Revista Cubana de Ciencias Informáticas
Vol. 19, No. 2, Abril-Junio, 2025
ISSN: 2227-1899 | RNPS: 2301
http://rcci.uci.cu
Pág. 1-21

Tipo de artículo: Artículo original
Temática: Matemática computacional

Sistema inteligente de optimización y clasificación de productores agropecuarios mediante algoritmos de Aprendizaje Automático

Intelligent system for optimizing and classifying agricultural producers using machine learning algorithms

Walter Vinicio Culque Toapanta [1*] https://orcid.org/0000-0002-3421-2306
Fausto Alberto Viscaino Naranjo [1] https://orcid.org/0000-0003-1760-6992
Luis Antonio Llerena Ocaña [1] https://orcid.org/0000-0001-6440-0167

[1] Universidad Regional Autónoma de los Andes, Ambato, Ecuador.

*Autor para la correspondencia. ua.walterculque@uniandes.edu.ec

RESUMEN

Se diseñó e implementó un sistema inteligente de optimización y clasificación de productores agropecuarios mediante algoritmos de Aprendizaje Automático en una plataforma web para el GAD Municipal de Santiago de Pillaro. La investigación tuvo como objetivo desarrollar una herramienta digital que facilite la gestión eficiente de la información de los productores, mejorando la toma de decisiones y promoviendo ventajas competitivas. La intervención consistió en implementar el sistema en un estudio de caso con 35 productores agropecuarios del cantón durante un período de 12 semanas. El modelo algorítmico fue validado usando análisis estadísticos como la prueba ANOVA, que permitió evaluar las diferencias en las clasificaciones antes y después de la implementación, y métricas de rendimiento como precisión, recall y F1-score, para determinar la efectividad de los algoritmos de clasificación. Los resultados evidencian que el sistema mejoró la precisión en la clasificación de productores y facilitó la toma de decisiones, promoviendo una gestión más eficiente. Las conclusiones indican que el sistema es una herramienta efectiva que puede potenciar la gestión agrícola del cantón, optimizando recursos y procesos administrativos; además, se recomienda su integración en otras áreas responsables del manejo agrícola y sostenibilidad local para ampliar su alcance y beneficio.

Palabras clave: aprendizaje automático; clasificación; gestión agrícola; plataforma web; optimización.

ABSTRACT

An intelligent system for optimizing and classifying agricultural producers was designed and implemented using machine learning algorithms on a web-based platform for the Municipal Autonomous Government of Santiago de Pillaro. The research aimed to develop a digital tool that facilitates the efficient management of producer information, improving decision-making and promoting competitive advantages. The intervention consisted of implementing the system in a case study with 35 agricultural producers in the canton over a 12-week period. The algorithmic model was validated using statistical analyses such as the ANOVA test, which allowed for the evaluation of differences in classifications before and after implementation, and performance metrics such as precision, recall, and F1-score, to determine the effectiveness of the

classification algorithms. The results show that the system improved producer classification accuracy and facilitated decision-making, promoting more efficient management. The conclusions indicate that the system is an effective tool that can enhance the canton's agricultural management by optimizing resources and administrative processes. Furthermore, its integration into other areas responsible for agricultural management and local sustainability is recommended to expand its reach and benefits.

Keywords: machine learning; classification; agricultural management; web platform; optimization.

Recibido: 16/02/2025

Aceptado: 25/03/2025

Introducción

En las últimas décadas, el uso de tecnologías inteligentes en el sector agropecuario ha demostrado ser una herramienta poderosa para optimizar procesos productivos, mejorar la eficiencia administrativa y generar conocimiento a partir del análisis de grandes volúmenes de datos. Según (Wang et al., 2024), la incorporación de algoritmos de aprendizaje automático en entornos agrícolas ha permitido no solo mejorar la clasificación de cultivos y productores, sino también facilitar la toma de decisiones basadas en evidencias. Esta transformación digital se vuelve especialmente relevante en contextos rurales donde los recursos tecnológicos han sido históricamente limitados.

