



Revisión de la Literatura
preparado para
Empleo de IA para la retención y disposición en sistemas digitales de
información y documento de archivo (AA01)
Un proyecto de IA InterPARES Trust

Patricia C. Franks, investigadora (SJSU)

Souvick Ghosh, investigador (BSISDA y SJSU)

Alicia Butler, Asistente de Investigación de Posgrado (SJSU)

20 de mayo de 2022

Traducción por máquina,

Edición: Alicia Barnard, consultora independiente

28 de febrero de 2026

Resumen

Este análisis bibliográfico busca revisar lo que se ha publicado sobre cómo se están utilizando la inteligencia artificial (IA) y el aprendizaje automático (ML) para la retención y disposición de documentos de archivo en los sistemas de gestión documental automatizados. Proporciona un breve repaso de qué son la inteligencia artificial, el aprendizaje automático, los algoritmos y cómo funcionan. A continuación, se explora la literatura sobre IA y retención y disposición, utilizando los Principios[®] de Gestión de Archivo Generalmente Aceptados de ARMA International (2019) y el Ciclo de Vida de Gestión Documental e Información (RIM)¹ como esquema organizativo. Los artículos relacionados con los Principios[®] revelaron que los modelos de IA creados o implementados para tomar decisiones sobre la conservación y disposición de los documentos de archivo deben ser capaces de tomar decisiones explicables e imparciales, demostrar integridad y ser capaces de cumplir con todo. Los artículos revisados relacionados con el ciclo de vida de RIM demostraron que se podían utilizar o adaptar herramientas de valoración y clasificación para determinar cuánto tiempo debían conservarse documentos e informar a archivistas o gestores de documentos sobre el final de ese periodo. No es que se haya creado un modelo específico para realizar las tareas de retención y disposición que se van a utilizar con ese propósito. Para los procesos de retención y disposición en los sistemas digitales de información y gestión documental se están utilizando o podrían analizarse diversas herramientas de inteligencia artificial, desde aquellas personalizadas hasta herramientas comerciales de e-descubrimiento² y software como servicio.

¹ Nota de edición. Los términos archivísticos, de gestión documental o inteligencia artificial se han traducido al español mientras los acrónimos se mantienen en inglés como referencia. En particular los términos de archivística y gestión documental en español pueden variar según el contexto de uso en los países hispanoparlantes

² Nota de edición. Los términos “descubrimiento electrónico” en español y “e. Discovery” en inglés por general se usan indistintamente.

Introducción

La inteligencia artificial (IA) está cada vez más presente en la vida diaria. Desde anuncios personalizados en nuestros navegadores hasta autos autónomos, la IA está creciendo en complejidad, capacidad y ubicuidad. El aprendizaje automático (ML) permite que los modelos de IA aprendan y cambien en función de la experiencia, avanzando aún más los sistemas y ampliando sus usos. Esto ha llevado a los profesionales de la gestión documental e información (RIM) a explorar cómo se puede implementar la IA en los sistemas gestión documental. En todo el mundo, profesionales, investigadores y proveedores comerciales de RIM están experimentando con IA y gestión documental, aprendiendo qué funciona y qué no, y compartiendo sus hallazgos. Al respecto, InterPARES busca comprender y aprovechar la IA para "apoyar la disponibilidad y accesibilidad continua de documentos de archivo públicos fiables" (InterPARES Trust AI, 2021) mediante investigación, formación y colaboración institucional. Este estudio busca examinar un aspecto de la consulta más amplia de InterPARES, y es el caso de la IA y la retención y disposición.

Este artículo es una revisión de la literatura sobre IA y retención y disposición. Primero explicamos brevemente qué son la inteligencia artificial y el aprendizaje automático, cómo funcionan y definimos la terminología utilizada en este artículo. Después, exploramos la literatura sobre el tema de la IA y la retención y disposición que se relacionan con los Principios® de Gestión Generalmente Aceptados (ARMA International, 2019). Los Principios® se utilizan aquí como un mecanismo organizativo a través del cual se presentan los recursos que tratan temas que se aplican a todo el ciclo de vida de la gestión de documentos y que, por tanto, no podrían incluirse en la sección final del artículo. Concluimos investigando cómo la IA se cruza con el ciclo de vida de la gestión documental e información, principalmente en las áreas de producción, distribución y uso, y retención y disposición (Franks, 2018, p. 36).

Pregunta de investigación

¿Cómo se están utilizando la inteligencia artificial (IA) y el aprendizaje automático (ML) para la retención y disposición en sistemas de información y documento de archivo de datos?

Inteligencia artificial y aprendizaje automático

La inteligencia artificial está en constante evolución, como resultado, aún existe consenso limitado sobre qué constituye la "inteligencia artificial". La OCDE (2019) afirmó que "no existe una

definición universalmente aceptada de IA" (p. 3) antes de presentar la definición que consideraban la más precisa. Mas adelante afirmó que "un sistema de IA es un sistema basado en máquinas que puede, para un conjunto determinado de objetivos definidos por humanos, hacer predicciones, recomendaciones o decisiones que influyan en entornos reales o virtuales" (OCDE, 2019, p. 4). La definición de Thomas (2019) fue similar, afirmando que "la IA es un término paraguas para una familia de técnicas que permiten a las máquinas aprender de los datos y actuar sobre lo que han aprendido en lugar de simplemente seguir instrucciones mecánicas creadas por un programador" (p. 2). Lepak (2021) ofreció una definición más sencilla, diciendo que "la IA simplemente enseña a las máquinas a aprender para que puedan tomar decisiones" (párrafo 5).

El aprendizaje automático es un tema menos ambiguo. La OCDE (2019) definió el aprendizaje automático como sistemas que "aprovechan enfoques estadísticos para aprender a partir de datos históricos y hacer predicciones en nuevas situaciones" (p. 1) o "un conjunto de técnicas que permiten a las máquinas aprender de manera automatizada mediante patrones e inferencias en lugar instrucciones explícitas de un humano" (p. 7). Goodfellow et al. (2016) describieron el aprendizaje automático como sistemas de IA con "la capacidad de adquirir su propio conocimiento, extrayendo patrones de datos en bruto" (p. 2). El aprendizaje automático es un tipo de tecnología de IA. No todos los sistemas de IA tienen componentes de ML, pero todos los sistemas de ML son un tipo de IA.

Lepak (2021) también presentó una conceptualización muy básica de cómo funcionan típicamente los sistemas de IA. La mayoría de los modelos de IA utilizan algoritmos, que son "procedimientos paso a paso, o conjunto de instrucciones, que la IA utiliza para realizar análisis según criterios antes de tomar su decisión de SÍ o NO" (Lepak, 2021, párrafo 10). Una máquina o un programa recibe datos, los analiza según criterios proporcionados por humanos (algoritmos), luego determina si esos datos cumplen o no con los criterios y procede a completar una tarea según las indicaciones previas (Lepak, 2021, párrafo 6). La OCDE (2019) ofreció una conceptualización más profunda pero aún de muy alto nivel. "El núcleo de un sistema de IA es el modelo de IA" (OCDE, 2019, p. 5), que representa el entorno del sistema, se guía por objetivos y mide el rendimiento. El modelo recoge información del entorno (ya sea real o virtual) mediante sensores, y luego utiliza lógica operativa (algoritmos) para proporcionar una salida basada en la información recopilada. Luego utiliza actuadores (o activadores) para realizar cambios en el entorno basándose en las decisiones tomadas por la lógica operativa (OCDE, 2019, p. 3).

Esto no es en absoluto un análisis exhaustivo de la inteligencia artificial, el aprendizaje automático, los algoritmos o su funcionamiento. Pretende ofrecer una breve visión general de las definiciones y funcionalidad para proporcionar conocimientos de base para el resto de la investigación presentada en esta revisión bibliográfica.

Los Principios®

La literatura sobre inteligencia artificial vinculada a retención y disposición incluía varios recursos centrados en aspectos de la gestión documental presentes a lo largo del ciclo de vida de los documentos de archivo. Estos elementos coincidieron con tres de los Principios® Generalmente Aceptados: Transparencia, Integridad y Cumplimiento (ARMA International, 2019).

Transparencia

El principio de transparencia establece que "los procesos y actividades institucionales o empresariales de una organización, incluido su programa de gobernanza de la información, deben documentarse de manera abierta y verificable y que la documentación estará disponible para todo el personal y las partes interesadas" (ARMA International, 2019). Uno de los mayores desafíos para la aplicación de la IA en los procesos de gestión documental, particularmente en la retención y la disposición, es el problema de la caja negra, o "la incapacidad actual de la máquina para explicar sus decisiones y acciones a los usuarios humanos" (Turek, s.f.). Los modelos de IA a menudo toman decisiones de forma no documentada e inexplicable. Otro desafío al que se enfrentan las comunidades de IA y de archivística y de gestión documental es el sesgo en IA. Las decisiones tomadas por un modelo de IA sesgado se ven afectadas por el sesgo del sistema, que puede estar oculto cuando el modelo carece de transparencia. Se han escrito varios artículos sobre el problema de la caja negra y el sesgo en los modelos de IA, incluyendo los siguientes.

Turek (s.f.) presentó un proyecto de investigación para crear soluciones de IA para explicar su razonamiento en la toma de decisiones a los usuarios a través de una interfaz de usuario. El artículo exploraba la incapacidad de los modelos de IA para comprender sus valores de salida a los usuarios y comentaba que esto limitaba su efectividad. Su proyecto tenía como objetivo explorar la psicología de la explicación y desarrollar soluciones de IA que "tuvieran la capacidad de explicar su razonamiento, caracterizar sus fortalezas y debilidades y transmitir una comprensión de cómo se

comportarán en el futuro" (Turek, s.f.). Turek defendió que los modelos de inteligencia artificial explicable (XAI) serán más fiables y eficaces que los modelos existentes.

Bunn (2020) también examinó XAI y cómo los profesionales de la gestión documental pueden interactuar con él. El artículo señalaba que "el uso creciente de técnicas de IA más opacas generalmente se presenta como disruptivo para el documento de archivo" (Bunn, 2020, p. 144) y comentaba que los profesionales de gestión documental están especialmente capacitados para ayudar a desarrollar modelos XAI. Bunn (2020) informó sobre un taller interdisciplinar organizado por la autora centrado en la IA explicable sustentado en los humanos y sus necesidades de explicación. Los asistentes al taller expresaron su deseo de una mejor comprensión pública de la IA y propusieron que la implementación de XAI podría cambiar la metáfora común de la caja negra por la de un iceberg, comentaron:

Aquí sabíamos que había más debajo de la superficie de lo que podíamos ver de inmediato, pero también necesitábamos poder mirar por encima y por debajo de la línea de flotación. En algunos casos, puede que no nos importe lo que haya bajo la superficie, pero en otros puede ser muy importante. (Bunn, 2020, p. 147)

El artículo defendía firmemente conversaciones interdisciplinarias y exploratorias sobre la IA y la explicabilidad y recomendaba que los responsables de los documentos de archivo podían ayudar en el desarrollo de XAI aprendiendo sobre IA y participando en estas conversaciones.

El juez Dixon Jr. (Ret.) (2021) evaluó la IA y sus usos en el sistema de justicia penal. El artículo explicaba cómo se utiliza la IA para el e-descubrimiento, la policía predictiva, la resolución de crímenes y la evaluación de riesgos. El juez Dixon (2021) examinó los riesgos del sesgo de IA en la policía predictiva y en la evaluación del riesgo de reincidencia (la probabilidad de que una persona cometa de nuevo un delito al ser liberada de la custodia). El artículo proporcionaba ejemplos en los que los modelos de IA utilizados para estos fines tomaban decisiones incorrectas y obviamente sesgadas, especialmente en casos en los que la raza de una persona era una variable. El autor concluyó pidiendo una evaluación más cuidadosa de la IA, sus capacidades y su idoneidad para una tarea determinada antes de la implementación del modelo.

