

Marco arquitectónico para sistemas de predicción aplicados a la producción del banano en Ecuador

Architectural framework for prediction systems applied to banana production in Ecuador

Jorge Hidalgo-Larrea¹, Mitchell John Vásquez Bermúdez², María del Pilar Avilés Vera³, Lorena Bravo⁴, y Jordi Miño⁵

RESUMEN

Contexto: El cultivo de banano es un pilar de la economía ecuatoriana y su producción depende de variables ambientales y edafológicas, lo que dificulta anticipar su rendimiento mediante métodos tradicionales. Aunque estudios previos han demostrado el potencial del aprendizaje automático para mejorar la predicción agrícola, aun no existe un marco conceptual adaptado a las condiciones del sector bananero ecuatoriano. Este trabajo propone y analiza un marco arquitectónico conceptual orientado a la integración de datos heterogéneos y al soporte de la toma de decisiones agrícolas. **Método:** El estudio adopta un enfoque investigativo conceptual y analítico. La arquitectura fue analizada mediante un enfoque híbrido: un análisis cualitativo utilizando un marco de referencia para derivar criterios de calidad en el diseño arquitectónico, y un análisis cuantitativo apoyado en métricas estructurales, con el fin de examinar propiedades como modularidad, cohesión y complejidad. **Resultados:** El análisis sugiere que la arquitectura propuesta presenta una organización modular clara, una separación funcional coherente entre capas y una estructura orientada a la escalabilidad y mantenibilidad. Las métricas estructurales permiten caracterizar el diseño como equilibrado y de baja complejidad relativa, atributos deseables en etapas tempranas de concepción de sistemas de información. **Conclusiones:** La arquitectura propuesta constituye una base conceptual sólida para el diseño de futuros sistemas predictivos aplicados a la producción de banano en Ecuador. Si bien no se presenta una validación empírica del sistema, el análisis realizado establece fundamentos técnicos y metodológicos que pueden ser utilizados como punto de partida para implementaciones piloto y estudios experimentales posteriores.

Palabras clave: arquitectura de sistemas, machine learning, pronóstico agrícola

ABSTRACT

Context: Banana cultivation is a pillar of the Ecuadorian economy, and its production depends on environmental and soil variables, making it difficult to predict yields using traditional methods. Previous studies have demonstrated the potential of machine learning to improve agricultural forecasting, but there is still no conceptual framework adapted to the conditions of the Ecuadorian banana sector. This paper proposes and analyzes a conceptual architectural framework for integrating heterogeneous data and supporting agricultural decision-making. **Method:** The study adopts a conceptual and analytical research approach. The architecture was analyzed using a hybrid approach: a qualitative analysis using a reference framework to derive quality criteria in architectural design, and a quantitative analysis based on structural metrics, in order to examine properties such as modularity, cohesion, and complexity. **Results:** The analysis suggests that the proposed architecture has a clear modular organization, a coherent functional separation between layers, and a structure geared toward scalability and maintainability. Structural metrics allow the design to be characterized as balanced and relatively low in complexity, desirable attributes in the early stages of information system design. **Conclusions:** The proposed architecture provides a solid conceptual basis for the design of future predictive systems applied to banana production in Ecuador. Although no empirical validation of the system is presented, the analysis carried out establishes technical and methodological foundations that can be used as a starting point for pilot implementations and subsequent experimental studies.

Keywords: systems architecture, machine learning, agricultural forecasting

Fecha de recepción: Diciembre 11, 2025

Fecha de aceptación: Febrero 12, 2026

¹Ingeniero en Sistemas Computacionales, Universidad Católica de Santiago de Guayaquil, Ecuador. Msc en Diseño y Gestión de Proyectos Tecnológicos, España. Afiliación: Universidad Agraria del Ecuador, Ecuador. Correo: jhidalgo@uagraria.edu.ec

²Ingeniero en Sistemas, Universidad de Guayaquil, Ecuador. Msc, Teleinformática y redes de computadoras, Universidad Tecnológica Equinoccial, Ecuador. Afiliación: Universidad de Guayaquil / Universidad Agraria del Ecuador, Ecuador. Correo: mitchell.vasquez@ug.edu.ec, mvasquez@uagraria.edu.ec

³Ingeniera Comercial, Universidad Laica Vicente Rocafuerte de Guayaquil. Msc en Tributación, Escuela Superior Politécnica del Litoral. Afiliación: Universidad Agraria del Ecuador, Ecuador. Correo: maviles@uagraria.edu.ec

⁴Ingeniera en Sistemas Computacionales, Universidad Católica de Santiago de Guayaquil, Ecuador. Msc en Diseño y Gestión de Proyectos Tecnológicos,

España. Afiliación: Universidad de Guayaquil, Ecuador. Correo: lorena.bravob@ug.edu.ec

⁵Ingeniero en Computación e Informática, Ecuador. Afiliación: Universidad Agraria del Ecuador, Ecuador. Correo: jmino@uagraria.edu.ec



This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International Licence.