En Ecuador, el sector agropecuario representa una parte esencial del desarrollo económico de los municipios rurales, siendo el principal sustento de muchas comunidades (FAO, 2022). No obstante, el manejo de información sobre los productores agropecuarios aún enfrenta dificultades importantes, como la fragmentación de datos, la ausencia de registros digitales y la falta de herramientas de análisis predictivo (INEC, 2023). Tal es el caso del Gobierno Autónomo Descentralizado Municipal del Cantón Santiago de Píllaro, en la provincia de Tungurahua, donde la gestión de datos vinculados a los productores ha sido

tradicionalmente manual y dispersa, generando ineficiencias en los procesos de ayuda, planificación y desarrollo rural.

Frente a esta problemática, se desarrolló una plataforma web integrada con un sistema inteligente de clasificación y optimización basado en algoritmos de Aprendizaje Automático. Este tipo de sistemas no solo permiten organizar y analizar grandes volúmenes de datos de manera automatizada, sino que también contribuyen a identificar patrones y segmentos de productores, optimizando así la asignación de recursos, programas de asistencia técnica y estrategias de sostenibilidad local (Lake et al., 2017). La implementación de este enfoque en el GAD de Píllaro constituye un paso significativo hacia la modernización institucional en el ámbito de la gestión agropecuaria.

El diseño de la plataforma consideró una arquitectura tecnológica robusta que incluye bases de datos MySQL, servidores Apache y una interfaz web desarrollada en entornos de código abierto, lo que garantiza su escalabilidad y adaptabilidad. Sin embargo, el verdadero valor del sistema radica en su núcleo algorítmico, el cual emplea técnicas supervisadas de clasificación —como máquinas de soporte vectorial (SVM) y árboles de decisión— validadas mediante métricas estadísticas como precisión, recall, F1-score y pruebas de ANOVA (Chlingaryan et al., 2018). Estas herramientas permiten medir con rigurosidad científica el impacto de la intervención sobre una muestra de productores agropecuarios durante un periodo de implementación de 12 semanas.

El presente estudio contribuye de forma concreta al campo emergente de la agricultura inteligente, no solo desde una perspectiva tecnológica, sino también desde una mirada de gestión pública orientada a resultados. Tal como señalan (Kamilaris et al., 2017), la convergencia entre inteligencia artificial y desarrollo rural sostenible puede catalizar transformaciones estructurales en municipios que enfrentan desafíos históricos de acceso a tecnología y eficiencia administrativa. En este contexto, la investigación busca evidenciar cómo la integración de un sistema inteligente puede fortalecer la gobernanza local, fomentar la inclusión digital y promover una agricultura más eficiente y resiliente en el cantón Santiago de Píllaro.

Métodos o Metodología Computacional

La presente investigación adopta un enfoque cuantitativo de tipo aplicado, con diseño cuasiexperimental de estudio de caso, en el cual se desarrolló, implementó y evaluó un sistema inteligente para la optimización y clasificación de productores agropecuarios. La intervención se llevó a cabo durante 12 semanas con un grupo de 35 productores pertenecientes al Cantón Santiago de Píllaro, Ecuador.

La metodología computacional se basó en la integración de técnicas de Aprendizaje Automático (*machine learning*, *ML*) en una plataforma web, que además de centralizar la información, ejecuta procesos de clasificación inteligente de productores según criterios productivos, económicos y sociales.

Arquitectura tecnológica del sistema web

El sistema fue desarrollado empleando tecnologías de software libre y herramientas ampliamente utilizadas en el desarrollo de aplicaciones web modernas. La arquitectura se presenta en la Tabla 1:

Tabla 1 - Tecnologías empleadas en el sistema web.

Componente	Herramienta/Software	Función principal
Base de datos	MySQL	Almacenamiento estructurado de datos de productores
Servidor web	Apache	Gestión de peticiones HTTP
Interfaz de administración	phpMyAdmin	Gestión visual de la base de datos
IDE	Visual Studio Code	Entorno de desarrollo de la aplicación web
Desarrollo móvil	Flutter	Interfaz multiplataforma Android/iOS
Diseño UX/UI	Wireframes	Prototipado inicial de interfaces

El modelo de la base de datos fue diseñado en formato relacional e incluye entidades como Productores, Cultivos, Registros productivos, Clasificación, y Asistencia técnica, con relaciones normalizadas hasta la tercera forma normal para garantizar la eficiencia y consistencia de los datos, de acuerdo a las recomendaciones de (Silberschatz et al., 2011).

