



NUEVAS REALIDADES PARA LA EDUCACIÓN EN INGENIERÍA:
CURRÍCULO, TECNOLOGÍA, MEDIO AMBIENTE Y DESARROLLO

13 - 16
DE SEPTIEMBRE

2022

CARTAGENA DE INDIAS,
COLOMBIA



Encuentro Internacional de
Educación en Ingeniería ACOFI

Diseño de una cadena de suministro agroalimentaria integral de producto perecederos en el departamento de Cundinamarca

Carlos Alberto Bejarano Martínez

**Pontificia Universidad Javeriana
Bogotá, Colombia**

Resumen

El objetivo del proyecto es diseñar una Cadena de Suministro Agroalimentaria que mejore la integración de los participantes, reduzca la pérdida de alimentos en poscosecha y reduzca los costos de intermediación, en productos perecederos representativos del departamento de Cundinamarca. En el desarrollo de la investigación se identificó un vacío en el conocimiento a nivel científico, empresarial y de política pública, sobre la aplicación de tecnologías digitales en la medición y seguimiento en tiempo real de propiedades fisicoquímicas en la determinación de la vida útil restante (RSL) de los alimentos. Para cubrir este vacío se propuso como primera etapa un modelo predictivo con base en imágenes reales de frutos de fresa y un algoritmo de Machine Learning con el fin de predecir el tiempo después de cosecha. Con ésto se facilita el cálculo del RSL en tiempo real y la toma de decisiones sobre la articulación de operaciones logísticas. Los resultados muestran que el modelo predictivo presenta una exactitud del 40.15% en prueba, lo que demuestra que el algoritmo funciona, aunque hay que perfeccionar más la asignación de los parámetros de entrada y la arquitectura de la red neuronal.

Palabras clave: fresa; poscosecha; machine learning

Abstract

The objective of the project is to design an Agrifood Supply Chain that improves the integration of its participants, reduces post-harvest food losses and reduces intermediation costs for perishable

products that are representative for the department of Cundinamarca. As a result of the investigation, a knowledge gap was identified at the scientific, business and public policy levels, on the application of digital technologies in measurement and monitoring on real time of physicochemical properties related with the Remaining Shelf Life (RSL) indicator. To fill the gap, a predictive model based on real images of strawberry fruits and a Machine Learning algorithm to predict the time after harvest was proposed as a first step. This facilitates the calculation of the RSL in real time and decision making on the articulation of logistic operations. The results show that the predictive model has an accuracy of 40.15% in test, which proves that the algorithm works, although the input parameter assignment and the neural network architecture need to be further refined.

Keywords: strawberry; postharvest; machine learning

1. Introducción

La Cadena de Suministro Agroalimentaria –CSA - se define como un conjunto de componentes que interactúan en torno al agronegocio, e incluye: sistemas productivos; proveedores de insumos y servicios; industrias de producción y transformación; agentes de distribución y comercialización; y consumidores finales (Flórez M., 2017; Reina & Adarme, 2014). El material que fluye en la CSA, es un organismo biológico, expuesto al riesgo de degradación por sus características, por lo cual requiere de métodos y tecnologías que mitiguen ese riesgo para la conservación de la calidad (Berkowitz, 2012; Navia *et al.*, 2010). Por su parte, Keizer *et al.* (2017) plantean que el efecto de degradación en la calidad, genera pérdidas y desperdicios de alimentos.

Para la presente investigación la CSA que se seleccionó es la fresa (*Fragaria x ananassa Duch*) por las siguientes razones: 1) se considera un producto altamente perecedero (Cybulska *et al.*, 2022); 2) es muy sensible a las prácticas de manipulación y a las condiciones de conservación durante poscosecha (Nunes *et al.*, 2021; Zhang *et al.*, 2020); 3) se encuentra priorizado por el Plan Estratégico de Ciencia, Tecnología e Innovación del Sector Agropecuario Colombiano – PECTIA; 4) existen demandas en Investigación, Desarrollo e Innovación en el departamento de Cundinamarca específicamente en el manejo y desarrollo de tecnología en poscosecha en la plataforma Siembra (<http://www.siembr.gov.co/>); y 5) se encuentra priorizado por el Plan Departamental de Extensión Agropecuaria – PDEA - 2020-2024 de la Gobernación de Cundinamarca.

