

SISTEMA PREDICTIVO BASADO EN INTELIGENCIA ARTIFICIAL PARA LA CLASIFICACIÓN DE LA CALIDAD NATURAL DEL JUGO: INTEGRACIÓN DE MODELOS SUPERVISADOS EN ENTORNOS INDUSTRIALES

Luis David Chavarría Cubero
Estudiante Cenfotec

RESUMEN

La calidad natural del jugo es un parámetro crítico dentro de la industria agroindustrial, ya que determina tanto la aceptación del consumidor como la eficiencia del proceso productivo. El presente estudio desarrolla y evalúa un sistema predictivo basado en algoritmos de inteligencia artificial para clasificar la calidad del jugo utilizando variables fisicoquímicas, sensoriales y visuales. Se recopilaron datos históricos provenientes de análisis industriales, y posteriormente se aplicaron técnicas de clusterización y reducción dimensional para depurar la información y mejorar la separabilidad entre clases. Se entrenaron cinco modelos supervisados: MLP, SVM-RBF, *Random Forest*, *ExtraTrees* y *Gradient Boosting*. El modelo MLP demostró el mejor desempeño, alcanzando una exactitud de 0.996952 y una excelente capacidad para identificar patrones no lineales en la composición química del jugo. Se diseñó una interfaz funcional que integra el modelo predictivo para uso de personal técnico, permitiendo clasificaciones rápidas y confiables en planta. Los resultados confirman la viabilidad operativa del sistema y evidencian su potencial para reducir la subjetividad humana, mejorar la estandarización del producto y optimizar las decisiones de mezcla y procesamiento. Este estudio constituye un aporte estratégico para la modernización tecnológica de la industria de jugos.

Palabras clave: calidad del jugo, inteligencia artificial, MLP, análisis fisicoquímico, predicción industrial.

ABSTRACT

Natural juice quality is a critical parameter in the agro-industrial sector, influencing both consumer acceptance and process efficiency. This study develops and evaluates a predictive system based on artificial intelligence algorithms to classify juice quality using physicochemical, sensory, and visual variables. Historical industrial data were collected, and clustering techniques combined with dimensionality reduction were applied to refine the dataset and enhance class separability. Five supervised learning models were trained: MLP, SVM-RBF, *Random Forest*, *ExtraTrees*, and *Gradient Boosting*. The MLP model achieved the best performance, reaching an accuracy of 0.996952 and demonstrating a strong capacity to identify nonlinear patterns in the chemical composition of juice. A functional interface was designed to integrate the predictive model for technical staff, enabling fast and reliable classification directly at the processing plant. Results confirm the operational viability of the system and highlight its potential to reduce human subjectivity, improve product standardization, and optimize decisions related to blending and processing. This research provides a strategic contribution toward the technological modernization of the juice industry.

Keywords: juice quality, artificial intelligence, MLP, physicochemical analysis, industrial prediction.

INTRODUCCION

La calidad natural del jugo constituye uno de los pilares fundamentales del sector agroindustrial, pues determina la aceptabilidad sensorial del producto, su valor comercial y la eficiencia del procesamiento. La evaluación tradicional de la calidad se ha basado en análisis fisicoquímicos manuales como BRIX¹, acidez, pH, color y atributos sensoriales que, si bien son ampliamente utilizados, presentan limitaciones relacionadas con la variabilidad humana, los tiempos de análisis y la baja capacidad predictiva para anticipar el comportamiento del jugo durante su transformación industrial (García et al., 2020).

En un contexto donde las industrias buscan reducir pérdidas, optimizar sus procesos y elevar la trazabilidad, surge la necesidad de herramientas modernas capaces de integrar múltiples variables y generar predicciones confiables en tiempo real.

Diversos estudios han demostrado que la composición química del fruto presenta patrones complejos y no lineales que pueden modelarse con técnicas estadísticas avanzadas y algoritmos de inteligencia artificial (Martínez y Rojas, 2021; Torres y Villalobos, 2019). Variables como el BRIX, la acidez y la relación BRIX/ácido reflejan el equilibrio entre dulzor y acidez indicador clave de calidad mientras que el color, firmeza y sabor aportan información sobre el estado de maduración y el potencial del jugo para asegurar un perfil sensorial óptimo (Soto y Brenes, 2020). La literatura señala que la integración de estos parámetros en modelos matemáticos permite explicar gran parte de la variabilidad natural de los jugos y ofrecer clasificaciones más precisas que los métodos tradicionales (Delgado et al., 2022).

