

Design of an electronic nose with artificial neural networks to determine fruit ripening

Diseño de una nariz electrónica con redes neuronales artificiales para determinar la maduración de frutos

Alberto Gudiño Ochoa^{*1}, Jaime Jalomo Cuevas¹, and Raquel Ochoa Ornelas¹

¹ *Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Guzmán, Departamento de Eléctrica y Electrónica, Av. Tecnológico 100, Carretera al Fresnito, Ciudad Guzmán, Jal., México, 49100. albertogudo@hotmail.com, {jaime.jc,raquel.oo}@cdguzman.tecnm.mx*

Abstract

Electronic noses, due to their portability, robustness and low price, are currently extremely useful in the agri-food area, allowing products to be analyzed in a non-destructive way, monitoring results in real time. In this research, a study is carried out based on a design of an electronic nose to naturally accelerate the ripening of climacteric fruits using ethylene gas produced by them. Artificial neural networks were used with a sequential model and binary classification with the ADAM optimizer. The results show a 100% precision to determine the ripeness of the avocado when it receives the gases produced by other fruits such as apples and bananas.

Keywords— Electronic nose, Neural Networks, ADAM Optimizer, Ethylene.

Resumen

Las narices electrónicas por su portabilidad, robustez y bajo precio son actualmente de suma utilidad en el área agroalimentaria permitiendo analizar de forma no destructiva los productos, monitoreando resultados en tiempo real. En esta investigación se realiza un estudio partiendo de un diseño de una nariz electrónica, para acelerar de forma natural la maduración de frutos climatéricos usando gas etileno producido por los mismos. Se emplearon redes neuronales artificiales con un modelo secuencial y clasificación binaria con el optimizador ADAM. Los resultados demuestran una precisión del 100 % para

determinar el estado de maduración del aguacate cuando recibe los gases producidos por otros frutos como son manzanas y plátanos.

Palabras clave— Nariz electrónica, Redes Neuronales, Optimizador ADAM, Etileno.

I. Introducción

Actualmente la producción del aguacate en el sur del estado de Jalisco ha crecido notoriamente con un alto impacto ambiental y económico. Para las empacadoras de la región, la maduración de este producto es un factor importante que se ve reflejado en el tiempo de almacenamiento, distribución y envío para su venta. En la mayoría de los casos esto se previene utilizando productos químicos para conservar las cosechas [1]. Con el fin de atrasar/acelerar la maduración una vez que son transportados, en algunos casos se producen afectaciones a corto plazo en el aroma y sabor natural de la fruta a pesar de presentar una textura/color presentable para el consumidor.

El etileno es un gas producido por los frutos que al medirse proporciona información del índice de maduración. El uso del etileno es una forma natural y limpia para acelerar la maduración y obtener la calidad deseada del fruto [2].

Un sistema de olfato electrónico surge con el fin de determinar la maduración de forma natural usando un sistema de captura de datos confiable. Una nariz electrónica es un dispositivo para detectar y discriminar muestras gaseosas complejas, los sensores que la conforman son sensibles a las sustancias que se desean medir, ya sean de origen químico o biológico. Uno de los beneficios es que permite mejorar los sistemas de distribución y almacena-

* Autor de correspondencia

miento para el control de calidad de frutos climatéricos [3].

Por lo anterior, este diseño está basado en una matriz de sensores de gas con una cámara de muestra y medida donde se captan los gases emitidos por diferentes frutos. Estos datos son transmitidos por medio de un microcontrolador Arduino Mega a un ordenador a través del puerto serial, almacenándolos en una base de datos generando un archivo en Excel por medio de un programa en Python. Los datos capturados en el archivo son procesados empleando un modelo secuencial de Redes Neuronales con TensorFlow y Keras realizando una clasificación binaria que incluye el optimizador ADAM [4].

