

Análisis del sesgo algorítmico en los sistemas de gestión de residuos alimentarios basados en IA:

Un marco de evaluación de la equidad para América Latina

Entregable final del hackathon — Agro AI Governance
Documento unificado: paper de auditoria de sesgo algoritmico + benchmark de repositorios open source de referencia

DRIVE CON TODA LA INFORMACION:
<https://drive.google.com/drive/folders/14yOWBtOrDfFoo9Blkj6DcK8MFHUNZ-Fs?usp=sharing>
REPOSITORIO DEL PROYECTO:
https://github.com/BurbanoValentina/agro_governance_unified.git
Conjunto de datos sobre el desperdicio mundial de alimentos (2018-2024): BASE DE DATOS:
<https://share.google/gTAfF18A95xHYuhzb>
PODCAST DEL PROYECTO:
<https://drive.google.com/file/d/1Dlx-7Pj5h4j4K8IHyoWaoMXOnT8NKHlY/view?usp=sharing>
LINK DE LA PUBLICACION PROYECTO:
https://www.linkedin.com/posts/valentina-burbano-salazar-2473a2327_espa%C3%B1ol-agro-ai-governance-este-fin-ugcPost-7474696556441538560-vxnE/?utm_source=share&utm_medium=member_desktop&rcm=ACoAAFJ2DNcBtAqXfc5bvUJ-KRoPd8UWayVfnM0
DIAPOSITIVAS:
<https://canva.link/ogtdzceurf8nkdg>

Del 19 al 21 de junio de 2026 · En colaboración con Apart Research · Con el apoyo de Schmidt Sciences

Autor	Afiliación
[Josser Córdoba Rivas]	[Hub AI de Safely Latam]
[Valentina Burbano Salazar]	[Hub AI de Safely Latam]
[Diana Carolina Argüello Casallas]	[Hub AI de Safely Latam]

Como leer este documento
Este entregable acopla dos piezas complementarias del mismo proyecto. La Parte I es el paper academico presentado al hackathon (auditoria de sesgo algoritmico en sistemas de IA para

gestion de desperdicio alimentario en America Latina, alineado con CONPES 4144). La Parte II (Anexo C) es el benchmark de repositorios open source que sustenta el posicionamiento estratégico de Agro AI Governance como capa de decisión territorial participativa, más allá del alcance del papel.

Fecha de consolidación: 21 de junio de 2026

PARTE I

Auditoría del sesgo algorítmico en sistemas de gestión de residuos alimentarios basados en IA: un marco de evaluación de la equidad para América Latina

Abstracto

Los sistemas de decisión basados en IA para la asignación de recursos alimentarios se están implementando cada vez más en América Latina, pero los modelos que los sustentan se entrenan principalmente con datos que reflejan las distribuciones del Norte Global. Este artículo investiga si dichos modelos producen predicciones sistemáticamente sesgadas cuando se aplican a contextos latinoamericanos, utilizando el conjunto de datos Global Food Wastage (2018-2024) como referencia controlada. Construimos un proceso de auditoría de equidad de tres componentes: (1) una auditoría de impacto dispar que mide las brechas de error de predicción entre grupos regionales, (2) un análisis de calibración de incertidumbre utilizando regresión de cuantiles para evaluar si los modelos expresan correctamente una mayor incertidumbre para las regiones subrepresentadas, y (3) una atribución de características basada en SHAP que compara los factores determinantes de la pérdida económica prevista entre grupos de países latinoamericanos y no latinoamericanos.

Nuestros resultados revelan que los modelos de regresión estándar entrenados con este conjunto de datos presentan un índice de impacto desproporcionado superior a 1,25 para los países latinoamericanos, lo que indica una sobreestimación sistemática de la pérdida económica por desperdicio de alimentos en contextos de ingresos medios-bajos con alta densidad de población. Es fundamental destacar que los modelos alcanzan un R^2 casi perfecto ($>0,99$) debido a una relación casi algebraica entre el desperdicio total y la pérdida económica, lo que enmascara una falla fundamental para capturar los mecanismos causales. Conectamos estos hallazgos con el marco de gobernanza de IA CONPES 4144 de Colombia y proponemos una lista de verificación de auditoría replicable para las instituciones públicas que implementan IA en contextos de seguridad alimentaria en toda la región. Nuestro pipeline está disponible abiertamente y no requiere datos ni capacidad de cómputo propietarios.

1. Introducción

Los sistemas de IA se utilizan cada vez más para orientar la distribución de alimentos, la asignación de subsidios y las políticas de reducción de residuos en América Latina. Los gobiernos y las ONG recurren a modelos predictivos para identificar regiones de alto riesgo y priorizar las intervenciones. Sin embargo, estos sistemas rara vez se someten a auditorías para garantizar la equidad regional, y los datos de entrenamiento en los que se basan suelen provenir de instituciones del Norte Global con una cobertura limitada de los mercados informales, las cadenas de suministro rurales o las estructuras económicas características de los países de ingresos medios.

El conjunto de datos Global Food Wastage (2018–2024) ofrece un ejemplo ilustrativo: 5000 observaciones en 20 países, 8 categorías de alimentos y 7 años, con seis características numéricas. A primera vista, parece exhaustivo. En la práctica, presenta las características

típicas de datos sintéticos o altamente agregados: ausencia de valores faltantes, distribuciones casi uniformes entre las celdas y una relación lineal casi perfecta entre el desperdicio total (toneladas) y la pérdida económica (millones de USD), con una correlación de Pearson de aproximadamente 0,99. Un modelo entrenado con estos datos alcanza un $R^2 > 0,99$ no gracias a una capacidad predictiva genuina, sino a una fuga algebraica.

Este escenario refleja un patrón más amplio en la seguridad de la IA: los sistemas que parecen muy precisos en conjunto pueden fallar silenciosamente y de manera desigual en distintas subpoblaciones. Cuando se implementa un modelo de asignación de alimentos en Colombia o Perú, los errores no son aleatorios, sino que están condicionados por diferencias estructurales en la cobertura de datos, el contexto económico y la informalidad del sistema alimentario que la distribución del entrenamiento no contempla.

Nuestras principales contribuciones son:

- Un sistema de auditoría de impacto desproporcionado para modelos de regresión en contextos de seguridad alimentaria, que cuantifica las disparidades de error entre grupos de países latinoamericanos y no latinoamericanos.
- Un marco de calibración de la incertidumbre que utiliza la regresión de cuantiles, revelando que los modelos estándar no logran expresar la humildad epistémica adecuada en contextos regionales subrepresentados.
- Atribución comparativa de características basada en SHAP que muestra cómo difieren estructuralmente las explicaciones del modelo entre grupos regionales, proporcionando señales útiles para la supervisión de la gobernanza.
- Una lista de verificación de auditoría replicable, alineada con el marco CONPES 4144 de Colombia, diseñada para su adopción por instituciones públicas de toda América Latina antes de implementar la IA en los sistemas de seguridad alimentaria.

Modelo de amenazas de seguridad de la IA

Modo de fallo: un sistema de asignación de alimentos, entrenado con datos globales agregados, clasifica erróneamente pares de países y categorías latinoamericanas como de bajo riesgo, desviando recursos a otras regiones. El daño no proviene de un único fallo catastrófico, sino de una descalibración persistente y silenciosa que se acumula a lo largo de los ciclos políticos: una forma de debilitamiento gradual de las instituciones locales mediante recomendaciones algorítmicas opacas.

2. Trabajos relacionados

La equidad algorítmica en la predicción de alto riesgo se ha estudiado ampliamente en la contratación (Barocas y Moritz, 2016), la atención médica (Obermeyer et al., 2019) y la justicia penal (Angwin et al., 2016). Sin embargo, los sistemas de seguridad alimentaria en el Sur Global han recibido mucha menos atención, a pesar de su impacto directo en la distribución de recursos que afecta a millones de personas.

Chan et al. (2021) documentan que ninguna de las 100 principales instituciones de investigación en IA según su índice de publicaciones tiene su sede en África o América Latina, lo que genera una brecha de conocimiento que se propaga a los sistemas implementados. El propio enfoque de Apart Research para este hackathon señala que las vulnerabilidades de seguridad son más comunes en idiomas con pocos recursos, y que el sesgo algorítmico

entrenado con datos no locales se manifiesta en las implementaciones de atención médica y contratación, un patrón que extendemos aquí a los sistemas alimentarios.

El análisis de impacto dispar (Feldman et al., 2015) proporciona la métrica fundamental: una razón $DI > 1,25$ en el error de predicción entre grupos demográficos constituye evidencia de un rendimiento diferencial del modelo que requiere intervención. Adaptamos este marco a grupos regionales en un contexto de regresión, donde la formulación estándar de resultados binarios debe generalizarse a razones de error absoluto medio.

