reportados).

El modelo NARX que predice la T_a con mejor porcentaje de ajuste se obtuvo al usar el 90% de la información para entrenamiento y 10% para validación; por otro lado, con el conjunto 70%:30% de información se obtuvo una bondad de ajuste 0.48% menor respecto al conjunto 90%:10% (Cuadro 4-6. Redes NARX obtenidas para predecir la T_a con la T_{amb} y la RH_{amb} como variables de entrada, para diferentes proporciones de datos para entrenamiento y evaluación.). Además, con el conjunto 70%:30% se cumplió con el análisis de residual de mejor forma, se utilizó este conjunto para entrenar y evaluar el modelo. Para el caso en el que se considera a la t_{ext} como variable de entrada, usando el conjunto 50%:50% de información se obtiene un buen porcentaje de ajuste (Cuadro 4-7. Redes NARX obtenidas para predecir la T_a con la T_{amb} , RH_{amb} y t_{ext} como variables de entrada, para diferentes proporciones de datos para entrenamiento y evaluación.) y se cumple de forma adecuada el análisis de residuales.

Cuadro 4-6. Redes NARX obtenidas para predecir la T_a con la T_{amb} y la RH_{amb} como variables de entrada, para diferentes proporciones de datos para entrenamiento y evaluación.

Estadísticos	Conjunto de datos				
	50%:50%	60%:40%	70%:30%	80%:20%	90%:10%
MAE	-0.00962	-0.01964	-0.01065	-0.01113	0.00665
EF	0.99913	0.99953	0.99963	0.99977	0.99985
NRMSE	98.63%	97.83%	98.31%	98.51%	98.79%

Cuadro 4-7. Redes NARX obtenidas para predecir la T_a con la T_{amb} , RH_{amb} y t_{ext} como variables de entrada, para diferentes proporciones de datos para entrenamiento y evaluación.

Estadísticos	Conjunto de datos				
	50%:50%	60%:40%	70%:30%	80%:20%	90%:10%
MAE	-0.01070	-0.01504	0.00699	-0.00124	0.00776
EF	0.99965	0.99923	0.99986	0.99986	0.99989
NRMSE	98.60%	97.24%	98.83%	98.84%	98.96%

Los Cuadro 4-8 a Cuadro 4-11 muestran los resultados de las redes NARX obtenidas para predecir M_{wb} , con variables de entrada medidas en el exterior y

con entradas medidas en el interior del secador, respectivamente; evaluadas con diferentes conjuntos de datos. En el caso 1) para predecir el M_{wb} usando variables ambientales externas considerando y sin considerar la t_{ext} , la mejor combinación fue los conjuntos de datos 60%:40% y 50%:50%, para entrenamiento y evaluación, respectivamente (Cuadro 4-8 y Cuadro 4-9). Se obtuvo un buen porcentaje de ajuste y se cumplió con el análisis de residuales. Para el caso 2) predecir M_{wb} con variables de entrada ambientales internas, el mejor desempeño sin considerar y considerando la t_{ext} se obtuvo con los conjuntos 50%:50% y 60%:40%, respectivamente (

Cuadro 4-10 y Cuadro 4-11).

Cuadro 4-8. Redes NARX obtenidas para predecir el M_{wb} con VPD_{amb} y W_s como variables de entrada ($marx_{out}$), para diferentes proporciones de datos para estimación y validación.

Estadísticos	Conjunto de datos				
	50%:50%	60%:40%	70%:30%	80%:20%	90%:10%
MAE	-0.00739	0.00977	-0.01662	-0.00195	-0.00604
EF	0.99740	0.99769	0.99933	0.99967	0.99979
NRMSE	94.90%	95.19%	97.42%	98.19%	98.58%

Cuadro 4-9. Redes NARX obtenidas para predecir el M_{wb} con VPD_{amb} , W_s y t_{ext} como variables de entrada ($marx_{out}$), para diferentes proporciones de datos para estimación y validación.

