La Revolución del muestreo Inteligente en la Fiscalización Pública: el uso de la IA No Supervisada.

Sandra Barrio Carvajal
Auditora de la Cámara de Cuentas de Andalucía

Revista Auditoría Pública nº 88. Diciembre 2026. Páginas: 139-148

Resumen: La auditoría pública tradicional, basada en el muestreo aleatorio simple y el juicio empírico se enfrenta a un riesgo sistémico, ante la dificultad de analizar los grandes volúmenes de información asociados al desarrollo del Big Data gubernamental. El uso del muestreo inteligente basado en la utilización de la Inteligencia Artificial No Supervisada, capaz de analizar los riesgos del 100% de los datos de la población, puede ser el complemento perfecto a este muestreo tradicional.
Mediante la integración de algoritmos de Inteligencia Artificial No Supervisada (por ejemplo, Isolation Forest, DBSCAN) y técnicas de Procesamiento de Lenguaje Natural (NLP) en entornos visuales Low-Code (por ejemplo, KNIME Analytics Platform), se democratiza la analítica avanzada sin requerir código complejo. La metodología propuesta contribuye a asegurar la trazabilidad, reproducibilidad e inmutabilidad exigida por los estándares internacionales de auditoría (ISSAI 1230, ISSAI 1530) y el marco regulatorio europeo.
El modelo propuesto no sustituye el juicio profesional del auditor, sino que transforma la alerta algorítmica en una hipótesis de trabajo objetiva, dotando a los informes de fiscalización de mayor solidez probatoria.

Palabras Clave: Auditoría Pública, muestreo Inteligente, IA No Supervisada, Isolation Forest, KNIME, Low-Code.

Abstract: Traditional public auditing, based on simple random sampling and empirical judgment, faces a systemic risk due to the difficulty of analyzing the large volumes of information associated with the growth of governmental Big Data. The use of smart sampling based on Unsupervised Artificial Intelligence, capable of analyzing risks across 100% of the population data, can be the perfect complement to this traditional sampling.
Through the integration of Unsupervised Artificial Intelligence algorithms (e.g., Isolation Forest, DBSCAN) and Natural Language Processing (NLP) techniques in visual Low-Code environments (e.g., KNIME Analytics Platform), advanced analytics is democratized without requiring complex code. The proposed methodology helps ensure the traceability, reproducibility, and immutability required by international auditing standards (ISSAI 1230, ISSAI 1530) and the European regulatory framework.
The proposed model does not replace the auditor's professional judgment, but rather transforms the algorithmic alert into an objective working hypothesis, providing oversight reports with greater evidentiary strength.

Keywords: Public Auditing, Smart Sampling, Unsupervised AI, Isolation Forest, KNIME, Low-Code.

1. Introducción: La evolución del control, el muestreo tradicional y el reto del volumen de datos.

La auditoría pública moderna se encuentra en una encrucijada histórica. Tradicionalmente, la labor de fiscalización ejercida por las Entidades de Control Externo se ha sustentado en metodologías de muestreo basadas en criterios estadísticos clásicos (muestreo aleatorio simple, sistemático o estratificado por importes) o en juicios empíricos condicionados por la experiencia del auditor. Estas técnicas, aunque aceptadas metodológicamente durante décadas, responden a una limitación estructural del pasado analógico: la imposibilidad material de procesar el 100% de las transacciones generadas por la administración pública en un tiempo razonable y con recursos limitados. En este contexto, el uso de la IA tiene un impacto directo en el sector público, especialmente en su papel de supervisión y regulación (Genaro-Moya et al., 2025).

En la actualidad, la transformación digital de las administraciones públicas ha generado una expansión exponencial en el volumen, la velocidad y la variedad de los datos financieros y contractuales. Millones de asientos contables, expedientes de contratación menor, liquidaciones de nómina y subvenciones circulan diariamente por los sistemas ERP del sector público. Ante este escenario de Big Data gubernamental, el muestreo aleatorio clásico se enfrenta a un riesgo sistémico severo: la posibilidad real de dejar sin fiscalización operaciones críticas o fraudulentas que se esconden en los datos de la población. Esto se debe a que las técnicas tradicionales de muestreo a veces resultan insuficientes para procesar anomalías y patrones complejos en grandes volúmenes de datos, ámbito en el que las herramientas de inteligencia artificial ofrecen una capacidad analítica superior (Omoteso, 2012).

El problema del muestreo tradicional no es su validez jurídica, sino su vulnerabilidad frente a patrones de irregularidad sofisticados y dispersos. Un muestreo aleatorio puede ignorar las «agujas en el pajar» que representan el verdadero menoscabo de los fondos públicos. El objetivo de este artículo no es abogar por la eliminación del muestreo, herramienta indispensable para la comprobación formal de la legalidad, sino usar como complemento el muestreo Inteligente que ayude a realizar un análisis de riesgo más eficiente. Mediante la IA No Supervisada, el auditor analiza los riesgos del 100% de los datos disponibles, aísla los comportamientos atípicos (patrones raros) y construye una muestra estratificada con máxima orientación al riesgo (Vasarhelyi et al., 2015).