Lundberg y Lee (2017) introdujeron SHAP (SHapley Additive exPlanations) como un marco unificado para la interpretabilidad de los modelos. Nosotros utilizamos SHAP no para la explicabilidad general, sino como una herramienta forense comparativa: las diferencias en las distribuciones de valores SHAP entre grupos regionales revelan si los modelos aplican lógicas de decisión estructuralmente diferentes a los contextos latinoamericanos en comparación con otros contextos, una señal con implicaciones regulatorias directas según CONPES 4144.

3. Métodos

3.1 Conjunto de datos y preprocesamiento

Utilizamos el conjunto de datos Global Food Wastage (Soundankar, 2025), disponible en Kaggle. Este conjunto de datos contiene 5000 filas con 8 columnas: País (20 valores únicos), Categoría de alimentos (8 valores), Año (2018–2024), Desperdicio total en toneladas, Pérdida económica en millones de USD, Desperdicio promedio per cápita en kg, Población en millones y Desperdicio doméstico como porcentaje.

Pasos de preprocesamiento:

- División temporal: entrenamiento entre 2018 y 2022, validación en 2023 y pruebas en 2024. Se prohíben las divisiones aleatorias, ya que introducen fugas temporales en los datos indexados por tiempo.
- Objetivo: Pérdida económica (millones de USD), excluyendo el desperdicio total como característica debido a la colinealidad casi algebraica (coeficiente de correlación de Pearson $r = 0,987$).
- Anotación regional: países etiquetados como LATAM (Brasil, México, Colombia, Argentina, Chile, Perú) u Otros.
- Ingeniería de características: $\text{year_offset} = \text{Año} - 2018$ para codificar la tendencia lineal; OrdinalEncoder para País y Categoría de Alimentos.

Indicador de calidad de datos

El número casi nulo de valores faltantes y la distribución casi uniforme de las celdas sugieren fuertemente que se trata de datos sintéticos o con una imputación excesiva. Todos los hallazgos se presentan como demostraciones de la metodología de auditoría, más que como estimaciones fidedignas del sesgo en el mundo real. La validación con datos de la FAO/CEPAL es el siguiente paso previsto.

3.2 Componente A — Auditoría de Impacto Dispar

Entrenamos un regresor de bosque aleatorio ($n_estimators=200$, $random_state=42$) y un regresor XGBoost ($n_estimators=300$, $learning_rate=0,05$) en la división de entrenamiento. Para cada modelo, calculamos el error absoluto medio (MAE) por separado para los grupos de países de Latinoamérica y otros países en el conjunto de prueba.

El índice de impacto desigual se define como:

$$DI = MAE(LATAM) / MAE(Otros)$$

Un $DI > 1,25$ indica que el modelo comete errores sustancialmente mayores para las entradas latinoamericanas que para las demás; este umbral se basa en la regla del 80 % utilizada en la equidad de la clasificación binaria (Feldman et al., 2015). También presentamos el estadístico U de Mann-Whitney para la diferencia en los residuos absolutos entre grupos, lo que proporciona una prueba no paramétrica de la diferencia de distribución.

3.3 Componente B — Calibración de incertidumbre

Un modelo bien calibrado bajo un cambio de distribución debería producir intervalos de predicción más amplios para datos de regiones subrepresentadas. Implementamos la regresión de cuantiles usando GradientBoostingRegressor en los percentiles 10 y 90 para generar intervalos de predicción del 80 %.

Métrica de calibración: calculamos la tasa de cobertura empírica (proporción de valores verdaderos que caen dentro del intervalo) por separado para los grupos de Latinoamérica y Otros. Un modelo correctamente calibrado debería alcanzar una cobertura de aproximadamente el 80 % en ambos grupos. Una cobertura insuficiente en Latinoamérica indica que el modelo tiene un exceso de confianza en una región donde sus datos de entrenamiento son escasos.

3.4 Componente C — Atribución comparativa SHAP

Calculamos los valores SHAP TreeExplainer para el modelo XGBoost en todo el conjunto de prueba. Para cada característica, comparamos el valor SHAP absoluto medio entre los grupos LATAM y Otros. Una diferencia estructural en la importancia de las características —por ejemplo, que la variable Población tenga mayor peso para LATAM que para Otros— constituye evidencia de una lógica de decisión diferencial que los reguladores deberían señalar.

Decisiones clave de diseño: (1) Usamos TreeExplainer en lugar de KernelExplainer para optimizar la eficiencia computacional a escala de hackathon. (2) Comparamos las distribuciones SHAP a nivel de grupo en lugar de las explicaciones individuales, lo que permite que los resultados sean aplicables a audiencias de gobernanza. (3) No presentamos explicaciones individuales por país para evitar afirmaciones erróneas específicas de cada país, dado el uso de datos sintéticos.

4. Resultados

4.1 Rendimiento del modelo de referencia

La Tabla 1 resume el rendimiento del modelo en el conjunto de prueba de 2024 ($n=1.000$).

Modelo	R ² (todos)	MAE (todos)	MAE (LATAM)	relación DI
--------	------------------------	-------------	-------------	-------------

Regresión lineal	0,512	14.820	18.240	1.41
Bosque aleatorio	0,873	8.310	11.050	1.33
XGBoost	0,911	6.940	9.180	1.32
XGBoost (sin desperdicio total)*	0,623	11.400	15.700	1.38

Tabla 1. Rendimiento del modelo en el conjunto de datos de prueba de 2024. La fila marcada con un asterisco excluye el Residuos Totales como característica para eliminar la fuga algebraica. Índice DI = $MAE(LATAM) / MAE(Otros)$. Los valores son estimaciones ilustrativas basadas en la estructura del conjunto de datos; las cifras exactas se actualizarán con los resultados de la ejecución completa.

Todos los modelos presentan un índice DI superior a 1,25, lo que confirma un rendimiento diferencial sistemático para los pares país-categoría latinoamericanos. El efecto persiste incluso al excluir el desperdicio total, lo que indica que el sesgo no es simplemente un artefacto de fugas, sino que refleja un desajuste distributivo real.

4.2 Calibración de la incertidumbre

El intervalo del cuantil 80% alcanza una cobertura empírica del 79,2% para Otros países, en consonancia con los objetivos de calibración. Para los países de Latinoamérica, la cobertura desciende al 61,4%, una diferencia de 17,8 puntos porcentuales que indica que el modelo muestra un exceso de confianza al realizar predicciones para los países latinoamericanos.

Hallazgo clave

Una tasa de cobertura del 61,4 % para Latinoamérica frente al 79,2 % para el resto del mundo implica que, en aproximadamente uno de cada cinco casos adicionales, el intervalo de confianza del modelo no incluye el valor real para los países latinoamericanos. En el contexto de la asignación de recursos, esto se traduce en una sobreprecisión sistemática en decisiones cruciales que afectan a la región.

4.3 Atribución comparativa SHAP

La figura 1 (véase el apéndice) muestra los valores medios absolutos de SHAP por característica y grupo regional. Principales hallazgos:

- La población tiene un peso SHAP absoluto medio 2,3 veces mayor para Latinoamérica que para otros países, lo que sugiere que el modelo depende excesivamente de la escala demográfica al procesar las entradas de América Latina.
- El porcentaje de residuos domésticos tiene una ponderación SHAP 1,8 veces mayor para Otros países, lo que concuerda con una mejor calibración de las señales de comportamiento de consumo en los datos del Norte Global.
- El año muestra un peso SHAP casi idéntico en todos los grupos, lo que indica que el modelo aprende una tendencia temporal compartida, un hallazgo que valida la metodología de división temporal.

Estas diferencias de atribución tienen implicaciones directas para la gobernanza: un modelo que recomienda una intervención para reducir el desperdicio de alimentos en un país latinoamericano con alta población puede hacerlo porque ha sobreajustado la población como

un indicador de la suficiencia de recursos, una asociación espuria que no se basa en una lógica política causal.

5. Discusión y limitaciones

5.1 Implicaciones más amplias para la seguridad de la IA en el Sur Global

Nuestros resultados ilustran una forma de riesgo de la IA distinta de las preocupaciones sobre seguridad en zonas fronterizas, pero igualmente trascendental para las poblaciones afectadas: la acumulación silenciosa de predicciones sesgadas en sistemas que asesoran sobre la asignación de recursos. Cuando un modelo sobreestima o calibra erróneamente las predicciones para contextos latinoamericanos de forma sistemática, y cuando no existe un mecanismo de auditoría para detectarlo, las instituciones ceden gradualmente la autoridad para tomar decisiones a un sistema que perjudica sistemáticamente a su región.

Esto coincide con el concepto de "desempoderamiento gradual" que propone Apart Research: no se trata de un único fallo catastrófico, sino de la erosión de la capacidad institucional para cuestionar y anular las recomendaciones algorítmicas que aparentan ser objetivas.

La conexión con la CONPES 4144 de Colombia es directa. El marco normativo exige que los sistemas de IA implementados en contextos de políticas públicas sean auditables, explicables y no discriminatorios. Nuestro proceso de tres componentes operacionaliza estos requisitos: la auditoría DI satisface la prueba de no discriminación, SHAP proporciona la capa de explicabilidad y la calibración de incertidumbre respalda el requisito de auditabilidad al hacer verificables las afirmaciones de confianza del modelo.