El artículo se organiza de la siguiente manera: en la sección II se describe la construcción de la nariz electrónica, implicaciones en el manejo de la fruta, así mismo se especifican los sensores, dispositivos y software utilizado para su correcto funcionamiento. En la sección III se detallan los parámetros y circuitos utilizados para la etapa de control, así como la aplicación de redes neuronales y Deep Learning. En la sección IV se describen las pruebas realizadas para determinar y acelerar el estado de maduración de frutos climatéricos. Finalmente, en las secciones V y VI se muestran los resultados obtenidos y las conclusiones de las pruebas realizadas.

II. Materiales y Métodos

II.1. Diseño de nariz electrónica

Una nariz electrónica puede ser utilizada dentro de las tareas relacionadas con la producción de la fruta, integrando software para determinar la fecha idónea de maduración de materia prima y establecer un control de calidad.

En el presente trabajo la nariz electrónica está conformada por una cámara de ozono, una cámara de muestra donde se coloca la fruta ya madurada, y una cámara de medida donde se almacena la fruta de interés a madurar como muestra la Fig. 1.

Las dimensiones de cada cámara son de $25 \times 18 \times 14$ cm y para su construcción se utilizó láminas de acrílico. El flujo de aire es controlado a partir de electroválvulas de $\frac{1}{2}$ " conectadas con mangueras industriales PVC de $\frac{1}{2}$ " a cada cámara. Se utiliza un microcontrolador Arduino Mega para la adquisición de datos.

En la cámara de ozono se incorpora un ozonador HF258 que se presenta en la Fig. 2 y un ventilador AC para limpiar el aire, eliminando restos de patógenos libres y volátiles de cada prueba realizada.

Así mismo en la cámara de muestra y medida se ubica una matriz de sensores catalíticos de la serie MQ, se incluye un sensor digital de temperatura y humedad DHT22.

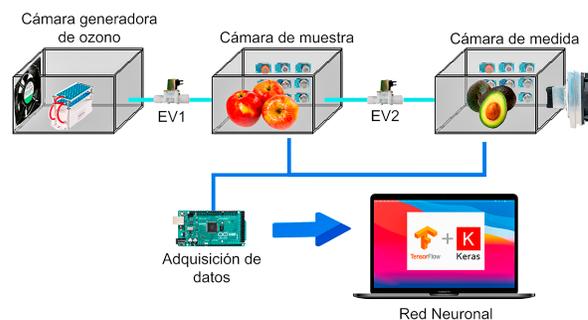


Figura 1: Diseño de la nariz electrónica



Figura 2: Generador de ozono industrial HF258

II.2. Sensores de Gas

Son dispositivos que indican que gases están presentes y miden la concentración de estos en partes por millón (ppm), se usaron sensores catalíticos los cuales están compuestos por dos bobinas de platino, uno de ellos está cubierto por un material catalizador y el segundo parte como elemento de referencia, por ende, es inerte.

En la cámara de medida se destaca la presencia de un sensor electroquímico de óxido de etileno para medir el estado de maduración de la fruta de interés. Dicho sensor tiene tres electrodos que se dividen en una capa de electrolíticos, la cual es líquida, sólida o en forma de gel; una vez que el gas ingresa, se aplica un voltaje de polarización al electrodo produciendo una reacción de reducción y oxidación. En la Fig. 3 se muestra este sensor.

En la Tabla 1 se muestran los sensores ubicados en la cámara de muestra.

En Tabla 2 se muestran los sensores ubicados en la cámara de medida, el sensor electroquímico se alimenta con una fuente lineal de 5V, para el resto de los sensores catalíticos se utiliza una fuente conmutada que propor-



Figura 3: Sensor 4ETO-500 por Honeywell

Tabla 1: Sensores en cámara de muestra

Sensor	Pin de conexión	Detección
MQ-2	A1	Monóxido de Carbono (200-10,000 ppm)
MQ-2	A2	Propano (200 – 10,000 ppm)
MQ-3	A3	Alcohol (0.1-10 mg/L)
MQ-4	A4	Metano (200-10,000 ppm)
MQ-9	A5	Monóxido de carbono (200-10,000 ppm)
DHT22	D2	Temperatura (°C) y Humedad Relativa (%)

ciona una tensión estable de 5V y una corriente salida de 3A.