Cómo citar: Hidalgo-Larrea, J., Vásquez Bermúdez, M. J., Avilés Vera, M. del P., Bravo, L. ., & Miño, J. (2026). Architectural framework for prediction systems applied to banana production in Ecuador. *Ecuadorian Science Journal*, 10(1), 7–14, Marzo–2026. DOI: <https://doi.org/10.46480/esj.10.1.280>

Introducción

La producción de banano representa un eje fundamental en la economía ecuatoriana, siendo uno de sus principales productos de exportación agrícola del país, tal como afirma (Vaca et al., 2020) y (FAO, 2025). Debido a su alta dependencia de factores ambientales y prácticas agrícolas, existe una marcada necesidad de sistemas capaces de anticipar y predecir su producción con una mayor precisión que los métodos tradicionales basados en estadísticas simples, que presentan limitaciones ante la complejidad de las variables involucradas. En respuesta a esta necesidad, diversas investigaciones han explorado la integración de tecnologías como el aprendizaje automático (Machine Learning) y el análisis geoespacial para la predicción de cultivos (Pandya et al., 2023).

Este artículo propone un marco arquitectónico conceptual para sistemas de predicción aplicados a la producción del banano, tomando como referencia experiencias internacionales, estudios previos y la especificidad del contexto ecuatoriano. Este marco busca facilitar el diseño y desarrollo de soluciones tecnológicas que integren datos históricos, ambientales y edafológicos para mejorar la capacidad predictiva y apoyar la toma de decisiones en el sector agrícola.

Revisión de literatura y antecedente

Contexto del cultivo de banano en Ecuador

Ecuador se posiciona como uno de los principales exportadores de banano a nivel mundial, según (Vaca et al., 2020) y (FAO, 2025) representa aproximadamente el 25% del comercio global, siendo las zonas de mayor producción las provincias de Los Ríos, Guayas y El Oro, donde predominan condiciones climáticas favorables como temperatura media anual entre 24°C y 27°C, alta humedad relativa y suelos ricos en materia orgánica.

No obstante, la producción bananera enfrenta desafíos relacionados con enfermedades como la Sigatoka negra (*Mycosphaerella fijiensis*), variabilidad climática, presión del mercado internacional y costos de producción, según se menciona por (Olivares et al., 2022) y (Quilango-Chimarro et al., 2024). En este contexto, contar con herramientas que permitan predecir el rendimiento del cultivo y anticipar afectaciones por condiciones adversas se vuelve fundamental para la sostenibilidad del sector.

Estudios recientes señalan que, a pesar de la importancia estratégica del banano para el país, existe una limitada adopción de tecnologías de agricultura de precisión y análisis predictivo en las fincas pequeñas y medianas (Okolie et al., 2019). Esta brecha tecnológica representa una oportunidad para el desarrollo de soluciones adaptadas al contexto local, que aprovechen datos ya disponibles en instituciones públicas, estaciones meteorológicas y registros de cosecha, facilitando así la toma de decisiones basada en datos.

Fundamentos teóricos y tecnológicos

El uso de inteligencia artificial y aprendizaje automático en la agricultura ha ganado terreno en las últimas décadas, permitiendo desarrollar modelos más precisos para el análisis y la predicción de fenómenos agrícolas complejos.

En el caso específico del cultivo de banano, se han utilizado algoritmos como redes neuronales artificiales, bosques aleatorios y modelos basados en series temporales para estimar rendimientos, tal como en los casos analizados por (Olivares et al., 2022), (Bustaliño et al., 2024) y (Souza et al., 2019). Estas técnicas han demostrado resultados prometedores al combinar datos de múltiples fuentes y reconocer patrones que escapan a los métodos estadísticos tradicionales.

El uso de sensores, imágenes satelitales, estaciones meteorológicas y datos históricos permite alimentar modelos predictivos capaces de anticipar el comportamiento de los cultivos, como mencionan (Prity et al., 2022) y (Patrick et al., 2023). Adicionalmente, el uso de sistemas de información geográfica (SIG) y plataformas de visualización permite representar espacialmente los resultados y facilitar su interpretación por parte de los productores y técnicos agrícolas (Soares et al., 2014).

Estos avances tecnológicos conforman la base sobre la cual se construye la arquitectura propuesta en este estudio.

Metodología y arquitectura propuesta

Enfoque metodológico

El presente estudio se enmarca en una investigación de tipo conceptual y analítica, orientada al diseño y análisis de una arquitectura de sistemas, sin contemplar una implementación funcional ni experimentación en campo. El objetivo metodológico no es medir el desempeño predictivo del sistema, sino examinar la coherencia estructural, organizativa y funcional de la arquitectura propuesta, así como su alineación con atributos deseables en sistemas de información orientados a la toma de decisiones.

Para el análisis de la arquitectura se adopta un enfoque híbrido, combinando métodos cualitativos y cuantitativos, con el propósito de obtener una valoración integral del diseño desde una perspectiva estructural y conceptual.

Para el enfoque cualitativo, se plantea usar las dimensiones del modelo de éxito de sistemas de información del modelo propuesto por (DeLone & McLean, 1992) como marco de referencia para la definición y análisis de requisitos de calidad, que evalúa el éxito de sistemas de información mediante dimensiones. Dicho modelo no se utiliza como un instrumento de evaluación empírica del sistema, sino como una guía conceptual que permite examinar cómo los distintos componentes de la arquitectura se alinean con atributos tales como calidad del sistema, calidad de la información e impacto potencial a nivel individual y organizacional.