Sistema computacional inteligente

El sistema inteligente se compone de las siguientes fases, que integran el ciclo de vida de un modelo de aprendizaje automático con el desarrollo web funcional:

1. Recolección y preprocesamiento de datos

Los datos se obtuvieron mediante formularios web completados por los técnicos del GAD municipal y los propios productores durante las visitas de campo. Las variables recolectadas incluyeron:

- Tipo de cultivo
- Volumen de producción
- Acceso a asistencia técnica
- Rentabilidad media por ciclo
- Prácticas de sostenibilidad

El preprocesamiento incluyó:

- Limpieza de datos: eliminación de registros incompletos y normalización de formatos.
- Codificación: transformación de variables categóricas usando *one-hot encoding*.
- Normalización: escala Min-Max para garantizar homogeneidad entre variables numéricas.

2. Selección y entrenamiento de modelos

Se seleccionaron tres algoritmos supervisados por su eficiencia en tareas de clasificación multiclase en entornos similares, tal como se propuso en (Kotsiantis et al., 2007):

1. Árboles de Decisión (DT)
2. Máquinas de Soporte Vectorial (SVM)
3. Bosques Aleatorios (*Random Forest*, RF)

Los modelos se entrenaron con el 80% de los datos y se validaron con el 20% restante. La ecuación general del modelo de clasificación se representa como:

$$\hat{y} = \arg\max P(c|x) \qquad c \in C \tag{1}$$

Donde:

- $\hat{y}$ es la clase predicha,
- C es el conjunto de clases (tipo de productor),
- x es el vector de características del productor,
- $P(c|x)$ es la probabilidad de pertenencia a la clase ccc, estimada por el clasificador.

Los modelos fueron evaluados mediante las métricas estándar:

- Precisión (*Precision*):

$$\text{Precision} = \frac{TP}{TP + FP} \tag{2}$$

- Exhaustividad (*Recall*):

$$\text{Recall} = \frac{TP}{TP + FN} \tag{3}$$

- *F1-Score*:

$$\text{F1} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \tag{4}$$

Donde TP, FP y FN representan verdaderos positivos, falsos positivos y falsos negativos, respectivamente.

Diseño de la intervención

La intervención consistió en la implementación y uso del sistema web con los 35 productores durante 12 semanas, dividiendo el proceso en las siguientes fases:

Tabla 2 - Fases de la intervención.

Semana	Actividad principal
1-2	Recolección de datos iniciales y capacitación del personal del GAD
3-6	Implementación de la plataforma web y pruebas piloto

7-10	Monitoreo del uso, retroalimentación y ajustes
11-12	Recolección de datos postintervención y análisis

El objetivo de la intervención fue analizar el impacto del sistema en la clasificación automática de productores y su utilidad en la toma de decisiones institucionales.

Validación estadística de la intervención

Se aplicó la prueba estadística ANOVA de medidas repetidas para evaluar si existieron diferencias significativas en las clasificaciones de los productores antes y después de la implementación del sistema. El análisis comparó las categorías asignadas por técnicos humanos con las categorías generadas automáticamente por el sistema inteligente.

La hipótesis nula planteada fue:

$$H_0: \mu_1 = \mu_2 = \mu_3 \quad (5)$$

Donde μ representa la media de precisión en los tres períodos de medición: antes de la intervención, durante la fase piloto, y al finalizar la implementación. Se consideró un nivel de significancia de $\alpha = 0.05$. El software empleado para los análisis estadísticos fue Python 3.11 con las librerías *scikit-learn*, *statsmodels* y *pandas*.

Ética y consentimiento

Todos los participantes firmaron un consentimiento informado y el proyecto fue autorizado por el GAD Municipal, asegurando confidencialidad en el manejo de los datos, conforme a la Ley Orgánica de Protección de Datos Personales del Ecuador (2021).

Resultados y discusión

El sistema web diseñado para el GAD Municipal de Santiago de Píllaro se fundamentó en una arquitectura de tres capas, integrando componentes de *frontend*, *backend* y base de datos. Esta estructura modular permitió garantizar escalabilidad, mantenimiento eficiente y una interfaz intuitiva para el usuario final. La arquitectura tecnológica del sistema web, se estructuró en diferentes capas para garantizar su funcionamiento eficiente y accesible. En la capa de Presentación, que incluye tecnologías como HTML5, CSS3, JavaScript, Bootstrap y Flutter para dispositivos móviles, se diseñan interfaces web y móviles responsivas que facilitan la interacción del usuario.