II.3. Predicciones con redes neuronales

La técnica más usada para el reconocimiento de patrones según las medidas obtenidas por las narices electrónicas son las redes neuronales artificiales [5]. El rendimiento de los modelos basados en este algoritmo es de suma importancia para la determinación de los compuestos detectables, generalmente se usa una matriz de sensores de gas en lugar de usar un solo sensor [6].

La plataforma utilizada para crear el modelo es Google Colab el cual es un servicio cloud, basado en los Notebooks de Jupyter, que no requiere configuración y que se ejecuta completamente en la nube, que permite el uso gratuito de las GPUs y TPUs de Google, en donde se incluye la plataforma de Tensorflow para detectar, descifrar

Tabla 2: Sensores en cámara de medida

Sensor	Pin de conexión	Detección
MQ-2	A6	Monóxido de Carbono (200-10,000 ppm)
MQ-3	A7	Alcohol (0.1-10 mg/L)
MQ-4	A8	Metano (200-10,000 ppm)
DHT22	D3	Temperatura (°C) y Humedad Relativa (%)
4-ETO-500	A9	Óxido de Etileno y derivados (0-500 ppm)

patrones y correlaciones en redes neuronales.

Adicionalmente se incluye la biblioteca de Keras que igualmente es una API diseñada para el Deep Learning y Machine Learning escrita en Python.

II.4. Frutos climatéricos

Este sistema ha sido diseñado exclusivamente para frutos climatéricos los cuales son capaces de seguir madurando aún después de la cosecha, por otro lado, los no climatéricos solo maduran mientras estén cultivados. Cabe señalar que no es recomendable conservar frutos susceptibles al etileno con frutos climatéricos que también lo producen y liberan, si se juntan frutas climatéricas con las que no lo son el etileno las afecta a la par [7].

Para este caso, en la cámara de medida la fruta de interés es el aguacate, la cual puede ser madurada de forma natural con el gas etileno producido de manzanas o plátanos, estas frutas son las únicas donde se han encontrado mejores resultados [8].

III. Etapa de control y programación

III.1. Circuito opto acoplador - TRIAC

Para realizar activación y desactivación del ozonador y el ventilador AC, se requiere de un dimmer, el cual controlará la activación según la lectura medida por un potenciómetro a un pin analógico del microcontrolador, se envía un nivel de corriente para que el programa interprete el aumento o disminución de voltaje.

III.2. Control de electroválvulas

Se utilizaron electroválvulas para permitir el paso de flujo de aire entre las tres cámaras, ya sea para la activación del ozonador o permitir el paso del gas etileno entre

la cámara de muestra y medida. Para controlar el sistema se usó un circuito con optoacopladores y transistores, el accionamiento de las electroválvulas es mediante la señal enviada a través de los pines digitales del microcontrolador.

Adicionalmente esto mismo se aplicó para unos ventiladores DC y celda Peltier para la cámara de medida, todo este sistema es alimentado por una fuente conmutada de 12V-5A.

III.3. Sistema de Refrigeración y control PID

Se incorpora un sistema de refrigeración con ventiladores y una celda Peltier para el correcto funcionamiento del sensor electroquímico que requiere una temperatura de 20°C, en la Fig. 4 se muestra dicho sistema.

Para mantener la temperatura estable se diseñó un control PID, esto ayuda a la conservación de la fruta para que madure naturalmente para cada prueba.