Estadísticos	Conjunto de datos				
	50%:50%	60%:40%	70%:30%	80%:20%	90%:10%
MAE	-0.00480	-0.01796	-0.00730	-0.00964	-0.00258
EF	0.99773	0.99743	0.99960	0.98893	0.99575
NRMSE	95.24%	94.93%	98.00%	89.47%	93.48%

Cuadro 4-10. Redes NARX obtenidas para predecir el M_{wb} con VPD y T_f como variables de entrada ($marx_{in}$), para diferentes proporciones de datos para estimación y validación.

Estadísticos	Conjunto de datos
--------------	-------------------

	50%:50%	60%:40%	70%:30%	80%:20%	90%:10%
MAE	0.00951	-0.00986	-0.00907	-0.01434	-0.01434
EF	0.99793	0.99772	0.99966	0.99839	0.99877
NRMSE	95.45%	95.23%	98.17%	95.99%	96.50%

Cuadro 4-11. Redes NARX obtenidas para predecir el M_{wb} con VPD , T_f y t_{ext} como variables de entrada ($marx_{in}$), para diferentes proporciones de datos para estimación y validación.

Estadísticos	Conjunto de datos				
	50%:50%	60%:40%	70%:30%	80%:20%	90%:10%
MAE	0.00567	-0.00607	-0.05652	-0.02570	-0.01473
EF	0.99793	0.99770	0.99720	0.99771	0.99769
NRMSE	95.45%	95.21%	94.70%	95.21%	95.19%

4.4.5 Análisis del rendimiento de predicción de los modelos NARX

Se obtuvo una red NARX que predice de forma adecuada la T_a durante secado de plátano dominico (98.31% de ajuste) usando 70% de los datos para entrenamiento y 30% para evaluación. El error obtenido entre la T_a medida y la predicha es pequeño, el cual aumenta cuando la temperatura es más elevada (graficas no mostradas). Estos resultados concuerdan con lo obtenido por Gao *et al.* (2023), quienes predijeron la temperatura del aire en el interior de un invernadero solar mediante una red neuronal NARX, con un error absoluto máximo de 0.67 °C y un coeficiente de correlación de 0.9996. De igual forma, Jung *et al.* (2020) obtuvieron un buen desempeño ($R^2 = 0.96$) durante la predicción de la temperatura del aire en un invernadero cinco minutos hacia adelante. Por otro lado, el análisis de correlación indica que los errores de entrada y salida no están correlacionados, pues se encuentran dentro del intervalo de confianza. Sin embargo, el modelo puede ser mejorado, ya que, los errores de la variable de salida están correlacionados (figuras no mostradas).

La Figura 4-7 muestra el comportamiento de la red NARX que redice T_a considerando a la t_{ext} como entrada, se puede observar que existe un error pequeño entre los datos predichos y los medidos siendo mayor en temperaturas elevadas. Además, la mayoría de las correlaciones se encuentran dentro del

intervalo de confianza (Figura 4-8a y Figura 4-8b). Por lo cual, este modelo podría emplearse para el desarrollo de un algoritmo de control, como lo proponen en estudios anteriores para el control de la temperatura del aire en el interior de invernaderos (Jung *et al.*, 2020; Gao *et al.*, 2023; Jung, Lee, Kim, & Park, 2022).




Figura 4-7. Comparación del valor de T_a medido y predicho un paso hacia adelante mediante la red NARX con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada.




Figura 4-8. Análisis del rendimiento de la red NARX para predecir T_a con la T_{amb} , la RH_{amb} y la t_{ext} como variables de entrada, a) correlación de la salida, b) correlación de las entradas.