El cultivo de fresa en Colombia representa cerca del 0.064% del área total sembrada nacional (3,424 ha), ocupando el puesto 16 de los 63 cultivos de frutales que se manejan en el territorio nacional, con una producción promedio anual de 91,278 t (Minagricultura, 2021). El departamento de Cundinamarca ocupa el primer lugar por área sembrada y producción anual, con un valor de 1,638 ha y 52,480, respectivamente. A pesar de la perspectiva promisoriosa del cultivo de fresa en el departamento de Cundinamarca, en la Cadena de Suministro Agroalimentaria –CSA- se presentan de forma paralela problemáticas en la etapa poscosecha, tales como: alta dispersión de precios por la variabilidad de la calidad de los frutos y sobre oferta en épocas de cosecha, alta manipulación de fruto en la cadena de distribución e inestabilidad económica por la variabilidad de precios en el mercado (Cámara de Comercio de Bogotá, 2015). Los efectos más representativos son; por un lado, la inestabilidad económica de los productores y, por otro, la



generación de altas pérdidas y desperdicios de producto en fresco (Corredor Tecnológico Agroindustrial - CTA, 2016).

En Colombia, cerca de 9,76 Mt de alimentos se pierden y desperdician al año; de los cuales el 62% corresponden a frutas y verduras (6,1 Mt) (DNP, 2016). El Departamento Nacional de Planeación - DNP, asegura que Colombia produce 28 millones de toneladas de alimentos al año, y que cerca del 34% de esta producción se pierde o desperdicia. Las pérdidas representan el 22%, y se generan en etapas de producción, poscosecha, almacenamiento y procesamiento industrial y, el 12% restante, corresponde a los desperdicios que se generan en las etapas de distribución, venta y consumo. Para el caso de las frutas y vegetales, dentro de las cuales se ubica la fresa, la cifra es aún más alarmante, se estima que se pierde y desperdicia el 58% de la producción, donde las pérdidas representan el 42% y los desperdicios el 16% restante (DNP, 2016). Por otra parte, la FAO (2015) argumenta que los desperdicios están relacionados con el contexto cultural, los hábitos de compra y consumo. A su vez, las pérdidas, son resultado de: condiciones climáticas adversas, instalaciones físicas deficientes, altos precios de insumos agrícolas, bajos precios de mercado y tecnología implementada; dependiendo lo anterior de la región específica y época del año. Sin embargo, en la mayoría de los casos, con excepción de las condiciones climáticas, las causas de pérdidas en la CSA, están relacionadas con decisiones hechas por uno o más de los participantes de la cadena (Gra *et al.*, 2016).

Con el panorama descrito de la CSA de fresa, surgió la inquietud de cuál ha sido el avance en investigación para dar solución a este tipo de problemáticas en las operaciones poscosecha haciendo uso de tecnologías emergentes. Se aborda el tema de tecnologías emergentes, en especial las tecnologías digitales, porque en una revisión de literatura previa se identificó en la base de datos SCOPUS, en el periodo comprendido entre 2007 y 2021, un total de 97 artículos de investigación que guardan relación con la evaluación del desempeño de una CSA. De éstos artículos, el 11% aplica algún tipo de tecnología digital para medir, recolectar, procesar y/o analizar el comportamiento de una CSA; resultado que demuestra un limitado abordaje de este tema. Teniendo en cuenta todo el contexto descrito surge como pregunta de investigación ¿cómo se puede medir el efecto acumulado en la calidad poscosecha de fresa en tiempo real haciendo uso de tecnologías digitales para facilitar la toma de decisiones logísticas como rotación de inventario, prácticas de manipulación y almacenamiento?

Para responder a esta pregunta se realizó una revisión de literatura aplicando el marco PRISMA en la base de datos SCOPUS con palabras clave relacionadas con el uso de tecnologías digitales en operaciones logísticas de la CSA de fresa. La búsqueda se aplicó al título, resumen y palabra clave, limitando al periodo comprendido entre 2010 y 2022. En esta revisión de literatura se identificaron 183 artículos de los cuales el 16% (30 artículos) están directamente relacionados con la aplicación de tecnologías digitales en la CSA de fresa. Sobre éste último grupo de artículos, el 62% evalúa la eficacia de tecnologías digitales como el tratamiento e impacta la conservación de la calidad y el 38% restante evalúa algún tratamiento directamente relacionado con la conservación de la calidad de fresa y se soporta en tecnologías digitales. Adicionalmente se identificaron las propiedades de calidad que se evalúan en las operaciones de la CSA de fresa y la tecnología digital respectiva (Figura 1).