Para el enfoque cuantitativo, se aplicarán un conjunto de métricas estructurales adaptadas del modelo "ISA Evaluation Metrics" propuesto por (Vasconcelos et al., 2007). Estas métricas se utilizan para caracterizar propiedades del diseño arquitectónico, tales como número de entidades, relaciones, cohesión, complejidad estructural y nivel de segmentación funcional. Los valores obtenidos permiten describir el comportamiento estructural de la arquitectura y contrastarlo con principios teóricos ampliamente aceptados en el diseño de arquitecturas de sistemas de información.

Cabe destacar que los resultados derivados de ambos enfoques no constituyen evidencia empírica de desempeño, sino indicadores analíticos que permiten evaluar la viabilidad conceptual del diseño arquitectónico y su adecuación como base para desarrollos posteriores. En este sentido, la metodología adoptada busca fortalecer la consistencia interna del marco propuesto y establecer fundamentos verificables para futuras fases de implementación y validación experimental.

Arquitectura propuesta

Esta arquitectura se inspira en marcos utilizados en otras regiones productoras de banano y se adapta a las condiciones tecnológicas y productivas del contexto ecuatoriano (Bhatta et al., 2023). Diseñada con un enfoque modular y estructurada en capas funcionales interrelacionada, lo que facilita su comprensión, escalabilidad y potencial implementación futura. Este diseño permite abstraer los procesos de adquisición de datos, análisis predictivo y visualización, manteniendo una clara separación de responsabilidades entre componentes.

Se compone de tres bloques principales: fuentes de datos, aprendizaje automático y plataformas de visualización, el proceso inicia con la recopilación de datos relevantes del entorno agrícola, continúa con su análisis y predicción mediante modelos de aprendizaje automático, y concluye con la presentación de los resultados a través de plataformas accesibles para los distintos tipos de usuarios involucrados en la gestión productiva.

El flujo entre los componentes de la arquitectura se representa en la Figura 1.

Fuentes de datos

Se contemplan tres tipos de información que deberían estar disponibles en cualquier finca bananera:

- **Ambientales:** incluyen variables meteorológicas como temperatura, humedad, precipitación, radiación solar, velocidad y dirección del viento.
- **Análisis de suelos:** abarca características edafológicas tales como el pH, nivel de nutrientes del suelo y materia orgánica.
- **Registros de producción:** comprenden datos históricos sobre el rendimiento, como racimos enfundados, racimos cosechados y cajas procesadas, asociados con sus respectivas fechas.

Todos estos datos se integran en una única estructura de entrada para alimentar el modelo predictivo de aprendizaje automático.

Aprendizaje automático

Este bloque constituye el núcleo de la arquitectura, encargado de procesar los datos integrados y generar predicciones a través de modelos previamente entrenados. Se divide en tres etapas:

- **Evaluación, validación y procesamiento:** limpieza, transformación y homogenización de datos para alimentar modelos predictivos.

- **Predicción:** se generan inferencias sobre la producción esperada implementando modelos de regresión, redes neuronales o ensambles, entrenados con los datos recopilados.
- **Procesamiento de Resultados:** preparación de las respuestas del modelo para su adecuada visualización e interpretación.

Plataformas de visualización

Interfaz web/móvil que permita a los usuarios consultar predicciones, alertas y recomendaciones de manejo agronómico.

- **Sitio web:** interfaz orientada a técnicos y administradores agrícolas, con acceso a reportes detallados y funciones administrativas.
- **Aplicación móvil:** diseñada para su uso en campo, facilita el acceso rápido a predicciones actuales e históricas, permitiendo una consulta ágil por parte de operarios o supervisores.

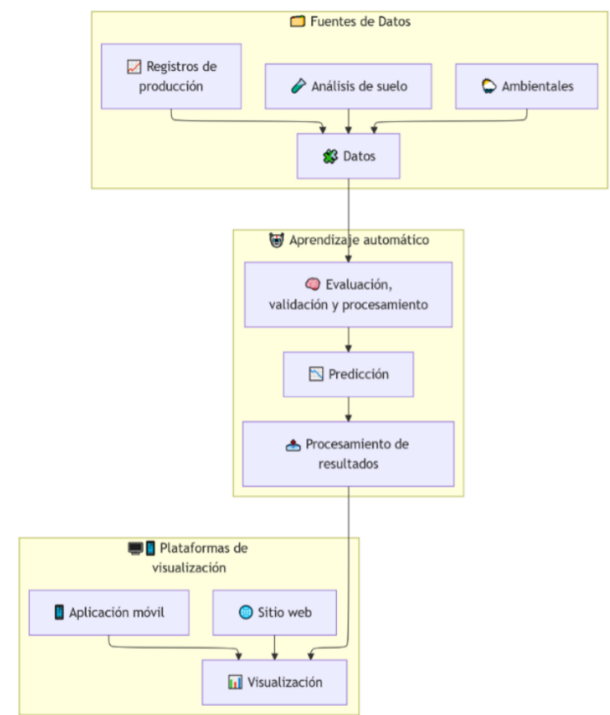


Figura 1. Flujo arquitectónico propuesto para sistemas de predicción en la producción de banano.