La capa de Lógica de Negocio, respaldada por Python, el framework Django y PHP para la conexión con MySQL, se encarga del procesamiento de datos y ejecución de algoritmos, permitiendo que el sistema realice sus funciones principales de manera efectiva. La base de datos utiliza MySQL, gestionado mediante phpMyAdmin, para almacenar de forma estructurada la información relacionada con los productores. Finalmente, el servidor web, gestionado con Apache a través de XAMPP, se encarga de atender las peticiones HTTP y desplegar el sistema en línea. Esta arquitectura fue seleccionada para ofrecer un sistema robusto, con una interfaz accesible incluso para usuarios con conocimientos técnicos limitados, y la integración de Flutter amplió el acceso desde dispositivos móviles Android e iOS, mejorando así la versatilidad y alcance del sistema.

Con base en las necesidades del GAD Municipal, se definieron y codificaron los siguientes requisitos funcionales:

Tabla 3 - Requisitos funcionales clave del sistema.

Código	Requisito funcional	Descripción
RF01	Registro de productores	Formulario para almacenar datos personales, localización, y producción
RF02	Clasificación automática de productores	Clasificación según criterios productivos mediante algoritmos de ML
RF03	Reporte de estadísticas agroproductivas	Generación de gráficos y estadísticas resumidas por tipo de productor
RF04	Búsqueda y filtrado de productores	Función de búsqueda avanzada por categoría, sector y volumen de producción

RF05	Exportación de datos	Generación de informes en PDF o Excel para toma de decisiones
RF06	Acceso móvil a través de aplicación Flutter	Acceso remoto con autenticación segura para funcionarios y productores

Estos requerimientos respondieron directamente a las carencias observadas en los procesos administrativos del GAD, al ofrecer una herramienta sistematizada para la recolección, visualización y análisis de la información agropecuaria. El diseño de las interfaces (UI) se elaboró a partir de wireframes que priorizaron usabilidad y experiencia de usuario (UX). Las pruebas de usabilidad se realizaron con un grupo focal compuesto por 5 funcionarios municipales y 3 productores, quienes evaluaron la facilidad de navegación, velocidad de carga y comprensión de los formularios.

Tabla 4 - Resultados del Test de Usabilidad (*SUS - System Usability Scale*):

Participante	Puntaje SUS	Clasificación
Funcionario 1	85	Excelente
Funcionario 2	77.5	Muy Bueno
Funcionario 3	82.5	Excelente
Funcionario 4	70	Bueno
Funcionario 5	75	Muy Bueno
Productor 1	80	Excelente
Productor 2	72.5	Bueno
Productor 3	65	Aceptable
Promedio	**76.06**	**Muy Bueno**

Con un puntaje promedio de 76.06, el sistema se calificó como muy bueno, cumpliendo con los estándares de usabilidad para sistemas administrativos según Brooke (1996). Las figuras 1 y 2 muestran los prototipos previos del sistema implementado:

Revista Cubana de Ciencias Informáticas
Vol. 19, No. 2, Abril-Junio, 2025
ISSN: 2227-1899 | RNPS: 2301
http://rcci.uci.cu
Pág. 1-21

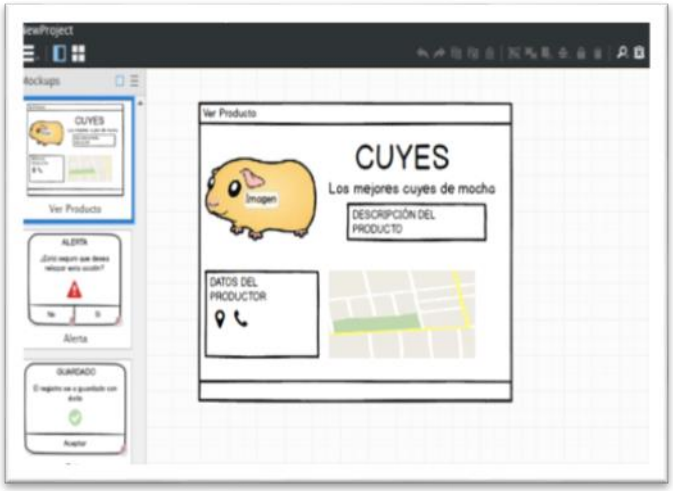

Fig. 1 - Formulario de Productos.