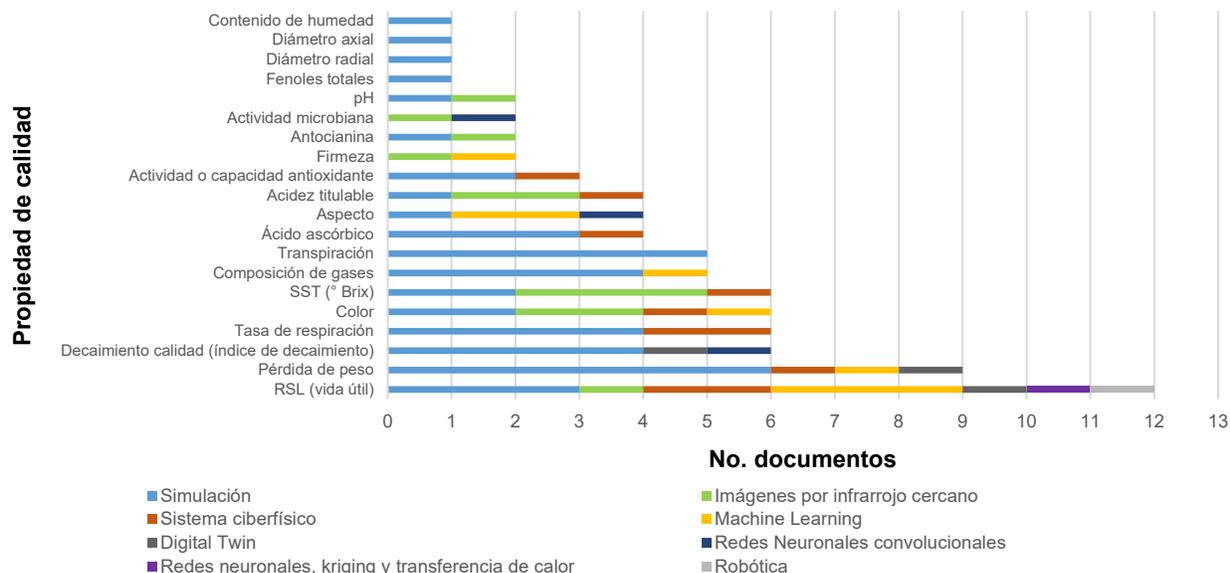


Figura 1. Propiedades de calidad evaluadas en la fresa en fresco en todos los procesos de la CSA por tecnología digital.

De acuerdo con la Figura 1, la simulación se usa para determinar el 90% de las propiedades de calidad reportadas en literatura, las imágenes por infrarrojo cercano para el 23%, los sistemas ciberfísicos (sensores de temperatura, humedad y/o concentración de gases para predecir la vida útil) para el 13% y Machine Learning para el 10%. El uso de Machine Learning en fresa ha sido reciente, desde el año 2020, la meta es predecir el RSL y algunas propiedades fisicoquímicas (pérdida de peso, el color, composición de gases en almacenamiento, aspecto visual y firmeza). Complementando lo anterior, en la Figura 1 se evidencia que la propiedad más evaluada es el indicador denominado Vida Útil Residual (RSL por sus siglas en inglés) en el 40% de los artículos. El RSL es la medida del tiempo entre un momento particular y el tiempo máximo que el fruto cumple con los requerimientos organolépticos del mercado antes que sea considerado como no conforme y por consiguiente desechado (Jalali *et al.*, 2020). El RSL es una medida simple de realizar además que se puede identificar con base en métodos no destructivos (Weng *et al.*, 2020). Otras propiedades de calidad importantes, de las más trabajadas en la literatura sobre poscosecha de fresa son: pérdida de peso (30%), modelos de decaimiento de calidad (20%), tasa de respiración (20%), color (20%), sólidos solubles totales en °Brix (20%), composición de gases (17%) y transpiración (17%).

Pese a la existencia de literatura sobre la poscosecha de fresa, el tiempo de vida útil del material vegetal con el que se trabaja en las investigaciones es diferente por las condiciones de precosecha y poscosecha, de acuerdo con las investigaciones de Chong *et al.* (2022), Cybulska *et al.* (2022) y Sezer *et al.* (2022). La diferencia en las características del material vegetal implica que, en primera instancia se deba medir el tiempo de vida útil máximo.

Por todo lo anterior, el objetivo de la presente investigación fue doble, por un lado, se determinó el tiempo de vida útil máximo en poscosecha de los frutos de fresa (*Fragaria x ananassa Duch*) a



condiciones ambientales de la ciudad de Bogotá, y por otro, se evaluó la implementación de algoritmos de Machine Learning para predecir el tiempo en poscosecha a partir del procesamiento de imágenes. Se consideraron las condiciones de almacenamiento a temperatura ambiente, dado que es el modelo tradicional en la CSA de fresa en Colombia. Además, la metodología trabajada en la presente cuenta con un diseño experimental que permite concluir las diferencias significativas entre los tiempos en poscosecha.

2. Materiales y métodos

2.1. Materia prima

Se utilizaron fresas de variedad Albion en estado 4 y 6 de madurez (ICONTEC, 1997). Se adquirió el material vegetal directamente en una unidad productiva que cumple las prácticas orgánicas de la Resolución 0187 de 2006 y que se ubica en el municipio de Guasca - Cundinamarca. Los frutos se seleccionaron por similitud en tamaño, color, peso y firmeza, teniendo en cuenta que estuvieran libres de daños mecánicos y/o enfermedades. Las fresas se cosecharon en horas de la mañana para garantizar mayor turgencia y posteriormente se transportaron en condiciones ambientales hasta la ciudad de Bogotá en donde se hizo el montaje del experimento.