El contenido que se aborda en este trabajo abarca:

1. El contexto y la problemática: Las limitaciones y crecientes complicaciones del muestreo aleatorio tradicional frente al gran volumen de datos (Big Data) en la gestión pública.

2. La propuesta estratégica y analítica: El Muestreo Inteligente mediante IA No Supervisada como aliado clave para examinar el 100% de los riesgos del universo, abordando tanto la detección de anomalías en datos estructurados (patrones raros) como el desafío de los datos no estructurados mediante Procesamiento de Lenguaje Natural (NLP).

3. El soporte tecnológico y la trazabilidad: La democratización del análisis masivo a través de plataformas visuales Low-Code, garantizando la transparencia, reproducibilidad e inmutabilidad exigidas por las normas internacionales de auditoría.

4. La aplicación práctica: La ilustración de la metodología en la plataforma KNIME Analytics Platform, mediante un caso de estudio automatizado enfocado en la fiscalización de la contratación menor.

5. Del hallazgo a la evidencia: La reivindicación del juicio profesional del auditor para gestionar los falsos positivos y transformar las alertas en evidencias, asegurando el cumplimiento de los imperativos legales.

6. Las conclusiones y la hoja de ruta: La formulación de una estrategia estructurada en cuatro fases para la institucionalización y gobernanza de la analítica avanzada en los órganos de control público.

2. Redefiniendo el muestreo con IA No Supervisada.

Existe el paradigma erróneo de que para aplicar IA en el sector público se requieren volúmenes masivos de datos históricos etiquetados (saber de antemano qué registros son fraude y cuáles son correctos). En la fiscalización pública, este enfoque supervisado resulta prácticamente inviable. A diferencia del sector privado, donde el fraude con tarjetas de crédito presenta patrones repetitivos, las conductas elusivas en la administración pública mutan constantemente para situarse por debajo de los controles preestablecidos. Prácticas como el fraccionamiento de contratos menores o la colusión entre licitadores evolucionan en su forma. Esperar a disponer de bases de datos de

corrupción «etiquetadas» para entrenar modelos predictivos es complicado y metodológicamente ineficaz.

Los algoritmos no supervisados no buscan patrones de irregularidad previamente conocidos, sino que aprenden matemáticamente la estructura intrínseca de la «normalidad» para aislar inmediatamente lo anormal.

- Isolation Forest (Bosques de Aislamiento). Este algoritmo aprovecha el principio de que las anomalías son observaciones escasas y diferentes (Liu et al., 2008). Al construir árboles de decisión con cortes aleatorios, las observaciones atípicas requieren sensiblemente menos particiones lógicas para ser aisladas que los datos normales, los cuales se agrupan en densas nubes de similitud.
- DBSCAN (Agrupamiento Basado en Densidad de Puntos con Ruido). Agrupa transacciones atendiendo a la densidad de sus atributos mediante métricas de proximidad específicas, tras un proceso previo de escalado y normalización de los datos. El algoritmo identifica explícitamente como «ruido» o valores atípicos (outliers) aquellas operaciones que quedan aisladas en regiones de baja densidad (Ester et al., 1996). Cabe precisar que este resultado depende sensiblemente de la escala de las variables y de la calibración de sus hiperparámetros constituyendo un indicador de atipicidad estadística que orienta la labor del auditor, sin que toda observación aislada implique necesariamente una irregularidad.