En el caso de la red NARX para predecir el M_{wb} con variables externas como entrada ($mnarx_{out}$) sin considerar a la t_{ext} , el mejor modelo obtenido tuvo un ajuste del 95.19% respecto a los datos experimentales. El error entre los datos del M_{wb} medidos y los predichos por el modelo es mínimo. Además, la mayoría de las correlaciones de la variable de salida y las variables de entrada se encuentran dentro del límite de confianza, lo que nos da seguridad de utilizar el

modelo (datos no mostrados). Se obtuvo un modelo capaz de pronosticar de forma precisa el M_{wb} un minuto antes de la medición. Li y Chen (2020), desarrollaron un modelo NARX para predecir el contenido de humedad en granos para un secador de granos mecánico, el modelo tuvo un rendimiento de $MSE = 0.0043$ y $MSE = 0.0231$ durante su entrenamiento y validación, respectivamente. Los modelos NARX también han demostrado ser adecuados para predecir el contenido de húmeda en secado por aspersión (Abdullah *et al.*, 2020) y el contenido de humedad de equilibrio en hongos (Argyropoulos & Paraforos, 2022).

Por otro lado, la predicción de la red NARX del M_{wb} con variables de entrada internas ($mnarx_{in}$) sin considerar a la t_{ext} fue más precisa en un 0.26% respecto al $mnarx_{out}$ sin señal de control como entrada. Los valores de M_{wb} predichos por el modelo se ajustaron correctamente a los valores de M_{wb} medidos ($R = 0.99897$) y la correlación cruzada del error de entrada y la correlación del error con los valores de la serie de tiempo en su mayoría estuvieron dentro del intervalo de confianza del 99% (datos no mostrados). Por lo que, el modelo se puede usar para la predecir el M_{wb} de forma precisa.

Finalmente, para ambos modelos $mnarx_{out}$ y $mnarx_{in}$ con variables climáticas externas (VPD_{amb} , W_s y t_{ext}) e internas (VPD , T_f y t_{ext}) como entradas donde se considera a la señal de control, se obtuvo un porcentaje de ajuste de 95.24% ($mnarx_{out}$) y 95.21% ($mnarx_{in}$), y en ambos modelos se obtuvo un coeficiente de determinación por arriba de 0.998 (Figura 4-9a y Figura 4-9b). En las Figura 4-10a a Figura 4-10d se observa que la correlación de entrada y error es muy baja, pues la mayoría de los residuos se encuentran dentro del intervalo de confianza. Sabiendo que, en la práctica es imposible garantizar que todas las correlaciones cruzadas estén dentro del intervalo de confianza (Afshar, Bahrampour, & Shahesmaeili, 2022), es posible utilizar los modelos para la construcción de un algoritmo de control automático del M_{wb} . Como Zhou y Wang (2018) quienes desarrollaron controladores de modo deslizante para el control de la temperatura de bulbo seco y contenido de humedad durante el proceso de secado de madera. De igual forma, se han empleado modelos NARX para

realizar control predictivo del contenido de humedad en granos (Li & Chen, 2020) y control inferencial del contenido de humedad de la leche de coco en polvo que se produjo a partir del secador por aspersión (Abdullah *et al.*, 2020).




Figura 4-9. Comparación del valor de M_{wb} medido y predicho un paso hacia adelante mediante redes NARX, a) con entradas medidas en el exterior ($mnarx_{out}$) considerando a la t_{ext} y b) con entradas medidas en el interior ($mnarx_{in}$) considerando a la t_{ext} .




Figura 4-10. Análisis del rendimiento de los modelos $mnarx_{out}$ y $mnarx_{in}$ para predecir M_{wb} considerando a la t_{ext} como entrada, a), c) correlación de la salida y b), d) correlación de las entradas.