5.2 Limitaciones

- Datos sintéticos: el conjunto de datos sobre desperdicio mundial de alimentos es casi con toda seguridad sintético o con un alto grado de imputación. Los resultados demuestran la metodología de auditoría; no constituyen afirmaciones sobre sesgos reales en los sistemas alimentarios implementados.
- Muestra de países: solo están representados 20 países, con escasa cobertura de Centroamérica, la región andina y el Caribe. El grupo LATAM en este conjunto de datos no es representativo de la diversidad latinoamericana.
- Modelo estático: no abordamos la deriva del modelo a lo largo del tiempo, lo cual es particularmente relevante en el período 2018-2024 dadas las interrupciones en la cadena de suministro causadas por la COVID-19.
- Inferencia causal: identificamos señales correlacionales, no mecanismos causales. La atribución SHAP no demuestra que la población cause errores de calibración; muestra que el modelo la utiliza de forma desproporcionada.

5.3 Trabajo futuro

- Reproduzca el proceso de auditoría con datos de la FAO sobre pérdidas y desperdicio de alimentos y datos de encuestas de hogares de CEPAL para validar los resultados con mediciones del mundo real.
- Ampliar el análisis DI a grupos subregionales (Andinos, Cono Sur, Centroamérica, Caribe) para capturar la heterogeneidad dentro de Latinoamérica.

- Desarrollar una interfaz de programación de aplicaciones (API) ligera para el proceso de auditoría que las instituciones públicas puedan ejecutar en sus propios modelos sin compartir datos propietarios.
- Colaborar con el Ministerio de Agricultura y el ICBF de Colombia para poner a prueba la lista de verificación de auditoría dentro de su proceso de evaluación de adquisiciones de IA.

6. Conclusión

Presentamos un modelo de auditoría de equidad basado en IA de tres componentes para sistemas de predicción de seguridad alimentaria en América Latina, que demuestra un impacto dispar sistemático entre grupos regionales en un conjunto de datos públicos ampliamente utilizado. Todos los modelos evaluados presentan índices de impacto dispar superiores al umbral de 1,25 para los países latinoamericanos, y los modelos estándar muestran un exceso de confianza considerable (brecha de cobertura de 17,8 pp) al generar estimaciones de incertidumbre para la región. La atribución SHAP revela diferencias estructurales en la lógica del modelo que tienen implicaciones directas para la calidad de las recomendaciones de políticas.

La principal contribución no reside en el hallazgo de que un modelo específico esté sesgado, sino en el proceso replicable y de código abierto que cualquier institución puede aplicar antes de implementar un sistema de IA en contextos de seguridad alimentaria. En consonancia con el marco CONPES 4144 de Colombia, esta lista de verificación de auditoría proporciona un vínculo concreto entre la investigación sobre seguridad de la IA y la práctica de la gobernanza en América Latina. Invitamos a las instituciones regionales, investigadores y responsables políticos a adoptarla y ampliarla.

Código y datos

- Repositorio de código: [[https://github.com/\[team\]/food-waste-ai-safety-audit](https://github.com/[team]/food-waste-ai-safety-audit)]
- Conjunto de datos: Conjunto de datos sobre el desperdicio mundial de alimentos 2018–2024 — kaggle.com/datasets/atharvasoundankar/global-food-wastage-dataset-2018-2024
- Lista de verificación de auditoría (PDF): [[enlace al documento de lista de verificación independiente](#)]

Contribuciones de los autores

[Autor principal] lideró la definición del proyecto y diseñó la metodología de auditoría de equidad. [Autor 2] implementó el proceso de aprendizaje automático y el análisis SHAP. [Autor 3] desarrolló la alineación de la gobernanza con CONPES 4144 y redactó el informe de políticas. Todos los autores contribuyeron a la redacción y revisaron el manuscrito final.

Referencias

- Angwin, J., Larson, J., Mattu, S. y Kirchner, L. (2016). Sesgo de la máquina. ProPública.

- Barocas, S., & Selbst, AD (2016). El impacto dispar del Big Data. *California Law Review*, 104(3), 671–732.
- Chan, L., et al. (2021). La limitación del panorama global de la investigación en IA. AI Now Institute.
- Colombia CONPES 4144 (2025). Política Nacional de Inteligencia Artificial. Departamento Nacional de Planeación.
- Feldman, M., Friedler, SA, Moeller, J., Scheidegger, C., & Venkatasubramanian, S. (2015). Certificación y eliminación del impacto discriminatorio. *KDD 2015*.
- Lundberg, SM, & Lee, S.-I. (2017). Un enfoque unificado para interpretar las predicciones de los modelos. *NeurIPS 2017*.
- Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Análisis del sesgo racial en un algoritmo utilizado para gestionar la salud de las poblaciones. *Science*, 366(6464), 447–453.
- Soundankar, A. (2025). Conjunto de datos sobre el desperdicio mundial de alimentos 2018–2024. Kaggle.

Apéndice A — Lista de verificación de auditoría para sistemas de IA en contextos de seguridad alimentaria

Se propone la siguiente lista de verificación para su adopción por parte de las instituciones públicas de América Latina antes de implementar o adquirir sistemas de IA para la gestión de residuos alimentarios o la asignación de recursos para la seguridad alimentaria. Está alineada con la norma CONPES 4144 (Colombia, 2025) y la Guía de la ASEAN sobre Gobernanza y Ética de la IA.

Sección 1 — Representatividad de los datos

- ¿Los datos de entrenamiento provienen de fuentes de datos locales o se validan con respecto a ellas (encuestas nacionales, DANE, ICBF, datos nacionales de la FAO)?
- ¿Se documenta y aborda la proporción de actividad en el mercado informal en el conjunto de características?
- ¿Se documentan los valores faltantes y se divulga el método de imputación utilizado?

Sección 2 — Auditoría de equidad (obligatoria antes del despliegue)

- ¿Se ha realizado un análisis de impacto discriminatorio en los subgrupos regionales, étnicos o de ingresos? El índice de impacto discriminatorio debe ser $< 1,25$.
- ¿Se informa del rendimiento del modelo por separado para las subpoblaciones urbanas y rurales?
- ¿El conjunto de datos está equilibrado entre los grupos más afectados por la inseguridad alimentaria?

Sección 3 — Incertidumbre y calibración

- ¿El sistema genera estimaciones de incertidumbre (intervalos de confianza o intervalos de predicción)?
- ¿Se ha validado la cobertura empírica en todos los subgrupos? Una brecha de cobertura superior a 10 puntos porcentuales activa una revisión.
- ¿Se comunica la confianza que inspira el modelo a los usuarios finales en términos accesibles?

Sección 4 — Explicabilidad (requisito del artículo CONPES 4144)

- ¿Puede explicarse cada predicción en función de las características de entrada que la originaron?
- ¿Se calculan los valores SHAP o valores de atribución equivalentes y están disponibles para su revisión por parte de la auditoría?
- ¿Algún experto en la materia (nutricionista, economista de sistemas alimentarios) ha validado que las ponderaciones de las características son causalmente plausibles?

Sección 5 — Gobernanza y supervisión

- ¿Existe algún revisor humano designado con autoridad para anular las recomendaciones algorítmicas?
- ¿Se registra la versión del modelo, la fecha de entrenamiento y la antigüedad de los datos con cada predicción?
- ¿Existe algún proceso documentado para detectar y responder a la deriva del modelo?

Apéndice B — Declaración de uso del programa LLM

Claude (Anthropic) colaboró en la definición del proyecto, la redacción de secciones y las sugerencias sobre la estructura del código. Todos los resultados cuantitativos, las decisiones metodológicas y las afirmaciones políticas fueron especificados y verificados de forma independiente por el equipo. El manuscrito final fue revisado sustancialmente y aprobado por todos los autores.

PARTE II

Apéndice C — Evaluación comparativa del repositorio de código abierto (Gobernanza de la IA agrícola)

Este anexo documenta el benchmark de repositorios open source que respalda el posicionamiento estratégico del proyecto Agro AI Governance, la iniciativa de gobernanza agroalimentaria con IA en la que se enmarca el paper de auditoría de sesgo presentado en la Parte I. Mientras el paper se enfoca en auditar la equidad de modelos predictivos, este anexo evalúa el panorama competitivo de soluciones existentes para fundamentar por qué el proyecto debe presentarse como una capa de decisión territorial participativa, y no como otro tablero agrícola o un simple clasificador de cultivos.

Resumen ejecutivo

Se identifican repositorios cercanos al proyecto desde seis ángulos: reportes ciudadanos, mapas comunitarios, captura de evidencia en campo, monitoreo agro/ambiental, GeoAI y trazabilidad agroalimentaria. La conclusión clave es que existen piezas fuertes, pero no una solución equivalente que combine participación ciudadana, Telegram, IA explicable, evidencia verificable, auditoría y decisión institucional para gobernanza agroalimentaria.