Mehrabi et al. (2021) también examinaron el problema del sesgo en el aprendizaje automático. Exploraron ejemplos de injusticia algorítmica en sistemas que demuestran discriminación y analizaron tipos de sesgo en datos, algoritmos y experiencias de usuario. El artículo presentó entonces un ciclo de sesgo en los modelos de aprendizaje automático. Si los datos de entrenamiento de un modelo están sesgados, entonces el algoritmo que entrenó con esos datos

también estará sesgado. Ese algoritmo produce entonces un resultado sesgado, que influye en la interacción del usuario con el modelo y genera datos más sesgados. El artículo exploró varias definiciones de equidad y concluyó que "no existe una definición universal de equidad" (Mehrabi et al., 2021, p. 11), pero que "en términos generales, la equidad es la ausencia de cualquier prejuicio o favoritismo hacia un individuo o un grupo basado en sus rasgos intrínsecos o adquiridos en el contexto de la toma de decisiones" (Mehrabi et al., 2021, p. 11). Luego analizaron la literatura sobre métodos a utilizar para que los algoritmos y el aprendizaje automático funcionen de forma más justa.

El Instituto Nacional de Estándares y Tecnología (NIST) publicó recientemente un documento que exploró los sesgos en la tecnología de inteligencia artificial y proporcionó orientación para abordarlos con el objetivo de iniciar un debate para la creación de un estándar del NIST con el propósito de apoyar en esta área (Schwartz et al., 2022). Los autores exploraron el contexto y las categorías de los sesgos de IA, discutieron cómo los sesgos en IA pueden causar daño y propusieron la adopción de un enfoque socio tecnológico para la creación de IA y un ciclo de vida actualizado de la IA. Los desafíos para la mitigación de sesgos en IA que identificaron incluían características de conjuntos de datos, problemas de pruebas y evaluación, y factores humanos (Schwartz et al., 2022, p. ii). El artículo concluyó con el compromiso del NIST de continuar colaborando con la comunidad investigadora y otros actores para brindar más orientación sociotécnica sobre cómo abordar el sesgo en los modelos de IA (Schwartz et al., 2022, p. 48).

Jo y Gebru (2020) examinaron las cuestiones de equidad, responsabilidad, transparencia y ética relacionadas con la colección de conjuntos de datos utilizados para entrenar sistemas de aprendizaje automático y argumentaron que este proceso debería estar informado por políticas y prácticas archivísticas y bibliotecarias (Jo & Gebru, 2020, p. 306). Defendían que, dado que archivistas y bibliotecarios llevan más tiempo gestionando colecciones que los profesionales de ML, los procesos de ML podrían mejorarse abordando la recopilación de datos desde una perspectiva archivística o bibliotecaria. El artículo exploró los conceptos de consentimiento, inclusión, poder, transparencia, ética y privacidad. Luego enumeró ejemplos de acciones que los profesionales de ML pueden tomar para recopilar conjuntos de datos de mejor calidad de manera más ética.

Las decisiones sobre la conservación y disposición de los documentos de archivo deben tomarse de manera que favorezca la transparencia, aunque los procesos actuales de IA no lo respaldan. Turek (s.f.) y Bunn (2020) exploraron el problema de la toma de decisiones opaca por

parte de los sistemas de IA y defendieron la inteligencia artificial explicable como solución al problema de la caja negra. Bunn (2020) vinculó específicamente este problema con el campo de la gestión documental y propuso una solución. Sin embargo, ninguno examinó explícitamente el impacto que puede tener XAI en las prácticas de retención y eliminación, ni discutió cómo podría implementarse XAI para mejorar las prácticas de retención y toma de decisiones de disposición. El juez Dixon Jr. (retirado) (2021) evaluó la IA y sus usos en el sistema de justicia penal, defendiendo que los modelos deberían evaluarse con mayor cuidado para asegurar que sean apropiados para una tarea determinada antes de su implementación. Mehrabi et al. (2021) y Schwartz et al. (2022) evaluaron el sesgo en los sistemas de IA en general, exploraron cómo el sesgo causa daño y propusieron soluciones para mitigarlo. Jo y Gebru (2020) abordaron específicamente el sesgo en los conjuntos de datos de entrenamiento como un problema en la creación de modelos sesgados. Así, cualquier modelo implementado para tomar decisiones sobre la conservación y disposición de los documentos de archivo debe considerar tanto la inteligencia artificial explicable como la sesgada.

Integridad

El principio de Integridad establece que "se construirá un programa de gobernanza de la información para que los activos de información generados o gestionados para la organización tengan una garantía razonable de autenticidad y fiabilidad" (ARMA International, 2019). Se ha escrito mucho sobre la integridad de los documentos de archivo digitales, pero menos sobre cómo la IA afecta a la integridad. El Grupo de Trabajo de Autenticidad de InterPARES (2002) establece los requisitos que deben cumplirse para establecer la autenticidad de los documentos de archivo electrónicos cuando se transfieren del creador al preservador y describe los requisitos que deben cumplirse para mantener la autenticidad de los documentos de archivo electrónicos una vez establecida dicha autenticidad. Estos requisitos son aplicables a documentos de archivo gestionados o afectados por modelos de IA, pero en el documento no se explica cómo la IA podría utilizarse para ayudar en el proceso de establecer y mantener la autenticidad de los documentos de archivo. Del mismo modo, el análisis de Katuu (2021b) sobre un proyecto de implementación de planificación de recursos empresariales (ERP) explora cuestiones relacionadas con la gestión documental en un sistema de IA. El proyecto que exploró Katuu sufría de una falta de prácticas de gestión documental con resultados de documentos de archivo poco fiables, inexactos y no fidedignos. Ambos recursos subrayan cómo los procesos y prácticas de gestión documental pueden aplicarse a los modelos de IA para mejorar o mantener la integridad de los documentos de

archivo conservados, pero ninguno examina cómo los modelos de IA pueden aplicarse a los procesos y prácticas gestión documental para lograr lo anterior.

Conformidad (cumplimiento normativo)

El principio de conformidad o cumplimiento normativo establece que "un programa de gobernanza de la información deberá construirse para cumplir con las leyes aplicables, otras autoridades vinculantes y las políticas de la organización" (ARMA International, 2019). El cumplimiento es un aspecto importante de la disposición, ya que muchas leyes y regulaciones sobre la gestión documental exigen los plazos de conservación de los documentos de archivo o cuales son las circunstancias mediante las cuales pueden (o deben ser) eliminados. Fosch Villaronga et al. (2017) analizaron cómo se cruzan la IA y el Derecho al Olvido. Los autores realizaron un análisis legal del Derecho al Olvido, su historia y definiciones relevantes. Discutieron controversias legales sobre la ley y examinaron los detalles técnicos de la eliminación para determinar si el Derecho al Olvido funciona con la IA. Concluyeron que "puede ser imposible cumplir los objetivos legales del Derecho al Olvido en entornos de inteligencia artificial" (Fosch Villaronga et al., 2017, p. 304) y teorizaron acerca de la desconexión entre los requisitos legales y la realidad técnica, la cual se extiende a otras áreas del cumplimiento de la privacidad y la IA.

Gestión (administración) del ciclo de vida del documento de archivo y de la información

El ciclo de vida de la gestión documental e información se compone de cinco etapas: creación, distribución y uso, almacenamiento y mantenimiento, retención y disposición, así como preservación archivística (Franks, 2018, p. 36). La mayor parte de la literatura revisada sobre inteligencia artificial y retención y disposición se dividió en una de tres etapas: creación, distribución y uso, o retención y disposición.

Colavizza et al. (2022) presentaron un estudio similar de la literatura reciente sobre la intersección entre la inteligencia artificial y la teoría y práctica archivística a través del prisma del Modelo de Continuidad de Documentos de Archivo (Colavizza et al., 2022, p. 1). Exploraron las consideraciones teóricas y profesionales de los archivos y la IA, incluyendo cómo la IA afecta a la teoría archivística y cómo la transformación de los archivos de espacios físicos a digitales afecta a los procesos tradicionales de valoración. Los autores revisaron varias publicaciones sobre la

automatización de procesos y decisiones de conservación de documentos de archivo, incluyendo valoración, metadatos y el manejo de información sensible. Artículos adicionales trataban sobre métodos para organizar y acceder a archivos, extracción e indexación automática de contenidos, formas alternativas de leer documentos de archivo y tácticas para mejorar la búsqueda y recuperación. Exploraron formas novedosas de archivos digitales y revisaron tendencias en la literatura sobre el uso ético de la IA y cómo podría utilizarse para crear un documento de archivo más inclusivo y diverso. El artículo analizaba cómo la IA está llevando los principios archivísticos al límite, introduciendo una nueva dimensión en el mundo de la gestión documental y señalaba la falta de debate sobre los límites y consecuencias de la implementación de la IA que puede existir. Colavizza et al. también comentaron cómo "hay espacio de sobra para diseñar y desarrollar soluciones impulsadas por IA que mejoren y enriquezcan la forma en que los académicos pueden utilizar los archivos" (2022, p. 10). Señalaron que gran parte de la literatura sobre este tema se centra en las dimensiones de "organizar" y "pluralizar" del Modelo de Continuidad de Documentos de Archivo, mientras que los temas relacionados con la "captura" (ingreso) son escasos y aún más sobre "crear" (producción) (Colavizza et al., 2022, p. 10). Concluyeron explorando áreas en las que el trabajo adicional beneficiaría a los archivos y a la comunidad de IA, como la elaboración de literatura sobre cómo transformar estudios de caso y proyectos en prácticas a largo plazo, el trabajo en el marco ético de la IA para mejorar la confianza en los sistemas de IA, la actualización de la teoría archivística y su relación con los avances de la IA que involucre la participación de archivistas en el desarrollo de la IA para dar a conocer sobre su desarrollo.

Creación

Una cuarta parte de los artículos revisados para este artículo trataban sobre la creación, valoración y clasificación de IA y documentos de archivo. Aunque al principio pueda parecer ilógico incluir estos recursos en una revisión de la IA y la retención y disposición, es importante recordar que el proceso de creación de documentos de archivo tiene un efecto directo en las prácticas de retención y eliminación. Algunas tecnologías o procesos de IA tienen la capacidad potencial de asignar periodos de retención y condiciones de disposición a un elemento al ser ingerido en un sistema. Esto significa que, al hablar de IA, retención y disposición, la creación debe formar parte de la conversación. En este contexto, la fase de creación del ciclo de vida incluye la valoración e ingesta de nuevos elementos en un sistema o fondo (o serie) y la tarea de clasificar esos elementos.

Valoración

La valoración de los documentos de archivo es especialmente importante en el entorno digital, ya que mantener cada elemento o colección para siempre no es sostenible. Belovari (2017) expuso que "la valoración significa determinar el valor y la calidad del contenido y, más allá de la identificación, en realidad implica seleccionar qué debe preservarse de forma permanente y qué no" (pp. 56-57). La valoración permite a los gestores de documentos de archivo y archivistas dirigir su energía y experiencia al cuidado de los documentos de archivo con valor. La cuestión es cómo la inteligencia artificial puede ayudar en este proceso el cual es muy común.