2.2. Montaje del experimento

Como se mencionó previamente, en una primera fase se determinó el tiempo máximo de vida útil del material vegetal en las condiciones del experimento. Para lograr este objetivo se comparó el efecto en algunas propiedades de la fresa durante su vida útil en poscosecha a condiciones ambientales. El nivel de madurez de los frutos se determinó a partir de la proporción pigmentada de su epidermis particularmente. En esta investigación se usaron frutos de los niveles 4 y 6 que se manejan en el mercado colombiano (Figura 2). Las muestras se empaquetaron en empaque PET con perforación a razón de 0.5 kg.

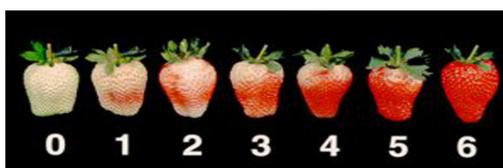


Figura 2. Nivel de madurez de frutos de fresa. Fuente: NTC 4103.

2.3. Diseño experimental

Se utilizó un diseño completamente aleatorio (DCA) para el factor tiempo. Cada 6 h se extrajeron 12 frutos a los que se les midió las propiedades fisicoquímicas. El análisis estadístico fue realizado mediante el software RStudio. Se llevó a cabo un análisis de varianza (ANOVA) ($p \leq 0.05$). En caso de identificar efecto significativo se aplicó la prueba comparativa de medias LSD ($p \leq 0.05$), para determinar si hay diferencia entre los tiempos de medición hasta el tiempo de vida útil. En cada

punto de seguimiento se midieron las dimensiones, el peso y el pH. A continuación, se detalla el procedimiento implementado para cada propiedad.

- *Dimensiones.* Se registró el diámetro ecuatorial y el diámetro polar de cada fruto. El diámetro ecuatorial corresponde al punto más ancho perpendicular al eje y el diámetro polar corresponde a la máxima longitud perpendicular al diámetro ecuatorial. Ambas medidas se determinaron en milímetros con un calibrador pie de rey.
- *Peso.* Se determinó con una balanza digital de precisión 0.01g (Table Top Scale, modelo TOLA, China).
- *pH.* Se determinó con un phmetro (Pometer, modelo PH-009(I)A, China) con ATC. La calibración se hizo con la solución de pH 7.01 (Hanna Instruments Buffer, USA), luego de cada 2 puntos de muestreo.

2.4. Algoritmo de Machine Learning (ML)

2.4.1. Adquisición y preprocesamiento de las imágenes

Para capturar las imágenes, se construyó una cámara acorde al diseño de Choi *et al.* (2021). Se ubicó una cámara de smartphone (Huawei Mate 20 Lite, China) 25 cm por encima de una alfombra negra mate. Para evitar la captura de sombras en las imágenes, se utilizó un aro de luz led de 30 W. Además, para bloquear la luz externa, se cubrió el entorno con una tela negra y la temperatura de la sala se mantuvo a condiciones ambientales a $15 \pm 5^\circ\text{C}$. Las fresas se colocaron paralelo al suelo en la alfombra negra y se fotografiaron individualmente una por una. Se tomaron en total 2.176 imágenes, distribuidas en los 17 tiempos de muestreo que resultaron del seguimiento hasta que se agotó la vida útil, lo cual dio como resultado 128 imágenes por hora de predicción. La vida útil de los frutos se determinó mediante una evaluación visual del aspecto, en donde se evidenciaba si los frutos presentaban alguna de las siguientes características de pérdida de calidad: ablandamiento, deshidratación, lixiviación e inicio de actividad microbiana.

Las imágenes capturadas se guardaron en formato JPG (resolución de 5120×3840 píxeles) y se prepararon para su uso en ML en formato JPG (resolución 224×224 píxeles) reduciendo el tamaño de la parte del fondo mediante un proceso de reescalamiento. Éste reescalamiento se desarrolló utilizando el lenguaje Python, empleando las librerías Scikit-learn, Skimage, Pandas y OpenCV en la plataforma Google Collab Research. En el algoritmo de reescalamiento, inicialmente, la imagen se convierte en una tabla de datos mediante la función "reshape". Sobre la tabla de datos de la imagen, se aplica el modelo Gaussian Mixture (GM) para diferenciar el fondo y la fruta. Posteriormente, se aplica de nuevo la función "reshape" para generar la imagen obtenida con la predicción del modelo GM. A continuación, se obtiene el "bounding box" que representa el rectángulo que cubre la segunda mayor área de la imagen, es decir la fruta. Éste último supuesto fue la hipótesis con la que se trabajó durante todo el algoritmo. A continuación, se reescala la imagen inicial teniendo en cuenta el bounding box. Para optimizar el tiempo computacional, se utilizó la función Thread Pool Executor, que permite al algoritmo procesar simultáneamente un conjunto de imágenes con lo que se procesaban 160 imágenes en 4.5 h.