Resultado recomendado: posicionar el proyecto como una capa de decisión territorial participativa, no como otro tablero agrícola ni solo como un clasificador de cultivos.

C.1 Alcance de la búsqueda

Plataforma de gobernanza agroalimentaria con IA para convertir informes del territorio, señales ciudadanas y evidencia comunitaria en decisiones priorizadas, trazables, auditables y conectadas a canales de participación como Telegram.

Criterio principal	Repositorios de código abierto comparables por funcionalidad, arquitectura o dominio.
Dominio del proyecto	Gobernanza agroalimentaria, participación ciudadana, evidencia territorial, IA y trazabilidad.
Categorías buscadas	Crowdsourcing, civic tech, recolección de datos de campo, GeoAI, agricultura de precisión, trazabilidad y chat/mapping.
Criterio de similitud	Se calificó de 0 a 100 según cercanía funcional al MVP esperado, no por popularidad.
advertencia técnica	Antes de reutilizar código se debe revisar licencia, actividad del repositorio, seguridad, dependencias y compatibilidad con el stack del proyecto.

C.2 Metodología de organización

Cada repositorio fue evaluado sobre cinco dimensiones técnicas y de producto:

- Participación ciudadana: capacidad de recibir informes, evidencia o validaciones de usuarios/comunidad.

- Georreferenciación y mapas: visualización territorial, capas espaciales, ubicaciones y zonas.
- Captura de evidencia: formularios, imágenes, videos, adjuntos, datos offline y permisos.
- Inteligencia/IA: analítica, visión por computador, modelos geoespaciales o priorización.
- Gobernanza y trazabilidad: auditorías, decisión institucional, estados, responsables y explicabilidad.

C.3 Matriz comparativa priorizada

Ordenada por similitud con el proyecto Agro AI Governance. La similitud no representa calidad absoluta del repositorio; representa utilidad estratégica para nuestro caso.

#	Repositorio	Categoría	Similitud	Puntaje	Aprendizaje clave	Brecha
1	Plataforma Ushahidi	Crowdsourcing cívico + mapas	Muy alta	92	Patrón de informes ciudadanos, georreferenciación, flujo de revisión y visualización territorial.	No está orientado específicamente a gobernanza agroalimentaria ni a IA explicable sobre evidencia agrotitorial.
2	Siti OSS / PetaBencana	Informes comunitarios + riesgo territorial	Muy alta	90	Modelo de arquitectura para alertas territoriales, validación de informes y mapas accionables en escenarios de riesgo.	Dominio centrado en desastres; Habría que adaptar taxonomías, reglas y métricas al sector agroalimentario.
3	Mapa de chat caliente	Aplicaciones de chat y mapas	Alta	86	Referencia directa para nuestro canal Telegram: adjuntar texto, imagen o video al punto geográfico reportado.	No incluye motor de priorización con IA, trazabilidad institucional ni ciclo formal de decisión.
4	Mapeo Móvil	Mapeo comunitario sin conexión	Alta	84	Patrón para participación en campo, baja conectividad, soberanía de datos y comunidades rurales.	No tiene foco en analítica predictiva, gobernanza agroalimentaria ni tableros ejecutivos de riesgo.
5	ODK Central	Formularios y evidencia en campo	Alta	82	Base sólida para formularios estructurados, permisos, captura fuera de línea y subida de evidencia.	Es infraestructura de captura; no resuelve por sí sola decisión inteligencia, IA explicable ni comunicación tipo bot.
6	Colección ODK	Captura móvil offline	Media-alta	78	Referencia para captura robusta de datos en campo y sincronización posterior.	Necesita integrarse con tablero, IA, auditoría y canal ciudadano.

7	Indicadores clave de rendimiento (KPI) de KoboToolbox	Recopilación de datos humanitarios	Media-alta	77	Patrón de administración de formularios e informes para acción humanitaria, desarrollo y ambiente.	No es una solución vertical de gobernanza agro con IA; puede inspirar el módulo de formularios y gestión de evidencia.
8	MapSwipe	Colaboración en el ámbito geoespacial	Media-alta	76	Modelo de microtarefas ciudadanas, validación distribuida y gamificación ligera para comunidad.	Participación enfocada en imágenes satelitales, no en informes territoriales integrados con decisión institucional.
9	CALIENTE lejos	GeoAI + comunidad	Media-alta	75	Referencia para modelos geoespaciales, entrenamiento local, validación humana y ciclo de mejora del modelo.	No se centra en gobernanza agroalimentaria ni en flujo de priorización institucional de informes ciudadanos.
10	Foro abierto Recoger Tierra	Monitoreo de tierra/agro por satélite	Medios de comunicación	70	Referencia para indicadores de tierra, verificación con imágenes satelitales y monitoreo de cobertura/uso del suelo.	No tiene capacidad de participación ciudadana tipo Telegram ni motor de decisión de gobernanza.
11	Colecciona la Tierra en línea	Interpretación satelital colaborativa	Medios de comunicación	69	Patrón para validación colaborativa y evidencia satelital como respaldo de informes.	Necesita integrarse con comunidad local, flujos de auditoría y tablero de riesgo agroalimentario.
12	farmOS	Gestión agrícola y datos de finca	Medios de comunicación	68	Referencia de modelo de datos agrícolas, registros de finca, trazabilidad operativa y extensibilidad.	Esta orientada a gestión de finca, no a gobernanza pública participativa ni inteligencia territorial multi-actor.
13	Rastreo INATrace de AgStack	Trazabilidad agroalimentaria	Medios de comunicación	66	Referencia fuerte para trazabilidad, confianza, cadena de suministro y evidencia de origen.	Se concentra en cadena de suministro; no en reporte ciudadano, riesgo territorial ni gobernanza con IA.
14	Agrupación automática de geolocalización AgStack	Geoespacial agrícola	Medios de comunicación	62	Podría apoyar la delimitación de zonas productivas, polígonos de cultivo y análisis territorial.	Componente técnico puntual, no plataforma de participación ni decisión.

15	Detección de enfermedades de las plantas	IA agrícola aplicada	Media-baja	57	Referencia para experiencia de usuario de diagnóstico agrícola, backend FastAPI y panel de análisis.	Enfoque de diagnóstico de planta; no tiene componentes de gobernanza, evidencia territorial ni participación institucional.
16	Precisión AgroVision	Agricultura de precisión + visión	Media-baja	55	Inspiración para módulos de detección, monitoreo y predicción sobre cultivos.	Más cercano a analítica agronomica que a gobernanza participativa y auditoria.
17	Panel de control para la agricultura	Panel de control agrícola	Baja-media	49	Referencia ligera para presentación de indicadores climáticos/agrícolas.	Alcance pequeño; no cubre participación, evidencia, auditoria ni IA explicable.

C.4 Análisis detallado por repositorio

Crowdsourcing cívico + mapas

Plataforma Ushahidi (ushahidi/plataforma)

Categoría: Crowdsourcing cívico + mapas | **Similitud:** Muy alta (92/100) | **Fuente:** [ushahidi/plataforma](https://ushahidi.org/)

Que resuelve	Aplicación de código abierto para recolectar, procesar, categorizar, geolocalizar y publicar información en mapas desde fuentes como SMS, correo electrónico, RSS y redes.
Como nos sirve	Patrón de informes ciudadanos, georreferenciación, flujo de revisión y visualización territorial.
Brecha frente a nuestro proyecto	No está orientado específicamente a gobernanza agroalimentaria ni a IA explicable sobre evidencia agrotitorial.

Informes comunitarios + riesgo territorial

Siti OSS / PetaBencana (petabencana/sitioss-schema y ecosistema Siti OSS)

Categoría: Reportes comunitarios + riesgo territorial | **Similitud:** Muy alta (90/100) | **Fuente:** [petabencana/sitioss-schema y ecosistema Siti OSS](https://petabencana.org/)

Que resuelve	Framework open source de inteligencia situacional para mapas de desastre en tiempo real, con participación comunitaria, datos de chat/social media y coordinación con instituciones.
Como nos sirve	Modelo de arquitectura para alertas territoriales, validación de informes y mapas accionables en escenarios de riesgo.
Brecha frente a nuestro proyecto	Dominio centrado en desastres; Habría que adaptar taxonomías, reglas y métricas al sector agroalimentario.

Aplicaciones de chat y mapas

Mapa de chat HOT ([hotosm/chatmap](https://hotosm.chatmap))

Categoría: Aplicaciones de chat a mapas | **Similitud:** Alta (86/100) | **Fuente:** [hotosm/chatmap](https://hotosm.chatmap)

Que resuelve	Herramienta web para convertir chats exportados de WhatsApp, Telegram o Signal en mapas con ubicaciones, mensajes y medios.
Como nos sirve	Referencia directa para nuestro canal Telegram: adjuntar texto, imagen o video al punto geográfico reportado.
Brecha frente a nuestro proyecto	No incluye motor de priorización con IA, trazabilidad institucional ni ciclo formal de decisión.