Harvey y Thompson (2010) investigaron los requisitos para la automatización del proceso de valoración y revaloración para objetos digitales. Encontraron que los principales problemas detrás de la imposibilidad de automatizar el proceso de valoración son el enorme volumen de materiales nacidos digitales y la experiencia técnica necesaria para gestionarlos (Harvey & Thompson, 2010, p. 314). Abordaron la valoración como "parte del proceso continuo de gestión del ciclo de vida" (Harvey & Thompson, 2010, p. 314) y un aspecto esencial de la gestión responsable y a largo plazo de colecciones. Una vez que un elemento recibe un periodo de retención o se determina que forma parte de la colección permanente, el repositorio es responsable de garantizar su supervivencia y accesibilidad. La re-valoración permite a los responsables de los documentos de archivo evaluar el riesgo de obsolescencia tecnológica de un elemento (una amenaza significativa para la supervivencia de los elementos digitales) y actuar para prevenirlo. El artículo sugería "que la re-valoración continua de los aspectos técnicos es un candidato principal para algún nivel de automatización" (Harvey & Thompson, 2010, p. 317) y expuso un marco de alto nivel para un proceso automatizado de re-valoración. La solución de IA primero validaría el formato de archivo de un objeto y luego identificaría la versión del formato. Se identificarían la(s) aplicación(es) necesaria(s) para generar (renderizar) el archivo y (opcionalmente) validarlo en contra de un clave hash (Harvey & Thompson, 2010, p. 318). Si alguno de esos pasos fallara, probablemente habría ocurrido una falla técnica y el programa alertaría del problema al gestor de documentos o a otro sistema. Las ventajas de la re-valoración automatizada incluyen una mayor eficiencia, la capacidad de detectar problemas previamente (ofreciendo más tiempo para su atención), contar con procesos fiables (si el sistema está bien diseñado), capacidad de planificar de forma más eficaz y una mayor capacidad para gestionar adecuadamente colecciones más grandes. Este enfoque se limita ante la imposibilidad de funcionar completamente sin intervención humana, solo funciona con metadatos técnicos, los metadatos creados por el proceso pueden ser legibles por máquina, es necesario crear

otros sistemas para actuar sobre la información descubierta por el proceso de re-valoración, y tiene poco o ningún valor para colecciones a corto plazo. Además, los autores plantearon la pregunta: "¿puede ser totalmente fiable un proceso automatizado que se ejecute sin supervisión?" (Harvey & Thompson, 2010, p. 319). Exploraron algunos requisitos necesarios para que el marco propuesto funcionara, a saber, cantidad y calidad suficientes de metadatos y sistemas o procesos adicionales para actuar sobre los resultados de la herramienta de re-valoración. También señalaron que el coste y la complejidad de crear e implementar una herramienta de re-valoración de IA eran desconocidos y podrían suponer una barrera significativa para su implementación. Concluyeron recomendando más investigación sobre la aplicación práctica de su modelo conceptual.

El artículo de Belovari (2017) describía el experimento del autor en la valoración de archivos digitales. El autor argumentó que la facilidad y rapidez de procesar colecciones digitales una vez valoradas hacen que "ciertas tareas tradicionales de organización sean innecesarias, así como las funcionalidades de búsqueda digital puedan hacer que muchas descripciones tradicionales sean redundantes" (Belovari, 2017, p. 57). Probaron diez tipos diferentes de software y finalmente seleccionaron TreeSize Professional (TSP) como el más eficaz para su organización y propósitos. Crearon un flujo de trabajo para la valoración de colecciones digitales que utilizaba software y métodos manuales y realizaban el flujo de trabajo en una colección en los Archivos Estatales de Ludwigsburg. Comenzaron con una rápida inspección, evaluando la colección en busca de riesgos. Luego, pasaron a hacer una evaluación general, eliminando manualmente directorios duplicados, usando software para eliminar archivos duplicados, carpetas vacías y archivos temporales o técnicos. Este proceso duró algo más de una hora y resultó en la eliminación del 70% de los archivos de la colección. Finalmente, el autor realizó una valoración cualitativa de profundidad en la que decidió qué nivel de profundidad era posible valorar la colección, detalló criterios sobre qué conservar, revisar archivos detalle o vistas con anterioridad para decidir qué conservar o eliminar. El flujo de trabajo detallado redujo una colección de 677 GB a una décima parte de ese tamaño en cuatro días.

Lee (2018) también habló sobre la valoración de materiales archivísticos y cómo los ordenadores pueden utilizarse para ayudar a los archivistas en el proceso de valoración. El artículo exploró cómo la sección (o serie) y la valoración de los materiales digitales difieren de los analógicos, ya que "los materiales digitales existen en múltiples niveles de representación" (Lee, 2018, p. 2721) y su naturaleza inherentemente legible por máquina facilita a los usuarios la identificación de patrones. Lee revisó tres tipos de tecnología que pueden utilizarse para ayudar en

la valoración archivística. La informática forense digital puede ser útil para extraer metadatos de diversas colecciones y construir líneas de tiempo a partir de la información extraída. El procesamiento del lenguaje natural (PLN) puede utilizarse para "capturar y proporcionar acceso a información contextual" (Lee, 2018, p. 2723), especialmente mediante el reconocimiento de entidades nombradas. Las herramientas de aprendizaje automático pueden utilizarse para automatizar la clasificación y reducir el tiempo que tarda en procesar una colección. Lee enumeró algunos proyectos o publicaciones que han explorado cada tecnología y concluyó con un llamamiento para continuar investigando y desarrollando tecnologías que mejoren la selección y valoración archivística.

Makhlouf Shabou et al. (2020) emprendieron un proyecto de investigación con la intención de crear una herramienta de valoración archivística que pudiera identificar y extraer datos relevantes de una colección llena de formatos y contenidos diversos, y luego ayudar en la toma de decisiones basadas en los datos extraídos. Los investigadores crearon una lista de atributos de datos variables y programaron software para asignar una puntuación a cada elemento de una colección para cada categoría de variable. Así, las puntuaciones proporcionaban un valor numérico al archivero que representaba la presencia de ese atributo en un conjunto de documentos. Por ejemplo, los investigadores evaluaron una carpeta raíz (colección o serie) para verificar la completitud de los metadatos. Ésta contenía 13.179 archivos (expedientes) y la herramienta de evaluación identificó que el 66,1% de la colección tenía metadatos completos, el 30,8% tenía metadatos medio completos y el 3,1% no tenía metadatos, lo que resultó en una puntuación global de metadatos del 81% (Makhlouf Shabou et al., 2020, pp. 192-193). Los archivistas podrían utilizar la información recopilada y las puntuaciones generadas por la herramienta de valoración para tomar decisiones de valoración, retención y disposición.

La literatura publicada sobre la intersección entre la gestión o archivos documentales, la inteligencia artificial y la valoración coincide en que el proceso de valoración se está volviendo cada vez más difícil a medida que las colecciones digitales aumentan en tamaño, complejidad y ubicuidad. También coinciden en que la IA podría aprovecharse para facilitar este proceso. Harvey y Thompson (2010) propusieron un marco de alto nivel para automatizar el proceso de valoración y re-valoración de objetos digitales y exploraron sus posibles beneficios y limitaciones. El experimento de Belovari (2017) con la idea de un flujo de trabajo para utilizar métodos manuales y de IA para valorar una colección digital demostró la eficacia de dicha solución. Lee (2018) revisó tecnologías específicas (forense digital, procesamiento de lenguaje natural y aprendizaje

automático) y detalló cómo podrían aprovecharse para ayudar en el proceso de valoración. Makhoulf Shabou et al. (2020) idearon una herramienta que podía extraer datos de colecciones y asignar puntuaciones a archivos individuales o colecciones completas. Su herramienta podría ahorrar tiempo a los archivistas y ayudar en la toma de decisiones rápidas durante el proceso de valoración. Aunque mejorar el proceso de valoración es un objetivo importante, solo Harvey y Thompson (2010) examinaron cómo las herramientas de valoración con IA podrían utilizarse durante la vida de las colecciones, pero no llegaron a considerar cómo estas herramientas podrían ayudar en los flujos de trabajo de retención y eliminación. Si una herramienta de valoración puede determinar si un ítem o colección es archivado en un sistema, ¿podría ser que también pueda determinar cuánto tiempo se conservará ese ítem o colección y alertar a los gestores de documentos para finalizar el periodo de retención?

Clasificación

La clasificación puede significar un par de cosas diferentes, para este artículo la clasificación se define como "el proceso de asignar algo a una clase específica dentro de una jerarquía, basado en las características de la cosa" (InterPARES Trust AI, 2018). La literatura sobre clasificación, inteligencia artificial y gestión documental o archivos consiste en estudios de caso. Estos tienden a centrarse en una solución o experimento y a informar sobre su eficacia o desarrollo.

Los Archivos Nacionales del Reino Unido (TNA) (2021) analizaron cómo la IA podría aplicarse a la selección de documentos de archivo y evaluaron cinco productos para su uso como herramientas que ayuden a procesar documentos de archivo gubernamentales. Detallaron cómo un modelo de clasificación con aprendizaje automático podía entrenarse con datos que habían sido clasificados manualmente por un experto y luego aplicar lo aprendido a gran escala. Explicaron que "las herramientas más útiles tendrán una medida de confianza junto con los resultados de la clasificación" (The National Archives [TNA], 2021, p. 5) a fin de que los gestores de documentos de archivo pudieran entender mejor dónde deberán intervenir en el proceso antes de tomar decisiones basadas en la salida del modelo. El artículo presentaba algunas lecciones que TNA aprendió del proceso de valoración, así como una guía general para que cualquier otra agencia gubernamental la utilice si debe implementar la IA. El Apéndice A detalló los pasos para desarrollar un clasificador de IA: recogida de datos, análisis exploratorio, ingeniería de características, entrenamiento y ajuste de modelos, y producción y despliegue (TNA, 2021, p. 13). El artículo presentó después la evaluación de TNA sobre Adlib Elevate, Amazon Web Services, Microsoft Azure, InSight de Iron Mountain y Records365 de RecordPoint. Revisaron la recopilación de datos, preprocesamiento y métodos de

análisis de cada producto, qué características (metadatos) la solución podía extraer de los elementos, el proceso de entrenamiento y ajuste de los modelos, y cada interfaz gráfica de usuario. El artículo concluyó que "aunque el proyecto intentó estandarizar la evaluación, quedó claro que la comparación directa entre diferentes productos y enfoques es difícil" (TNA, 2021, p. 15). Las lecciones aprendidas sobre la valoración y selección de IA podrían utilizarse para guiar a una organización durante el proceso, a fin de seleccionar la mejor herramienta que se adapte a sus necesidades. El proceso de desarrollo del modelo de clasificación también podría ser replicado por otras instituciones que busquen crear su propio modelo de IA de clasificación.

Más recientemente, Franks (2021) escribió sobre un estudio que realizaron para determinar qué tipo de tecnología de procesamiento de lenguaje natural es la más eficaz para ayudar en la clasificación automática de los documentos de archivo. Se realizaron experimentos con datos auténticos de documentos de archivo, cada uno utilizando un modelo diferente de clasificación de texto. Un modelo utilizó el término frecuencia inversa de frecuencia de documento (TF-IDF) y una máquina de vectores de soporte (SVM), tres usaron diferentes arquitecturas de redes neuronales y otros tres usaron distintos modelos de lenguaje Transformer. Los experimentos encontraron que "los modelos de lenguaje Transformer superan tanto a las redes neuronales sin preentrenamiento como a técnicas estadísticas en tareas de clasificación de texto cuando se prueban con datos auténticos de documentos de archivo" (Franks, 2021, p. 15). Basándose en los experimentos descritos, la autora concluyó que es razonable esperar que las herramientas de clasificación de texto demuestren alrededor del 88% de precisión y 0,77 F1 (Franks, 2021, p. 16). Franks reiteró que la clasificación se utiliza en software de gestión documental principalmente para determinar los periodos de retención y los requisitos de disposición o para identificar información sensible en los documentos de archivo, y que el uso de técnicas de IA y aprendizaje automático puede ayudar a los gestores de documentos de archivo a completar estas tareas de forma más eficiente (Franks, 2021, p. 2).