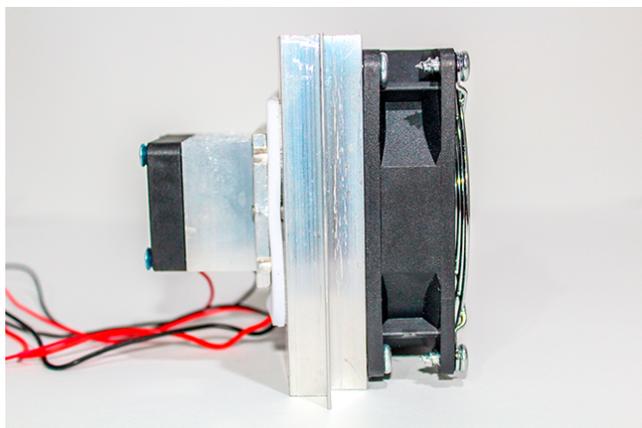


Figura 4: Sistema de refrigeración con celda Peltier

Para este controlador se hizo una adquisición de datos con respecto a la variable a controlar y al actuador (celda Peltier), se usó el mismo sensor DTH22 para leer y registrar el valor máximo de temperatura medido dentro de la cámara de medida hasta llegar a una estabilización.

Los datos capturados son importados a la herramienta "System identification tool" para estimar el modelo para los datos de entrada/salida que han sido medidos.

Al generar el modelo se encontró que la función de transferencia ideal es con un retardo y un polo real, donde se obtiene una eficiencia óptima para el sistema del 98.61 %. Exportado el modelo se ejecuta la aplicación "PID Tuner" para ajustar automáticamente las ganancias del controlador [9]. En la Tabla 3 muestran los valores para el controlador.

Tabla 3: Parámetros para el controlador PID

Parámetro	Ganancia
Kp	126.7472
Ki	0.56668
Kd	42.4645

III.4. Base de datos serial a Excel

En la codificación del microcontrolador se usó el software de Arduino en donde se definieron todos los pines como pines de entrada y salida, tanto analógicos/digitales, así también se incorporaron las librerías necesarias para ejecutar los controladores antes mencionados.

Se utilizó el editor Visual Studio Code donde se importan dos librerías como lo son "serial", "xlwt" y "datetime" para hacer registro de los datos de las concentraciones medidas en tiempo real por el puerto serial creando un archivo en Excel que incorpora cada dato que se imprime en el puerto serie, según el tiempo que se declara en el microcontrolador y el tiempo de muestreo, este archivo es guardado como "SerialToExcel.py".

En un nuevo código se importó el programa anterior "SerialToExcel.py" y se declara el puerto serial donde se ubica el Arduino y la cantidad de baudios usados, así mismo se establece el registro del archivo con el nombre que sea más adecuado para guardarlo con extensión "xls".

III.5. Clasificación multiclase y binaria con ROC

Contando con los registros de las mediciones se importa el archivo a la plataforma en Google Colab. El modelo de RNA se basa en la adquisición, procesamiento de datos y predicciones si el aguacate se encuentra en un estado de maduración, por lo que, la clasificación multiclase, está definida por una clasificación binaria [10]; entre dos posibilidades positivas y negativas.

En el caso de la detección de maduración del aguacate se debe considerar entonces lo siguiente:

- Falso positivo: la prueba (red neuronal) indicó que el aguacate ya está madurado; sin embargo, el aguacate todavía no lo está.
- Falso negativo: la prueba (red neuronal) indicó que el aguacate no está maduro; sin embargo, el aguacate si presenta cierta maduración.
- Verdadero positivo: la prueba (red neuronal) identificó correctamente que el aguacate está madurado.
- Verdadero negativo: la prueba (red neuronal) identificó correctamente que el aguacate no está madurado.

III.6. Arquitectura de la red neuronal

Para esta red neuronal se tienen tres elementos como datos de entrada, en este caso las mediciones de CO , CH_4 y C_2H_4 las cuales corresponden a las concentraciones de los gases más importantes en la cámara de medida.

En la primera capa oculta se usaron 16 neuronas, en la segunda capa 32 nodos, la elección de cuántas neuronas tiene este nodo también es arbitraria.