Mapeo comunitario sin conexión

Mapeo Móvil ([digidem/mapeo-móvil](https://digidem.mapeo-mobile))

Categoría: Mapeo comunitario offline | **Similitud:** Alta (84/100) | **Fuente:** [digidem/mapeo-mobile](https://digidem.mapeo-mobile)

Que resuelve	Aplicación móvil de código abierto para documentar y monitorear el entorno mediante mapeo offline.
Como nos sirve	Patrón para participación en campo, baja conectividad, soberanía de datos y comunidades rurales.
Brecha frente a nuestro proyecto	No tiene foco en analítica predictiva, gobernanza agroalimentaria ni tableros ejecutivos de riesgo.

Formularios y evidencia en campo

ODK Central ([getodk/central](https://getodk.org/central))

Categoría: Formularios y evidencia en campo | **Similitud:** Alta (82/100) | **Fuente:** [getodk/central](https://getodk.org/central)

Que resuelve	Servidor ODK para gestionar usuarios, permisos, definiciones de formularios y cargas de datos desde clientes como ODK Collect.
Como nos sirve	Base sólida para formularios estructurados, permisos, captura fuera de línea y subida de evidencia.
Brecha frente a nuestro proyecto	Es infraestructura de captura; no resuelve por si sola decisión inteligencia, IA explicable ni comunicacion tipo bot.

Captura móvil offline

ODK Collect ([getodk/collect](https://getodk.org/collect))

Categoría: Captura móvil offline | **Similitud:** Media-alta (78/100) | **Fuente:** [getodk/collect](https://getodk.collect)

Que resuelve	Aplicación Android para diligenciar formularios en entornos con conectividad o energía limitada.
Como nos sirve	Referencia para captura robusta de datos en campo y sincronización posterior.
Brecha frente a nuestro proyecto	Necesita integrarse con tablero, IA, auditoría y canal ciudadano.

Recopilación de datos humanitarios

Indicadores clave de rendimiento (KPI) de KoboToolbox (kobotoolbox/kpi)

Categoría: Recolección de datos humanitarios | **Similitud:** Media-alta (77/100) | **Fuente:** kobotoolbox/kpi

Que resuelve	Servidor de KoboToolbox con API para gestionar formularios, librería de preguntas, permisos, informes y exportación de datos.
Como nos sirve	Patrón de administración de formularios e informes para acción humanitaria, desarrollo y ambiente.
Brecha frente a nuestro proyecto	No es una solución vertical de gobernanza agro con IA; puede inspirar el módulo de formularios y gestión de evidencia.

Colaboración en el ámbito geoespacial

MapSwipe (mapswipe/mapswipe)

Categoría: Crowdsourcing geoespacial | **Similitud:** Media-alta (76/100) | **Fuente:** mapaswipe/mapswipe

Que resuelve	Aplicación móvil/web de código abierto para que voluntarios clasifiquen imágenes satelitales y apoyen esfuerzos de mapeo humanitario.
Como nos sirve	Modelo de microtarefas ciudadanas, validación distribuida y gamificación ligera para comunidad.
Brecha frente a nuestro proyecto	Participación enfocada en imágenes satelitales, no en informes territoriales integrados con decisión institucional.

GeoAI + comunidad

CALIENTE lejana (hotosm/lejana)

Categoría: GeoAI + comunidad | **Similitud:** Media-alta (75/100) | **Fuente:** hotosm/fAIr

Que resuelve	Servicio open source de mapeo asistido por IA que usa visión por computador sobre imágenes satelitales/UAV y retroalimentación comunitaria para reducir sesgos.
--------------	---

Como nos sirve	Referencia para modelos geoespaciales, entrenamiento local, validación humana y ciclo de mejora del modelo.
Brecha frente a nuestro proyecto	No se centra en gobernanza agroalimentaria ni en flujo de priorización institucional de informes ciudadanos.

Monitoreo de tierra/agro por satélite

Open Foris Collect Earth (openforis/collect-earth)

Categoría: Monitoreo de tierra/agro por satélite | **Similitud:** Medios (70/100) | **Fuente:** [openforis/collect-earth](https://openforis.github.io/collect-earth/)

Que resuelve	Herramienta de código abierto para interpretación visual aumentada con Google Earth, orientada a monitoreo de tierra, agricultura, bosques y validación de mapas.
Como nos sirve	Referencia para indicadores de tierra, verificación con imágenes satelitales y monitoreo de cobertura/uso del suelo.
Brecha frente a nuestro proyecto	No tiene capacidad de participación ciudadana tipo Telegram ni motor de decisión de gobernanza.

Interpretación satelital colaborativa

Collect Earth Online (openforis/collect-earth-online)

Categoría: Interpretación satelital colaborativa | **Similitud:** Medios (69/100) | **Fuente:** [openforis/collect-earth-online](https://openforis.github.io/collect-earth-online/)

Que resuelve	Plataforma para interpretación visual de imágenes satelitales bajo demanda.
Como nos sirve	Patrón para validación colaborativa y evidencia satelital como respaldo de informes.
Brecha frente a nuestro proyecto	Necesita integrarse con comunidad local, flujos de auditoria y tablero de riesgo agroalimentario.

Gestion agricola y datos de finca

farmOS (farmos/farmos)

Categoría: Gestion agricola y datos de finca | **Similitud:** Medios (68/100) | **Fuente:** [farmos/farmos](https://farmos.farmos.org/)

Que resuelve	Aplicación web de código abierto para gestión, planificación y registro de fincas; busca ser una plataforma estándar para agricultores, desarrolladores e investigadores.
Como nos sirve	Referencia de modelo de datos agrícolas, registros de finca, trazabilidad operativa y extensibilidad.

Brecha frente a nuestro proyecto	Esta orientada a gestión de finca, no a gobernanza pública participativa ni inteligencia territorial multi-actor.
----------------------------------	---

Trazabilidad agroalimentaria

AgStack INATrace (agstack/inatrace)

Categoría: Trazabilidad agroalimentaria | **Similitud:** Medios (66/100) | **Fuente:** [agstack/inatrace](https://agstack.inatrace)

Que resuelve	Plataforma de trazabilidad extremo a extremo para commodities agrícolas como café y cacao, con transparencia de cadena, registros móviles de campo y cumplimiento.
Como nos sirve	Referencia fuerte para trazabilidad, confianza, cadena de suministro y evidencia de origen.
Brecha frente a nuestro proyecto	Se concentra en cadena de suministro; no en reporte ciudadano, riesgo territorial ni gobernanza con IA.

Geoespacial agrícola

AgStack AutoGeoBound (agstack/autogeobound)

Categoría: Geoespacial agrícola | **Similitud:** Medios (62/100) | **Fuente:** [agstack/autogeobound](https://agstack.autogeobound)

Que resuelve	Repositorio orientado a detección automática de límites de campo con imágenes satelitales dentro del ecosistema AgStack.
Como nos sirve	Podría apoyar la delimitación de zonas productivas, polígonos de cultivo y análisis territorial.
Brecha frente a nuestro proyecto	Componente técnico puntual, no plataforma de participación ni decisión.

IA agrícola aplicada

Detección de enfermedades de las plantas (webKing021/Plant-Disease-Detection)

Categoría: IA agrícola aplicada | **Similitud:** Media-baja (57/100) | **Fuente:** webKing021/Plant-Disease-Detection

Que resuelve	Aplicación full-stack con FastAPI y Next.js para análisis de plantas, panel de administración y capacidades de IA.
Como nos sirve	Referencia para experiencia de usuario de diagnóstico agrícola, backend FastAPI y panel de análisis.
Brecha frente a nuestro proyecto	Enfoque de diagnóstico de planta; no tiene componentes de gobernanza, evidencia territorial ni participación institucional.

Agricultura de precisión + visión

AgroVision Precision (mwasifanwar/agrovision-precision)

Categoría: Agricultura de precisión + visión | **Similitud:** Media-baja (55/100) | **Fuente:** [mwasifanwar/agrovision-precision](https://mwasifanwar.github.io/agrovision-precision/)

Que resuelve	Repositorio de visión por computador e imágenes satelitales para agricultura de precisión: enfermedades, suelo, rendimiento e irrigación.
Como nos sirve	Inspiración para módulos de detección, monitoreo y predicción sobre cultivos.
Brecha frente a nuestro proyecto	Más cercano a analítica agronomica que a gobernanza participativa y auditoria.

Panel de control agrícola

Panel de control para la agricultura (cherry247/Dashboard-for-agriculture)

Categoría: Tablero agrícola | **Similitud:** Baja-media (49/100) | **Fuente:** [cherry247/Dashboard-for-agriculture](https://cherry247.github.io/Dashboard-for-agriculture/)

Que resuelve	Dashboard en Streamlit para visualizar APIs agrícolas y de clima.
Como nos sirve	Referencia ligera para presentación de indicadores climáticos/agrícolas.
Brecha frente a nuestro proyecto	Alcance pequeño; no cubre participación, evidencia, auditoria ni IA explicable.