Fuente: Autores.

Evaluación y análisis de la arquitectura

La arquitectura conceptual propuesta fue evaluada empleando un enfoque híbrido, combinando criterios cualitativos y métricas estructurales, con el objetivo de examinar sus propiedades de diseño y su coherencia interna, más que evaluar su desempeño operativo en un entorno real.

Este análisis se fundamenta en la premisa de que, en etapas tempranas de concepción de sistemas de información, resulta pertinente evaluar atributos estructurales y organizativos que permitan anticipar su viabilidad técnica

y su capacidad de adaptación a futuros escenarios de implementación.

Enfoque cualitativo

Las dimensiones del modelo de éxito de sistemas de información de (DeLone & McLean, 1992) fueron empleadas como categorías analíticas de referencia, con el fin de examinar cómo los distintos componentes de la arquitectura se alinean con atributos teóricos de calidad comúnmente aceptados en el diseño de sistemas de información. Este análisis no constituye una evaluación empírica del sistema, sino una valoración conceptual derivada del diseño propuesto.

Fuentes de datos: Ambientales, Análisis de suelo, Registros de producción

Desde una perspectiva de diseño, estos componentes presentan una estructura modular claramente definida, lo que favorece su integración progresiva y su eventual sustitución sin afectar al resto del sistema. En términos conceptuales, su rol como insumos primarios los vincula directamente con la dimensión de calidad de la información, al constituir la base sobre la cual se construyen los procesos de análisis predictivo.

Dado que estos componentes no interactúan directamente con los usuarios finales, no se consideran dentro de las dimensiones asociadas al impacto individual. No obstante, su correcta estructuración resulta estratégica a nivel organizacional, ya que condiciona la confiabilidad de los análisis y decisiones derivadas del sistema.

Agregador de datos (Datos)

El agregador de datos cumple una función integradora, consolidando información proveniente de fuentes heterogéneas. Desde el punto de vista arquitectónico, este componente contribuye a la interoperabilidad y estandarización de datos, aspectos asociados a la calidad del sistema y de la información en el modelo de referencia.

Su inclusión explícita como bloque independiente permite aislar responsabilidades relacionadas con normalización, transformación y gestión de esquemas de datos, lo cual representa una buena práctica de diseño en arquitecturas orientadas a datos.

Evaluación, validación y procesamiento de datos

Este módulo técnico actúa como un filtro previo al proceso predictivo, asegurando que los datos cumplan condiciones mínimas de consistencia y estructura. A nivel conceptual, su presencia refuerza la calidad del sistema al reducir la propagación de errores hacia etapas posteriores del flujo de procesamiento.

Dado su carácter interno, este componente no se analiza en términos de impacto individual u organizacional directo, sino como un habilitador técnico del funcionamiento global del sistema.

Predicción

El bloque de predicción constituye el núcleo lógico de la arquitectura. Desde una perspectiva de diseño, su

ubicación central y su independencia funcional permiten la incorporación futura de distintos enfoques de aprendizaje automático, tales como modelos de regresión supervisada, ensambles o redes neuronales, sin requerir modificaciones estructurales en el resto del sistema.

Este desacoplamiento favorece la escalabilidad y la evolución tecnológica del sistema, atributos relevantes en contextos agrícolas caracterizados por cambios constantes en la disponibilidad y calidad de los datos.

Procesamiento de resultados

Este componente actúa como una capa intermedia entre los modelos predictivos y los mecanismos de visualización. Su función principal es traducir las salidas técnicas del modelo en formatos comprensibles, lo que, desde una perspectiva conceptual, contribuye tanto a la calidad de la información como a la interpretabilidad de los resultados.

Interfaces web y móvil

Las interfaces de usuario representan el principal punto de contacto entre el sistema y los actores involucrados en la gestión productiva. Conceptualmente, su inclusión responde a la necesidad de atender distintos perfiles de usuario, desde operarios en campo hasta personal técnico y administrativo.

Desde el marco de referencia utilizado, estas interfaces se asocian principalmente con la dimensión de impacto individual, al facilitar el acceso oportuno a información relevante para la toma de decisiones.

Enfoque cuantitativo

Con el propósito de complementar el análisis cualitativo, se aplicaron métricas estructurales adaptadas del enfoque de (Vasconcelos et al., 2007). Estas métricas permiten caracterizar la arquitectura desde un punto de vista organizativo y estructural, sin pretender medir su rendimiento operativo.

Para desarrollar la evaluación adecuadamente fue necesario identificar los elementos que componen la estructura arquitectónica, para lo cual se revisó el diagrama de flujo arquitectónico presentado en la Figura 1, logrando determinar sus componentes que se clasificaron en: capas funcionales, bloques funcionales y conexiones, mismos que se presentan a continuación:

Capas funcionales:

- Capa 1: Fuentes de Datos.
- Capa 2: Aprendizaje Automático.
- Capa 3: Visualización.