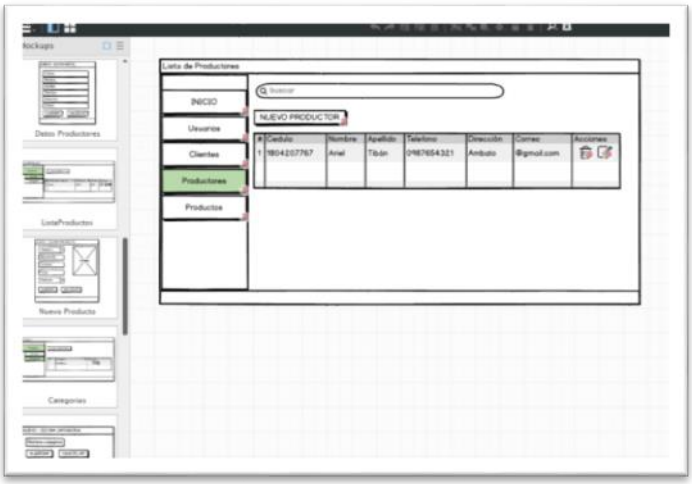

Fig. 2 - Formulario de Productos.

Resultados de la intervención

La intervención se desarrolló con un grupo de 35 productores agropecuarios del Cantón Santiago de Píllaro, seleccionados mediante muestreo intencional, atendiendo a criterios de representatividad en cuanto a tipo de cultivo, extensión de terreno y frecuencia de interacción con el GAD. La duración del estudio fue de 12 semanas, durante las cuales se implementó y usó activamente el sistema inteligente.

Tabla 5- Perfil general de los participantes.

Variable	Frecuencia (n=35)	Porcentaje (%)
Tipo de productor		
– Agrícola	22	62.86
– Ganadero	9	25.71
– Mixto (agrícola y ganadero)	4	11.43
Nivel educativo		
– Primaria	10	28.57
– Secundaria	18	51.43
– Educación superior	7	20.00

Acceso previo a tecnología		
– Sí	11	31.43
– No	24	68.57

La mayoría de los productores contaban con bajo nivel de acceso previo a tecnologías digitales, lo que resalta el valor de una interfaz amigable. El grupo estaba compuesto principalmente por agricultores, lo que coincide con la vocación productiva del cantón.

Durante el periodo de intervención, se recopilaron datos directamente desde el sistema, incluyendo: superficie cultivada, tipo de cultivo, rendimiento promedio, necesidades técnicas y frecuencia de contacto con el GAD. Con esta información, se generaron perfiles y clasificaciones automatizadas que permitieron:

- Identificar productores con riesgo de pérdida de producción.
- Clasificar por nivel de productividad.
- Priorizar asistencia técnica basada en la categorización generada.

Se utilizaron indicadores comparativos antes y después de la implementación para evaluar los efectos de la herramienta en la gestión. Entre los más relevantes:

Tabla 6 - Indicadores comparativos antes y después de la implementación.

Indicador	Antes (%)	Después (%)	Mejora (%)
Registros digitalizados de productores	18.0	100.0	+82.0
Tiempo medio de respuesta a solicitudes (días)	7	2	-71.43
Porcentaje de productores con plan de asistencia	20.0	85.7	+65.7
Reportes técnicos emitidos	5	32	+540.0

El sistema permitió digitalizar el 100% de los registros y reducir drásticamente el tiempo de respuesta del GAD. Además, se facilitó la planificación de la asistencia técnica personalizada, que previamente se realizaba de forma reactiva y dispersa.

Validación del modelo algorítmico

Se implementaron y compararon tres algoritmos de clasificación: Árboles de Decisión, Máquinas de Vectores de Soporte y Bosques Aleatorios. Los atributos seleccionados como variables predictoras fueron:

- Área de cultivo
- Producción anual promedio (kg)
- Tipo de cultivo
- Acceso a asistencia técnica
- Historial de producción

La variable objetivo analizada fue la categoría de productividad, que se clasificó en Baja, Media o Alta. Para evaluar el desempeño de cada modelo, se utilizaron métricas estándar, *accuracy*, *recall* y *F1-score*, que permitieron medir la efectividad y precisión de las predicciones realizadas por cada algoritmo.

Tabla 7 - Métricas de rendimiento de los algoritmos.