Si se usa cada uno de los modelos ARX y redes NARX de base para el diseño de un dispositivo de control de la temperatura del aire dentro del secador, lo recomendable sería emplear el conjunto de datos para estimar y evaluar del 50% - 50%, considerando en ambos modelos como entrada a la señal de control. Mientras que, para predecir el M_{wb} lo más recomendable es usar los modelos NARX con entradas medidas en el interior del secador con el subconjunto de datos 60%- 40%. En general, la calidad de predicción de los modelos ARX para predecir T_a y M_{wb} es precisa. Sin embargo, será necesario recalibrar periódicamente los modelos (Montoya-Ríos *et al.*, 2020). Una alternativa es usar los modelos NARX que actualizan sus parámetros en el tiempo, dando origen a nuevas estructuras ante nuevos escenarios para tener buenas predicciones (Ljung, 1998).

4.5 Conclusiones

Se evaluaron modelos ARX y NARX para predecir la temperatura del aire y contenido de humedad del producto durante el proceso de deshidratado de plátano dominico en el interior de un secador solar tipo invernadero, utilizando como entradas de los modelos mediciones de variables fuera y dentro del secador. En ambos casos, los mejores modelos obtenidos utilizan dos variables de entrada; para predecir temperatura del aire se utilizaron como entradas a la temperatura y la humedad exterior. Para predecir el contenido de humedad de los plátanos con entradas medidas en el exterior, se usaron como entradas el déficit de presión de vapor y velocidad del aire exterior, mientras que con entradas medidas en el interior se usaron el déficit de presión de vapor y la temperatura del piso interior. Los modelos obtenidos presentaron un nivel de ajuste similar al obtenido por otros investigadores que usaron un mayor número de variables de entrada (radiación solar global, velocidad del viento, temperatura y humedad relativa). Los modelos obtenidos con y sin la señal de control como entrada presentaron una bondad de ajuste mayor del 90% en predicción de un paso hacia adelante sobre el conjunto de datos de estimación y evaluación. Además, se satisface el análisis residual, sus coeficientes estimados son

precisos y las estructuras de los modelos obtenidos son de bajo orden. Por lo anterior, los modelos pueden emplearse para el diseño de un sistema de control automático y manejo del proceso de secado de plátano.

4.6 Bibliografía

- Abdullah, Z., Taip, F. S., Kamal, S. M., & Rahman, R. Z. (2020). Nonlinear Model-Based Inferential Control of Moisture Content of Spray Dried Coconut Milk. *Foods*, 9(9), 1177. doi:<https://doi.org/10.3390/foods9091177>
- Afshar, P. J., Bahrampour, A., & Shahesmaeili, A. (2022). Determination of the trend of incidence of cutaneous leishmaniasis in Kerman province 2014-2020 and forecasting until 2023. A time series study. *PLOS Neglected Tropical Diseases*, 16(4), e0010250. doi:<https://doi.org/10.1371/journal.pntd.0010250>
- Argyropoulos, D., & Paraforos, D. S. (2022). Predicting equilibrium moisture content of mushrooms by NARX neural network and first order kinetic modelling approaches. *IFAC-PapersOnLine*, 55(32), 241-246. doi:<https://doi.org/10.1016/j.ifacol.2022.11.146>
- Aumporn, O., Janjai, S., Khunkaeo, T., & Bala, B. K. (2021a). Development of a Household Scale Solar Dryer: Performance Evaluation and ARX Modeling. *Journal of Renewable Energy and Smart Grid Technology*, 16(1), 1-11.
- Aumporn, O., Pankaew, P., Chanpen, N., & Janjai, S. (2021b). Experimental performance and auto-regressive with eXogenous Input (ARX) modelling of an anti-uv polycarbonate sheet-covered solar dryer equipped with a control system for drying Para rubber sheets. *Journal of Renewable Energy and Smart Grid Technology*, 16(2), 68-80.
- Azaizia, Z., Kooli, S., Elkhadraoui, A., Hamdi, I., & Guizani, A. (2017). Investigation of a new solar greenhouse drying system for peppers. *International Journal of hydrogen energy*, 42(13), 8818-8826. doi:<https://doi.org/10.1016/j.ijhydene.2016.11.180>
- Calín-Sánchez, Á., Lipan, L., Cano-Lamadrid, M., Kharaghani, A., Masztalerz, K., Carbonell-Barrachina, Á. A., & Figiel, A. (2020). Comparison of traditional and novel drying techniques and its effect on quality of fruits, vegetables and aromatic herbs. *Foods*, 9(9), 1261. doi:<https://doi.org/10.3390/foods9091261>
- Castañeda-Miranda, A., & Castaño, V. M. (2017). Smart frost control in greenhouses by neural networks models. *Computers and Electronics in Agriculture*, 137, 102-114. doi:<https://doi.org/10.1016/j.compag.2017.03.024>