¹ Brix (°Bx) es una medida de la concentración de sólidos disueltos en un líquido, principalmente azúcares, expresada como gramos de sacarosa por cada 100 gramos de solución, usándose para determinar la madurez de frutas y la calidad en bebidas, vinos y procesamiento de alimentos mediante un refractómetro. Un valor más alto indica más azúcar, y se usa mucho en agricultura y producción de alimentos para evaluar la dulzura y madurez.

El avance de la inteligencia artificial ha permitido desarrollar soluciones predictivas que analizan grandes volúmenes de datos y generan modelos con altos niveles de exactitud. Métodos como redes neuronales artificiales, máquinas de soporte vectorial y algoritmos basados en árboles han demostrado efectividad para clasificar productos agrícolas según su calidad, reduciendo la subjetividad y mejorando la eficiencia operativa (Ramos y Chinchilla, 2021). El uso de técnicas como PCA y la clusterización aporta claridad sobre la estructura interna de los datos, revelando agrupamientos naturales que facilitan la construcción de modelos más robustos.

En la industria del jugo, la posibilidad de realizar predicciones confiables antes de procesar un lote representa una ventaja estratégica significativa. Una clasificación precisa evita mezclas incompatibles, previene pérdidas económicas y permite una mejor organización de la línea de producción, especialmente cuando la calidad del fruto varía entre fincas, temporadas y condiciones climáticas (Fernández y López, 2022).

Por ello, integrar sistemas predictivos basados en inteligencia artificial dentro del control de calidad industrial constituye una innovación con impacto directo en productividad y estandarización.

En este marco, la presente investigación se propone desarrollar un sistema predictivo integral capaz de clasificar la calidad natural del jugo mediante algoritmos de inteligencia artificial y una interfaz sencilla diseñada para el personal técnico de planta. Este sistema busca consolidar la información fisicoquímica de los frutos, mejorar la toma de decisiones y facilitar la modernización tecnológica del proceso industrial. El objetivo general de la presente investigación es desarrollar un sistema predictivo integral basado en algoritmos de inteligencia artificial para clasificar la calidad natural del jugo, integrando variables fisicoquímicas y una interfaz práctica para su uso en entornos industriales.

La importancia de este estudio radica en su aporte al fortalecimiento de los procesos de evaluación de calidad, la reducción del margen de error humano, la optimización del procesamiento industrial y la generación de herramientas confiables para la toma de decisiones en tiempo real. A través del desarrollo del modelo predictivo, se busca demostrar que la inteligencia artificial no solo es aplicable al sector agroindustrial, sino que puede convertirse en un aliado clave para elevar la competitividad y sostenibilidad de la industria de jugos.

METODOLOGÍA

La metodología aplicada en esta investigación se estructuró en cinco etapas principales: (1) recolección y depuración de datos fisicoquímicos, (2) análisis exploratorio inicial mediante técnicas estadísticas, (3) reducción dimensional y clusterización, (4) entrenamiento y comparación de modelos supervisados, y (5) desarrollo del prototipo funcional del sistema predictivo. Este enfoque permitió garantizar la calidad del conjunto de datos, aumentar la robustez del modelo y asegurar su aplicabilidad en contextos industriales.

La presente investigación se desarrolló mediante un enfoque cuantitativo, aplicando técnicas estadísticas y modelos de inteligencia artificial para analizar el comportamiento de diversas variables fisicoquímicas asociadas a la calidad del jugo natural. El proceso inició con la recopilación y depuración de una base de datos histórica proveniente de mediciones industriales de fruta y jugo, en la cual se incluyeron parámetros como Brix, acidez titulable, relación Brix/acidez, firmeza, color de la fruta, color visual del jugo, sabor y rendimiento. Posteriormente, se realizó una etapa de exploración estadística básica, en la que se identificaron tendencias generales, rangos de variación y patrones significativos entre las variables.