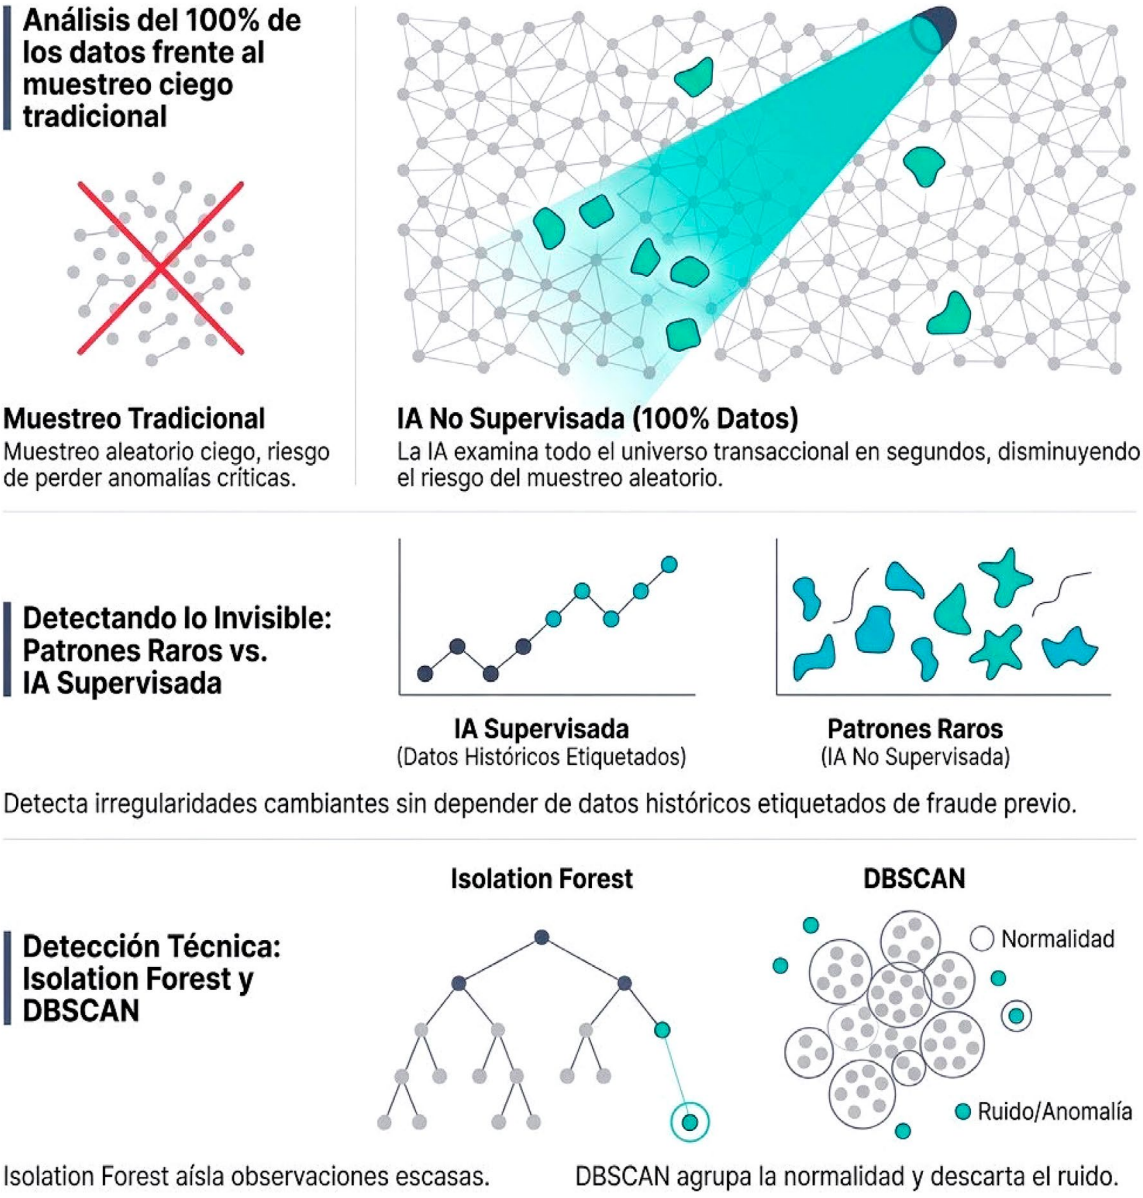

Fuente: Elaboración propia creada con Gemini.

Bajo esta transformación metodológica se puede redefinir la estrategia de fiscalización:

- **El nuevo modelo de muestreo inteligente**: En lugar de seleccionar un número limitado de expedientes al azar, el auditor utiliza la IA para complementar el estudio de los riesgos con el análisis del universo. La muestra final se puede componer del 100% de los expedientes catalogados como anomalías extremas y de una muestra aleatoria representativa para verificar el cumplimiento formal rutinario.

- **Eficiencia operativa y asignación de recursos**: El equipo de auditoría puede focalizar sus capacidades cognitivas y temporales en las áreas de mayor riesgo, complementando la estadística del muestreo tradicional y elevando sustancialmente la probabilidad de detectar irregularidades complejas.

3. El desafío de los datos no estructurados en la fiscalización pública.

Es importante destacar que la analítica sobre datos cuantitativos y metadatos estructurados (importes, NIF, fechas y partidas presupuestarias) permite detectar desviaciones numéricas evidentes, una parte sustancial del riesgo de irregularidad y menoscabo de fondos públicos se refugia en los datos no estructurados y campos de texto libre. En la gestión pública general, desde la concesión de subvenciones y ayudas sociales hasta la gestión de nóminas, expedientes sancionadores o facturación contable, las conductas elusivas y los errores sistémicos no siempre se reflejan en las cifras, sino en la redacción de memorias justificativas, informes de necesidad o descripciones del gasto.