2.4.2 Entrenamiento de la red neuronal

En este estudio se utilizó un modelo de red de neuronal (RN) como método representativo de ML. El total de las imágenes reescaladas se separaron en dos conjuntos, el primero, con el 82% (1,740) de las imágenes se llamó "train", y el segundo, con el 18% restante (391) se llamó "test". El modelo RN puede predecir el tiempo que transcurre desde que se cosecha un fruto de fresa (0h) hasta que pierde su vida útil (96h). La separación del intervalo de predicción es de 6h, es decir, puede predecir si un fruto está a 0, 6, 12, 18, 24, 30, 36, 42, 48, 54, 60, 66, 72, 78, 84, 90 o 96h. El modelo RN se desarrolló usando el lenguaje Python, empleando las librerías Pandas, TensorFlow, Keras, Seaborn y Scikit-learn en la plataforma Google Collab Research. La exactitud de entrenamiento y la exactitud de prueba del modelo RN se compararon según las variables dadas, como se indica a continuación. En resumen, se utilizaron 10 configuraciones experimentales variando los siguientes parámetros.

- Número de capas: 3 y 4.
- Función de activación: Relu, Tanh y Lineal. Estas dependían del número de capas.
- Neuronas por capa: 128, 64, 32, 17 y 1. Estas dependían del número de capas.
- Batch: 1, 32, 40, 64, y 128.
- Epoch: 3, 30 y 60.

Las especificaciones de hardware del ordenador que realizó el proceso anterior fueron las siguientes: el sistema operativo era Windows 10 de 64 bits, CPU Intel® Core™ i7-6500U y la memoria de la CPU es de 8 GB. Esta configuración de ordenador proporcionada es adecuada para uso personal. El rendimiento de los clasificadores se evaluó a partir de los resultados del modelo entrenado de RN y se midió en función del accuracy (exactitud) mediante la siguiente ecuación (Taheri-Garavand *et al.*, 2015).

$$Accuracy (AC) = \frac{TP + TN}{TP + TN + FP + FN}$$

3. Resultados y discusión

3.1. Efectos significativos del tiempo

En la Tabla 1 se presentan los resultados generales del experimento al aplicar el ANOVA para cada variable de respuesta. Se observa que el factor tiempo solo tiene efecto estadísticamente significativo sobre el pH ($p \leq 0.05$). Esto significa que durante las 96 h de la vida útil la variable que resulta afectada es el pH, mientras que las otras propiedades no.

Tabla 1. P-valor por factor de variabilidad respecto a todas las propiedades.

Factor de Variabilidad	Polar	Ecuatorial	Peso	pH
Tiempo	0.957	0.547	0.390	5.39 e-09

Fuente: El Autor



Profundizando sobre el efecto de los niveles del factor tiempo de almacenamiento, se aplicó la prueba LSD y los resultados se presentan en la Figura 3. En la figura se evidencia que el pH en el periodo de tiempo comprendido entre 0 y 48 h, resulta estadísticamente diferente al pH del periodo entre 90 y 96 h. Entre estos periodos de tiempo descritos, el pH promedio aumentó de 3.35 a 3.64. La interpretación del aumento del pH indica que los frutos, por su propio mecanismo de supervivencia, consumen sus reservas de carbohidratos para transformarlos en energía (Jalali *et al.*, 2020; Shen *et al.*, 2018) y por consiguiente se empieza a perder la turgencia de los frutos de fresa.

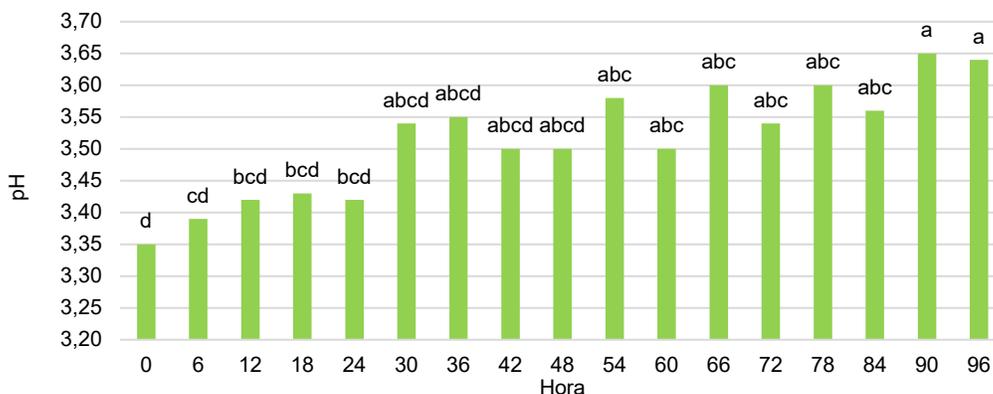


Figura 3. pH por tiempo. Las letras por filas indican diferencia significativa, según la prueba LSD ($p \leq 0.05$). Fuente: El Autor.