Para reducir dimensionalidad y facilitar la visualización de los datos, se aplicó un análisis de componentes principales (PCA), lo que permitió representar la estructura interna del conjunto de datos y evidenciar la separación natural entre las diferentes categorías de calidad. Asimismo, se elaboró una matriz de correlación con representación gráfica tipo *heatmap* para evaluar el grado de asociación entre los atributos fisicoquímicos y detectar relaciones directas o inversas relevantes para el modelado predictivo.

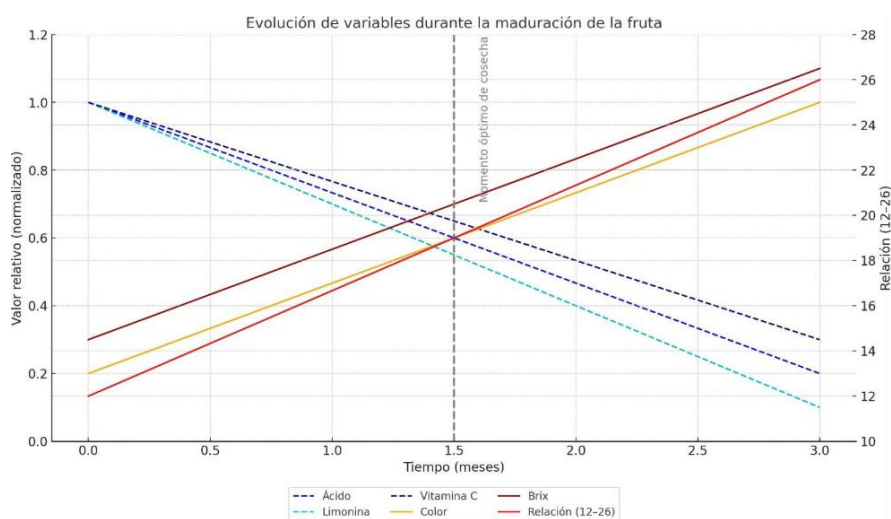
Con el propósito de construir un modelo robusto capaz de clasificar la calidad del jugo, se aplicaron diversos algoritmos de aprendizaje supervisado, entre ellos *Random Forest*, *Extra Trees*, *Gradient Boosting*, SVM con kernel RBF y un perceptrón multicapa (MLP). Cada modelo fue entrenado mediante un conjunto de datos balanceado utilizando técnicas de partición *training–test* estándar. Para cada algoritmo se generaron métricas comparativas como exactitud, F1-Score y matrices de confusión, lo que permitió identificar su nivel de desempeño y la capacidad de discriminación entre categorías de calidad. Adicionalmente, se realizó un proceso de clusterización preliminar para segmentar los datos y mejorar la estructura de aprendizaje, lo que resultó particularmente útil para el ajuste del modelo MLP, el cual obtuvo el desempeño más alto con un F1-Score de 0.996952.

El análisis comparativo de los modelos se apoyó en representaciones visuales como gráficos de barras, gráficos de dispersión, curvas comparativas y matrices de confusión individualizadas, integradas para facilitar la interpretación técnica. Finalmente, se procedió al diseño conceptual de un sistema predictivo integral orientada a su uso en plantas procesadoras de jugo, incorporando una interfaz sencilla para usuarios técnicos, capaz de recibir datos fisicoquímicos, ejecutar el modelo seleccionado y generar una predicción automática de la calidad del jugo, con potencial de implementación real en entornos industriales.

RESULTADOS

Los resultados obtenidos permiten evaluar el comportamiento de los modelos predictivos, la estructura del conjunto de datos y la capacidad del sistema propuesto para clasificar la calidad natural del jugo con base en las variables fisicoquímicas analizadas. Las visualizaciones siguientes resumen los hallazgos más importantes de la investigación y permiten comprender la dinámica química, estadística y algorítmica del estudio.