Los gestores o solicitantes pueden alterar la redacción sintáctica en los expedientes para esquivar los controles automatizados tradicionales basados en coincidencia exacta de texto. Por ejemplo, en la fiscalización de subvenciones y ayudas públicas, dos proyectos idénticos presentados por entidades vinculadas pueden denominarse "Acompañamiento a colectivos vulnerables en el entorno urbano" y "Programa de inclusión social para familias en riesgo", esto podría evitar las alertas de duplicidad estricta, cuando en realidad constituyen un mismo proyecto financiado dos veces.

Con el fin de resolver estas vulnerabilidades en la gestión pública, el muestreo inteligente integra técnicas de Procesamiento de Lenguaje Natural (NLP) y vectorización semántica en su flujo no supervisado. Esto permite al algoritmo identificar similitudes entre descripciones en contratos y expedientes, identificando coincidencias o patrones sospechosos en la redacción:

1. **Preprocesamiento y estandarización textual**: Nodos especializados limpian el texto libre de memorias, observaciones contables o informes administrativos, eliminando palabras vacías, lematizando términos y estandarizando sintaxis.

2. **Vectorización y similitud del coseno**: A diferencia de las comparaciones léxicas tradicionales (basadas en la coincidencia sintáctica de palabras), las descripciones de los expedientes se transforman en representaciones vectoriales densas (embeddings), fundamentadas en los modelos de proyección en espacios continuos (Mikolov et al., 2013). Mediante la similitud del coseno, el algoritmo mide la cercanía geométrica entre los vectores de cada documento. Aunque un nivel alto de similitud no demuestra por sí solo la identidad jurídica del objeto del contrato, constituye un potente indicador de afinidad semántica que orienta la investigación del auditor hacia posibles duplicidades o fraccionamientos encubiertos.

3. **Clustering semántico no supervisado**: Algoritmos basados en densidad como DBSCAN o métodos de agrupamiento jerárquico identifican cúmulos (clusters) de expedientes que comparten un contenido sustantivo atípico o sospechosamente idéntico. Cuando estas agrupaciones o patrones raros coinciden con indicadores adicionales de riesgo, como la concentración de importes cerca de los umbrales de licitación, la vinculación entre proveedores o la cercanía temporal de adjudicación, los expedientes son derivados al Estrato de mayor riesgo para la revisión exhaustiva del auditor.

4. Plataformas Visuales y Trazabilidad.

La dependencia histórica de lenguajes de programación complejos (Python, R, SQL) ha frenado la digitalización masiva de las oficinas de auditoría. Exigir a equipos constituidos por auditores que dominen la sintaxis de código es poco realista. Las plataformas analíticas Low-Code / No-Code (como KNIME Analytics Platform) democratizan el tratamiento masivo de datos mediante flujos de trabajo visuales basados en nodos funcionales

conectados lógicamente.

Desde la óptica de las normas internacionales de auditoría, uno de los principios rectores inquebrantables es la trazabilidad y la reproducibilidad. Todo hallazgo, salvedad o conclusión reflejada en un informe definitivo de fiscalización debe estar respaldado por un papel de trabajo bien estructurado que cualquier otro revisor independiente pueda reproducir, verificar y validar bajo los mismos criterios y premisas analíticas.

Un flujo de trabajo basado en entornos visuales debe cumplir esta función con las siguientes características:

- **Transparencia algorítmica**: Al prescindir de código oculto o scripts opacos, el diagrama visual facilita el seguimiento de las transformaciones de los datos.
- **Estructura secuencial auditable**: Desde la importación inicial del fichero bruto extraído directamente del ERP de la administración pública, pasando por las fases de limpieza, normalización de variables, hasta la ejecución del algoritmo de aislamiento de anomalías y la exportación final de la lista priorizada, cada etapa queda documentada gráficamente.
- **Control de versiones**: La gestión centralizada del flujo analítico en repositorios de control de versiones (como KNIME Server/Hub) permite registrar la evolución histórica del modelo, auditar los cambios realizados en cada etapa y certificar la versión exacta del algoritmo que fue aplicada en una fecha determinada.
- **Inmutabilidad y reproducibilidad**: La inmutabilidad de las evidencias se puede asegurar mediante registros de trazabilidad no modificables, control de accesos por roles y sellado de tiempo para evitar alteraciones a posteriori, mientras que la reproducibilidad técnica conlleva mantener el conjunto de datos de entrada, el entorno de ejecución y fijar una semilla aleatoria estática (random seed) para que cualquier supervisor pueda replicar exactamente los mismos resultados conforme a la ISSAI 1230.

Caraterísticas de un flujo de trabajo.