Por lo anterior, la vida útil máxima de los frutos estudiados es de 96 h (4 días) en condiciones ambientales y sin manipulación. Éste último valor sirve para determinar el RSL aplicando la fórmula que propone Bogataj *et al.* (2017), la cual establece la diferencia entre el tiempo de vida útil y el tiempo (T) en un momento particular. El tiempo T en la presente investigación es el que se predice a través del modelo RN. En síntesis, para la presente investigación el RSL se calcula mediante la siguiente ecuación.

$$RSL = 96 - T$$

Es importante reconocer que la determinación del RSL es muy variable y depende de muchos factores que inciden en el decaimiento de la calidad del producto (da Silva Simão *et al.*, 2022).

3.2. Desempeño del modelo RN

Es difícil que una red neuronal feedforward tenga un rendimiento adecuado en un conjunto de datos de visión por ordenador, sobre todo con la única información de ese conjunto de datos, por lo cual se propone el uso de la arquitectura CNN con entrenamiento transferido. Esta arquitectura reduce la dimensionalidad de las imágenes de entrada a un vector que se puede utilizar para entrenar el resto de la red. Como el modelo preentrenado ha visto muchas más imágenes y más diversas, hará un mejor trabajo resumiendo cada imagen en un vector que nuestros intentos anteriores (Defraeye *et al.*, 2021). En la Tabla 2 se presentan los resultados del parámetro accuracy en entrenamiento (train) y en prueba (test). En total se realizaron 10 combinaciones entre los parámetros enunciados. Con base en los resultados, se concluye que la mejor solución para la predicción del tiempo en poscosecha de fresa se logra con la prueba 4 porque logra AC train y AC test de 48.31% y 40.15%, respectivamente. Además, se observa que las mejores soluciones son aquellas

que las neuronas de la última capa corresponden al número de categorías de los tiempos de predicción (17).

Tabla 2. Resultados del accuracy (AC) en entrenamiento (train) y prueba (test) por la variación de los parámetros del modelo RN.

Prueba	Ca-pas	Función de activación	Neuronas	Bach	Epoch	AC train	AC test
1	5	Relu, Relu, Relu, Lineal	128, 128, 64, 1	40	3	24.72%	28.90%
2	5	Relu, Relu, Relu, Lineal	128, 128, 64, 17	40	3	34.27%	27.11%
3	4	Relu, Tanh, Lineal	128, 64, 17	1	30	44.94%	38.36%
4	5	Relu, Relu, Tanh, Lineal	128, 64, 32, 17	1	30	48.31%	40.15%
5	5	Relu, Relu, Tanh, Lineal	128, 64, 32, 1	32	30	7.87%	5.88%
6	5	Relu, Relu, Tanh, Lineal	128, 64, 32, 17	32	30	44.94%	37.60%
7	4	Relu, Tanh, Lineal	128, 64, 17	128	30	46.07%	35.55%
8	4	Relu, Tanh, Lineal	128, 32, 17	1	60	45.51%	35.04%
9	4	Relu, Tanh, Lineal	128, 64, 17	1	60	46.63%	38.87%
10	5	Relu, Relu, Tanh, Lineal	128, 64, 32, 17	1	60	47.19%	37.08%

Fuente: Elaboración propia.

La mejor precisión y los porcentajes de la prueba están relacionados con el número de neuronas de la capa de salida con función de activación lineal, en esta prueba, el aumento de neuronas de salida genera un impacto positivo significativo en la precisión final en comparación con las pruebas con una sola neurona de salida que tiene una tasa de pérdida constante. La Figura 4 muestra la configuración del modelo RN con la mejor solución de 5 capas. La primera capa es Input Layer que corresponde a la red MovilnetV2 que ya tiene incorporada la propia función de activación. La segunda, tiene 128 neuronas y la función de activación es Relu. La tercera capa tiene 64 neuronas y la función de activación es Relu. La cuarta capa tiene 32 neuronas y la función de activación es Hyperbolic Tangent. Finalmente, la quinta capa tiene 17 neuronas y la función de activación es Lineal.

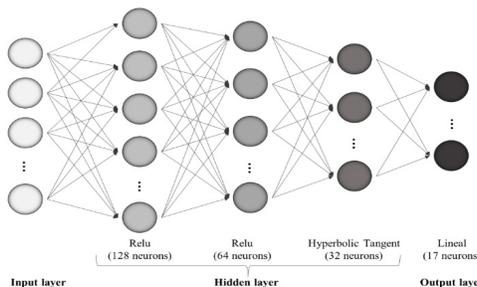


Figura 4. Configuración de la mejor solución del modelo RN. Fuente: Elaboración propia.