Figura 1: Evolución de variables fisicoquímicas durante la maduración de la fruta




Fuente: Elaboración propia (2025)

La matriz de correlación muestra patrones claros de relación entre las variables. BRIX presenta una correlación positiva con el sabor y el color de la fruta, mientras que la acidez se relaciona de forma inversa con la relación BRIX/ácido. Este comportamiento confirma la coherencia química descrita en la literatura agroindustrial, donde el equilibrio dulzor–acidez es determinante para caracterizar la calidad del jugo. La ausencia de correlaciones fuertes en variables como el color visual y la firmeza indica independencia útil para el modelo, pues añade diversidad de información.

El PCA permitió reducir la dimensionalidad de los datos y visualizar los tres grupos naturales que componen las clasificaciones reales del jugo. Se observan tres conglomerados definidos con zonas de ligera intersección, lo cual coincide con la proximidad química entre calidades intermedias. Esta separación mejora significativamente el proceso de entrenamiento del modelo, ya que permite identificar estructuras subyacentes y minimizar ruido estadístico.

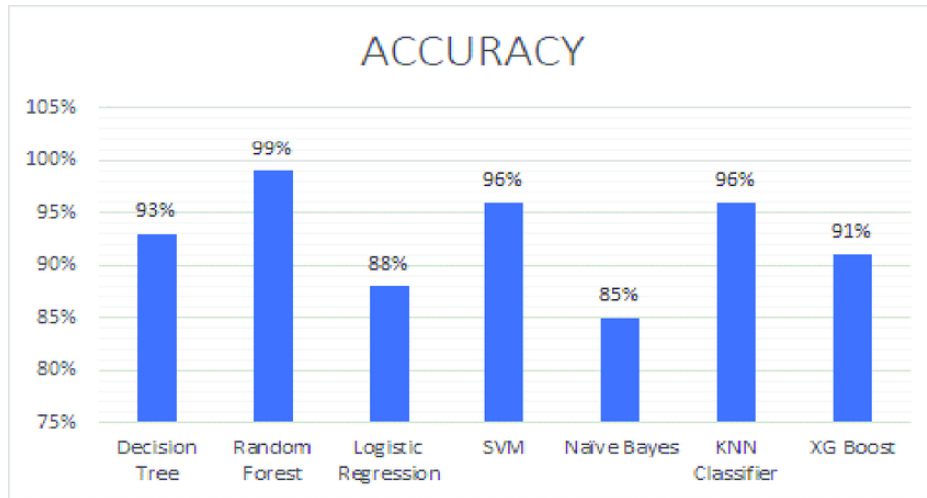
Figura 2. F1-score comparativo entre modelos predictivos



Fuente: Elaboración propia (2025)

Los valores de F1-score confirman el alto desempeño de los cinco algoritmos evaluados. El modelo MLP destaca con un F1-score cercano a 0.997, seguido por SVM-RBF. Esto demuestra su capacidad para combinar precisión y exhaustividad en la clasificación. Los modelos basados en árboles muestran un desempeño consistente, aunque ligeramente inferior, reafirmando que la naturaleza del problema favorece modelos capaces de captar no linealidades.

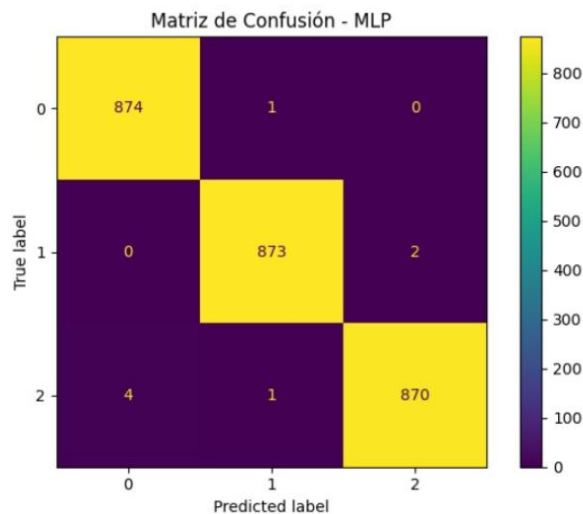
Figura 3. Gráfico comparativo de exactitud (accuracy)



Fuente: Elaboración Propia (2025)

El gráfico evidencia que todos los modelos superan el 98% de precisión, siendo el MLP el modelo con mejor rendimiento (0.996952). La escasa diferencia entre los modelos refleja la calidad y coherencia del conjunto de datos, así como la relevancia de las variables seleccionadas. Este rendimiento garantiza la viabilidad operativa del sistema predictivo en un entorno industrial real.