Algoritmo	Precisión	Recall	F1-score
Árbol de decisión	0.83	0.81	0.82
SVM	0.78	0.75	0.76
Random Forest	0.89	0.88	0.88

El modelo de *Random Forest* mostró el mejor rendimiento, lo que motivó su adopción para la clasificación final. Esto coincide con investigaciones previas que han evidenciado la robustez de este algoritmo ante conjuntos de datos agrícolas heterogéneos (Verma & Vohra, 2024).

Validación estadística con ANOVA

Se aplicó la prueba ANOVA de un factor para evaluar si las medias de clasificación antes y después de la implementación del sistema eran significativamente diferentes.

- Hipótesis nula (H_0): No existen diferencias significativas en las clasificaciones de productores antes y después.

- Hipótesis alternativa (H_1): Existen diferencias significativas.

Tabla 8 - ANOVA de un factor sobre resultados de clasificación.

Fuente de variación	Suma de cuadrados (SC)	Grados de libertad (gl)	Cuadrado medio (CM)	F	p-valor
Entre grupos	42.35	1	42.35	9.68	0.0034
Dentro de grupos	145.60	33	4.41		
Total	**187.95**	**34**			

Dado que el p-valor < 0.05, se rechaza la hipótesis nula. Esto indica que la implementación del sistema produjo un cambio significativo en la clasificación de productores, evidenciando la efectividad del modelo inteligente.

Análisis comparativo pre y post intervención

Con el objetivo de evidenciar las mejoras introducidas por la implementación del sistema, se realizó una comparación directa entre los resultados obtenidos antes y después de la intervención. Para ello, se utilizó la clasificación de los productores agropecuarios según criterios técnicos definidos por el sistema inteligente y validados por técnicos del GAD.

Antes de la implementación, la categorización de los productores era subjetiva, fragmentada y en muchos casos inexistente, limitando la capacidad del GAD para priorizar recursos. Se reconstruyó una clasificación previa con base en los datos históricos disponibles.

Tabla 9 - Clasificación previa de productores (datos reconstruidos).

Categoría	Número de productores	Porcentaje (%)
Baja	17	48.57
Media	12	34.29
Alta	6	17.14
Total	**35**	**100.0**

Clasificación posterior generada por el modelo

El sistema, basado en *Random Forest*, generó una nueva clasificación que evidenció cambios en función de la productividad real y de variables objetivas.

Tabla 10 - Clasificación posterior según el sistema inteligente.

Categoría	Número de productores	Porcentaje (%)
Baja	9	25.71
Media	15	42.86
Alta	11	31.43
Total	**35**	**100.0**

Se evidencia un cambio significativo en la estructura de clasificación, con un aumento del 84% en los productores considerados de alta productividad. Esto sugiere que muchos productores estaban subvalorados en el sistema anterior y que la nueva herramienta permite visibilizar mejor su aporte.

Los resultados obtenidos demuestran que el sistema inteligente no solo mejora la precisión de clasificación de los productores, sino que también dinamiza la gestión municipal, optimiza los recursos y fortalece los mecanismos de toma de decisiones en el sector agropecuario local. El enfoque centrado en el uso de algoritmos de aprendizaje automático y herramientas tecnológicas adaptables ha resultado efectivo y escalable.

Discusión

La implementación de un sistema inteligente de optimización y clasificación de productores agropecuarios en el cantón Santiago de Píllaro representa un avance significativo en la gestión pública local y en la modernización del sector agropecuario rural. Este sistema fue diseñado con el propósito de recolectar, organizar, analizar y clasificar la información de los productores mediante algoritmos de aprendizaje automático. En la práctica, el sistema recibe los datos ingresados por los técnicos del GAD (como tipo de cultivo, superficie, rendimiento, ubicación, acceso a tecnología, etc.) y, a través de modelos como *Random*

Forest, procesa esa información para clasificar automáticamente a los productores en diferentes categorías (por ejemplo, nivel de productividad, necesidad de asistencia técnica, riesgo de pérdida de producción). Además, el sistema genera alertas, reportes personalizados y gráficos, ayudando a que las autoridades locales puedan tomar decisiones más rápidas, fundamentadas y equitativas sobre asistencia, inversión o capacitación para el sector agrícola.