- Chauhan, P. S., Kumar, A., & Gupta, B. (2017). A review on thermal models for greenhouse dryers. *Renewable and Sustainable Energy Reviews*, 75, 548-558. doi:<https://doi.org/10.1016/j.rser.2016.11.023>
- El Hage, H., Herez, A., Ramadan, M., Bazzi, H., & Khaled, M. (2018). An investigation on solar drying: A review with economic and environmental assessment. *Energy*, 157, 815-829. doi:<https://doi.org/10.1016/j.energy.2018.05.197>
- Erell, E., Leal, V., & Maldonado, E. (2005). Measurement of air temperature in the presence of a large radiant flux: an assessment of passively ventilated thermometer screens. *Boundary-Layer Meteorology*, 114, 205-231. doi:<https://doi.org/10.1007/s10546-004-8946-8>
- Gao, M., Wu, Q., Li, J., Wang, B., Zhou, Z., Liu, C., & Wang, D. (2023). Temperature prediction of solar greenhouse based on NARX regression neural network. *Scientific Reports*, 13(1), 1563. doi:<https://doi.org/10.1038/s41598-022-24072-1>
- Hamdi, I., Kooli, S., Elkhadraoui, A., Azaizia, Z., Abdelhamid, F., & Guizani, A. (2018). Experimental study and numerical modeling for drying grapes under solar greenhouse. *Experimental study and numerical modeling for drying grapes under solar greenhouse*, 127, 936-946. doi:<https://doi.org/10.1016/j.renene.2018.05.027>
- Hasan, M. U., Malik, A. U., Ali, S., Imtiaz, A., Munir, A., Amjad, W., & Anwar, R. (2019). Modern drying techniques in fruits and vegetables to overcome postharvest losses: A review. *Journal of Food Processing and Preservation*, 43(12), e14280. doi: <https://doi.org/10.1111/jfpp.14280>
- Jung, D. H., Kim, H. S., Jhin, C., Kim, H. J., & Park, S. H. (2020). Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. *Computers and Electronics in Agriculture*, 173, 105402. doi:<https://doi.org/10.1016/j.compag.2020.105402>
- Jung, D.-H., Lee, T. S., Kim, K., & Park, S. H. (2022). A Deep Learning Model to Predict Evapotranspiration and Relative Humidity for Moisture Control in Tomato Greenhouses. *Agronomy*, 12(9), 2169. doi:<https://doi.org/10.3390/agronomy12092169>
- Keesman, K. J. (2011). *System Identification: An Introduction*. London: Springer. doi:10.1007/978-0-85729-522-4
- Li, H., & Chen, S. (2020). A neural-network-based model predictive control scheme for grain dryers. *Drying Technology*, 38(8), 1079-1091. doi:10.1080/07373937.2019.1611598