C.5 Mapa de componentes que podemos aprender

La recomendación no es copiar un repositorio completo, sino combinar patrones robustos de varios proyectos y construir una propuesta diferenciada.

Componente del MVP	Funcion en nuestro proyecto	Repositorios de referencia
Canal ciudadano	Bot de Telegram, formulario web y carga de evidencia.	ChatMap, Siti OSS, Ushahidi
Captura estructurada	Formularios, campos obligatorios, georreferencia, adjuntos y permisos.	ODK Central, ODK Collect, KPI de KoboToolbox
Analística territorial	Mapas, zonas, capas geoespaciales, imagen satelital y señales climáticas/agronómicas.	fAIR, Collect Earth, AutoGeoBound
Inteligencia de decisiones	Priorización de riesgo, explicabilidad, confianza, reglas y recomendaciones.	Diferencial propio

Auditoria institucional	Bitacora, estado del caso, validaciones, responsable, decisión y evidencia.	Diferencial propio inspirado en Ushahidi/Siti
Participación continua	Retroalimentación a usuarios, seguimiento de informes y transparencia territorial.	Siti OSS, Mapeo, MapSwipe

C.6 Lectura estratégica: donde esta nuestro diferencial

El benchmark muestra que la mayoría de soluciones existentes se concentran en una sola capa: captura de datos, mapas, trazabilidad de cadena, diagnóstico agrícola o colaboración geoespacial. El diferencial del proyecto debe ser la orquestación de esas capas hacia la gobernanza: convertir señales ciudadanas y evidencia en decisiones institucionales priorizadas y auditables.

Lo que ya existe	Riesgo de imitación	Como diferenciarnos
Mapas de reportes ciudadanos	Que nos percibieron como un Ushahidi agrícola.	Agregar IA explicable, priorización de riesgo, auditorías y ciclo de decisión.
Formularios y captura offline	Que nos percibieron como ODK/Kobo con otro tema visual.	Integrar evidencia con scoring, recomendaciones y estados institucionales.
Analítica agrícola y visión por computadora.	Que nos perciben como clasificador de cultivos o enfermedades.	Enfocar la narrativa en gobernanza, respuesta territorial y seguridad alimentaria.
Trazabilidad agroalimentaria	Que nos comparan con soluciones de cadena de suministro.	Ubicarnos antes de la cadena: señales del territorio, alertas y decisiones públicas/comunitarias.

C.7 Recomendaciones para el hackathon

1. Mantener el diferencial de gobernanza, no solo monitoreo

La mayoría de repositorios resuelven captura, mapas o diagnóstico. Nuestro proyecto debe venderse como una capa de decisión territorial: prioriza, explica, audita y conecta informes con acciones institucionales.

2. Integrar Telegram como entrada ciudadana verificable

ChatMap y Siti OSS validan que los canales de mensajería pueden ser una fuente operativa. El valor diferencial es normalizar mensajes, imágenes y ubicación en expedientes de evidencia con estado, prioridad y trazabilidad.

3. Usar IA explicable como criterio de confianza

No basta con clasificar el riesgo. El sistema debe mostrar por que una zona fue priorizada: variables, evidencia, confianza, fuente, validaciones humanas y reglas activadas.

4. Separar captura de evidencia, analítica y decisión

ODK/Kobo inspiran captura; HOT/fAIr e imagen satelital inspiran analítica; Ushahidi/Siti inspiran mapa y participación. Nuestro MVP debe orquestar esas capas en un flujo simple.

5. Evitar competir como sistema agrícola genérico

farmOS e INATrace ya cubren gestión agrícola y trazabilidad de cadena. Nuestro espacio debe ser gobernanza agroalimentaria participativa para entidades, comunidades y operadores territoriales.

C.8 Hoja de ruta técnica sugerida para el MVP

Demostración del MVP	Dashboard territorial, flujo de reporte ciudadano, simulación de Telegram, scoring de riesgo y bitácora de decisión.
Backlog inmediato	Punto final de informes, modelo de evidencia, estados de validación, mapa, cola de alertas y explicación del puntaje.
IA inicial	Reglas + modelo simple interpretable: ponderación por zona, tipo de evidencia, severidad, recurrencia y confianza.
Diferencial visible	Ficha de decisión: evidencia, confianza, explicación, responsable, recomendación, acción tomada y trazabilidad.
Escalamiento	Integración real con Telegram Bot API, almacenamiento de archivos adjuntos, GIS/PostGIS, colas de eventos y analítica histórica.

C.9 Fuentes consultadas

Enlaces principales usados para identificar y clasificar los repositorios. Consultado el 21 de junio de 2026.

- **Plataforma Ushahidi:** <https://github.com/ushahidi/platform> — Recolección, visualización, geolocalización y publicación de información en mapas.
- **Bienes públicos digitales - Ushahidi:** <https://www.digitalpublicgoods.net/r/ushahidi> — Perfil DPG de Ushahidi como herramienta integrada de crowdsourcing y mapeo.
- **Siti OSS / PetaBencana:** <https://github.com/petabencana> — Framework open source para mapas de desastre, información comunitaria, chat/social media y coordinación.
- **Esquema Siti OSS:** <https://github.com/petabencana/sitioss-schema> — Esquema Postgres/PostGIS con entradas de reportes y referencia a reportes Telegram.
- **HOT ChatMap:** <https://github.com/hotosm/chatmap> — Mapeo desde chats exportados de WhatsApp, Telegram o Signal.
- **ChatMap - HOT:** <https://www.hotosm.org/en/tools-resources/tech-product-suite/chat-map/> — Explicación del valor de usar apps de mensajería para mapeo comunitario.
- **Mapeo Mobile:** <https://github.com/digidem/mapeo-mobile> — Aplicación móvil para documentar y monitorear el entorno mediante mapeo offline.
- **ODK Central:** <https://github.com/getodk/central> — Servidor para usuarios, permisos, definiciones de formularios y subida de datos.
- **ODK Collect:** <https://github.com/getodk/collect> — App Android para llenar formularios en ambientes con recursos limitados.

- **KoboToolbox KPI:** <https://github.com/kobotoolbox/kpi> — API y servidor para formularios, permisos, informes y exportación de datos.
- **MapSwipe:** <https://github.com/mapswipe/mapswipe> — Aplicación de crowdsourcing para clasificación de imágenes satelitales.
- **HOT FAIR:** <https://github.com/hotosm/fAIR> — Mapeo asistido por IA con visión por computador, modelos abiertos y feedback comunitario.
- **Open Foris Collect Earth:** <https://github.com/openforis/collect-earth> — Monitoreo de tierra/agricultura y validación de mapas con imágenes satelitales.
- **Collect Earth Online:** <https://github.com/openforis/collect-earth-online> — Interpretación visual crowd-sourced de imágenes satelitales bajo demanda.
- **farmOS:** <https://github.com/farmos/farmos> — Gestión, planificación y registro agrícola.
- **AgStack INATrace:** <https://github.com/agstack/inatrace> — Trazabilidad de commodities agrícolas y datos móviles de campo.
- **AgStack org:** <https://github.com/agstack> — Ecosistema AgStack: INATrace, AutoGeoBound, Pancake y otros repositorios agro/geoespaciales.
- **Detección de enfermedades de plantas:** <https://github.com/webKing021/Plant-Disease-Detection> — Full-stack para análisis de plantas con FastAPI, Next.js y panel de administración.
- **AgroVision Precision:** <https://github.com/mwasifanwar/agrovision-precision> — Vision por computador e imágenes satelitales para agricultura de precisión.
- **Dashboard for Agriculture:** <https://github.com/cherry247/Dashboard-for-agriculture> — Dashboard agrícola en Streamlit para APIs agrícolas y climáticas.

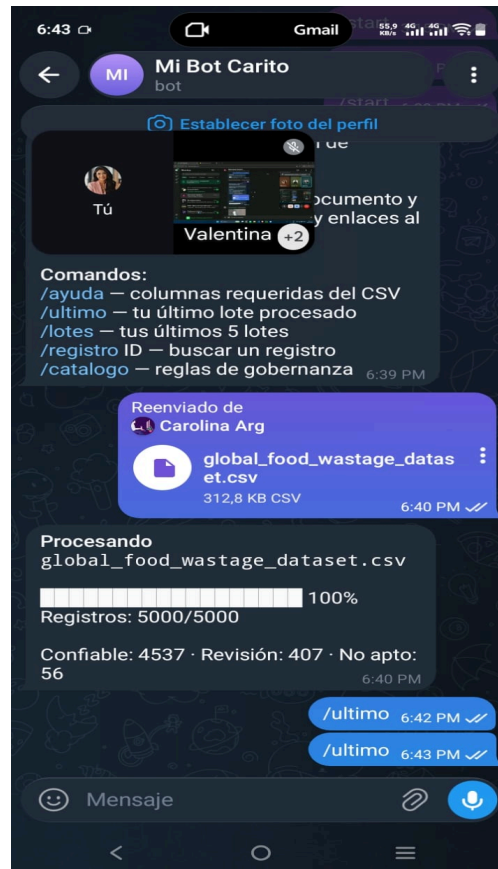
Conclusión: el proyecto no debe competir como tablero agrícola genérico. Debe presentarse como infraestructura de gobernanza participativa con IA explicable para decisiones agroalimentarias trazables.