Un artículo de Tanvir (2021) exploró una solución de clasificación de documentos de varias páginas que podría utilizarse para sortear cuellos de botella en la industria hipotecaria. Cuando las compañías hipotecarias realizan auditorías de préstamos hipotecarios, deben analizar un paquete de préstamos, que es un conjunto de páginas escaneadas que pueden tener entre 100 y 400 páginas, que contienen subcomponentes que pueden variar desde una hasta unas 30 páginas (Tanvir, 2021). El análisis de estos documentos generalmente se externaliza y se realiza mediante una combinación de trabajo manual y semi-automatización, generando resultados

cuestionablemente precisos y requiriendo una cantidad significativa de tiempo (Tanvir, 2021). Este estudio se desarrolló con la intención de crear una solución de clasificación de documentos que redujera el esfuerzo manual que implica este proceso, al tiempo que aumentara la precisión del análisis documental. Los investigadores se centraron en crear una solución que identificara las diferencias entre los diferentes documentos del paquete. Primero, el paquete se dividía en páginas individuales, que luego se procesaban mediante una herramienta de reconocimiento óptico de caracteres (OCR) y se enviaban mediante un vectorizador de texto (usaban Doc2Vec). Finalmente, el paquete pasaba por un clasificador de regresión logística, donde cada página se etiquetaba como la primera página de un documento, la última página de un documento u otra (representando las páginas centrales) y se asignaba una puntuación de confianza para la categoría seleccionada (Tanvir, 2021). El flujo de trabajo resultante produjo predicciones rápidas, precisas y con altos niveles de confianza.

Vellino & Alberts (2016) realizaron un estudio que examinó las prácticas de clasificación de correos electrónicos y el proceso de toma de decisiones de ocho profesionales de la gestión de la información, y luego desarrollaron un modelo de IA para replicar sus procesos. Los autores entrevistaron a profesionales de la gestión de la información y revisaron ejemplos de decisiones sobre el triaje de correos electrónicos. A partir de ahí, crearon un "Modelo de Categorías de Valor" (Vellino & Alberts, 2016, p. 300) que visualizaba las categorías que los profesionales aplican a las colecciones de correo electrónico. Luego recopilaron dos colecciones de correos donadas para usarlas como datos de entrenamiento para el modelo que crearían. Los investigadores etiquetaron manualmente los correos electrónicos como "Correos de valor empresarial" o "Correos electrónicos de NINGÚN valor empresarial" (Vellino & Alberts, 2016, p. 301) y equilibraron los datos de la muestra para que hubiera cantidades iguales de cada categoría. A continuación, extrajeron características de los correos como los campos "To/From/Body/Attachment/Importance" (Vellino & Alberts, 2016, p. 302) y entrenaron los clasificadores Support Vector Machine (SVM). Se crearon cuatro modelos, dos para cada buzón, uno de los dos uno utilizaba las características extraídas mientras que otro no. Los modelos fueron "construidos con el LightSide Labs Researcher's Workbench (2015), una herramienta de minería de texto de código abierto que integra el Apache OpenNLP" (Vellino & Alberts, 2016, p. 304). Validaron los clasificadores con "validación cruzada de 10 veces" (Vellino & Alberts, 2016, p. 305) y probaron la precisión de cada clasificador en el buzón que no había sido entrenado. Ninguno de los dos modelos fue "capaz de detectar el 'Valor de Negocio' con cierto grado de precisión en el otro conjunto de datos" (Vellino & Alberts, 2016, p. 306),

por lo que fusionaron los dos buzones y entrenaron un nuevo modelo en la colección resultante. Compararon el nuevo modelo con uno que detecta spam y un conjunto de correos seleccionados aleatoriamente de Enron, descubriendo que el clasificador SVM era "ligeramente menos preciso que el SVM Spam/Ham y, sin embargo, ambos fueron bastante precisos" (Vellino & Alberts, 2016, p. 306). Además, el sistema replicó con éxito los procesos de los expertos con altos niveles de precisión. Los autores concluyeron reiterando la viabilidad de su enfoque, pero señalando la naturaleza altamente sensible al contexto de un modelo creado con esta metodología (Vellino & Alberts, 2016, p. 309).

En el Proyecto Memorias Industriales en el University College de Dublín, Irlanda, fue un grupo de humanidades digitales el que utilizó incrustación de palabras y clasificación de texto para analizar un informe de 2.600 páginas y destilar sus hallazgos en información útil (Leavy et al., 2017). El Informe Ryan de 2009 es "el informe de la investigación del Gobierno Irlandés sobre abusos en las escuelas industriales irlandesas" desde 1920 hasta 1990 (Leavy et al., 2017, p. 1). El informe tiene una extensión de 2.600 páginas, más de 500.000 palabras, y documenta una investigación de nueve años (Leavy et al., 2017, p. 1). Los investigadores digitalizaron el informe y diseñaron una "interfaz exploratoria basada en la web" (Leavy et al., 2017, p. 1) con una base de datos relacional para permitir la búsqueda y el análisis. Segmentando el informe en entradas de datos utilizables, los investigadores identificaron y etiquetaron nombres utilizando un kit de herramientas para procesamiento de lenguaje natural. Crearon un conjunto de categorías para anotar entradas y así ayudar aún más en el descubrimiento. Las categorías se crearon utilizando clasificación automatizada de texto, una búsqueda basada en reglas, un clasificador de bosque aleatorio y métodos manuales. Los investigadores intentaron un enfoque de bolsa de palabras, pero "obtuvo resultados que estaban sobreajustados debido a las pequeñas muestras de datos de entrenamiento" (Leavy et al., 2017, p. 1). En su lugar, utilizaron un algoritmo de incrustación de palabras en los datos de entrenamiento para identificar "palabras semilla" que a su vez fueron utilizadas por Word2Vec para generar léxicos semánticos específicos de contenido (Leavy et al., 2017, p. 1) para cada categoría de conocimiento. La primera categoría, "Movimientos del personal y el clero (Párrafos de transferencia)" (Leavy et al., 2017, p. 1), tuvo que identificar inicialmente manualmente sus palabras semilla debido al lenguaje oculto utilizado en el informe. El léxico para la segunda categoría, "Testimonio de testigos (párrafos de testigos)", se basó en verbos de reporte como "dijo", "dijo" y "explicó" (Leavy et al., 2017, p. 2). Las palabras semilla para la tercera categoría, "Descripciones de Eventos Abusivos (Párrafos de Abuso)", eran más difíciles de identificar, por lo

que se utilizó un algoritmo de máquina de vectores de soporte que acabó creando cinco léxicos para identificar estos párrafos (Leavy et al., 2017, p. 2). Las entradas de datos se clasificaron entonces bajo la categoría de conocimiento correspondiente según los léxicos creados. Una evaluación de rendimiento en muestras aleatorias devolvió tasas de precisión de 0,58 a 0,86, tasas de recuerdo de 0,88 a 1,0, tasas de puntuación F de 0,73 a 0,88 y tasas de precisión del 92% al 95% (Leavy et al., 2017, p. 3). El proyecto ha sido puesto a disposición del público [en https://industrialmemories.ucd.ie/](https://industrialmemories.ucd.ie/) y ha demostrado que el aprendizaje automático, utilizado junto con incrustaciones de palabras y léxicos específicos de contenido, puede clasificar documentos grandes, haciéndolos más accesibles para su uso.

La mayor parte de la literatura sobre clasificación, inteligencia artificial y gestión documental o archivos son estudios de caso que se centran en la eficacia o desarrollo de una solución concreta. Los Archivos Nacionales del Reino Unido (TNA) (2021) reiteraron el valor de la clasificación automatizada y evaluaron cinco soluciones diferentes de IA. También ofrecieron orientación sobre cómo seleccionar una solución de IA para una organización o crear un clasificador. Franks (2021) determinó que los modelos de lenguaje Transformer superan a la frecuencia inversa de la frecuencia de término en los documentos, soportan máquinas vectoriales y arquitecturas de redes neuronales en un procesamiento efectivo del lenguaje natural. Tanvir (2021) creó una solución de clasificación de documentos de varias páginas que identificaba si una página dada era la primera, media o última de un documento, resultando en un flujo de trabajo que sorteaba un complicado cuello de botella en los procesos de la industria hipotecaria. Vellino & Alberts (2016) desarrollaron un clasificador SVM que podía replicar el proceso de toma de decisiones de un profesional de la información cuando se aplicaba a una colección de correos electrónicos. Leavy et al. (2017) demostraron que un modelo de IA que utiliza aprendizaje automático, procesamiento de lenguaje natural, incrustación de palabras y léxicos específicos de contenido puede clasificar documentos grandes, haciéndolos más accesibles para su uso y revisión. Algunos de estos diferentes métodos de clasificación podrían utilizarse o adaptarse para determinar los periodos de retención y los requisitos de disposición.

Distribución y uso

Otra parte significativa de la literatura sobre inteligencia artificial e IA se centra en la fase de distribución y uso del ciclo de vida de RIM. Al igual que en la fase de creación, puede parecer contraintuitivo incluir la distribución y el uso en una discusión que se centra en la retención y la

disposición. Sin embargo, la forma en que un objeto se utiliza y se mueve durante su vida puede afectar su valor probatorio, cambiando su periodo de conservación o su disposición final. Muchos de los estudios siguientes tratan soluciones o flujos de trabajo que podrían explorarse, adaptarse o modificarse para adaptarse a las necesidades y flujos de trabajo de retención y disposición.

Obukhov et al. (2020) crearon una herramienta de software y un algoritmo que podía utilizarse para modificar y personalizar la interfaz de un sistema electrónico de gestión documental (EDMS). Esto cambió la forma en que los usuarios interactuaban con el EDMS y por extensión, cómo interactuaban con los documentos de archivo. El algoritmo formalizó diferentes procesos de flujo de trabajo, adaptó automáticamente la interfaz EDMS a las necesidades del usuario y evaluó la capacidad del sistema para cambiar (Obukhov et al., 2020). Recogía automáticamente datos de preferencias de los usuarios y los utilizaba para aumentar la flexibilidad del sistema. Obukhov et al. (2020) descubrieron que esto resultaba en que los usuarios tuvieran una mejor primera experiencia con el EDMS.

Baron (2005) analizó la falta de un punto de referencia para evaluar los resultados de búsqueda de documentos de archivo electrónicos durante el proceso de e-descubrimiento. El artículo describía diversas metodologías de búsqueda, incluyendo búsquedas booleanas avanzadas, técnicas estadísticas, búsqueda de conceptos, búsqueda en lenguaje natural y técnicas de lógica difusa, describiendo brevemente cómo funciona cada una. Explicó que el problema que impide la eficiencia de muchas herramientas de búsqueda es el equilibrio entre el número de documentos de archivo que se recuperan en una búsqueda determinada y la relevancia de esos documentos de archivo. "La recuperación de grandes cantidades de documentos falsos positivos que no responden es ciertamente gravosa y molesta; sin embargo, la falta de documentos que respondan puede ser crítica" (Baron, 2005, p. 243). Se propuso una solución en la que se establece un punto de referencia para la comprobación de los procesos de búsqueda y los proveedores de software que ofrecen funcionalidades de búsqueda probados por un organismo de estándares acreditado.