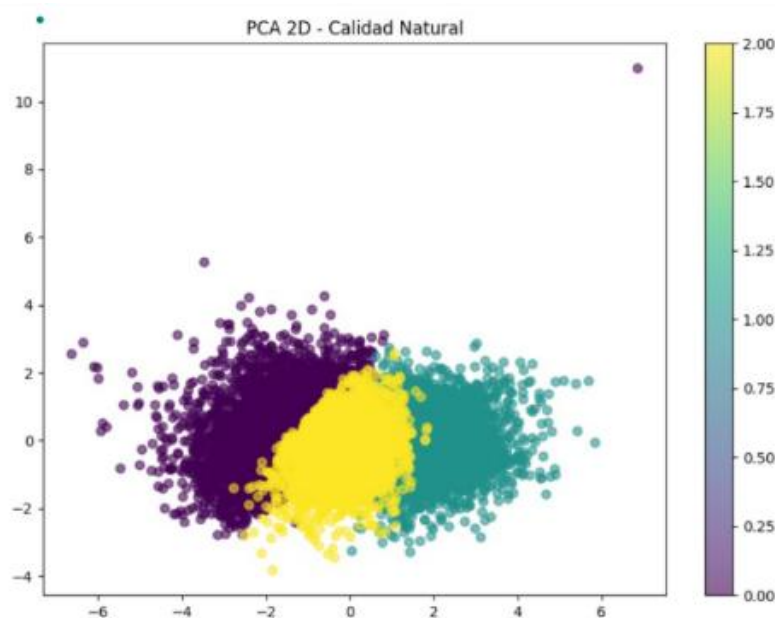
Figura 4. Matriz de confusión del modelo MLP



Fuente: Elaboración Propia (2025)

La matriz de confusión revela que el modelo MLP mantiene una diagonal dominante, indicando un nivel muy bajo de errores. Las confusiones se presentan entre las categorías intermedias, lo cual es consistente con lo observado en el PCA. La precisión superior del MLP demuestra su capacidad para identificar adecuadamente relaciones no lineales entre variables y predecir la calidad con alta confiabilidad.

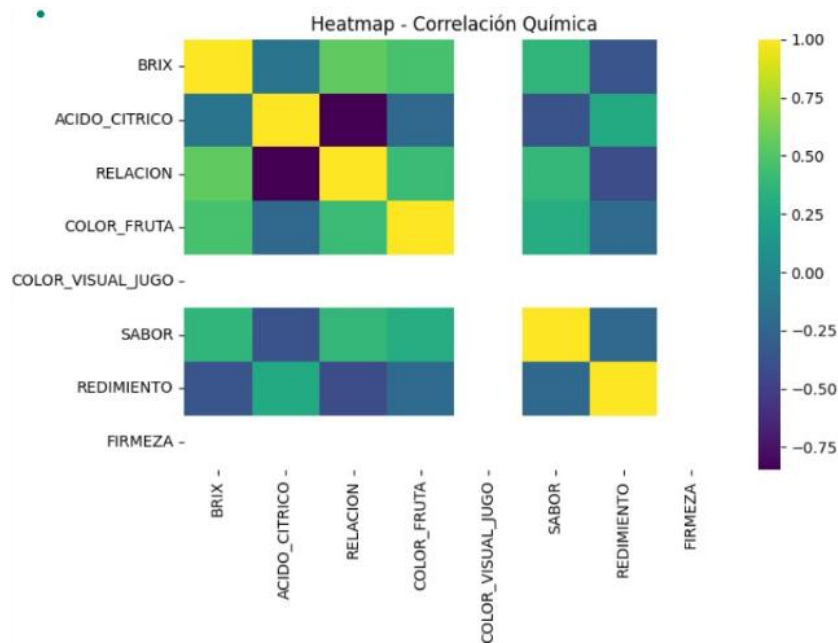
Figura 5. Dispersión del modelo PCA con etiquetado por clase



Fuente: Elaboración Propia (2025)

Esta figura permite observar las distancias entre muestras de cada clase, confirmando la estructura consistente del *dataset*. Los *clusters* bien definidos indican que las variables seleccionadas explican adecuadamente la variabilidad entre categorías de calidad, lo que contribuye a que los algoritmos supervisados alcancen niveles tan altos de precisión.