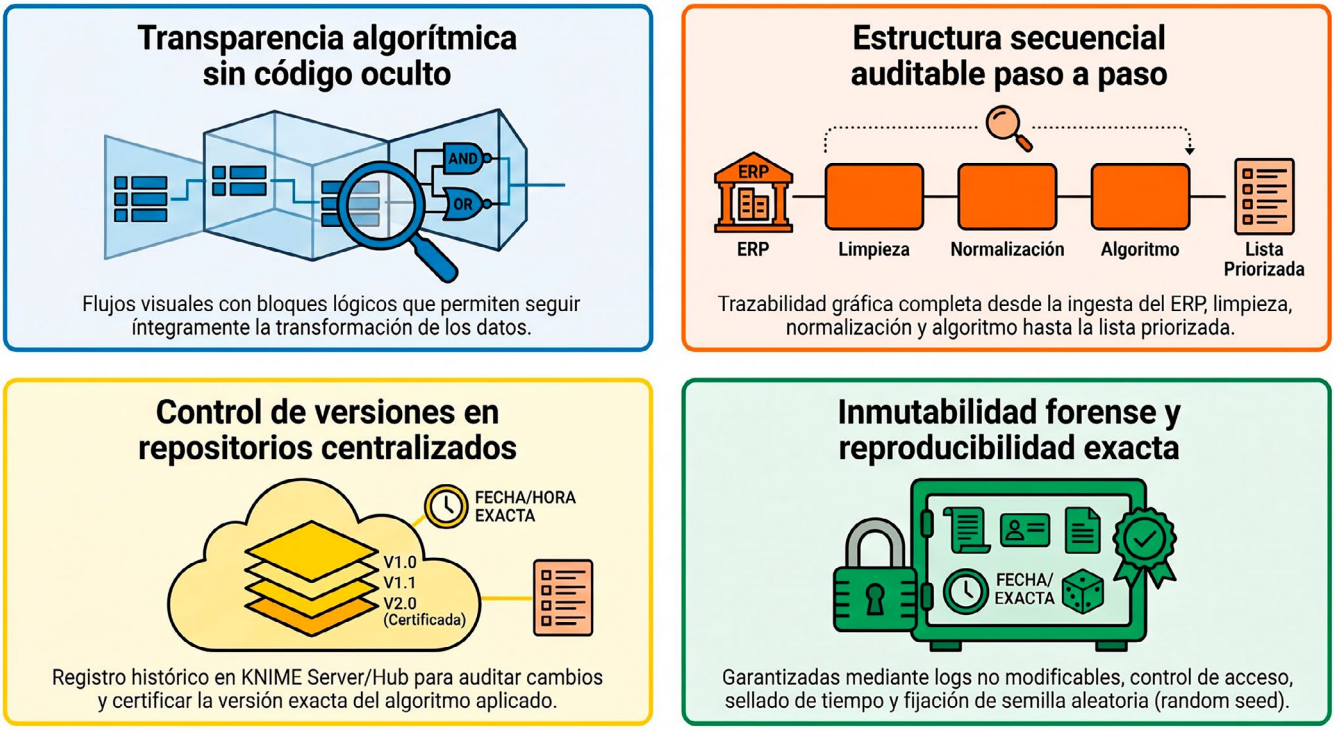

Fuente: elaboración propia creada con Notebook LLM.

5. KNIME Analytics Platform: Un ejemplo de ecosistema visual.

En este contexto metodológico, KNIME Analytics Platform constituye un ejemplo de ecosistema tecnológico para la modernización de las Entidades de Control Superior. KNIME permite al auditor construir flujos analíticos de alta complejidad mediante una interfaz gráfica basada en la conexión visual de nodos, cajas de herramientas funcionales especializadas en tareas concretas como filtrados avanzados, uniones relacionales, cálculos estadísticos descriptivos e inferenciales, y modelado de aprendizaje automático no supervisado (Isolation Forest, clustering, etc.).

Vamos a suponer un caso práctico del 100% de los datos a la selección de la muestra de auditoría y calibración algorítmica.

Para ilustrar la aplicación práctica de esta metodología, desarrollaremos un caso simulado en el ámbito de la fiscalización de la contratación menor de una administración pública local, un área clásicamente vulnerable al fraccionamiento ilegal y a la elusión de procedimientos abiertos de licitación.

Supongamos que el órgano de control se enfrenta a la revisión de la contratación menor de un ayuntamiento de un ejercicio. El universo analítico está compuesto por 8.500 registros de contratos menores. Tradicionalmente, seleccionar 50 o 100 expedientes de esta masa habría dejado aproximadamente el 99% de la contratación sin analizar. Mediante el flujo automatizado, el proceso se desglosa en tres fases prácticas enriquecidas con criterios de limpieza de datos y calibración técnica:

Fase 1: Ingesta, higiene de datos y preparación.