Conrad (2010) definió y exploró el e-descubrimiento, con la intención de hacer que el campo de esté más accesible para investigadores en IA y derecho. El autor exploró el proceso de e-descubrimiento y proporcionó varios ejemplos diferentes en la práctica. Las actividades de la Conferencia Text REtrieval (TREC) del Instituto Nacional de Estándares y Tecnología de EE. UU. (NIST) durante los cuatro años anteriores fueron resumidas, evaluadas y criticadas. El autor expuso la naturaleza multidisciplinar del e-descubrimiento y presentó un modelo de e-descubrimiento

diseñado para enmarcar el proceso desde una "perspectiva tecnológica" (Conrad, 2010, p. 334). Continuó explorando tendencias entre los proveedores de servicios de e-descubrimiento y sus clientes. Esto reveló que los clientes tienden a intentar gestionar el proceso de e-descubrimiento por sí mismos y las empresas que gestionan todo el proceso de principio a fin venden mejor que aquellas que solo gestionan un aspecto del e-descubrimiento. Conrad (2010) continuó hablando de varias tecnologías nuevas que creían beneficiarían al proceso de e-descubrimiento. La retroalimentación inteligente sobre la relevancia, o "una publicación parcial de documentos relevantes, seguida de una segunda 'consulta'" (Conrad, 2010, p. 337-338), podría mejorar sustancialmente la efectividad de la recuperación. El autor afirmó que hacer que los ordenadores respondieran a una consulta y luego emplearan humanos para revisar esa salida sería más efectivo que confiar toda la investigación a humanos u ordenadores (Conrad, 2010, p. 338). También defendió una gestión del correo electrónico más eficaz, ya que, en el momento de escribir esto, "al menos el 50% del material en el entorno actual de E-descubrimiento está en forma de correo electrónico" (Conrad, 2010, p. 338). El procesamiento del lenguaje natural que incluye "análisis morfológico, ontologías y resolución de entidades nombradas" (Conrad, 2010, p. 339) podría simplificar enormemente el proceso de descubrimiento electrónico por correo electrónico. El autor también comentó sobre el impacto que el análisis de redes sociales podría tener en el proceso de e-descubrimiento al permitir a los investigadores filtrar "contenido electrónico externo" (Conrad, 2010, p. 339) desde el principio del flujo de trabajo, disminuyendo el tiempo dedicado a analizar contenido que no es relevante para el caso. También se discutieron técnicas de aprendizaje automático, con el programa CategoriX de Xerox como ejemplo. CategoriX utiliza dos modelos de aprendizaje automático, uno que aprende de un conjunto de datos que ha sido "categorizado manualmente por Expertos en la Materia (SMEs) usando una taxonomía predefinida" (Conrad, 2010, p. 339) y otro modelo predictivo que clasifica un conjunto de documentos similares. Una evaluación de CategoriX demostró que el sistema identificaba con precisión los documentos más sensibles con una tasa de precisión similar a la de los revisores humanos. La última tecnología que Conrad (2010) recomendó para investigar fue la e-descubrimiento anticipatoria, que es un método que prepara a una empresa para la posibilidad de acciones y retenciones legales.

Los Archivos Nacionales del Reino Unido (TNA) (2016) realizaron ensayos con software de e-descubrimiento y analizaron investigaciones adicionales para probar cómo las herramientas y procesos podían afrontar los retos de los documentos de archivo digitales nativos. La investigación llevó a TNA a concluir que las herramientas de e-descubrimiento pueden "apoyar a los

departamentos gubernamentales durante la valoración, selección y revisión de sensibilidad" (The National Archives [TNA], 2016, p. 5). Se aprendió que las herramientas de e-descubrimiento pueden proporcionar una comprensión general de la información digital de una organización, reducir la cantidad de información necesaria para revisarse manualmente durante el proceso de e-descubrimiento y "extraer significado de una gran colección de documentos de archivo nacidos digitales" (TNA, 2016, p. 17) mediante procesos de categorización, agrupamiento y visualización de correo electrónico. Estas soluciones también pueden ayudar a localizar y ocultar información sensible. Los investigadores "encontraron un mercado maduro de eDiscovery" (TNA, 2016, p. 21) con productos bien consolidados y soluciones menos desarrolladas con potencial. También aprendieron que la "interfaz de usuario de una solución es tan importante como la calidad del algoritmo" (TNA, 2016, p. 22), y que la coordinación con colegas de tecnología de la información es vital para el éxito en el despliegue de la solución. Concluyeron que hay un aumento en los niveles de confianza en la precisión de las soluciones de e-descubrimiento, así como una mayor aceptación de la legalidad del uso de herramientas de e-descubrimiento en el proceso legal.

La literatura sobre cómo la IA se cruza con la distribución y el uso de documentos de archivo que se centra en la recuperación de documentos de archivo y la interacción de éstos con el usuario. Obukhov et al. (2020) escribieron sobre una herramienta que crearon para alterar y personalizar la interfaz de un sistema electrónico de gestión documental (EDMS) y descubrieron que su uso resultaba en que los usuarios tuvieran una mejor primera experiencia con el EDMS. Baron (2005) examinó la metodología de búsqueda de documentos de archivo electrónicos y propuso la creación de un referente para los procesos de búsqueda. Conrad (2010) analizó el e-descubrimiento desde una perspectiva tecnológica y evaluó un modelo que encontraron para identificar documentos más sensibles con precisión. Los Archivos Nacionales del Reino Unido (TNA) (2016) realizaron ensayos con software de e-descubrimiento e informaron que hay un aumento de la confianza en la precisión y legalidad de las soluciones de e-descubrimiento. Las lecciones aprendidas y los modelos o algoritmos desarrollados en estos estudios de caso podrían explorarse, adaptarse o modificarse para adaptarse a las necesidades de los flujos de trabajo de retención y disposición.

Retención y disposición

Se ha escrito poco específicamente sobre retención y disposición e inteligencia artificial. ¿El libro de Rolan et al. (2019) "More Human than Human? "Inteligencia artificial en el archivo" es la

excepción. Los autores presentaron varios estudios de caso en los que la IA ha sido o será implementada en entornos de la gestión de documentos de archivo.

El primer estudio de caso revisado por la Oficina Australiana de Archivos Públicos de Victoria (PROV) creó recientemente una prueba de concepto que utilizaba IA para abordar el problema de la valoración por correo electrónico. Utilizaron una herramienta comercial de e-descubrimiento llamada Nuix con 1,5 TB de datos para realizar una evaluación técnica de la composición de la colección utilizada en el estudio. Luego hicieron que Nuix identificara y eliminara documentos de archivo duplicados, descubriendo que "aproximadamente el 40% de los 4,6 millones de correos electrónicos del conjunto de datos" eran duplicados (Rolan et al., 2019, p. 189). Finalmente, PROV hizo que Nuix evaluara y aplicara metadatos para los elementos del conjunto de datos y evaluara si debían conservarse o no. La evaluación se basó en direcciones de correo electrónico y dominios, "definiciones de roles de agencias asociadas"; verbos/objetos de acción; y términos de función/actividad" (Rolan et al., 2019, p. 189). PROV concluyó que "la herramienta Nuix eDiscovery podría utilizarse eficazmente para reducir el volumen de correo electrónico que PROV necesita analizar para la valoración" (Rolan et al., 2019, p. 190). La capacidad de este modelo para deshacerse de duplicados es una capacidad compartida solo por otro modelo mencionado anteriormente, el flujo de trabajo de Belocari (2017). El modelo de PROV también era diferente a los listados en la sección "Valoración" de este artículo, ya que aplicaba requisitos rudimentarios de retención.

Otro estudio de caso explorado por Rolan et al. (2019) fue el del estudio de los Archivos Estatales de Nueva Gales del Sur (NSWSAR) realizado en 2017. El objetivo del estudio fue explorar el uso de software para aplicar periodos de retención y eliminación a un conjunto de documentos de archivo no estructurados y comprobar su exactitud. Los investigadores evaluaron soluciones de software para este experimento y se limitaron a soluciones de bajo coste o gratuitas debido a las limitaciones de recursos del proyecto. Finalmente eligieron "scikit-learn, una biblioteca de aprendizaje automático libre y de código abierto para el lenguaje de programación Python" (Rolan et al., 2019, p. 191). La colección utilizada para el experimento era "30 GB de datos, en 7.561 carpetas, que contenían 42.653 archivos" (Rolan et al., 2019, p. 191) y había sido asignada manualmente a nivel de carpeta para ser conservada por los Archivos Estatales. Los investigadores utilizaron únicamente aquellos archivos de los que se podía extraer texto, como archivos PDF, DOC y DOCX para su estudio. Ejecutaron un extractor de texto y limpiaron los datos eliminando formatos, palabras vacías, documentos innecesarios y convirtieron todo el texto a minúsculas (Rolan et al.,

2019, p. 192). A continuación, los investigadores ejecutaron un vectorizador de texto y un extractor de características, utilizando un enfoque de bolsa de palabras (Rolan et al., 2019, p. 192). Finalmente, los investigadores ejecutaron dos algoritmos de clasificación para determinar cuál sería más efectivo. Cada algoritmo se ejecutaba sobre dos copias de los datos, una que había sido limpiada y otra que no. De los dos algoritmos, Multinomial Naïve Bayes y Multi-Layer Perceptron, se descubrió que "el algoritmo Multi-Layer Perceptron con datos limpios fue el más exitoso, con una tasa máxima de éxito del 84%" (Rolan et al., 2019, p. 192). Los investigadores concluyeron que, aunque una tasa de precisión del 84% no sea lo que querrían ver en operaciones normales, resultaba prometedor dado que el estudio era relativamente corto y limitado en alcance y recursos. Este estudio de caso reveló un flujo de trabajo y un algoritmo específico que podría ser útil para asignar periodos de retención y que podría merecer una exploración más profunda.

Rolan et al. (2019) también discutieron dos estudios de caso de proyectos que aún no se habían completado en el momento de la publicación del artículo. Los Archivos Nacionales de Australia estaban trabajando en un proyecto de investigación para explorar la creación y emisión de autorizaciones de eliminación y retención automáticas o con la mínima participación humana. Se esperaba que el proyecto evaluara diversas tecnologías de aprendizaje automático, incluyendo herramientas de autoclasificación, agrupamiento e indexación (Rolan et al., 2019, p. 194). Este proyecto se diferencia de muchos otros estudios de caso por su especificidad en una sola tarea que podría automatizarse para ahorrar tiempo a los gestores de información, en lugar de un modelo o solución que pudiera automatizar todo el proceso o una prueba de concepto que pudiera ampliarse para incluir otras tareas.

El otro proyecto fue una prueba de concepto realizada por el Departamento de Finanzas del Gobierno Australiano para "probar la aplicación de la arquitectura de microservicios y tecnologías de datos enlazados para automatizar la gestión documental" (Rolan et al., 2019, p. 195). La idea era evaluar las necesidades de gestión documental de usuarios, luego crear herramientas de microservicios para satisfacer esas necesidades y desplegarlas en Amazon Web Services. La prueba de concepto propuesta era un modelo que evaluaría automáticamente el valor empresarial de los correos capturados y los clasificaría según un calendario de retención. El estudio no se había completado en el momento de la redacción de Rolan et al. (2019), pero una investigación posterior en la página web del Departamento de Finanzas del Gobierno Australiano reveló detalles adicionales sobre el estudio. Finalmente, los investigadores concluyeron que

Aunque el Gobierno es el mejor indicado para describir sus funciones, [la] industria está trabajando hacia la automatización y estaría en la mejor posición para proporcionar sistemas de gestión documental digitales compatibles con el Marco de Interoperabilidad de Documentos de archivo del Gobierno Australiano desarrollado por el gobierno. (Departamento de Finanzas del Gobierno Australiano, 2021)

El Departamento de Finanzas del Gobierno Australiano finalmente seleccionó un producto de software como servicio, "Records365 de la empresa australiana RecordPoint" (Birmingham, 2021) para cubrir sus necesidades. Esto implicaba que, para esta organización, la tarea de automatizar las funciones de gestión de documentos era lo suficientemente compleja como para que decidieran buscar ayuda.