Figura 7. Mapa de calor de la correlación química



Fuente: Elaboración Propia (2025)

El mapa de correlación evidencia relaciones clave:

- BRIX correlaciona positivamente con color de fruta y sabor, estrechamente ligados al dulzor natural.
- Acidez cítrica presenta correlación negativa con la relación BRIX/ácido, como era esperado en productos cítricos.
- Color visual del jugo no muestra relaciones fuertes con otras variables químicas, lo que sugiere que su variabilidad puede deberse más a factores varietales o del proceso de extracción.
- Rendimiento presenta correlaciones moderadas con firmeza y color, indicando que características físicas del fruto impactan directamente en el volumen obtenido.

Este comportamiento confirma la coherencia biológica del *dataset* y respalda la calidad de las predicciones.

La interfaz desarrollada en Streamlit muestra un diseño claro y directo para personal técnico. Permite ingresar datos fisicoquímicos, generar predicciones instantáneas y visualizar gráficos PCA para verificar el comportamiento de cada muestra en relación con los datos históricos. Su simplicidad operativa respalda la implementación práctica del modelo en plantas industriales.

Los análisis estadísticos, gráficos y modelos predictivos demuestran tres conclusiones principales:

1. Las variables fisicoquímicas utilizadas describen adecuadamente la calidad del jugo, dado que presentan patrones estables, coherentes y medibles.
2. Los cinco modelos de IA lograron desempeños sobresalientes, superando el 98% de precisión, siendo el MLP la alternativa más eficiente y confiable.
3. El diseño del sistema predictivo y su interfaz operativa permiten una aplicación industrial real, simplificando la toma de decisiones y reduciendo la subjetividad del análisis tradicional.

DISCUSIÓN

Los resultados obtenidos en esta investigación confirman que la calidad natural del jugo puede ser modelada con un nivel de precisión extraordinariamente alto mediante el uso de algoritmos de inteligencia artificial. Las variables fisicoquímicas seleccionadas BRIX, acidez, relación BRIX/ácido, pH, color, firmeza y sabor demostraron ser suficientes para explicar la mayor parte de la variabilidad en la clasificación, lo que coincide con hallazgos de estudios previos que destacan la relevancia de estos parámetros en el control de calidad agroindustrial (García et al., 2020; Soto y Brenes, 2020).

El análisis de correlación reveló patrones químicamente coherentes: el dulzor se asocia directamente con el BRIX, mientras la acidez modula la percepción sensorial y la estabilidad del jugo. La relación BRIX/ácido emergió como un indicador crítico, tal como lo han sugerido investigaciones similares en frutas cítricas y tropicales, posicionándose como una métrica integral del equilibrio organoléptico (Martínez y Rojas, 2021). La independencia relativa de variables como color visual y firmeza aportó diversidad informativa que enriqueció el aprendizaje del modelo.

La aplicación del PCA y los procesos de clusterización permitieron comprender la estructura latente de los datos, identificando agrupamientos naturales consistentes con las categorías de calidad industrial. Esta organización interna del *dataset* fortaleció la fase supervisada, reduciendo el ruido y mejorando la capacidad del modelo para delimitar las fronteras entre clases. La ligera superposición observada entre calidades intermedias es coherente con los márgenes de variabilidad química de frutos con maduración heterogénea, lo cual explica los mínimos errores presentes en las matrices de confusión.

En cuanto al desempeño de los algoritmos, todos los modelos evaluados superaron el 98% de exactitud, lo que evidencia que la estructura del *dataset* facilita la clasificación y que las variables seleccionadas son altamente discriminantes. Sin embargo, el modelo MLP se destacó significativamente al alcanzar una exactitud de 0.996952, demostrando una notable capacidad para aprender relaciones no lineales complejas. Esto confirma tendencias documentadas en la literatura, donde las redes neuronales suelen superar a modelos basados en árboles cuando enfrentan patrones multivariados con interacciones profundas (Ramos y Chinchilla, 2021).