En la capa de salida se tendrán 2 neuronas, esto se debe a que se tiene dos posibles resultados, si el aguacate se encuentra ya maduro o todavía no lo está. Esta vez, la función de activación que se usa es 'softmax', que dará una distribución de probabilidad entre las posibles salidas, en la Fig. 5 se muestra el diagrama de la arquitectura de la red neuronal.

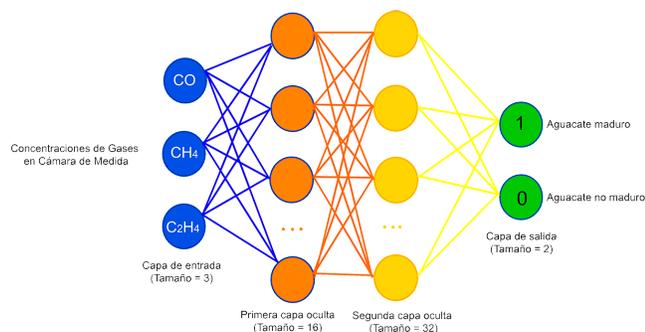


Figura 5: Arquitectura de red neuronal

III.7. Entrenamiento y evaluación del modelo

Se importaron un total de 32,289 datos de la cámara de medida para el modelo. En la fase del entrenamiento se utilizaron 70 % del conjunto de datos completo, aplicando un 15 % para la fase de validación y el 15 % restante para la fase de prueba.

Una vez establecida la arquitectura de la red neuronal lo primero que se debe hacer es entrenar el modelo especificando el optimizador a usar. En este caso el optimizador de Adam es un método de descenso de gradiente estocástico (SGD) ideal para el modelo [11]. El siguiente parámetro para considerar es 'loss' que son las pérdidas del modelo cuando haya sido entrenado, se usa la función 'sparse_categorical_crossentropy' para los valores que están en un rango de 0 a 1.

El número de épocas requerido para este entrenamiento son de 100, se asigna 'verbose=2' el cual sirve para establecer la cantidad de posibles respuestas que se quieren ver durante cada época de entrenamiento, por lo que se obtiene la salida más detallada.

El entrenamiento presentó una precisión del 100 % donde se corrobora que el modelo aprendió las características de los datos de entrenamiento y como puede generalizar datos nuevos e invisibles del conjunto de validación.

La Fig. 6 muestra la gráfica ROC que valida los datos en un porcentaje del 100 % con resultados de verdaderos positivos en futuras predicciones, esto garantiza que el modelo es confiable para predecir el estado de maduración del aguacate almacenado en la cámara de medida.

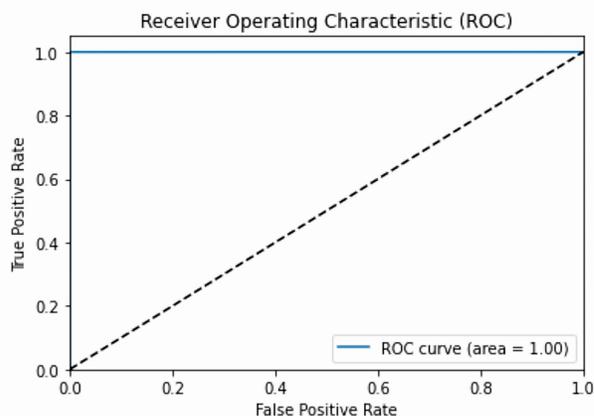


Figura 6: Gráfica ROC

IV. Pruebas

IV.1. Pruebas con manzanas

Para las primeras pruebas se ubicaron manzanas en la cámara de muestra como se visualiza en la Fig. 7.