El equipo de auditoría extrae del sistema de gestión económico–financiera (ERP) un fichero estructurado con todos los contratos menores ejecutados en el ejercicio fiscal (un universo de 8.500 registros). Las variables disponibles incluyen Código de Expediente, Órgano Gestor, Descripción del objeto, Importe, NIF del Proveedor, Fecha de Adjudicación y Partida Presupuestaria.

- Tratamiento avanzado de la calidad del dato: El flujo analítico integra nodos previos de depuración para erradicar errores sintácticos y tipográficos antes del modelado. Esta preparación previa asegura que tanto la evaluación de distancias espaciales en DBSCAN como el proceso de partición aleatoria en Isolation Forest identifiquen patrones de riesgo económico reales en lugar de ser distorsionados por ruido en la calidad de los datos.

Fase 2: Ejecución del modelo de IA No Supervisada y Calibración de Hiperparámetros.

En lugar de establecer reglas rígidas o umbrales fijos arbitrarios, se conecta un nodo de análisis de anomalías (Isolation Forest o DBSCAN). En el caso de algoritmos estocásticos como Isolation Forest, se fija una semilla aleatoria estática (random seed) para garantizar que el modelo produzca resultados deterministas y reproducibles.

- Sensibilidad de hiperparámetros: El auditor calibra de forma iterativa los hiperparámetros críticos del modelo (por ejemplo, el parámetro de contaminación en Isolation Forest, que determina el porcentaje esperado de observaciones atípicas, o el radio ϵ y el número mínimo de puntos en DBSCAN). Es importante aclarar que la "contaminación" es un simple umbral numérico de corte, cuyo comportamiento varía según la herramienta tecnológica utilizada, y no un reflejo del nivel real de irregularidad o fraude en la masa. Este ajuste fino mitiga el sesgo de selección y adapta la sensibilidad del algoritmo al perfil de riesgo específico de la entidad auditada.

- Ejemplo práctico de análisis multivariante: El algoritmo evalúa simultáneamente importes, frecuencia de contratación reiterada con un mismo proveedor por parte de la misma área proponente en un breve espacio de tiempo, y dispersión temporal. Si un gestor adjudica de manera fragmentada múltiples contratos menores de 14.000 euros al mismo proveedor en semanas consecutivas para un objeto similar, el modelo detecta que esta combinación se desvía drásticamente del comportamiento masivo, conectando directamente con el riesgo de que se produzca un fraccionamiento ilegal de contratos tipificados en la legislación de contratos del sector público (LCSP) para eludir los umbrales de licitación abierta.

Fase 3: Construcción de la muestra estratificada inteligente.

El modelo del ejemplo prpcesa los 8.500 registros y asigna a cada contrato una puntuación de anomalía (score entre 0 y 1), clasificando el universo en tres estratos principales (ISSAI 1530). Hay que destacar que tanto la puntuación score como los estratos son elegidos para este ejemplo, por lo que no tienen por qué coincidir con la realidad ya que se pueden asignar otras puntuaciones y elegir otros estratos:

- **Estrato 1**: Alto Riesgo (Anomalías Extremas 3% / 255 expedientes): Fiscalización del 100% de los expedientes por presentar características alta-

mente atípicas (indicios claros de posible fraccionamiento o concentración de proveedores).

- **Estrato 2**: Riesgo Moderado (12% / 1.020 expedientes): Aplicación de un muestreo aleatorio sistemático del 20% para comprobar consistencias dudosas.
- **Estrato 3:** Normalidad Operativa (85% / 7.225 expedientes): Aplicación de una muestra mínima de control de calidad del 1% orientada a verificar el cumplimiento formal, para nuestro ejemplo.