- Ljung, L. (1998). System Identification. En A. Procházka, J. Uhlíř, P. Rayner, & N. Kingsbury, *Signal Analysis and Prediction* (págs. 163-173). Boston: Birhiuser. doi:https://doi.org/10.1007/978-1-4612-1768-8_11
- Maas, S. G., Schaldach, G., Littringer, E. M., Mescher, A., Griesser, U. J., Braun, D. E., . . . Urbanetz, N. A. (2011). The impact of spray drying outlet temperature on the particle morphology of mannitol. *Powder Technology*, 213(1-3), 27-35. doi:<https://doi.org/10.1016/j.powtec.2011.06.024>
- Montoya-Ríos, A. P., García-Mañas, F., Guzmán, J. L., & Rodríguez, F. (2020). Simple tuning rules for feedforward compensators applied to greenhouse daytime temperature control using natural ventilation. *Agronomy*, 10(9), 1327. doi:[10.3390/agronomy10091327](https://doi.org/10.3390/agronomy10091327)
- Nemzer, B., Vargas, L., Xia, X., Sintara, M., & Feng, H. (2018). Phytochemical and physical properties of blueberries, tart cherries, strawberries, and cranberries as affected by different drying methods. *Food Chemistry*, 262, 242-250. doi:<https://doi.org/10.1016/j.foodchem.2018.04.047>
- Nimnuan, P., & Nabnean, S. (2022). Improvement of the Thepsatri Rajabhat-type household solar dryer. *Journal of Energy Systems*, 6(4), 573-582. doi:[10.30521/jes.1148625](https://doi.org/10.30521/jes.1148625)
- Patil, R., & Gawande, R. (2016). A review on solar tunnel greenhouse drying system. *Renewable and Sustainable Energy Reviews*, 56, 196-214. doi:<https://doi.org/10.1016/j.rser.2015.11.057>
- Patil, S. L., Tantau, H. J., & Salokhe, V. M. (2008). Modelling of tropical greenhouse temperature by auto regressive and neural network models. *Biosystems Engineering*, 99(3), 423-431. doi:<https://doi.org/10.1016/j.biosystemseng.2007.11.009>
- Pilario, K. E., Ching, P. M., Calapatia, A. M., & Culaba, A. B. (2022). Predicting Drying Curves in Algal Biorefineries using Gaussian Process Autoregressive Models. *Digital Chemical Engineering*, 4, 100036. doi:<https://doi.org/10.1016/j.dche.2022.100036>
- Pragati, S., & Preeti, B. (2014). Technological revolution in drying of fruit and vegetables. *International Journal of Science and Research*, 3(10), 705-7011.
- Rivas-Perez, R., Feliu-Batlle, V., & Salcedo-Hernandez, J. (2021). State feedback temperature control based on a Smith predictor in a precalciner of a cement kiln. *IEEE Latin America Transactions*, 19(1), 138-146. doi:[10.1109/TLA.2021.9423857](https://doi.org/10.1109/TLA.2021.9423857)

- Singh, P., Shrivastava, V., & Kumar, A. (2018). Recent developments in greenhouse solar drying: A review. *Renewable and Sustainable Energy Reviews*, 82, 3250-3262. doi:<https://doi.org/10.1016/j.rser.2017.10.020>
- Sun, Q., Zhang, M., Mujumdar, A. S., & Yang, P. (2019). Combined LF-NMR and artificial intelligence for continuous real-time monitoring of carrot in microwave vacuum drying. *Food and Bioprocess Technology*, 12, 551–562. doi:<https://doi.org/10.1007/s11947-018-2231-1>
- Tiwari, A. (2016). A review on solar drying of agricultural produce. *Journal of Food Processing & Technology*, 7(9), 1-12. doi:10.4172/2157-7110.1000623
- Zhou, F., Peng, H., Ruan, W., Wang, D., Liu, M., Gu, Y., & Li, L. (2018). Cubic-RBF-ARX modeling and model-based optimal setting control in head and tail stages of cut tobacco drying process. *Neural Computing and Applications*, 30, 1039–1053. doi:<https://doi.org/10.1007/s00521-016-2735-4>
- Zhou, Z., & Wang, K. (2018). Sliding mode controller design for wood drying process. *Wood Science and Technology*, 52, 1039-1048. doi:<https://doi.org/10.1007/s00226-018-1006-1>