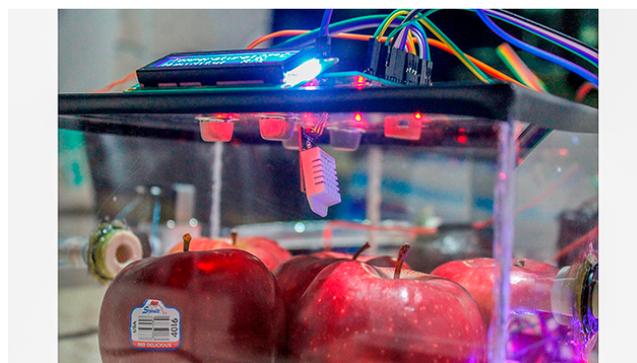


Figura 7: Manzanas en cámara de muestra

Los gases emitidos por dicha fruta fueron medidos por los sensores y recibidos por los aguacates como se presenta en la Fig. 8.

Por medio de una aceleración natural en el proceso, se obtuvieron resultados confiables, logrando un tiempo de maduración de 4 días para el aguacate recién cosechado.



Figura 8: Aguacates en cámara de medida

En la Fig. 9 se muestra el tiempo transcurrido de los gases ubicados en la cámara de medida, donde el CO como el CH_4 disminuyen considerablemente.

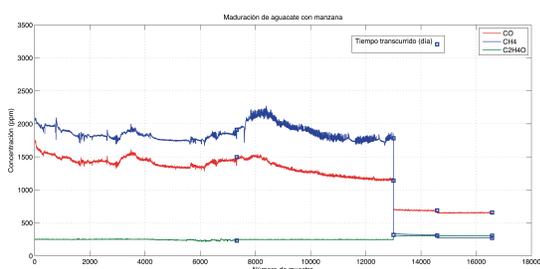


Figura 9: Maduración de aguacate con el etileno producido por manzanas en 4 días

Capturados los datos se procesan creando el modelo de la RNA, validando el entrenamiento de la red (clasificación binaria que hace uso del optimizador ADAM), como así también la precisión para este modelo. En la Fig. 10 se muestran las pérdidas obtenidas en el modelo para los datos validados y entrenados.

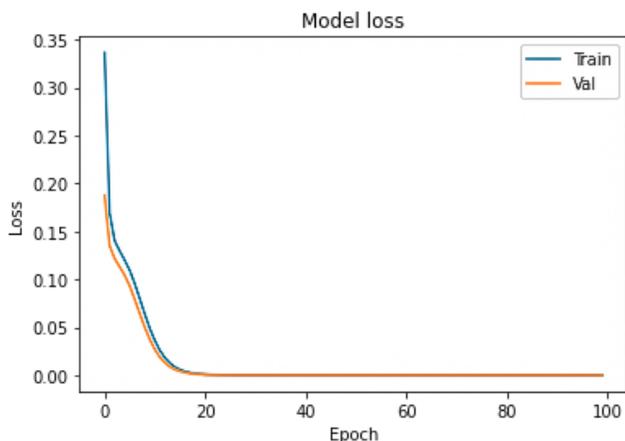


Figura 10: Pérdidas del modelo con manzanas

IV.2. Pruebas con plátanos

En las pruebas realizadas con plátanos el tiempo transcurrido de maduración en el aguacate recién cosechado fue de 7 días. En la Fig. 11 se muestra la evolución de etileno obtenido en la cámara de medida.

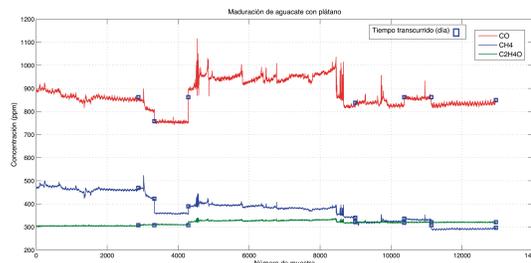


Figura 11: Maduración de aguacate con el etileno producido del plátano en 7 días

Capturados los datos se procesan creando el modelo de la red neuronal. En la Fig. 12 se muestran las pérdidas obtenidas en el modelo para los datos validados y entrenados.