En otras investigaciones se han encontrado valores mucho más altos sobre la exactitud en la cosecha de fresa. Es el caso de la investigación de Choi *et al.* (2021) la arquitectura cuenta con 3 capas de red convolucional y lograron una exactitud de promedio del 90%. Feldmann *et al.* (2020) lograron una exactitud de clasificación entre el 68% y el 99% en la identificación de fenotipos de fresa a través de un método creado por los autores que denominaron "Principal Progression of k



Clusters (PPKC)". Ni *et al.* (2021) plantearon un modelo de ML como la mejora de AlexNet para la clasificación de estados de los frutos de fresa, lograron que la exactitud del modelo pasara de la versión base de AlexNet a la mejorada del 89.34% al 95.75%, los cambios se presentan en el tamaño de la convolución de Kernel y el aumento en el número de capas convolucionales. Esta discusión muestra que existe oportunidad de mejora del modelo ML que se propone en la presente investigación mediante la definición de parámetros y la configuración de la RN.

4. Conclusiones

Machine Learning (ML) es un campo de la Inteligencia Artificial (IA) que ha estimulado la innovación en numerosos otros campos que implican las tecnologías básicas de algoritmos. Este estudio utilizó ML aplicado a redes neuronales, un método de IA, para predecir el tiempo en poscosecha de la CSA de fresa en fresco. Como la investigación busca el diseño de un sistema que permita la predicción en tiempo real, se requiere en primera instancia conocer la vida útil máxima de los frutos de fresa. Para esto, en la presente se desarrolló un experimento en poscosecha a condiciones ambientales con seguimiento periódico a ciertas propiedades fisicoquímicas, que son de las más reportadas en la literatura. Con base en este tiempo se tiene la capacidad de predecir el RSL en tiempo real haciendo uso del modelo ML. El modelo de entrenamiento se desarrolló con un conjunto de imágenes reales y se variaron algunos parámetros revisando el efecto sobre la exactitud en entrenamiento y en prueba. Se observó un máximo rendimiento de aprendizaje del 48.31% y de prueba del 40.15%. Los resultados evidencian que el modelo propuesto funciona, aunque hay que perfeccionar más la configuración de los parámetros para que la exactitud genere mayor confiabilidad. Por lo anterior, la siguiente fase de la investigación debe determinar estrategias sobre las imágenes y/o los parámetros de la configuración de la red para que la exactitud logre valores más altos.

5. Referencias

- Berkowitz, D. E. (2012). Industria Alimentaria. *Enciclopedia de Salud y Seguridad En El Trabajo*, 43–60.
- Bogataj, D., Bogataj, M., & Hudoklin, D. (2017). Mitigating risks of perishable products in the cyber-physical systems based on the extended MRP model. *International Journal of Production Economics*, 193, 51–62.
- Cámara de Comercio de Bogotá. (2015). *Manual de fresa*. 1–54.
- Choi, J. Y., Seo, K., Cho, J. S., & Moon, K. D. (2021). Applying convolutional neural networks to assess the external quality of strawberries. *Journal of Food Composition and Analysis*, 102(July), 104071. <https://doi.org/10.1016/j.jfca.2021.104071>
- Chong, L., Ghatge, V., Zhou, W., & Yuk, H. G. (2022). Developing an LED preservation technology to minimize strawberry quality deterioration during distribution. *Food Chemistry*, 366(July 2021), 130566. <https://doi.org/10.1016/j.foodchem.2021.130566>
- Corredor Tecnológico Agroindustrial - CTA. (2016). *Evaluación de tecnologías innovadoras para el manejo integral de los cultivos de mango, naranja y mandarina en zonas productoras del departamento de Cundinamarca*.
- Cybulska, J., Drobek, M., Panek, J., Cruz-Rubio, J. M., Kurzyńska-Szklarek, M., Zdunek, A., & Frąć, M.