5 CONCLUSIONES GENERALES

Se realizaron tres experimentos de secado de plátano dominico del 11 al 30 de marzo de 2023, en un secador solar parabólico tipo invernadero ubicado en la Universidad Autónoma Chapingo (19°29' N, 98°53' O y a 2240 m de altitud). Durante las pruebas, se obtuvieron picos máximos de radiación solar global por arriba de los 1000 W m⁻², la radiación solar tuvo un comportamiento variable debido a la presencia de nubosidad y lluvia. Aun así, con estas condiciones climáticas se alcanzó en el interior del secador la temperatura apropiada para el deshidratado de plátano (50°) durante aproximadamente un periodo de cinco horas por día, permitiendo reducir el contenido de humedad de los plátanos de un 70% a un 20% w.b., niveles comercialmente aceptables (entre 20 y 25%).

Los plátanos deshidratados presentaron un cambio total grande en el color, un mínimo de 25.63 y un máximo de 29.86, obteniendo una tonalidad final marrón dorado oscuro, que visualmente no es agradable por lo que es necesario realizar pruebas de secado con muestras pretratadas para mejorar la calidad visual del producto. Por otro lado, el contenido de azúcar en los plátanos deshidratados se incrementó debido a la pérdida de humedad.

El sistema de monitoreo tuvo un correcto funcionamiento durante las pruebas, permitió recopilar y guardar información del comportamiento de la temperatura y humedad relativa dentro del secador y su visualización a distancia mediante un teléfono móvil. En un trabajo futuro, será necesario incorporar al sistema un módulo de control que permita el prendido/apagado de los extractores a distancia, para regular el flujo de aire dentro de la cámara de secado. Además, incluir la medición automática del contenido de humedad de los plátanos, para conocer su estado de deshidratación con la finalidad de reducir el tiempo de secado y consumo de energía.

El modelo ARX con estimación de parámetros en línea que mejor predijo el contenido de humedad en los plátanos un paso hacia delante de un minuto se obtuvo utilizando el método del gradiente conjugado normalizado, de acuerdo con el coeficiente de determinación, error cuadrado medio y error absoluto medio el

modelo predice de forma precisa el comportamiento del contenido de humedad de los plátanos. El modelo usa como entradas datos proporcionados por el sistema de monitoreo por lo que ambos podrían trabajar en conjunto para optimizar el proceso de secado.

De las pruebas realizadas para determinar a la mejor combinación de variables de entra, para predecir la temperatura del aire interior del secador y contenido de humedad de los plátanos en los dos casos: 1) con entradas medidas en el exterior y 2) con entradas medidas en el interior del secador. Se obtuvo que, para predecir temperatura del aire interior, donde solo se planteó el caso uno, el modelo obtenido solo utiliza dos variables de entrada: la temperatura y humedad del aire exterior. Mientras que, para predecir el contenido de humedad de los plátanos, en el primer caso, se utilizan como entradas el déficit de presión de vapor y velocidad del aire exterior; y el segundo caso, utiliza el déficit de presión de vapor y la temperatura del piso interior. Los modelos obtenidos para el primer caso presentaron un nivel de ajuste similar al obtenido por otros investigadores, que usaron un mayor número de variables de entrada (radiación solar global, velocidad del viento, temperatura y humedad relativa).

Finalmente, se evaluaron los modelos ARX y NARX identificados en el caso uno y caso dos para predecir la temperatura del aire y contenido de humedad del producto un paso hacia adelante. Los modelos obtuvieron en evaluación una bondad de ajuste mayor del 90%, satisficieron el análisis residual, sus coeficientes estimados son precisos y las estructuras de los modelos obtenidos son de bajo orden. Por lo anterior, los modelos pueden emplearse para evaluar el rendimiento y el diseño de un sistema de control automático del proceso de secado de plátano.