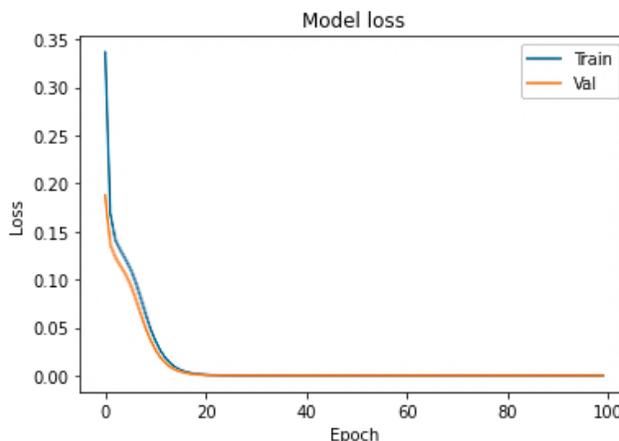


Figura 12: Pérdidas del modelo con plátanos

V. Resultados

Una vez validado el modelo se importaron 6570 muestras capturadas de otras pruebas donde se usaron manzanas para acelerar la maduración del aguacate, cada muestra esta compuesta de tres elementos (CO , CH_4 , C_2H_4). La salida obtenida se representa a continuación en una matriz de confusión en la Fig. 13. Para leerla, es necesario comenzar desde la parte superior izquierda a la inferior derecha, las cuales contienen el número de muestras que el modelo predijo con precisión.

Como se aprecia, el modelo no predijo incorrectamente ninguna muestra de las que fueron importadas, esto

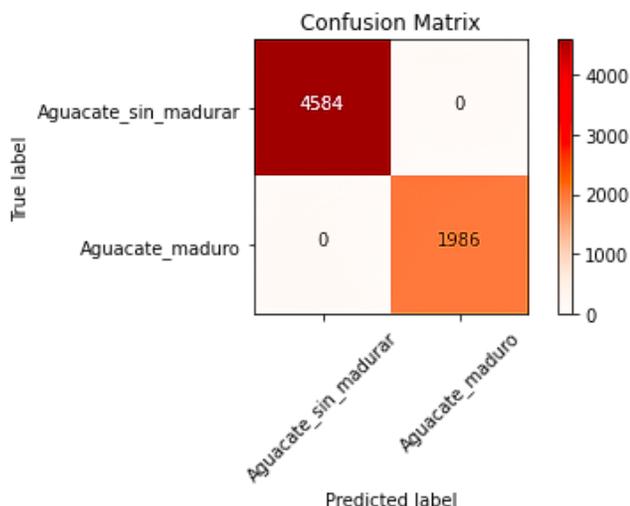


Figura 13: Matriz de confusión para predecir la maduración del aguacate en 4 días

valida una precisión del 100 % para las predicciones en la maduración del aguacate con verdaderos positivos y verdaderos negativos.

Para la aceleración con plátanos se obtuvieron resultados con precisión en la salida, ya que se capturaron y procesaron 4950 datos de otras pruebas con la fruta climatérica mencionada. En la Fig. 14 se muestra la matriz de confusión que válida 1817 muestras donde el aguacate ya presenta signos de maduración.

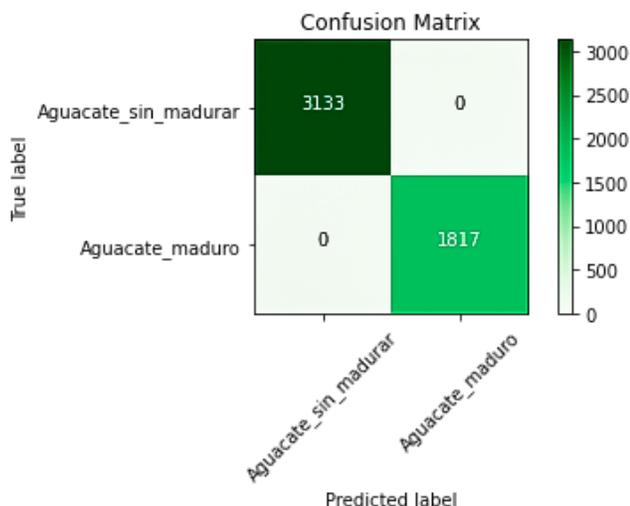


Figura 14: Matriz de confusión para predecir la maduración del aguacate en 7 días