La revista *Medicina de Urgencias Australasia* publicó un artículo sobre un estudio realizado para predecir dónde se necesitaría atención un paciente de urgencias en función de su problema presente (Rendell et al., 2019). Aunque esto no parece aplicable a primera vista a la gestión documental, las técnicas y tecnologías utilizadas por los investigadores podrían adaptarse a predecir las necesidades de disposición de un paciente similares a las requeridas para la disposición final de un documento de archivo. El estudio analizó seis algoritmos de clasificación y cinco técnicas de selección de características y evaluó cada modelo en función de la especificidad del problema presentado, comparándolos con el modelo existente, la Herramienta de Triage de Riesgos de Admisión de Sídney (START). Cuando el problema presentado era amplio, el modelo con el "algoritmo de vecino más cercano con selección manual de características tenía la mejor área bajo la curva (AUC) de 0,8206 (indicador de confianza [IC] del 95% $\pm 0,0006$)", mientras que el modelo con el "árbol de decisión sin selección de características tenía la mejor precisión del 74,83% (IC 95% $\pm 0,065$)" (Rendell et al., 2019). Cuando el problema presentado era extenso, el modelo con el "vecino más cercano con selección manual de funciones obtuvo una mejor franja en la curva (AUC) de 0,8267 (IC 95% $\pm 0,0006$)" y el modelo con "árbol de decisión con envolvente o sin selección de características tuvo la mejor precisión del 75,24% (IC 95% $\pm 0,064$)" (Rendell et al., 2019). Es interesante señalar que el algoritmo que proporcionó el mejor AUC en ambos casos fue el algoritmo de vecino más cercano y el que proporcionó mayor precisión fue el árbol de decisión sin selección de características. Un análisis más detallado de la metodología de los investigadores podría revelar elementos del modelo que los profesionales de la información podrían explorar al considerar la retención y disposición de documentos de archivo e información.

Challen et al. (2019) también exploraron la inteligencia artificial en el campo médico. Descubrieron que "la mayor parte de la investigación sobre aplicaciones médicas del aprendizaje automático se ha centrado en el apoyo a la decisión diagnóstica" (Challen et al., 2019, p. 231). Las decisiones diagnósticas son decisiones tomadas para identificar la dolencia de un paciente y decidir qué hacer por él. Este proceso es paralelo al proceso de valoración, retención y disposición archivística, lo que significa que los problemas en la IA médica pueden surgir durante el desarrollo y uso de la IA en archivos. El artículo analizaba cómo los sistemas basados en reglas, el aprendizaje supervisado y el aprendizaje por refuerzo son las formas más comunes de IA utilizadas e investigadas en el ámbito médico y que las tendencias de investigación están evolucionando de sistemas reactivos a sistemas autónomos más proactivos (Challen et al., 2019, p. 232). Se discutieron cuestiones que han surgido durante el uso de la IA en la sanidad, como los cambios de distribución, la insensibilidad de un sistema al impacto de las decisiones que se toman, la toma de decisiones en la caja negra y las predicciones producidas sin confianza en su precisión (Challen et al., 2019, p. 234). Otros problemas incluyeron la complacencia de los profesionales en el uso de la IA y daban más peso a las predicciones del sistema que a las suyas propias, sistemas que reforzaban prácticas obsoletas por su incapacidad para adaptarse a nuevos cambios, y una implementación de sistemas que "refuerza el resultado para el que está diseñado para detectar" (Challen et al., 2019, p. 234). Los autores exploraron entonces algunas cuestiones teóricas sobre la calidad y seguridad de la IA que se habían observado en entornos de prueba (Challen et al., 2019, p. 234). Estos incluían efectos secundarios negativos no deseados que resultaban de que un sistema realizara una tarea sin tener en cuenta información contextual más amplia, el "hacking de recompensas" (Challen et al., 2019, p. 234), o el sistema encontrando un método alternativo para lograr su recompensa sin cumplir realmente su objetivo, explorando nuevas estrategias de una manera que no sea segura para los pacientes, y la implementación o cambios en un sistema que no sean escalables (Challen et al., 2019, p. 234). El artículo enumeraba varias preguntas para facilitar la evaluación y el control de calidad de los sistemas de IA. Estas cuestiones y los problemas descubiertos en el ámbito médico podrían examinarse para comprobar su aplicabilidad en la gestión documental y los contextos de archivos.

Aunque no se ha escrito tanto sobre la intersección entre la IA y la retención y disposición como sobre la intersección entre la IA y otros aspectos del ciclo de vida de RIM, varios estudios de caso demuestran que el tema ha sido explorado. Rolan et al. (2019) ofrecieron una instantánea de varias iniciativas australianas de IA y documento de archivo de datos. El estudio de caso de la

Oficina Australiana de Archivos Públicos de Victoria (PROV) utilizó una herramienta de e-descubrimiento para evaluar correos electrónicos y aplicar requisitos rudimentarios de retención. El caso de estudio de los Archivos Estatales de Nueva Gales del Sur (NSWSAR) exploró un flujo de trabajo utilizando un algoritmo Multi-Layer Perceptrón que clasificaba los documentos según los calendarios de retención, revelando una metodología que podía perfeccionarse para ayudar a aplicar los periodos de conservación de los documentos de archivo digitales. El estudio inconcluso de los Archivos Nacionales de Australia (en 2019) centró la implementación de la IA en la tarea de autorizaciones automáticas de eliminación y retención para ayudar a los humanos a ser más eficientes, en lugar de intentar reformar todo un programa. Además, el Departamento de Finanzas del Gobierno australiano exploró opciones para crear su propio sistema de IA para gestionar documentos de archivo y, finalmente, eligió RecordPoint para cubrir sus necesidades. Rendell et al. (2019) y Challen et al. (2019) escribieron ambos sobre la IA y el proceso de disposición médica. La exploración de Rendell et al. (2019) sobre algoritmos que podrían utilizarse para determinar las necesidades a largo plazo de un paciente basándose en sus problemas presentes, reveló que los algoritmos de vecinos más cercanos y árboles de decisión eran las mejores opciones. La discusión de Challen et al. (2019) sobre algunos de los problemas que se encuentran cuando la IA se pone en marcha y da lugar a varias preguntas que podrían plantearse para facilitar la evaluación y el control de calidad de los sistemas de IA. Desde herramientas de e-descubrimiento hasta algoritmos específicos y software como servicio, ya se utilizan diversas soluciones de inteligencia artificial para ayudar en los flujos de retención y disposición en la gestión documental.

Conclusión

Esta revisión bibliográfica busca responder a la pregunta de lo que se ha escrito sobre cómo se están utilizando la inteligencia artificial (IA) y el aprendizaje automático (ML) para la retención y disposición en sistemas de información y documento de archivo de datos. Revisamos brevemente qué son la inteligencia artificial, el aprendizaje automático, los algoritmos y cómo funcionan, con explicaciones proporcionadas por Goodfellow et al. (2016), Lepak (2021), OCDE (2019) y Thomas (2019). A partir de ahí, exploramos la literatura sobre inteligencia artificial y retención y disposición, utilizando los Principios® de ARMA International (2019) y el Ciclo de Vida de Gestión documental e información como esquema organizativo.

Varios artículos se centraron en aspectos de la gestión documental presentes a lo largo de todo el ciclo de vida de los documentos de archivo, coincidiendo con tres de los Principios®

Generalmente Aceptados de Conservación de Documentos de archivo (ARMA International, 2019): Transparencia, Integridad y Cumplimiento. Se reveló que, aunque las decisiones sobre la conservación y disposición de los documentos de archivo deben tomarse de manera que favorezca la transparencia, los procesos actuales de IA no lo respaldan. Turek (s.f.) y Bunn (2020) exploraron el problema de la toma de decisiones opaca por parte de los sistemas de IA y defendieron la inteligencia artificial explicable como solución al problema de la caja negra. El juez Dixon Jr. (retirado) (2021), Mehrabi et al. (2021), Schwartz et al. (2022), y Jo y Gebru (2020) revisaron el problema del sesgo en los modelos de IA y exploraron soluciones que podrían aprovecharse para mitigar el problema. En conjunto, estos artículos demostraron que cualquier modelo de IA implementado para tomar decisiones sobre la retención y disposición de los documentos de archivo debería considerar tanto la inteligencia artificial explicable como la sesgada. El Grupo de Trabajo de Autenticidad de InterPARES (2002) y Katuu (2021b) exploraron el problema de la integridad de los modelos de IA y concluyeron que los procesos y prácticas de gestión documental podrían aplicarse a los modelos de IA para mejorar su integridad y la de los documentos de archivo que gestionan. La capacidad de demostrar la integridad de un modelo es especialmente importante para los modelos que realizan tareas de retención y eliminación, ya que la elección de conservar o deshacerse de un objeto es importante y a menudo irreversible. Fosch Villaronga et al. (2017) exploraron la cuestión del cumplimiento normativo e IA, planteando la preocupación de que podría no ser posible que los modelos de IA cumplan con ciertas leyes de privacidad y teorizando que la desconexión entre los requisitos legales y la realidad técnica se extiende a otras áreas del cumplimiento. Esto es especialmente preocupante en lo que respecta a la retención y la disposición, ya que las decisiones tomadas para conservar o eliminar objetos suelen tomarse para facilitar el cumplimiento de una o más leyes, normativas o políticas.

El resto de los artículos revisados se agruparon en una de tres etapas del ciclo de vida de la Gestión documental e Información: Creación, Distribución y Uso, o Retención y Disposición. Quienes discutían la creación de documentos de archivo se centraban en la valoración o clasificación de documentos de archivo. Harvey y Thompson (2010) discutieron un marco para automatizar el proceso de valoración, mientras que Belovari (2017), Lee (2018) y Makhoulf Shabou et al. (2020) exploraron tecnologías específicas para hacer lo mismo. Belovari (2017) probó diez tipos diferentes de software y finalmente seleccionó TreeSize Professional (TSP) como el más eficaz para su organización y propósitos, Lee (2018) defendió el uso de forense digital, procesamiento de lenguaje natural (PLN) y tecnología de aprendizaje automático, y Makhoulf Shabou et al. (2020)

crearon su propia herramienta que asignaba una puntuación a cada elemento de una colección. Los artículos que revisaban la clasificación de documentos de archivo eran estudios de caso centrados en la eficacia o desarrollo de una solución concreta. Algunos se centraban en soluciones comerciales. Los Archivos Nacionales del Reino Unido (TNA) (2021) evaluaron Adlib Elevate, Amazon Web Services, Microsoft Azure, InSight de Iron Mountain y Records365 de RecordPoint, concluyendo finalmente que sus diferencias impedían una evaluación estandarizada. Vellino & Alberts (2016) adoptaron LightSide Labs Researcher's Workbench (2015), una máquina de vectores de soporte (SVM) que utilizaba Apache OpenNLP. Otros artículos informaban sobre los experimentos de los autores creando sus propios clasificadores. Franks (2021) defendió el uso de modelos de lenguaje Transformer en el procesamiento de lenguaje natural, y Tanvir (2021) creó su propio modelo de clasificación usando reconocimiento óptico de caracteres (OCR) y Doc2Vec (una herramienta de PLN). Leavy et al. (2017) crearon su propio clasificador utilizando léxicos específicos de contenido formulados mediante clasificación automatizada de texto, una búsqueda basada en reglas, un clasificador de bosque aleatorio, métodos manuales, un algoritmo de incrustación de palabras y Word2Vec (una herramienta de PLN). Es posible que estas herramientas de valoración y clasificación puedan utilizarse o adaptarse para determinar cuánto tiempo deben conservarse los elementos o colecciones y alertar a los responsables del fin de ese periodo.