- (2022). Changes of pectin structure and microbial community composition in strawberry fruit (*Fragaria x ananassa* Duch.) during cold storage. *Food Chemistry*, 381(July 2021). <https://doi.org/10.1016/j.foodchem.2022.132151>
- da Silva Simão, R., de Moraes, J. O., Lopes, J. B., Frabetti, A. C. C., Carciofi, B. A. M., & Laurindo, J. B. (2022). Survival Analysis to Predict How Color Influences the Shelf Life of Strawberry Leather. *Foods*, 11(2). <https://doi.org/10.3390/foods11020218>
 - Defraeye, T., Shrivastava, C., Berry, T., Verboven, P., Onwude, D., Schudel, S., ... Rossi, R. M. (2021). Digital twins are coming: Will we need them in supply chains of fresh horticultural produce? *Trends in Food Science and Technology*, 109, 245–258. <https://doi.org/10.1016/j.tifs.2021.01.025>
 - DNP. (2016). *Pérdida y desperdicio de alimentos en Colombia*.
 - FAO. (2015). *Desarrollo de Cadenas de valor alimentarias Sostenibles - Principios rectores*. Retrieved from <http://www.fao.org/3/a-i3953s.pdf>
 - Feldmann, M. J., Hardigan, M. A., Famula, R. A., López, C. M., Tabb, A., Cole, G. S., & Knapp, S. J. (2020). Multi-dimensional machine learning approaches for fruit shape phenotyping in strawberry. *GigaScience*, 9(5), 1–17. <https://doi.org/10.1093/gigascience/giaa030>
 - Flórez M., D. H. (2017). Diseño de un modelo de articulación entre la cadena productiva hortofrutícola colombiana y la cadena logística de frío. *Temas Agrarios*, 23(1), 77–94.
 - Gra, J. La, Kitinoja, L., & Alpizar, K. (2016). *Metodología de evaluación de cadenas agroalimentarias*.
 - ICONTEC. (1997). *Norma Técnica Colombiana NTC 4103*.
 - Jalali, A., Linke, M., Geyer, M., & Mahajan, P. V. (2020). Shelf life prediction model for strawberry based on respiration and transpiration processes. *Food Packaging and Shelf Life*, 25(May), 100525. <https://doi.org/10.1016/j.fpsl.2020.100525>
 - Keizer, M. De, Akkerman, R., Grunow, M., Bloemhof, J. M., Haijema, R., & Vorst, J. G. A. J. Van Der. (2017). Logistics network design for perishable products with heterogeneous quality decay. *European Journal of Operational Research*, 262, 535–549.
 - Minagricultura. (2021). *Evaluaciones Agropecuarias Municipales*.
 - Navia, D. P., Villada, H. S., & Mosquera, S. A. (2010). Las biopelículas en la industria de alimentos. *Facultad de Ciencias Agropecuarias*, 8(2), 118–128.
 - Ni, J., Gao, J., Li, J., Yang, H., Hao, Z., & Han, Z. (2021). E-AlexNet: quality evaluation of strawberry based on machine learning. *Journal of Food Measurement and Characterization*, 15(5), 4530–4541. <https://doi.org/10.1007/s11694-021-01010-9>
 - Nunes, G., Teixeira, F., Schwarz, K., Camargo, C. K., De Resende, J. T. V., Dos Santos, E. F., ... Novello, D. (2021). Influence of genetic variability on the quality of strawberry cultivars: Sensorial, physical-chemical and nutritional characterization. *Acta Scientiarum - Agronomy*, 43(November), 1–10. <https://doi.org/10.4025/actasciagron.v43i1.46862>
 - Reina, M. L., & Adarme, W. (2014). Logística de distribución de productos perecederos: estudios de caso Fuente de Oro (Meta) y Viotá. *Revista Colombiana de Ciencias Hortícolas*, 8(1), 80–91.
 - Sezer, B., Tayyarcı, E. K., & Boyacı, I. H. (2022). The use of bacteriophage-based edible coatings for the biocontrol of Salmonella in strawberries. *Food Control*, 135(December 2021), 108812. <https://doi.org/10.1016/j.foodcont.2022.108812>
 - Shen, F., Zhang, B., Cao, C., & Jiang, X. (2018). On-line discrimination of storage shelf-life and prediction of post-harvest quality for strawberry fruit by visible and near infrared spectroscopy. *Journal of Food Process Engineering*, 41(7), 1–9. <https://doi.org/10.1111/jfpe.12866>
 - Weng, S., Yu, S., Dong, R., Pan, F., & Liang, D. (2020). Nondestructive detection of storage time of strawberries using visible/near-infrared hyperspectral imaging. *International Journal of Food Properties*, 23(1), 269–281. <https://doi.org/10.1080/10942912.2020.1716793>
 - Zhang, G., Li, G., & Peng, J. (2020). Risk assessment and monitoring of green logistics for fresh



produce based on a support vector machine. *Sustainability (Switzerland)*, 12(18), 1–20.
<https://doi.org/10.3390/su12187569>

Sobre el Autor

- **Carlos Alberto Bejarano Martínez** PhD (c) en Ingeniería e Ingeniero Industrial de la Pontificia Universidad Javeriana, MSc en Ingeniería Agrícola de la Universidad Nacional de Colombia. Profesional en Procesos Logísticos del Sector Agropecuario en la Agencia de Comercialización e Innovación para el Desarrollo de Cundinamarca – ACIDC. bejarano.carlos@javeriana.edu.co

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2022 Asociación Colombiana de Facultades de Ingeniería (ACOFI)