Bloques funcionales:

- Capa 1: Fuente de datos
 - Ambientales.
 - Análisis de suelo.
 - Registros de producción.
 - Agregador de datos (Datos).

- Capa 2: Aprendizaje automático
 - Evaluación, validación y procesamiento.
 - Predicción.
 - Procesamiento de resultados.
- Capa 3: Plataformas de visualización
 - Sitio web.
 - Aplicación móvil.
 - Componente central de visualización.

Conexiones:

A1 → A A → B1 B3 → C
 A2 → A B1 → B2 C ← C1
 A3 → A B2 → B3 C ← C2

Una vez identificados los elementos que integran la estructura arquitectónica se llevó a cabo la evaluación aplicando métricas específicas y adaptadas en función del caso.

Average Number of Possible Operating Systems (NPOS)

Se evaluó la cantidad de posibles familias de sistemas operativo en función de las plataformas de visualización propuestas en la arquitectura: web y móvil. Para calcularla aplicó la fórmula:

$$NPOS = \frac{\sum_{i=1}^P NPOS_i}{P} \quad (1)$$

Donde:

- *NPOS*: es el número de posibles familias de sistemas operativos que soporta una plataforma.
- *P*: es el total de plataformas.

Se determinó el valor de *NPOS* para la plataforma web en 4 y para móvil en 2, obteniendo un valor de 3, tal como se demuestra a continuación.

$$NPOS = \frac{4+2}{2} = 3 \quad (2)$$

El valor final *NPOS* = 3 refleja a futuro un buen nivel de portabilidad e interoperabilidad técnica.

Average Number of (Different) Implementations of an Information Entity (NIIE)

Se evaluó el número de datos diferentes que utilizan los bloques. Para calcularlo aplicó la fórmula:

$$NIIE = \frac{\sum_{i=1}^E NLLIE_i}{E} \quad (3)$$

Donde:

- *NLLIE*: es el número de datos utilizados por una entidad de sus relaciones cercanas.

- *E*: es el total de entidades involucradas.

Se determinó el valor de *NLLIE* en 7 debido a que la entrada de datos original es 3 y luego se va procesando en los 4 bloques consecuentes retornando a su vez un tipo de datos diferente para cada bloque, iniciando en el bloque A y finalizando en el bloque C.

$$NIIE = \frac{7}{5} = 1,4 \quad (4)$$

El valor final *NIIE* = 1,4 se interpreta como un nivel casi perfecto de interoperabilidad sintáctica.

Average Lack of Cohesion (LCO)

Se evaluó si cada bloque utiliza un conjunto de datos diferente. Para calcularlo aplicó la fórmula:

$$LCO = \frac{\sum_{i=1}^B LCO_i}{B} \quad (5)$$

Donde:

- *LCO*: es el número de conjuntos de datos que son utilizados por bloques distintos.
- *B*: es el total de bloques involucrados.

Se determinó el valor de *LCO* y *B* en 5 debido a que son 5 los bloques que hacen uso de conjuntos de datos diferentes.

$$LCO = \frac{5}{5} = 1 \quad (6)$$

El valor final *LCO* = 1 asegura un alto nivel de seguridad.

Average Number of Operations (NO)

Se evaluó la cantidad de operaciones que se realizan en cada bloque. Para calcularlo aplicó la fórmula:

$$NO = \frac{\sum_{i=1}^B O_i}{B} \quad (7)$$

Donde:

- *O*: es el número operaciones en un bloque.
- *B*: es el total de bloques involucrados.

Se determinó el valor de *O* en 6 y el valor de *B* en 4.

$$NO = \frac{6}{4} = 1,5 \quad (8)$$

El valor final *NO* = 1,5 sugiere un buen nivel de modificabilidad.

Average Service Cyclomatic Complexity (SCC)

Se evaluó el promedio entre el número de bloques y la cantidad de conexiones. Para calcularlo se aplicó la fórmula:

$$SCC = R - B + 2 \quad (9)$$

Donde:

- *R*: es el número relaciones entre bloques.
- *B*: es el total de bloques.

Se determino el valor de *R* en 9 y el valor de *B* en 10.

$$SCC = 9 - 10 + 2 = 1 \quad (10)$$

El valor final $SCC = 1$ garantiza baja complejidad y alta mantenibilidad.

Number of Entities (NE)

Se evaluó el total bloques de la arquitectura.

$$NE = 10 \quad (11)$$

Number of Relations (NR)

Se evaluó el total relaciones de la arquitectura.

$$NR = 9 \quad (12)$$

El valor final $NR = 9$ y $NE = 10$ demuestran un equilibrio entre bloques y relaciones, tal como lo evidencia el nivel de complejidad ciclomática.

Los valores obtenidos reflejan una arquitectura con una segmentación clara en capas funcionales, un número controlado de bloques y relaciones, y niveles de cohesión adecuados para sistemas diseñados bajo principios modulares. En particular, métricas asociadas a la complejidad estructural y a la cantidad de relaciones sugieren un diseño manejable, lo que resulta consistente con arquitecturas concebidas para evolucionar progresivamente hacia implementaciones reales.