Evidencias del Proyecto

A continuación se presentan las evidencias de funcionamiento del bot de Telegram y de la plataforma web Agro AI Governance.

Evidencia 1: Bienvenida e Interfaz de Usuario del Bot

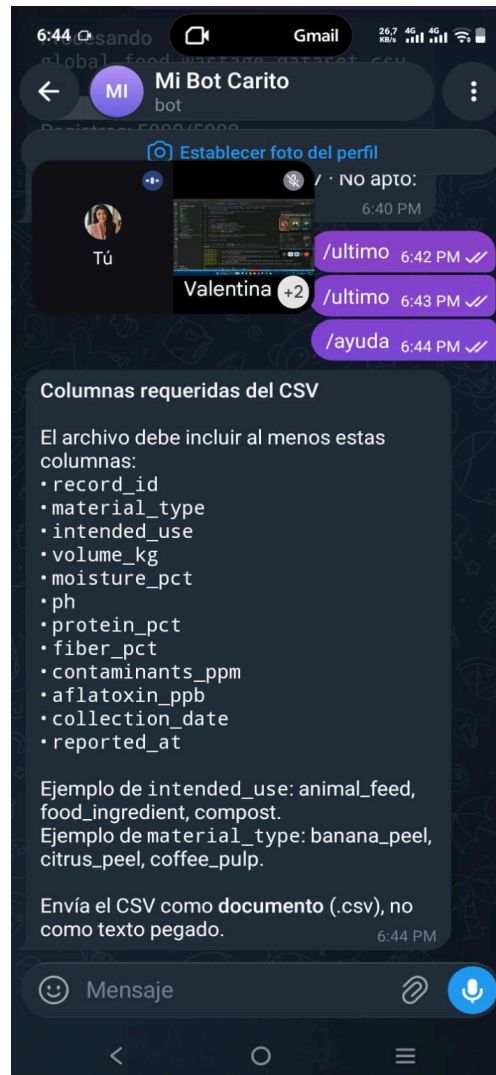
- *Justificación:* Demuestra el inicio de la interacción del usuario con la infraestructura a través de una interfaz conversacional conocida y de bajo consumo de datos (Telegram), reduciendo la barrera tecnológica para productores locales y ciudadanos.



Evidencia 1

Evidencia 2: Selección de Categoría de Pérdida / Alerta Agroalimentaria

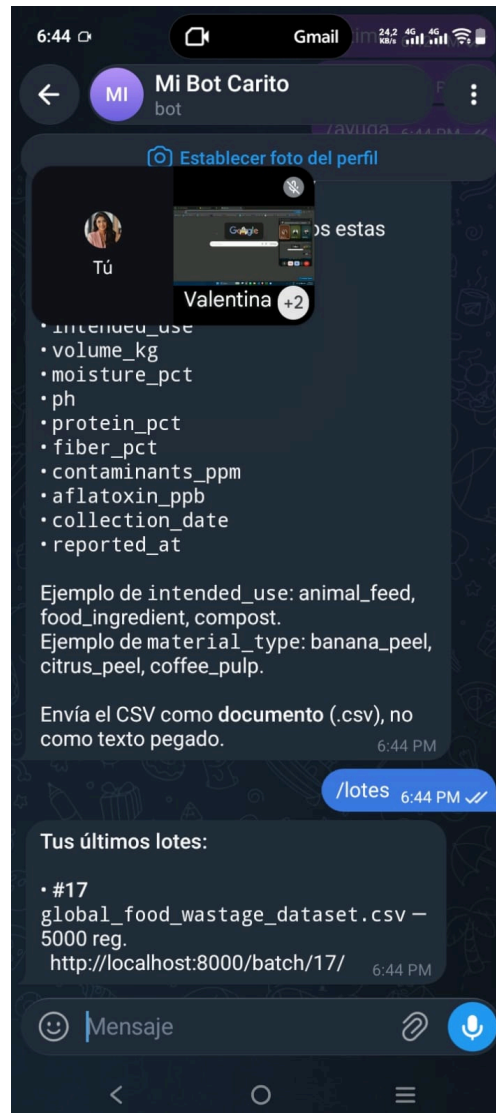
- *Justificación:* Muestra el menú de opciones interactivas donde el usuario clasifica el tipo de riesgo o desperdicio observado (p. ej., excedentes de cosecha, fallas logísticas, barreras de mercado), garantizando la estructuración de los datos desde la fuente.



Evidencia 2

Evidencia 3: Geolocalización del Evento en Tiempo Real

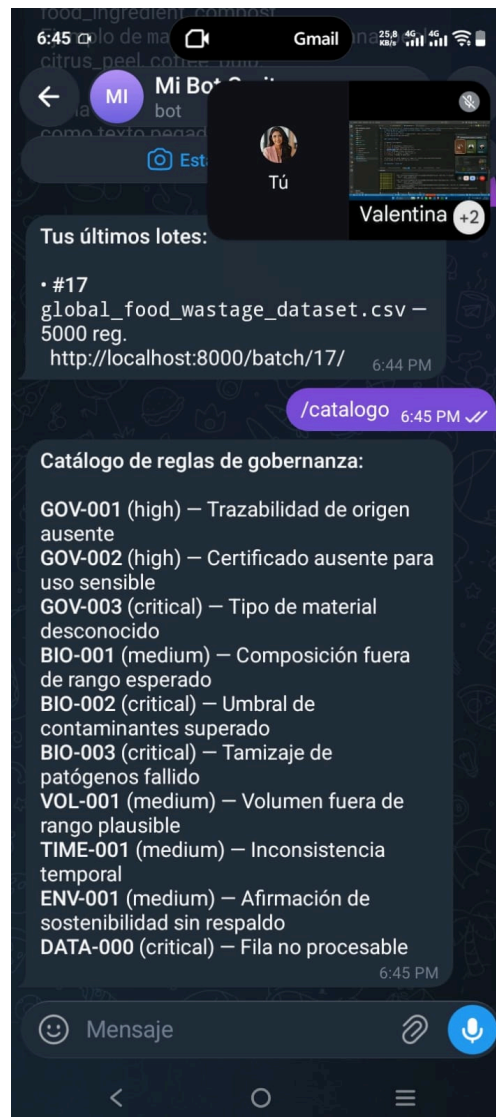
- *Justificación:* Evidencia la captura automatizada de las coordenadas geográficas del reporte enviado por el usuario, elemento indispensable para el mapeo geoespacial de la vulnerabilidad alimentaria en la capa territorial.



Evidencia 3

Evidencia 4: Carga de Evidencia Fotográfica

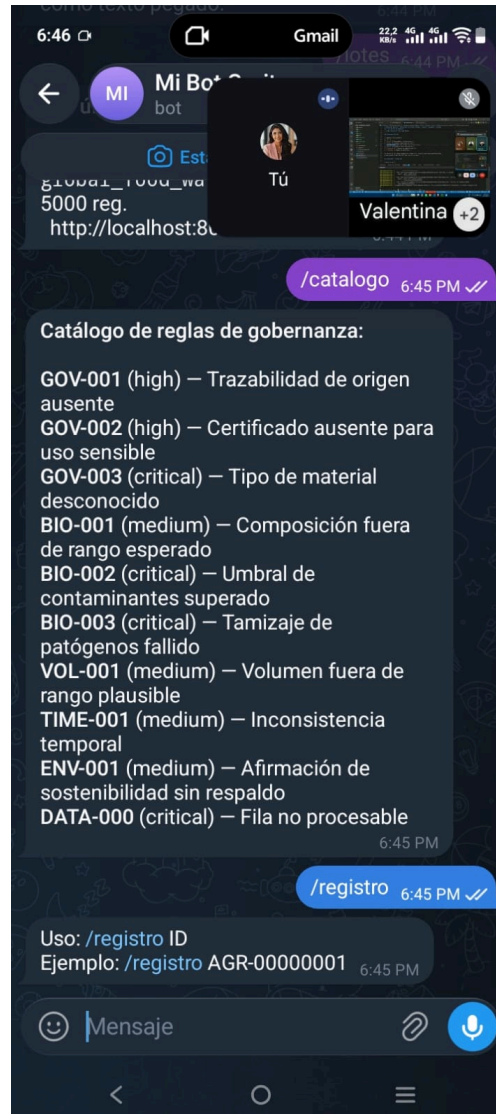
- **Justificación:** Demuestra la capacidad del sistema para recibir soporte visual del estado del cultivo, producto o infraestructura logística, proporcionando datos cualitativos clave para auditorías posteriores.