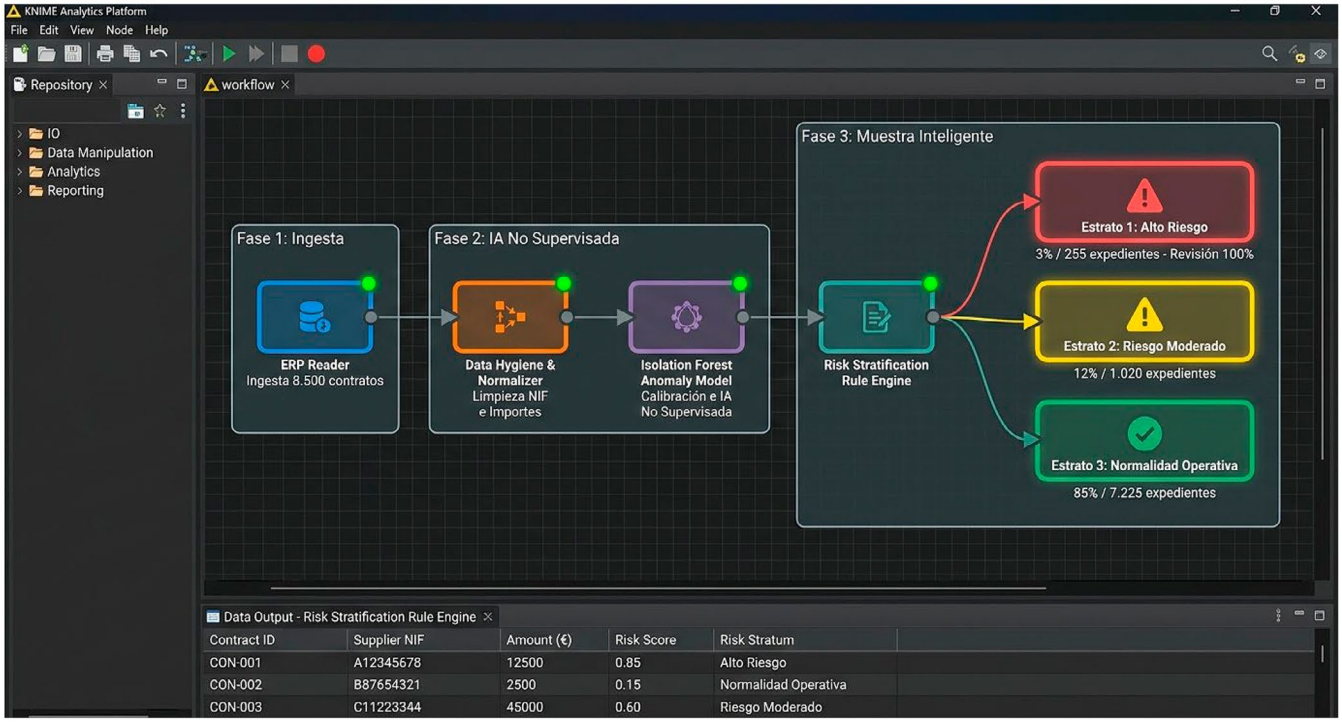

Fuente: elaboración propia creada con Notebook LLM.

6. Del Hallazgo a la Evidencia de Auditoría.

La implantación de tecnologías analíticas y de inteligencia artificial en la fiscalización pública no exime en ningún caso al auditor de su responsabilidad intelectual, técnica y jurídica; por el contrario, la eleva a un plano superior de exigencia analítica. Una alerta o puntuación de anomalía generada por un algoritmo informático no constituye por sí misma un hallazgo de auditoría definitivo ni una prueba de irregularidad, sino que representa una hipótesis de trabajo que requiere la posterior investigación y las conclusiones obtenidas por el auditor.

En el marco de las Entidades de Control Externo, el juicio profesional es un activo insustituible. Las herramientas tecnológicas actúan como aceleradores masivos de datos, pero carecen de capacidad interpretativa jurídica, de comprensión del contexto administrativo real y de discernimiento sobre la intencionalidad o el error material.

Esta centralidad del juicio humano no solo responde a una necesidad técnica, sino a un imperativo legal. Al asegurar que la IA actúe de forma puramente instrumental como soporte analítico, se da estricto cumplimiento al principio de supervisión humana (Human in the Loop) exigido por el Reglamento Europeo de Inteligencia Artificial (AI Act - Reglamento UE 2024/1689). Asimismo, esta intervención humana garantiza el respeto al Reglamento General de Protección de Datos (Reglamento UE 2016/679), evitando la toma de decisiones íntegramente automatizadas con efectos jurídicos sobre los administrados (Soriano, 2021). Todo este ecosistema tecnológico debe, finalmente, desplegarse sobre infraestructuras que aseguren la trazabilidad y protección de la información conforme a las exigencias del Esquema Nacional de Seguridad (Real Decreto 311/2022).

Uno de los principales retos operativos en la aplicación de modelos de IA no supervisada es la gestión de los falsos positivos:

- **Naturaleza de los falsos positivos y coste de oportunidad**: En cualquier universo masivo existen operaciones que resultan estadísticamente extrañas, pero cuentan con justificación jurídica válida (ej. la adquisición de un equipamiento científico–técnico especializado o licencias de software de proveedor único, donde el importe o la concentración en un único proveedor salta en el algoritmo, pero la memoria justificativa demuestra la exclusividad y legalidad del expediente). Un exceso de falsos positivos genera una fuerte «fatiga de alertas» en el equipo auditor, consumiendo valiosas horas de trabajo en descartar falsas alarmas.

- **Mitigación mediante umbrales adaptativos**: Para optimizar el esfuerzo, se recomienda el uso de matrices de decisión ajustadas al riesgo material y al coste de oportunidad, calibrando los umbrales del Estrato 1 para filtrar exclusivamente aquellas anomalías cuya desviación estadística supere un umbral de significatividad financiera y legal relevante.