En conjunto, los resultados de ambas evaluaciones evidencian que la arquitectura conceptual propuesta es sólida, coherente y adecuada para su propósito.

Desde una perspectiva cualitativa, destaca por su claridad organizativa, su enfoque modular, y su capacidad para integrar diversas fuentes de datos en un sistema de predicción accesible y útil. La consideración de múltiples perfiles de usuario y niveles de decisión refuerza su aplicabilidad en contextos reales.

Desde el punto de vista cuantitativo, las métricas muestran una arquitectura equilibrada, de baja complejidad, con alta cohesión y segmentación funcional clara. Estas características son especialmente valiosas en fases tempranas de diseño, ya que facilitan futuras implementaciones, mantenimiento y escalabilidad del sistema.

En síntesis, el enfoque híbrido de evaluación proporciona una visión integral que valida la propuesta arquitectónica

y ofrece una base firme para futuras implementaciones en escenarios productivos reales.

Discusión

La presente investigación se centra en el análisis conceptual de una arquitectura orientada a sistemas de predicción aplicados a la producción de banano, por lo que sus resultados deben interpretarse dentro de este alcance. A diferencia de estudios empíricos que evalúan el desempeño de modelos predictivos mediante datos reales, este trabajo se enfoca en examinar la coherencia estructural y la viabilidad teórica del diseño arquitectónico propuesto.

Al comparar esta propuesta con modelos desarrollados en países como Filipinas, India o China, se observa una convergencia en cuanto al uso de tecnologías emergentes para mejorar la gestión agrícola tal como plantea (Bustaliño et al., 2024), (Khan et al., 2020), (Khan et al., 2021) y (da Silva et al., 2023). Estudios previos destacan la eficacia de modelos híbridos que combinan aprendizaje profundo con variables agroclimáticas específicas como sugiere (Rebortera & Fajardo, 2019a) y (Baswaraju et al., 2023).

También se observa que la arquitectura propuesta comparte principios comunes, como modularidad, separación de responsabilidades e integración de múltiples fuentes de datos, ampliamente documentados en la literatura sobre sistemas predictivos agrícolas. No obstante, su principal aporte radica en la adaptación conceptual de estos principios al contexto del sector bananero ecuatoriano, caracterizado por limitaciones de conectividad, heterogeneidad de datos y brechas tecnológicas en pequeños y medianos productores.

El énfasis en una arquitectura desacoplada y extensible resulta particularmente relevante frente a la variabilidad en la calidad de los datos y concuerda con propuestas como la de (Rebortera & Fajardo, 2019a), que resalta la importancia de dividir los sistemas en subsistemas funcionales independientes para facilitar la escalabilidad y el mantenimiento. Asimismo, el uso de microservicios en lugar de arquitecturas monolíticas, sugerido en (Quiloango-Chimarro et al., 2024), permite actualizar componentes específicos sin afectar la operatividad total de los sistemas, lo que resulta crucial en entornos agrícolas donde la continuidad operativa es prioritaria. Además, al no vincular el diseño a un algoritmo específico, la arquitectura mantiene su vigencia frente a avances tecnológicos futuros, lo cual constituye una ventaja desde el punto de vista de sostenibilidad del sistema.

Asimismo, la inclusión explícita de capas de procesamiento y visualización reconoce la importancia de la interpretabilidad y el acceso a la información como factores clave para la adopción tecnológica en entornos agrícolas. Estudios previos como el de (UNDP, 2021) se señala que la falta de interfaces comprensibles constituye una de las principales barreras para la adopción de herramientas de análisis avanzado en el sector agroproductivo, especialmente en economías en desarrollo.

Además de las ventajas mencionadas, es importante considerar los retos técnicos concretos que podrían dificultar la futura implementación de este tipo de arquitecturas en el contexto ecuatoriano. Uno de los desafíos más significativos es la conectividad limitada en zonas rurales, especialmente en áreas de producción

bananera donde la cobertura de internet es intermitente o inexistente. Esto puede afectar la transmisión en tiempo real de datos ambientales, edafológicos o de sensores IoT, reduciendo la capacidad de los sistemas para generar predicciones actualizadas de forma continua.

Otro factor crítico es la variabilidad en la calidad y calibración de los sensores utilizados. Muchos productores, especialmente pequeños y medianos, no cuentan con acceso a dispositivos de alta precisión o mantenimiento adecuado, lo que puede comprometer la integridad de los datos recopilados y, en consecuencia, la fiabilidad de las predicciones.

Asimismo, se presenta el reto de la interoperabilidad entre diversas fuentes de datos, ya que no siempre existen estándares unificados para la integración de datos agroclimáticos, históricos de producción o análisis de suelos. Esta fragmentación dificulta la automatización del flujo de información entre sistemas y plataformas, exigiendo mecanismos de normalización, limpieza y estructuración de datos antes de su procesamiento.

Finalmente, debe considerarse la formación técnica del personal agrícola. Para que una arquitectura de este tipo tenga impacto real, se requiere que tanto los encargados de recolectar los datos, como los usuarios finales (productores, técnicos y tomadores de decisiones) tengan una comprensión básica del funcionamiento de los sistemas, lo que implica esfuerzos paralelos en capacitación y alfabetización digital.