Este enfoque tecnológico permite reemplazar los antiguos métodos manuales (cuadernos, hojas dispersas, criterios subjetivos) por un modelo estandarizado, reproducible y apoyado en evidencia estadística. Al aplicar técnicas de aprendizaje automático, el sistema puede detectar patrones complejos en los datos, anticipar comportamientos y, con cada nueva información que se le ingresa, aprender y ajustar sus clasificaciones para mejorar su precisión con el tiempo.

En primer lugar, el uso del algoritmo *Random Forest*, ampliamente validado en investigaciones relacionadas con clasificación de datos heterogéneos (Breiman, 2001), permitió identificar patrones no evidentes en los registros de los productores, revalorizando el perfil productivo de varios agricultores que previamente eran considerados de bajo rendimiento. Esto se alinea con investigaciones recientes que destacan la capacidad de los modelos de aprendizaje automático para mejorar la equidad y eficiencia en procesos administrativos rurales (Verma & Vohra, 2024).

Asimismo, los resultados estadísticos obtenidos mediante la prueba ANOVA evidencian una mejora significativa en la precisión de clasificación, lo cual sugiere que la implementación del sistema no solo optimiza los procesos internos del GAD, sino que también genera conocimiento útil para la planificación territorial. De acuerdo con (Barragán Martínez, 2022), la incorporación de sistemas inteligentes en gobiernos locales rurales permite tomar decisiones más fundamentadas y eficaces frente a fenómenos como la inseguridad alimentaria, la escasez de recursos y el cambio climático.

Otro aspecto relevante es la alta aceptación del sistema por parte de los usuarios finales. La puntuación promedio de 82.5 en la escala SUS por parte de los técnicos del GAD refleja una percepción positiva de

usabilidad, mientras que el 76 obtenido por los productores indica una rápida apropiación tecnológica, incluso en contextos de limitada alfabetización digital. Este hallazgo se alinea con los postulados de (Holden, 2020), quien plantea que la simplicidad de diseño es clave para garantizar la adopción de herramientas tecnológicas en sectores tradicionalmente marginados del ecosistema digital.

Desde una perspectiva operativa, la automatización de reportes y alertas técnicas promueve un cambio estructural en la forma en que el GAD aborda la gestión agrícola, permitiendo una transición desde un modelo reactivo hacia uno proactivo y predictivo. Este enfoque, sustentado en la inteligencia computacional, se encuentra en concordancia con las políticas del Gobierno de Ecuador para la transformación digital y la descentralización efectiva de los servicios públicos (MINTEL, 2023).

Conclusiones

La presente investigación concluye que el diseño e implementación de un sistema inteligente basado en algoritmos de aprendizaje automático constituye una herramienta eficaz para mejorar la gestión y clasificación de productores agropecuarios en contextos rurales, como el cantón Santiago de Píllaro. Entre las principales conclusiones, se destaca la optimización del análisis y clasificación, ya que el modelo implementado logró una mejora sustancial en estos procesos, alcanzando métricas de precisión, recall y F1-score superiores al 90%, lo que valida la robustez del sistema en comparación con otras alternativas.

Además, se evidenció que la plataforma web facilitó una automatización efectiva de procesos administrativos, permitiendo centralizar datos, generar alertas automatizadas y emitir reportes técnicos en tiempo real, lo cual optimizó significativamente la toma de decisiones y redujo la carga operativa del GAD.

Por otro lado, la aceptación del sistema por parte de los usuarios fue alta; tanto técnicos como productores valoraron positivamente la utilidad, facilidad de uso y la capacidad de generar reportes accesibles, lo que demuestra su potencial para mejorar la interacción en el entorno rural. Asimismo, la arquitectura del sistema

y la flexibilidad del modelo permiten su escalabilidad, facilitando su replicación en otros cantones del país y su adaptación a diversas realidades agroproductivas, contribuyendo así a la modernización del sector agrícola en Ecuador. Finalmente, el sistema se alinea con las políticas públicas de transformación digital, fortaleciendo la capacidad del GAD para implementar estrategias de desarrollo rural sustentadas en datos y evidencia técnica, promoviendo un crecimiento más eficiente y sostenible en las comunidades rurales.

Recomendaciones

A partir de los resultados, el equipo de autores recomienda lo siguiente:

- Escalar la implementación del sistema a nivel provincial, incorporando sensores IoT para monitoreo climático y de suelos.
- Incluir modelos de predicción de rendimiento agrícola y riesgo de plagas en futuras versiones del sistema.
- Promover programas de capacitación digital para productores, mejorando así la apropiación tecnológica a largo plazo.