VI. Conclusiones

La nariz electrónica desarrollada puede ofrecer resultados confiables y es de suma utilidad para la agroindustria. El reconocimiento de calidad del producto es de gran ayuda para cumplir con los estándares de almacenamiento y transporte, de tal manera que cuando el producto sea enviado para su distribución, se controle el nivel de maduración y se entregue en buen estado. El algoritmo computacional de redes neuronales generó un sistema preciso para la verificación del estado actual de la fruta con el fin de ofrecer al consumidor un producto de calidad.

Se puede afirmar que el estudio cumplió todas las condiciones impuestas, además de predecir la maduración, esta nariz electrónica permite acelerar la maduración específica para alguna fruta climatérica que sea de interés, sobre todo en casos cuando es solicitada por contar una mayor demanda.

En general, el proyecto contribuye al sector agroindustrial, ofreciendo resultados de una investigación científica que permite acelerar la maduración de un producto de forma natural, garantizando la medición de olor/gases para reconocer, cuantificar, comparar, predecir y discriminar los compuestos orgánicos volátiles.

Agradecimientos

Gracias al Instituto Tecnológico de Ciudad Guzmán por darme la oportunidad de cursar la carrera de Ingeniería Electrónica y realizar el proyecto de tesis denominado “Diseño de una nariz electrónica con redes neuronales artificiales para determinar la maduración de frutos”.

Referencias

- [1] Jacobo Rodríguez Campos, ANTONIO ESCOBEDO REYES y DEL CARMEN LUGO CERVANTES EUGENIA. «Inocuidad en Aguacate». En: *Inocuidad y Trazabilidad en los Alimentos Mexicanos*. Guadalajara, Jalisco México. CIATEJ (2017).
- [2] Jesús Brezmes Llecha. *Diseño de una nariz electrónica para la determinación no destructiva del grado de la maduración de la fruta*. Universitat Politècnica de Catalunya, 2001.
- [3] Eduardo Javid Corpas Iguarán y Omar Alberto Tapasco Alzate. «Hallazgos de la biosíntesis del etileno en frutas climatéricas y de los factores que afectan la ruta metabólica». En: *Alimentos Hoy* 22.31 (2014), págs. 46-63.
- [4] Jason Brownlee. *Deep learning with Python: develop deep learning models on Theano and TensorFlow using Keras*. Machine Learning Mastery, 2016.

- [5] Martha C Quicazán, Carlos M ZULUAGA y col. «La nariz electrónica, una novedosa herramienta para el control de procesos y calidad en la industria agroalimentaria». En: *Vitae* 18.2 (2011), págs. 209-217.
- [6] Carlos Eduardo Carbajal Peñaloza y col. «Nariz electrónica: Herramienta para detección de gases empleando redes neuronales artificiales.» En: *Revista Tecnología Digital. Vol 8.1* (2018), págs. 39-47.
- [7] Gabriel Oscar Sozzi. «Fisiología de maduración de los frutos de especies leñosas». En: *Árboles frutales: ecofisiología, cultivo y aprovechamiento. Editorial Facultad de Agronomía, Universidad de Buenos Aires, Buenos Aires* (2007), págs. 668-687.
- [8] Carolina García-Salinas, Perla A Ramos-Parra y Rocío I Díaz de la Garza. «Ethylene treatment induces changes in folate profiles in climacteric fruit during postharvest ripening». En: *Postharvest Biology and Technology* 118 (2016), págs. 43-50.
- [9] Liuping Wang. *PID control system design and automatic tuning using MATLAB/Simulink*. John Wiley & Sons, 2020.
- [10] Josh Patterson y Adam Gibson. *Deep learning: A practitioner's approach*. .°Reilly Media, Inc.", 2017.
- [11] Aurélien Géron. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, 2019.