A pesar de estas limitaciones, el análisis realizado proporciona un marco conceptual estructurado que puede servir como referencia para investigadores y desarrolladores interesados en el diseño de sistemas predictivos agrícolas. En este sentido, el trabajo no busca cerrar la discusión, sino abrir una línea de investigación orientada a la implementación y validación progresiva de arquitecturas inteligentes en el sector bananero ecuatoriano.

Conclusiones

Las transformaciones digitales en el sector agrícola requieren no solo el desarrollo de modelos predictivos avanzados, sino también arquitecturas de sistemas capaces de integrar datos heterogéneos, escalar progresivamente y adaptarse a contextos productivos específicos. En este sentido, el presente trabajo propone y analiza un marco arquitectónico conceptual orientado a sistemas de predicción de la producción de banano en Ecuador, atendiendo a las particularidades técnicas, ambientales y organizacionales del sector.

La arquitectura planteada se fundamenta en un enfoque modular y por capas, que permite separar de forma clara las responsabilidades asociadas a la adquisición de datos, el procesamiento mediante técnicas de aprendizaje automático y la visualización de resultados. Esta organización estructural facilita la comprensión del sistema, su mantenibilidad y su potencial evolución hacia implementaciones funcionales, aspectos clave en entornos agrícolas caracterizados por limitaciones de infraestructura y variabilidad en la calidad de los datos.

El diseño propuesto promueve tanto la flexibilidad como la escalabilidad, facilitando su adopción progresiva en distintos

contextos agrícolas. Adicionalmente, la incorporación de herramientas de visualización adaptadas a los distintos perfiles de usuario busca asegurar una interpretación efectiva de los resultados, apoyando una toma de decisiones más fundamentada en el ámbito productivo.

El análisis realizado, apoyado en un enfoque híbrido de carácter conceptual y estructural, permitió examinar la coherencia interna del diseño arquitectónico y su alineación con atributos teóricos deseables en sistemas de información. Por un lado, las dimensiones del modelo de (DeLone & McLean, 1992) fueron utilizadas como marco de referencia para derivar criterios de calidad aplicables al diseño, sin pretender evaluar el éxito operativo del sistema. Por otro lado, la aplicación de métricas estructurales adaptadas del modelo ISA propuesto por (Vasconcelos et al., 2007), permitió caracterizar propiedades como la complejidad, la cohesión y la segmentación funcional de la arquitectura, aportando una visión complementaria desde la ingeniería de sistemas.

Los resultados de este análisis no constituyen evidencia empírica de desempeño, sino indicadores analíticos que sugieren la viabilidad conceptual del marco propuesto como base para el desarrollo de sistemas predictivos agrícolas. En este contexto, el principal aporte del trabajo radica en ofrecer una referencia estructurada para investigadores y desarrolladores interesados en diseñar soluciones inteligentes orientadas al cultivo de banano, especialmente en países en desarrollo con características productivas similares a las del Ecuador.

Como líneas de trabajo futuro, se plantea la implementación progresiva de la arquitectura en escenarios piloto, en diferentes escalas de producción, desde pequeñas fincas hasta plantaciones de gran escala, lo que permitirá evaluar empíricamente su desempeño predictivo, su robustez frente a datos reales y su aceptación por parte de los usuarios finales. Asimismo, se considera relevante explorar su integración con tecnologías complementarias, como sensores IoT, sistemas de información geográfica y plataformas de análisis en tiempo real, con el fin de avanzar hacia enfoques más integrales de agricultura de precisión.

En conclusión, este estudio no busca presentar un sistema terminado, sino sentar las bases conceptuales y arquitectónicas necesarias para el desarrollo informado de sistemas de predicción aplicados a la producción del banano en Ecuador, contribuyendo al fortalecimiento teórico y metodológico de la investigación en tecnologías digitales para el sector agrícola.

Referencias Bibliográficas

- Baswaraju, S., Maheswari, V., Chennam, K., Thirumalraj, A., Kantipudi, M., & Aluvalu, R. (2023). Future Food Production Prediction Using AROA Based Hybrid Deep Learning Model in Agri-Sector. *Human-Centric Intelligent Systems*, 3(1), 521–536. <https://doi.org/10.1007/s44230-023-00046-y>
- Bhatta, S., Pant, P., Kapri, R., & Mishra, B. (2023). Production efficiency of banana cultivation in Chitwan District, Nepal. *Cogent Food & Agriculture*, 9(1). <https://doi.org/10.1080/23311932.2023.2212461>