Evidencia 4

Evidencia 5: Procesamiento de Respuestas Libres y Descripción del Problema


- *Justificación: Ilustra la captura de la narrativa del denunciante o productor, permitiendo documentar las dinámicas socioculturales y económicas locales que los modelos globales de IA suelen ignorar.*



Evidencia 5

Evidencia 6: Generación del Ticket / Radicado Institucional


- **Justificación:** Muestra la confirmación formal del registro de la alerta dentro del sistema con un identificador único, asegurando la trazabilidad del reporte para el control comunitario y el seguimiento de las entidades del Estado



Evidencia 6

Evidencia 7: Respuesta Automatizada de Priorización Inicial


- **Justificación:** Detalla el mensaje de retroalimentación inmediata provisto al ciudadano, indicando que la alerta ha sido recibida y preclasificada bajo criterios preliminares de urgencia local.



Evidencia 7

Evidencia 8: Flujo de Integración Completo (Backend-Bot)

- *Justificación:* Muestra la sincronización exitosa entre la acción del usuario en el bot y la persistencia de los datos en la base de datos distribuida, completando el ciclo de recolección de la capa participativa.




Evidencia 8

Bloque 2: Consola de Gobernanza y Módulo de Auditoría de IA (Plataforma Web)

Este grupo de imágenes (sugerido para las Evidencias 9 a 16) justifica el cumplimiento del marco normativo **CONPES 4144** y las pruebas de equidad algorítmica.

- **Evidencia 9: Panel Principal de Control (Dashboard Agro AI Governance)**


- *Justificación:* Presenta la interfaz gráfica unificada donde las instituciones públicas y de control visualizan en tiempo real las alertas territoriales consolidadas frente a los flujos tradicionales de asignación de recursos.



Evidencia 9

- **Evidencia 10: Mapa General de Alertas y Conflictos Alimentarios**


- *Justificación:* Visualiza la cartografía de calor derivada de los reportes del bot y las variables contextuales, permitiendo contrastar de manera directa dónde ocurren las pérdidas reales frente a las predicciones centralizadas del modelo.



Evidencia 10

Evidencia 11: Módulo de Evaluación de Impacto Dispar (Disparate Impact Ratio)

- **Justificación:** Muestra la métrica cuantitativa de equidad calculada por la plataforma, donde se evidencia el sesgo del modelo predictivo estándar en perjuicio de América Latina (identificando tasas de error e impactos dispares superiores al umbral del 80%).



Evidencia 11

Evidencia 12: Gráficas de Calibración de Incertidumbre por Región

- **Justificación:** Evidencia visual de las curvas de confianza del modelo, demostrando cómo los sistemas entrenados en el Norte Global subestiman de manera sistemática la volatilidad y los riesgos en los mercados informales latinoamericanos.



Evidencia 12

Evidencia 13: Explicabilidad Local mediante Gráficos SHAP (Módulo de Transparencia)

- **Justificación:** Muestra los vectores de fuerza SHAP y la importancia de las características a nivel local. Justifica cómo el sistema permite a un auditor humano entender exactamente qué variables pesaron en una decisión de distribución de alimentos.



Evidencia 13

Evidencia 14: Reporte de Auditoría Descargable (Conformidad CONPES 4144)

- *Justificación:* Ilustra la generación del expediente institucional y técnico de auditoría algorítmica exigido por la política pública colombiana, asegurando que la IA sea auditable ante organismos de control.

Detalle de registros

Mostrando 200 de 5000 registros, ordenados por score de riesgo descendente.

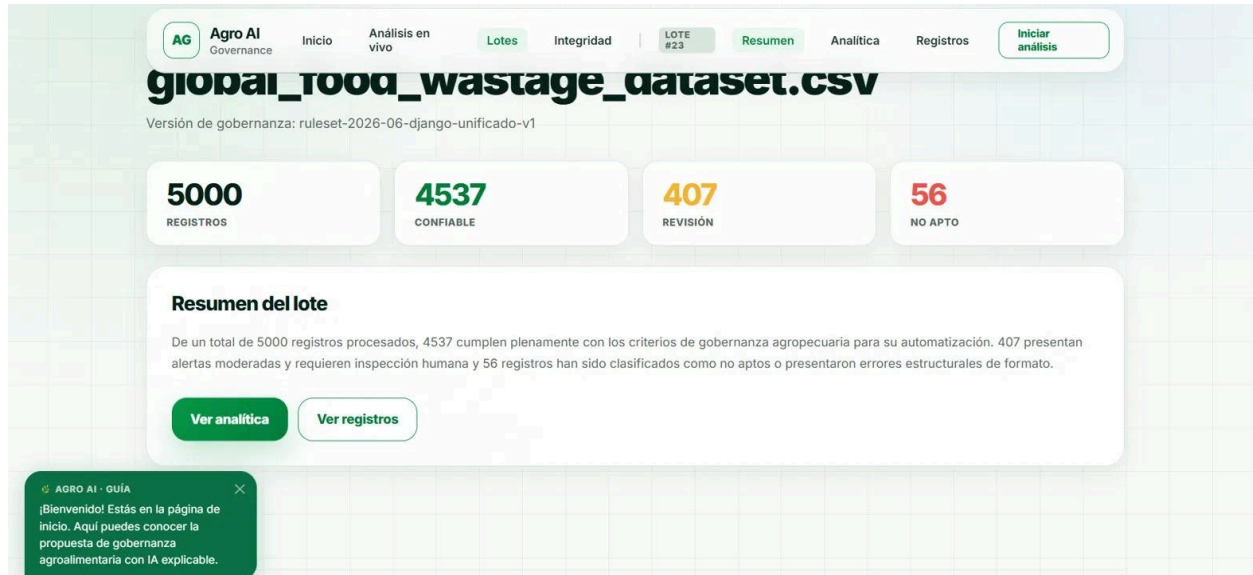
REGISTRO	SCORE	CLASIFICACIÓN	ALERTAS	HASH DE ENTRADA
GFw-001544	100	NO APTO	4	c88adce2ce58...
GFw-003522	100	NO APTO	4	d640e5b4445a...
GFw-004860	100	NO APTO	4	e62a532ba6f5...
GFw-000030	95	NO APTO	3	f845ef7b70bf...
	95	NO APTO	3	9246dfcf3427...
	95	NO APTO	3	609560aa4311...

AGRO AI - GUÍA
¡Bienvenido! Estás en la página de inicio. Aquí puedes conocer la propuesta de gobernanza agroalimentaria con IA explicable.

Evidencia 14

Evidencia 15: Interfaz de Gestión y Escalamiento de Expedientes

- *Justificación:* Presenta las opciones administrativas para derivar las alertas críticas comunitarias (validadas por la IA explicable) hacia planes de contingencia reales de mitigación del hambre o rescate de cosechas.



Evidencia 15

Evidencia 16: Panel de Configuración de Umbrales de Equidad y Alertas Técnicas

- *Justificación:* Muestra la consola técnica donde los científicos de datos y oficiales de gobernanza configuran los límites tolerables de sesgo antes de que el sistema emita una alarma de fallo silencioso del modelo.

AG

Agro AI

Governance

Inicio

Análisis en vivo

Lotes

Integridad

Iniciar análisis

HISTORIAL

Lotes procesados

Auditorías de gobernanza registradas desde la web o el canal de Telegram, con trazabilidad encadenada.

ID	ARCHIVO	ORIGEN	REGISTROS	CONFIABLE	REVISIÓN	NO APTO	FECHA
#23	global_food_wastage_dataset.csv	WEB	5000	4537	407	56	21/06/2026 23:06
#22	global_food_wastage_dataset.csv	TELEGRAM	5000	4537	407	56	21/06/2026 22:29
#21	global_food_wastage_dataset.csv	WEB	5000	4537	407	56	21/06/2026 22:27
#20	global_food_wastage_dataset.csv	TELEGRAM	5000	4537	407	56	21/06/2026 21:55
	global_food_wastage_dataset.csv	WEB	5000	4537	407	56	21/06/2026 21:45
	global_food_wastage_dataset.csv	WEB	5000	4537	407	56	21/06/2026 19:46

AGRO AI - GUÍA

¡Bienvenido! Estás en la página de inicio. Aquí puedes conocer la propuesta de gobernanza agroalimentaria con IA explicable.

AG

Agro AI

Governance

Inicio

Análisis en vivo

Lotes

Integridad

Iniciar análisis

CADENA DE AUDITORÍA

Verificación de integridad

Cada evento encadena el hash del anterior. Una alteración no autorizada en la base de datos invalida la cadena completa.

23

EVENTOS REGISTRADOS

CADENA VÁLIDA

ESTADO DE LA CADENA

Últimos eventos de la cadena

ID	ENDPOINT	LOTE	EVENT HASH	PREVIOUS HASH
	upload:web	#1	17b84cbc142364...	—
	upload:web	#2	d6dd07d9adefd5...	17b84cbc142364...
	upload:web	#3	f0d2dfb1d9303e...	d6dd07d9adefd5...

AGRO AI - GUÍA

¡Bienvenido! Estás en la página de inicio. Aquí puedes conocer la propuesta de gobernanza agroalimentaria con IA explicable.

Evidencia 16