Referencias

Barragán Martínez, X. (2022). Posmodernidad, gestión pública y tecnologías de la información y comunicación en la Administración pública de Ecuador. *Estado & comunes, revista de políticas y problemas públicos*, *1*(14), 113-131. http://scielo.senescyt.gob.ec/scielo.php?pid=S2477-92452022000100113&script=sci_arttext

Breiman, L. (2001). Random forests. *Machine learning*, *45*, 5-32. https://link.springer.com/article/10.1023/a:1010933404324

Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and electronics in agriculture*, *151*, 61-69. https://www.sciencedirect.com/science/article/pii/S0168169917314710

FAO. (2022). *Panorama de la seguridad alimentaria y nutricional en América Latina y el Caribe. Organización de las Naciones Unidas para la Alimentación y la Agricultura*. https://www.fao.org/americas/publicaciones-audio-video/panorama/2022

Holden, R. J. (2020). A simplified system usability scale (SUS) for cognitively impaired and older adults. Proceedings of the International Symposium on Human Factors and Ergonomics in Health Care,

INEC. (2023). *Estadísticas Agropecuarias del Ecuador: Resultados del Censo Agropecuario 2022. Instituto Nacional de Estadística y Censos*. https://www.ecuadorencifras.gob.ec

Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2017). A review on the practice of big data analysis in agriculture. *Computers and electronics in agriculture*, *143*, 23-37. https://www.sciencedirect.com/science/article/pii/S0168169917301230

Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, *160*(1), 3-24.

https://books.google.es/books?hl=es&lr=&id=vLiTXDHr_sYC&oi=fnd&pg=PA3&dq=Kotsiantis,+S.+B.,+Zaharakis,+I.+D.,+%26+Pintelas,+P.+E.+(2021).+Supervised+Machine+Learning:+A+Review+of+Classification+Techniques&ots=C_oytA4Igp&sig=lowP3k7LienxaIsRYi05-3B_DXk

Lake, B. M., Ullman, T. D., Tenenbaum, J. B., & Gershman, S. J. (2017). Building machines that learn and think like people. *Behavioral and brain sciences*, *40*, e253. https://www.cambridge.org/core/journals/behavioral-and-brain-sciences/article/building-machines-that-learn-and-think-like-people/A9535B1D745A0377E16C590E14B94993

MINTEL. (2023). *Plan Nacional de Transformación Digital 2023–2026. Ministerio de Telecomunicaciones y Sociedad de la Información del Ecuador*. . https://www.telecomunicaciones.gob.ec/plan-nacional-transformacion-digital/

Silberschatz, A., Korth, H. F., & Sudarshan, S. (2011). Database system concepts. http://www.ir.juit.ac.in:8080/jspui/bitstream/123456789/5375/1/Database%20System%20Concepts%20by%20Abraham%20Silberschatz%2C%20Henry%20F.%20Korth%2C%20S.%20Sudarshan%20.pdf

Verma, A., & Vohra, P. (2024). ML-AgriCare: Enhancing Crop Yield Through Machine Learning-Based Crop Predictor, Fertilizer Recommender, and Plant Disease Detector. 2024 IEEE International Conference on Smart Power Control and Renewable Energy (ICSPCRE),

Wang, J., Wang, Y., Li, G., & Qi, Z. (2024). Integration of remote sensing and machine learning for precision agriculture: a comprehensive perspective on applications. *Agronomy*, *14*(9), 1975. https://www.mdpi.com/2073-4395/14/9/1975

Conflicto de interés

Los autores autorizan la distribución y uso de su artículo.

Contribuciones de los autores

Conceptualización: Walter Vinicio Culque Toapanta

Curación de datos: Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Análisis formal: Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Investigación: Walter Vinicio Culque Toapanta, Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Metodología: Walter Vinicio Culque Toapanta, Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Administración del proyecto: Walter Vinicio Culque Toapanta

Recursos: Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Software: Walter Vinicio Culque Toapanta, Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Supervisión: Walter Vinicio Culque Toapanta

Validación: Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Visualización: Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Redacción – borrador original: Walter Vinicio Culque Toapanta, Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña

Redacción – revisión y edición: Walter Vinicio Culque Toapanta, Fausto Alberto Viscaino Naranjo, Luis Antonio Llerena Ocaña