- Bustalíño, B., Galos, T., & Cajudo, S. (2024). Arima Modeling and Forecasting of Banana Production in Eastern Visayas, Philippines: 2010-2022. *Research Square*. <https://doi.org/10.21203/rs.3.rs-4260041/v1>
- Da Silva, A., Oliveira, F., Da Fonseca, R., & Braga, G. (2023). Yield prediction in banana (*Musa sp.*) using STELLA model. *Acta Scientiarum, Agronomy*, 45(1), e58947. <https://doi.org/10.4025/actasciagron.v45i1.58947>
- DeLone, W., & McLean, E. (1992). Information Systems Success: The Quest for the Dependent Variable. *Information Systems Research*, 3(1), 60–95. <https://doi.org/10.1287/isre.3.1.60>
- FAO (2025). *Banana Market Review. Preliminary results 2024*. <https://openknowledge.fao.org/handle/20500.14283/cd3731en>
- Khan, T., Qiu, J., Qureshi, M., Iqbal, M., Mehmood, R., & Hussain, W. (2020). Agricultural Fruit Prediction Using Deep Neural Networks. *Procedia Computer Science*, 174, 72–78. <https://doi.org/10.1016/j.procs.2020.06.058>
- Khan, T., Sherazi, H., Ali, M., Letchmunan, S., & Butt, U. (2021). Deep Learning-Based Growth Prediction System: A Use Case of China Agriculture. *Agronomy*, 11(8). <https://doi.org/10.3390/agronomy11081551>
- Okolie, H., Obasi, C., & Obidiebube, E. (2019). Yield prediction and predictors in banana/plantain cultivars (*Musa spp.*). *Nigerian Journal Of Crop Science*, 6(3), 32–39. <https://www.researchgate.net/publication/348834066>
- Olivares, B., Vega, A., Rueda Calderón, M., Montenegro-Gracia, E., Araya-Almán, M., & Marys, E. (2022). Prediction of Banana Production Using Epidemiological Parameters of Black Sigatoka: An Application with Random Forest. *Sustainability*, 14(21). <https://doi.org/10.3390/su142114123>
- Pandya, U., Mudaliar, A., & Gaikwad, A. (2023). Forecasting of Banana Crop Productivity Using Geospatial Approach: A Case Study of Anand District. *Environmental Sciences Proceedings*, 25(1). <https://doi.org/10.3390/ECWS-7-14248>
- Patrick, S., Mirau, S., Mbalawata, I., & Leo, J. (2023). Time series and ensemble models to forecast banana crop yield in Tanzania, considering the effects of climate change. *Resources, Environment and Sustainability*, 14(1). <https://doi.org/10.1016/j.resenv.2023.100138>
- Prity, K., Dinesh, P., Sathish, K., Yogesh, L., & Ashish, M. (2022). An artificial neural network approach for predicting area, production and productivity of Banana in Gujarat. *The Pharma Innovation Journal*, 11(4), 816–821. <https://www.thepharmajournal.com/special-issue?year=2022&vol=11&issue=4S&ArticleId=11983>
- Quiloango-Chimarro, C., Gioia, H., & Costa, J. (2024). Typology of Production Units for Improving Banana Agronomic Management in Ecuador. *AgriEngineering*, 6(3), 2811–2823. <https://doi.org/10.3390/agriengineering6030163>
- Rebortera, M., & Fajardo, A. (2019). An Enhanced Deep Learning Approach in Forecasting Banana Harvest Yields. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 10(9). <https://doi.org/10.14569/IJACSA.2019.0100935>
- Rebortera, M., & Fajardo, A. (2019). Forecasting Banana Harvest Yields using Deep Learning. *2019 IEEE 9th International Conference on System Engineering and Technology (ICSET)*, Shah Alam, Malaysia. 380–384. <https://doi.org/10.1109/ICSEngT.2019.8906427>
- Sacala, R., Abad, J., & Arboleda, E. (2024). Integration Of Machine Learning Techniques in Banana Production: A Literature Review. *JSRED-International Journal of Scientific Research and Engineering Development*, 7(1), 677–695. <https://doi.org/10.5281/zenodo.10667895>
- Soares, J., Pasqual, M., Lacerda, W., Silva, S., & Donato, S. (2014). Comparison of techniques used in the prediction of yield in banana plants. *Scientia Horticulturae*, 167, 84–90. <https://doi.org/10.1016/j.scienta.2013.12.012>
- Souza, A., Neto, A., Piazentin, J., Junior, B., Gomes, E., Bonini, C., & Putti, F. (2019). Artificial neural network modelling in the prediction of bananas' harvest. *Scientia Horticulturae*, 257. <https://doi.org/10.1016/j.scienta.2019.108724>
- Vaca, E., Gaibor, N., & Kovács, K. (2020). Analysis of the chain of the banana industry of Ecuador and the European market. *Applied Studies in Agribusiness and Commerce*, 14(1-2), 57–65. <https://doi.org/10.19041/APSTRACT/2020/1-2/7>
- Vasconcelos, A., Sousa, P., & Tribolet, J. (2007). Information System Architecture Metrics: an Enterprise Engineering Evaluation Approach. *The Electronic Journal Information Systems Evaluation*, 10(1), 91–122. <https://academic-publishing.org/index.php/ejise/article/view/317>
- UNDP (2021). *Precision Agriculture for Smallholder Farmers*. United Nations Development Programme Global Centre for Technology, Innovation and Sustainable Development, Singapore. <https://www.undp.org/sites/g/files/zskgke326/files/2021-10/UNDP-Precision-Agriculture-for-Smallholder-Farmers.pdf>