La literatura sobre cómo la IA se cruza con la distribución y el uso de documentos de archivo se centró en la interacción del usuario con los documentos de archivo y su recuperación. Obukhov et al. (2020) discutieron alteraciones en la interfaz gráfica de usuario (GUI) de un modelo y Baron (2005) defendió una metodología estandarizada de búsqueda electrónica de documentos de archivo. Conrad (2010) analizó cómo las herramientas de e-descubrimiento podrían mejorarse utilizando retroalimentación inteligente de relevancia, análisis de redes sociales y NLP para aprovechar el análisis morfológico, ontologías y el reconocimiento de entidades nombradas (NER). También examinaron la herramienta de e-descubrimiento de Xerox, CategoriX y se descubrió que ésta identifica con mayor precisión y exactitud los documentos que la revisión manual. Los Archivos Nacionales del Reino Unido (TNA) (2016) realizaron pruebas de software de e-descubrimiento e informaron que herramientas de e-descubrimiento son más eficaces para procesos de categorización, agrupamiento y visualización de correo electrónico. Las lecciones aprendidas y los modelos o algoritmos desarrollados en estos estudios de caso también podrían explorarse, adaptarse o modificarse para adaptarse a las necesidades de los flujos de trabajo de retención y disposición.

Los artículos que se centran en la intersección entre la IA y la retención y disposición suelen ser también estudios de caso que se centran en la implementación o evaluación de una herramienta o solución concreta. Rolan et al. (2019) ofrecieron una instantánea de varias iniciativas australianas de IA y documento de archivo de datos. La Oficina Pública de Archivos de Australia Victoria (PROV) seleccionó una herramienta comercial de e-descubrimiento llamada Nuix y la utilizó para la valoración por correo electrónico, incluyendo la disposición de correos electrónicos innecesarios. Los Archivos Estatales de Nueva Gales del Sur (NSWSAR) seleccionaron una biblioteca de aprendizaje automático de código abierto llamada scikit-learn que utilizaba un extractor de texto, vectorizador de texto, un extractor de características con un enfoque de bolsa de palabras y un algoritmo de clasificación Multi-Layer Perceptron para aplicar periodos de retención y eliminación a un conjunto de documentos de archivo no estructurados. El Departamento de Finanzas del Gobierno Australiano probó la eficacia de las herramientas de microservicios de Amazon Web Services en la creación y emisión automática de autorizaciones de eliminación y retención, pero finalmente eligió una solución comercial, Records365 de RecordPoint. Otros artículos sobre disposición e IA no se escribieron desde la perspectiva de la gestión documental, sino desde el punto de vista del triaje médico. Rendell et al. (2019) evaluaron algoritmos para determinar necesidades de disposición a largo plazo y seleccionaron algoritmos de vecinos más cercanos y árboles de decisión como los más efectivos. Challen et al. (2019) analizaron la prevalencia de sistemas basados en reglas, el aprendizaje supervisado y el aprendizaje por refuerzo en los modelos de IA por disposición médica y exploraron algunos de los beneficios y desventajas de su uso.

Se ha escrito poco específicamente sobre retención y disposición e inteligencia artificial, y mucho sobre IA y otras áreas incorporación. Sin embargo, la exploración de la literatura sobre IA y gestión documental ha revelado que no es necesario crear un modelo específicamente para completar tareas de retención y disposición que se utilizarán con este propósito. Desde herramientas personalizadas hasta herramientas comerciales de e-descubrimiento y software como servicio diversas herramientas de inteligencia artificial se están utilizando o podrían explorarse para apoyar en la retención y disposición en los sistemas gestión de información y documento de archivos digitales.

Referencias

(versión en español)³

ARMA Internacional. (2017). *Los principios*[®]. <https://www.arma.org/page/principles>

Departamento de Finanzas del Gobierno Australiano. (6 de julio de 2021). *Más sobre la iniciativa de transformación de documentos de archivo digitales*. <https://www.finance.gov.au/government/digital-records-transformation-initiative/more-digital-records-transformation-initiative>

Grupo de Trabajo sobre Autenticidad. (2002). *Requisitos para evaluar y mantener la autenticidad de los documentos de archivo electrónicos*. InterPARES. http://www.interpares.org/display_file.cfm?doc=ip1_authenticity_requirements.pdf

Baron, J. R. (2005). Hacia un estándar federal de comparación para evaluar productos de recuperación de información utilizados en el descubrimiento electrónico. *Diario de la Conferencia de Sedona*, 6, 237–246. https://thesedonaconference.org/sites/default/files/publications/237-246%20Baron_237-246%20Baron.qxd_0.pdf

Birmingham, S. (2021). *Una empresa australiana eleva el listón en la gestión de datos digitales*. Senador el Honorable Simon Birmingham, ministro de Finanzas. <https://www.financeminister.gov.au/media-release/2021/06/25/australian-company-raises-bar-digital-data-management>

Belovari, S. (2017). Evaluación digital acelerada para archivistas habituales: un enfoque tipo MPLP. *Journal of Archival Organization*, 14(1–2), 55–77. <https://doi.org/https://doi.org/10.1080/15332748.2018.1503014>

Bunn, J. (2020). Trabajar en contextos en los que la transparencia es importante: una visión incorporación de la inteligencia artificial explicable (XAI). *Diario de Gestión documental*, 30(2), 143–153. <https://doi-org.libaccess.sjlibrary.org/10.1108/RMJ-08-2019-0038>

Challen, R., Denny, J., Pitt, M., Gompels, L., Edwards, T., & Tsaneva-Atanasova, K. (2019). Inteligencia artificial, sesgos y seguridad clínica. *BMJ Calidad y Seguridad*, 28(3), 231–237. <https://doi.org/https://doi.org/10.1136/bmjqs-2018-008370>

³ Como complemento también se incluye la lista de referencias en inglés.

- Colavizza, G., Blanke, T., Jeurgens, C., & Noordegraaf, J. (2022). Archivos e IA: Una visión general de los debates actuales y perspectivas futuras. *Revista sobre Informática y Patrimonio Cultural*, 15(1), 1–15. <https://doi.org/https://doi.org/10.1145/3479010>
- Conrad, J. G. (2010). E-descubrimiento revisitado: La necesidad de inteligencia artificial más allá de la recuperación de información. *Inteligencia Artificial y Derecho*, 18, 321–345. <https://doi.org/https://doi.org/10.1007/s10506-010-9096-6>
- Dixon Jr. (Retirado), J. H. B. (2021). Inteligencia artificial: beneficios y riesgos desconocidos. *Diario de los Jueces*, 60(1), 41–43. <https://search-ebSCOhost-com.libaccess.sjlibrary.org/login.aspx?direct=true&db=a9h&AN=148239554&site=ehost-live&scope=site>
- Fosch Villaronga, E., Kieseberg, P., & Li, T. (2017). Los humanos olvidan, las máquinas recuerdan: la inteligencia artificial y el derecho al olvido. *Revisión de Derecho Informático y Seguridad*, 34, 304–313. <https://doi.org/https://doi.org/10.1016/j.clsr.2017.08.007>
- Franks, J. (2021). Clasificación de texto para la gestión documental. *Revista sobre informática y patrimonio cultural*, recién aceptado. <https://doi.org/https://doi.org/10.1145/3485846>
- Franks, P. C. (2018). *Gestión documental e información* (2ª ed.). Chicago, IL: ALA Neal-Schuman.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Aprendizaje profundo*. La prensa del MIT. <https://books.google.com/books?hl=en&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=related:MHq4MMenr-gJ:scholar.google.com/&ots=MNQ-cnqHPZ&sig=r6rDVtNwWSC45emOUC4VMKI2NDY>
- Harvey, R., & Thompson, D. (2010). Automatizar la valoración de la información digital. *Biblioteca Hi Tech*, 28(2), 313–322. <https://doi.org/https://doi.org.libaccess.sjlibrary.org/10.1108/07378831011047703>
- InterPARES Trust AI. (2018). *Clasificación* [inglés]. <https://interparestrustai.org/terminology/term/classification>
- InterPARES Trust AI. (2021). *InterPARES Trust AI*. <https://interparestrustai.org/trust>
- Jo, E. S., & Gebru, T. (2020). Lecciones de archivos: Estrategias para recopilar datos socioculturales en aprendizaje automático. *FAT 2020 - Actas de la Conferencia 2020 sobre Equidad, Responsabilidad y Transparencia*, 306–316. <https://doi.org/https://doi.org/10.1145/3351095.3372829>

- Katuu, S. (2021b). Gestión documental en sistemas de planificación de recursos empresariales. *Conferencia Internacional IEEE sobre Big Data (Big Data)*, 2240–2245. <https://doi.org/10.1109/BigData52589.2021.9672034>
- Leavy, S., Pine, E., & Keane, M. T. (agosto de 2017). *Explorando la memoria cultural de las escuelas industriales irlandesas utilizando incrustación de palabras y clasificación de textos*. Conferencia de Humanidades Digitales 2017, Montreal, Canadá. <https://dh2017.adho.org/abstracts/098/098.pdf>
- Lee, C. A. (2018). Evaluación asistida por ordenador y selección de materiales de archivo. *Conferencia Internacional IEEE sobre Big Data (Big Data)*, 2721–2724. <https://doi.org/10.1109/BigData.2018.8622267>
- Lepak, N. (24 de junio de 2021). *¿Qué es la inteligencia artificial y por qué es valiosa para la gestión de la información?* Material de colaboración. <https://blog.collabware.com/what-is-artificial-intelligence-4-ways-to-take-advantage-of-ai-in-records-management>
- Makhlouf Shabou, B., Tièche, J., Knafou, J., & Gaudinat, A. (2020). Métodos algorítmicos para explorar la automatización de la valoración de datos digitales estructurados y no estructurados. *Diario de Gestión documental*, 30(2), 175–200. <https://doi.org/https://doi.org/10.1108/RMJ-09-2019-0049>
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). Una encuesta sobre sesgo y equidad en el aprendizaje automático. *Encuestas de Computación ACM*, 54(6), 1–35. <https://doi.org/https://doi.org/10.1145/3457607>
- Obukhov, A., Krasnyanskiy, M., y Nikolyukin, M. (2020). Algoritmo de adaptación de un sistema electrónico de gestión documental basado en tecnología de aprendizaje automático [Resumen]. *Progreso en inteligencia artificial*, 9, 287–303. <https://doi.org/https://doi.org/10.1007/s13748-020-00214-2>
- OCDE. (2019). *La inteligencia artificial en la sociedad*. OECD Publishing. <https://doi.org/10.1787/eedfee77-en>
- Rendell, K., Koprinska, I., Kyme, A., Ebker-White, A. A., & Dinh, M. M. (2019). La herramienta de triaje a riesgo de admisión de Sídney (START2) que utiliza técnicas de aprendizaje automático para apoyar la toma de decisiones sobre la disposición [Resumen]. *Medicina de Urgencias Australasia*, 31(3), 429–435. <https://doi.org/10.1111/1742-6723.13199>