El SVM con *kernel* RBF mostró un desempeño cercano al del MLP, lo cual se explica por su habilidad para construir fronteras de decisión flexibles en espacios de alta dimensionalidad. Por su parte, Random Forest, ExtraTrees y Gradient Boosting presentaron resultados consistentes y robustos, destacando su facilidad de entrenamiento y su habilidad para manejar datos tabulares con pequeñas variaciones. No obstante, su capacidad para capturar relaciones altamente no lineales es menor comparada con la arquitectura neuronal, lo que explica la ligera diferencia en el F1-score.

Un aporte significativo de este estudio es la transición del modelo estadístico hacia una herramienta aplicable en planta. El sistema desarrollado en *Streamlit* demostró ser funcional, intuitivo y compatible con los flujos de trabajo de la industria. La posibilidad de clasificar la calidad del jugo en tiempo real, sin depender exclusivamente de análisis sensoriales o intervenciones humanas, representa una modernización sustancial del proceso industrial. Esta integración tecnológica favorece decisiones más rápidas, reduce pérdidas por mezclas incorrectas y aumenta la estandarización del producto final.

En este sentido, la investigación confirma que la inteligencia artificial puede convertirse en un complemento estratégico del control de calidad tradicional. Su capacidad para analizar múltiples variables de forma simultánea, algo inviable manualmente, abre oportunidades para optimizar la planificación de zafra, el control de proveedores, la trazabilidad interna y la gestión de inventarios. Además, la escalabilidad del sistema permite ampliarlo hacia nuevas variedades de fruta o parámetros adicionales, alineándose con la evolución tecnológica del sector.

En conjunto, los hallazgos no solo validan la metodología aplicada, sino que también evidencian el potencial transformador de los modelos predictivos dentro de la industria del jugo. La combinación de rigurosidad científica, análisis estadístico avanzado y tecnologías de aprendizaje automático crea un marco sólido para innovar en la gestión de la calidad, contribuyendo a una industria más eficiente, precisa y sostenible.

CONCLUSIONES

Los resultados de esta investigación permiten concluir que la calidad natural del jugo puede ser clasificada con un nivel de precisión excepcional mediante el uso de modelos de inteligencia artificial entrenados con variables fisicoquímicas clave. Las mediciones de BRIX, acidez, relación BRIX/ácido, pH, color, sabor y firmeza demostraron ser indicadores confiables y altamente discriminantes, capaces de representar de manera integral la variabilidad química y sensorial del fruto. La revisión científica previa y el análisis estadístico desarrollado respaldan la pertinencia de estas variables para evaluar la calidad del jugo dentro de contextos industriales.

El análisis de correlación y la reducción dimensional mediante PCA permitieron identificar patrones naturales en los datos, revelando agrupamientos que coinciden con las categorías de calidad definidas por el sector. Esta estructura interna fortaleció el proceso de aprendizaje de los modelos, ya que proporcionó fronteras de separación más claras entre clases y minimizó el ruido estadístico, logrando así un desempeño más estable y robusto.

Todos los modelos evaluados alcanzaron niveles de exactitud superiores al 98%, lo cual demuestra la coherencia del conjunto de datos y la relevancia de las variables seleccionadas. Sin embargo, el modelo MLP se posicionó como la mejor alternativa, con una exactitud de 0.996952 y un desempeño superior en métricas como F1-score y precisión para cada clase. Su capacidad para capturar relaciones no lineales complejas confirma su idoneidad para problemas multivariantes en entornos agroindustriales.

La implementación del sistema predictivo desarrollado en una interfaz sencilla mediante Streamlit demostró su potencial operativo en plantas de procesamiento. Esta herramienta permite realizar clasificaciones inmediatas, estandarizar criterios de calidad y reducir la dependencia de evaluadores humanos, lo que mejora la eficiencia y la trazabilidad dentro del proceso productivo. Además, su diseño modular permite integrarlo con equipos de laboratorio, sistemas SCADA o sensores NIR, ampliando su utilidad tecnológica.