Cuando la investigación posterior confirma que la alerta oculta una anomalía sustancial o una infracción normativa, esta se transforma formalmente en un hallazgo de auditoría:

- **Prueba pericial interna**: El flujo de trabajo documentado y versionado sirve como una prueba interna de gran solidez jurídica. Ante los argumentos de defensa del fiscalizado que traten de tildar la selección de arbitraria, el auditor demuestra que la fiscalización obedeció a un análisis sistemático, automatizado e integral de los riesgos del 100% de la población bajo criterios estadísticos objetivos.

- **Garantía de objetividad institucional**: La trazabilidad algorítmica ayuda a que las conclusiones del informe estén mejor soportadas frente a posibles alegaciones, reforzando la autoridad institucional del órgano de control externo y aumentando la seguridad jurídica en la protección de los fondos públicos.



7. Conclusiones y hoja de ruta para integrar la analítica en las auditorías.

La incorporación de la inteligencia artificial no supervisada y de plataformas visuales en la fiscalización pública representa un salto cualitativo importante y un puente hacia la madurez digital de los órganos de control externo. Lejos de sustituir el juicio humano, de desvirtuar la esencia de la función fiscalizadora o de eliminar el tradicional muestreo, estas tecnologías lo complementan y transforman radicalmente la auditoría en un proceso altamente estratégico.

Para que la transformación tecnológica no quede reducida a una iniciativa aislada, las Entidades de Control Externo deben transitar de forma ordenada por una hoja de ruta estructurada:

- **Fase 1: Arquitectura de Gobernanza del Dato, Higiene y Estandarización de Ingesta**. Establecer protocolos homogéneos de extracción directa desde los sistemas ERP y diseñar un repositorio centralizado que garantice la limpieza y el acceso al 100% de la población transaccional.

- **Fase 2: Formación del Auditor y Control de Versiones**. Adoptar entornos Low-Code / No-Code (como KNIME Analytics Platform) integrados con sistemas de control de versiones (KNIME Server/Hub) para reforzar la trazabilidad forense y eliminar la barrera de la programación avanzada.

- **Fase 3: Ejecución, Calibración de Hiperparámetros y Gestión de Alertas**. Desplegar los modelos en nichos críticos de alto volumen (como contratación menor), calibrando rigurosamente los hiperparámetros de aislamiento (Isolation Forest / DBSCAN) y controlando la fatiga de falsos positivos.

- **Fase 4: Institucionalización Metodológica y Blindaje Jurídico**. Actualizar los manuales técnicos internos para reconocer los flujos visuales versionados como papeles de trabajo electrónicos, de forma que se queden documentados adecuadamente, y que sirvan para defender los informes ante alegaciones y recursos jurídicos.



Fuente: elaboración propia creada con Notebook LLM.

8. Referencias Bibliográficas.

Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. En Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96) (pp. 226–231). AAAI Press.

Genaro-Moya, D., López-Hernández, A. M., & Godz, M. (2025). Artificial Intelligence and Public Sector Auditing: Challenges and Opportunities for Supreme Audit Institutions. World, 6(2), 78. https://doi.org/10.3390/world6020078

Ley 9/2017, de 8 de noviembre, de Contratos del Sector Público, por la que se trasponen al ordenamiento jurídico español las Directivas del Parlamento Europeo y del Consejo 2014/23/UE y 2014/24/UE, de 26 de febrero de 2014. Boletín Oficial del Estado, 272.

Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). Isolation forest. En 2008 Eighth IEEE International Conference on Data Mining (pp. 413–422). IEEE.

Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. arXiv preprint arXiv:1301.3781.

Omoteso, K. (2012). The application of artificial intelligence in auditing: Looking back to the future. Expert Systems with Applications, 39(9), 8490–8495.

Real Decreto 311/2022, de 3 de mayo, por el que se regula el Esquema Nacional de Seguridad. Boletín Oficial del Estado, 106.

Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo, de 27 de abril de 2016, relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos (Reglamento General de Protección de Datos - RGPD). Diario Oficial de la Unión Europea, L 119.

Reglamento (UE) 2024/1689 del Parlamento Europeo y del Consejo, de 13 de junio de 2024, por el que se establecen normas armonizadas en materia de inteligencia artificial (Ley de Inteligencia Artificial / AI Act).

Soriano, A. (2021). Decisiones automatizadas: problemas y soluciones jurídicas. Más allá de la protección de datos. Revista de Derecho Público: Teoría y Método, 3, 85–127.

Vasarhelyi, M. A., Kogan, A., & Tuttle, B. M. (2015). Big Data in accounting: An overview. Accounting Horizons, 29(2), 381–396.