- Rolan, G., Humphries, G., Jeffrey, L., Samaras, E., Antsoukova, T., & Stuart, K. (2019). ¿Más humano que humano? Inteligencia artificial en el archivo. *Archivos y Manuscritos*, 47(2), 179–203. <https://doi.org/https://doi.org/10.1080/01576895.2018.1502088>
- Schwartz, R., Vassilev, A., Greene, K., Perine, L., Burt, A., & Hall, P. (2022). *Hacia un estándar para identificar y gestionar sesgos en inteligencia artificial*. Instituto Nacional de Estándares y Tecnología. <https://doi.org/10.6028/NIST.SP.1270>
- Tanvir, Q. (7 de agosto de 2021). *Clasificación de documentos de varias páginas usando aprendizaje automático y PLN*. Hacia la ciencia de datos. <https://towardsdatascience.com/multi-page-document-classification-using-machine-learning-and-nlp-ba6151405c03>
- Los Archivos Nacionales [TNA]. (2016). *La aplicación de la revisión asistida por tecnología a la transferencia, consultas y más allá de documentos de archivo nacidos digitales* (pp. 1–27). <https://www.nationalarchives.gov.uk/documents/technology-assisted-review-to-born-digital-records-transfer.pdf>
- Los Archivos Nacionales [TNA]. (2021). *Uso de IA para la selección de documentos de archivo digitales para el gobierno: Orientación para gestores de documentos de archivo basada en una evaluación de soluciones actuales del mercado*. <https://cdn.nationalarchives.gov.uk/documents/using-ai-digital-selection-in-government.pdf>
- Thomas, R. (2019). *La escalera de la IA*. O'Reilly. <https://www.oreilly.com/online-learning/report/The-AI-Ladder.pdf>
- Turek, M. (s.f.). *Inteligencia artificial explicable (XAI)*. Agencia de Proyectos de Investigación Avanzada en Defensa. <https://www.darpa.mil/program/explainable-artificial-intelligence>
- Vellino, A., & Alberts, I. (2016). Asistencia en la valoración de documentos de archivo de correo electrónico mediante clasificación automática. *Revista de Gestión documental*, 26(3), 293–313. <https://doi.org/https://doi.org/10.1108/RMJ-02-2016-0006>

Bibliografía

Los recursos revisados durante este proyecto que no se incluyeron en la revisión final de la literatura pueden consultarse para obtener más información sobre la gestión de proyectos de IA, la planificación de recursos empresariales, los archivos y cuestiones de justicia social.

Davenport, T. H., & Ronanki, R. (2018). Inteligencia artificial para el mundo real: No empieces con fotos de la luna. *Harvard Business Review*, enero-febrero, 2–10. <https://www.kungfu.ai/wp-content/uploads/2019/01/R1801H-PDF-ENG.pdf>

Jimerson, R. C. (2007). Archivos para todos: responsabilidad profesional y justicia social. *El archivero americano*, 70(2), 252–281. <https://doi.org/https://doi.org/10.17723/aarc.70.2.5n20760751v643m7>

Katuu, S. (2020). Planificación de recursos empresariales: pasado, presente y futuro. *Nueva Revisión de Redes de Información*, 25(1), 37–46. <https://doi.org/https://doi.org/10.1080/13614576.2020.1742770>

Katuu, S. (2021a). Tendencias en el panorama del mercado de planificación de recursos empresariales. *Journal of Information & Organizational Sciences*, 45(1), 55–75. <https://doi.org/10.31341/jios.45.1.4>

Luca, M., Kleinberg, J., y Mullainathan, S. (2016). Los algoritmos también necesitan gestores. *Harvard Business Review*, enero-febrero, 96–101. <https://hbr.org/2016/01/algorithms-need-managers-too>

OCDE. (2022). *Marco de la OCDE para la clasificación de sistemas de IA*. OECD Publishing. <https://doi.org/10.1787/20716826>

Wilson, H. J., & Daugherty, P. R. (2018). Inteligencia colaborativa: Los humanos y la IA están uniendo fuerzas. *Harvard Business Review*, julio-agosto, 2–11. <https://hometownhealthonline.com/wp-content/uploads/2019/02/ai2-R1804J-PDF-ENG.pdf>

References

- ARMA International. (2017). *The Principles*°. <https://www.arma.org/page/principles>
- Australian Government Department of Finance. (2021, July 6). *More about the digital records transformation initiative*. <https://www.finance.gov.au/government/digital-records-transformation-initiative/more-digital-records-transformation-initiative>
- Authenticity Task Force. (2002). *Requirements for assessing and maintaining the authenticity of electronic records*. InterPARES. http://www.interpares.org/display_file.cfm?doc=ip1_authenticity_requirements.pdf
- Baron, J. R. (2005). Toward a federal benchmarking standard for evaluating information retrieval products used in e-discovery. *Sedona Conference Journal*, 6, 237–246. https://thesedonaconference.org/sites/default/files/publications/237-246%20Baron_237-246%20Baron.qxd_0.pdf
- Birmingham, S. (2021). *Australian company raises the bar for digital data management*. Senator the Hon. Simon Birmingham Minister for Finance. <https://www.financeminister.gov.au/media-release/2021/06/25/australian-company-raises-bar-digital-data-management>
- Belovari, S. (2017). Expedited digital appraisal for regular archivists: an MPLP-type approach. *Journal of Archival Organization*, 14(1–2), 55–77. <https://doi.org/https://doi.org/10.1080/15332748.2018.1503014>
- Bunn, J. (2020). Working in contexts for which transparency is important: A recordkeeping view of explainable artificial intelligence (XAI). *Records Management Journal*, 30(2), 143–153. <https://doi-org.libaccess.sjlibrary.org/10.1108/RMJ-08-2019-0038>
- Challen, R., Denny, J., Pitt, M., Gompels, L., Edwards, T., & Tsaneva-Atanasova, K. (2019). Artificial intelligence, bias and clinical safety. *BMJ Quality & Safety*, 28(3), 231–237. <https://doi.org/https://doi.org/10.1136/bmjqs-2018-008370>
- Colavizza, G., Blanke, T., Jeurgens, C., & Noordegraaf, J. (2022). Archives and AI: An overview of current debates and future perspectives. *Journal on Computing and Cultural Heritage*, 15(1), 1–15. <https://doi.org/https://doi.org/10.1145/3479010>
- Conrad, J. G. (2010). E-discovery revisited: The need for artificial intelligence beyond information retrieval. *Artificial Intelligence and Law*, 18, 321–345. <https://doi.org/https://doi.org/10.1007/s10506-010-9096-6>
- Dixon Jr. (Ret.), J. H. B. (2021). Artificial intelligence: Benefits and unknown risks. *Judges' Journal*, 60(1), 41–43. <https://search-ebSCOhost->

- com.libaccess.sjlibrary.org/login.aspx?direct=true&db=a9h&AN=148239554&site=ehost-live&scope=site
- Fosch Villaronga, E., Kieseberg, P., & Li, T. (2017). Humans forget, machines remember: Artificial intelligence and the right to be forgotten. *Computer Law & Security Review*, 34, 304–313. <https://doi.org/https://doi.org/10.1016/j.clsr.2017.08.007>
- Franks, J. (2021). Text classification for records management. *Journal on Computing and Cultural Heritage, Just Accepted*. <https://doi.org/https://doi.org/10.1145/3485846>
- Franks, P. C. (2018). *Records and information management* (2nd ed.). Chicago, IL: ALA Neal-Schuman.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT Press. <https://books.google.com/books?hl=en&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=related:MHq4MMenr-gJ:scholar.google.com/&ots=MNQ-cnqHPZ&sig=r6rDVtNwWSC45emOUC4VMKI2NDY>
- Harvey, R., & Thompson, D. (2010). Automating the appraisal of digital information. *Library Hi Tech*, 28(2), 313–322. <https://doi.org/https://doi.org.libaccess.sjlibrary.org/10.1108/07378831011047703>
- InterPARES Trust AI. (2018). *Classification* [English]. <https://interparestrustai.org/terminology/term/classification>
- InterPARES Trust AI. (2021). *InterPARES Trust AI*. <https://interparestrustai.org/trust>
- Jo, E. S., & Gebru, T. (2020). Lessons from archives: Strategies for collecting sociocultural data in machine learning. *FAT 2020 - Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency*, 306–316. <https://doi.org/https://doi.org/10.1145/3351095.3372829>
- Katuu, S. (2021b). Managing records in enterprise resource planning systems. *IEEE International Conference on Big Data (Big Data)*, 2240–2245. <https://doi.org/10.1109/BigData52589.2021.9672034>
- Leavy, S., Pine, E., & Keane, M. T. (2017, August). *Mining the cultural memory of Irish industrial schools using word embedding and text classification*. Digital Humanities 2017 Conference, Montreal, Canada. <https://dh2017.adho.org/abstracts/098/098.pdf>
- Lee, C. A. (2018). Computer-assisted appraisal and selection of archival materials. *IEEE International Conference on Big Data (Big Data)*, 2721–2724. <https://doi.org/10.1109/BigData.2018.8622267>

- Lepak, N. (2021, June 24). *What is artificial intelligence & why is it valuable for information management?* Collabware. <https://blog.collabware.com/what-is-artificial-intelligence-4-ways-to-take-advantage-of-ai-in-records-management>
- Makhlouf Shabou, B., Tièche, J., Knafou, J., & Gaudinat, A. (2020). Algorithmic methods to explore the automation of the appraisal of structured and unstructured digital data. *Records Management Journal*, 30(2), 175–200. <https://doi.org/https://doi.org/10.1108/RMJ-09-2019-0049>
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 1–35. <https://doi.org/https://doi.org/10.1145/3457607>
- Obukhov, A., Krasnyanskiy, M., & Nikolyukin, M. (2020). Algorithm of adaptation of electronic document management system based on machine learning technology [Abstract]. *Progress in Artificial Intelligence*, 9, 287–303. <https://doi.org/https://doi.org/10.1007/s13748-020-00214-2>
- OECD. (2019). *Artificial intelligence in society*. OECD Publishing. <https://doi.org/10.1787/eedfee77-en>
- Rendell, K., Koprinska, I., Kyme, A., Ebker-White, A. A., & Dinh, M. M. (2019). The Sydney Triage to Admission Risk Tool (START2) using machine learning techniques to support disposition decision-making [Abstract]. *Emergency Medicine Australasia*, 31(3), 429–435. <https://doi.org/10.1111/1742-6723.13199>
- Rolan, G., Humphries, G., Jeffrey, L., Samaras, E., Antsoukova, T., & Stuart, K. (2019). More human than human? Artificial intelligence in the archive. *Archives & Manuscripts*, 47(2), 179–203. <https://doi.org/https://doi.org/10.1080/01576895.2018.1502088>
- Schwartz, R., Vassilev, A., Greene, K., Perine, L., Burt, A., & Hall, P. (2022). *Towards a standard for identifying and managing bias in artificial intelligence*. National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.1270>
- Tanvir, Q. (2021, August 7). *Multi page document classification using machine learning and NLP*. Towards Data Science. <https://towardsdatascience.com/multi-page-document-classification-using-machine-learning-and-nlp-ba6151405c03>
- The National Archives [TNA]. (2016). *The application of technology-assisted review to born-digital records transfer, inquires and beyond* (pp. 1–27).

<https://www.nationalarchives.gov.uk/documents/technology-assisted-review-to-born-digital-records-transfer.pdf>

The National Archives [TNA]. (2021). *Using AI for digital records selection for government: Guidance for records managers based on an evaluation of current marketplace solutions.*

<https://cdn.nationalarchives.gov.uk/documents/using-ai-digital-selection-in-government.pdf>

Thomas, R. (2019). *The AI ladder*. O'Reilly. <https://www.oreilly.com/online-learning/report/The-AI-Ladder.pdf>

Turek, M. (n.d.). *Explainable artificial intelligence (XAI)*. Defense Advanced Research Projects Agency. <https://www.darpa.mil/program/explainable-artificial-intelligence>

Vellino, A., & Alberts, I. (2016). Assisting the appraisal of e-mail records with automatic classification. *Records Management Journal*, 26(3), 293–313.

<https://doi.org/https://doi.org/10.1108/RMJ-02-2016-0006>