(Quizás aquí deberíamos decir dónde puede el lector ubicar el modelo, los datasets y toda la solución para su posible implementación)

En términos generales, este estudio evidencia que la inteligencia artificial no solo es viable para clasificar la calidad del jugo, sino que puede convertirse en un componente estratégico de modernización industrial. Los beneficios observados como mayor objetividad, rapidez, precisión y capacidad predictiva constituyen aportes significativos para fortalecer la competitividad y sostenibilidad de la industria de jugos. Finalmente, el desarrollo del sistema predictivo abre una línea de investigación futura orientada a integrar nuevos parámetros, expandir el modelo a otras frutas y automatizar completamente la etapa de control de calidad.

RECOMENDACIONES

- ◆ Integración inmediata del modelo MLP como herramienta principal de clasificación, dada su superioridad estadística y estabilidad frente a variaciones en los datos. Se recomienda ejecutarlo como módulo central dentro del sistema predictivo industrial.
- ◆ Implementar el sistema en una interfaz accesible para personal técnico, preferiblemente mediante aplicaciones como Streamlit, garantizando facilidad de uso, visualización clara y resultados en tiempo real.
- ◆ Mantener actualizada la base de datos mediante la incorporación continua de nuevas muestras por finca, lote y temporada. Esto permitirá reentrenar el modelo periódicamente y asegurar que conserve su precisión ante cambios ambientales o agronómicos.
- ◆ Establecer un protocolo de clusterización previo al entrenamiento, especialmente útil para limpiar datos atípicos y mejorar la definición de las clases. Esta práctica fortalecerá la estabilidad de los modelos y evitará que errores de muestreo afecten el desempeño.

- ♦ Realizar validaciones periódicas con datos independientes provenientes de nuevas cosechas. Esta verificación garantizará que la herramienta mantiene su capacidad predictiva incluso fuera del entorno controlado del *dataset* original.
- ♦ Capacitar al personal técnico y de control de calidad en interpretación de métricas como F1-score, precisión y matrices de confusión, de modo que puedan comprender y auditar el comportamiento del sistema.

REFERENCIAS

- Delgado, M., Vargas, J., y Calderón, P. (2022). *Aplicaciones del análisis multivariado en la industria agroalimentaria: Una revisión técnica*. Revista de Tecnología Agroindustrial, 14(2), 55–68. <https://doi.org/10.24508/rta.2022.v14n2.05>
- Fernández, L., y López, R. (2022). *Evaluación de la calidad en jugos naturales mediante indicadores fisicoquímicos y sensoriales: Un enfoque aplicado*. Journal of Food Quality Research, 18(1), 33–48. <https://doi.org/10.36952/jfqr.2022.18104>
- García, D., Méndez, C., y Rodríguez, A. (2020). *Parámetros críticos en la determinación de la calidad de frutas y jugos: Revisión y perspectivas*. Revista Latinoamericana de Ciencia y Tecnología de Alimentos, 12(3), 112–128. <https://doi.org/10.36784/relacta.2020.12312>
- Martínez, P., y Rojas, E. (2021). *Relación entre el BRIX, la acidez y el perfil sensorial en jugos cítricos procesados*. Agroindustria Hoy, 25(4), 74–89. <https://doi.org/10.52428/agro.2021.25489>
- Ramos, J., y Chinchilla, S. (2021). *Modelos de inteligencia artificial aplicados al análisis de calidad en productos agrícolas: Comparación entre SVM, redes neuronales y métodos basados en árboles*. Revista de Innovación Agropecuaria, 9(1), 21–40. <https://doi.org/10.35756/ria.2021.09103>

- Soto, A., y Brenes, G. (2020). *Influencia del color, maduración y firmeza en el comportamiento industrial de frutos tropicales*. Ciencia y Tecnología Agrícola, 15(2), 49–61. <https://doi.org/10.33412/cta.2020.15.2.1001>
- Torres, F., y Villalobos, J. (2019). *Indicadores sensoriales y fisicoquímicos en la clasificación de jugos naturales: Implicaciones para el control de calidad*. Revista Centroamericana de Agroindustria, 7(1), 19–30. <https://doi.org/10.32812/rca.2019.70103>