

# Inteligencia artificial y datos masivos en archivos digitales sonoros y audiovisuales

*Perla Olivia Rodríguez Reséndiz*  
Coordinadora



**Q335** Inteligencia artificial y datos masivos en archivos digitales  
**I57** sonoros y audiovisuales / Coordinadora Perla Olivia Rodríguez  
Reséndiz. - México: UNAM. Instituto de Investigaciones  
Bibliotecológicas y de la Información, 2020.

xviii, 182 p. - (Tecnologías de la información)

ISBN:

Investigación realizada gracias al programa

DGAPA - PAPIIT IT400118.

1. Inteligencia artificial - Procesamiento de datos. 2. Internet  
de las cosas. 3. Archivos sonoros. 4. Big data. I. Rodríguez  
Reséndiz, Perla Olivia, coordinadora. II. ser.

Diseño de portada: Oscar Fernando Arcos Casañas

Imágenes:

Envato Elements

(<https://elements.envato.com/es-419/>)

Primera edición, 2020

D.R. © UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

Ciudad Universitaria, 04510, México D.F.

Impreso y hecho en México

ISBN: En trámite

Publicación dictaminada

# Propuesta metodológica y de análisis computacional para identificar el proceso fotográfico en fotografías históricas del siglo XIX y XX

GUSTAVO LOZANO SAN JUAN

*Instituto de Investigaciones Estéticas. Universidad Nacional Autónoma de México.*

RODRIGO COLÍN RIVERA

*Laboratorio Audiovisual de Investigación Social, Instituto Mora.*

## OBJETIVO

El objetivo de este proyecto es diseñar una metodología de trabajo que permita a los archivistas, historiadores, conservadores y otros profesionales de los archivos, identificar correctamente la técnica de las fotografías producidas durante los siglos XIX y XX.

## ANTECEDENTES

Como sabemos, el catálogo es el instrumento que describe ordenadamente y de forma individualizada las unidades documentales de una serie o conjunto documental (Heredia, 1991), las operaciones necesarias para la catalogación de una fotografía son: la elaboración de un lenguaje documental, el análisis de las unidades documentales y la sistematización de la información (Boadas, 2001). El análisis documental se refiere tanto al contenido como al continente, y el aspecto más relevante a documentar en este último caso, es la identificación de la técnica o proceso fotográfico.

**Figura 1. Diversos procesos fotográficos**



En la bibliografía sobre el tema, la identificación del proceso fotográfico no se presenta como un procedimiento sistemático compuesto por pasos claramente delimitados, sino como la aplicación de habilidades de observación y reconocimiento que son adquiridas de manera empírica a lo largo de años de práctica y estudio. Bajo el planteamiento

tradicional, es obligatorio que dichas habilidades se acompañen de un conocimiento sólido de la cronología de los procesos fotográficos y de sus principales hitos tecnológicos, requerimientos que plantean una curva de aprendizaje pronunciada.

En los cursos de capacitación y actualización existentes, la identificación de los procesos fotográficos se enseña de forma casi personalizada en grupos de tamaño pequeño y en clases de duración limitada. El instructor es generalmente un profesional de la conservación especializado en fotografías y de manera invariable se requiere de una colección de estudio variada que permita a los participantes desarrollar las habilidades de observación y análisis descritas previamente.

*Tabla 1. Procesos fotográficos utilizados en los siglos XIX y XX*

<b>Imágenes de cámara</b>	<b>Impresiones</b>	<b>Negativos</b>	<b>Transparencias</b>
Daguerrotipo	Cianotipo	Negativo de colodión húmedo	Transparencia plata gelatina sobre vidrio
Ambrotipo	Albúmina	Negativo de placa seca de gelatina	Transparencia procesos de pantalla aditiva
Ferrotipo	Colodión de impresión directa	Plata gelatina sobre nitrato de celulosa	Transparencia cromógena sobre acetato de celulosa
	Plata gelatina de impresión directa	Plata gelatina sobre acetato de celulosa	Transparencia cromógena sobre poliéster
	Platinotipo	Plata gelatina sobre poliéster	
	Impresión plata gelatina	Cromógeno sobre acetato de celulosa	

	Impresión por difusión de plata	Cromógeno sobre poliéster	
	Impresión cromógena		
	Impresión por difusión de colorantes		
	Impresión por blanqueo de colorantes		

## JUSTIFICACIÓN

El proceso fotográfico se refiere tanto a los materiales como a la manera en que estos se combinan -artesanal o industrialmente- para crear la fotografía. Su documentación es importante porque da cuenta de la evolución tecnológica de prácticas extintas hoy en día y porque algunos procesos requieren de medidas de conservación especiales, como por ejemplo, el almacenamiento a bajas temperaturas para las impresiones, transparencias y negativos cromógenos o las medidas de prevención y combate de incendios para los negativos con soporte de nitrato de celulosa.

Desafortunadamente los vehículos tradicionales para la enseñanza-aprendizaje de los conocimientos y las habilidades requeridos para la identificación del proceso fotográfico, presentan varias limitantes que impiden su disseminación entre los profesionales de los archivos.

## DESARROLLO

La propuesta que aquí se plantea pretende aliviar algunas de las limitaciones antes mencionadas, ya que se trata de una metodología de fácil acceso para los profesionales de los archivos, por medio de la cual es posible identificar el proceso de una fotografía de interés,

entre una gama de 30 alternativas utilizadas a lo largo de los siglos XIX y XX. Algunas de sus características más relevantes son que se pueden aplicar de forma individual sin necesidad de un instructor, no es necesaria, una colección de estudio, no depende del estudio previo de la historia técnica de la fotografía. Adicionalmente, permite a usuarios que aplican la metodología por primera vez, obtener resultados positivos y facilitar la diseminación de un conocimiento de acceso limitado.

A continuación se describe la manera en que esta propuesta fue desarrollada.

## INVESTIGACIÓN BIBLIOGRÁFICA

En la primera etapa de este trabajo se hizo una búsqueda bibliográfica que permitiera identificar las principales características físicas que definen a cada uno de los procesos fotográficos (Reilly, 1986) (Sepiades, 2003) (Aasbø, 2003) (Barra, 2005) (Image Permanence Institute, 2019).

*Tabla 2. Características físicas.*

Soporte primario	Tonalidad
Iluminación	Brillo
Polaridad	Superficie
Tono	Texto
Fecha	Deterioro
Estratigrafía	Tonalidad
Magnificación	Particularidades del Objeto

## SÍNTESIS DE LA INFORMACIÓN

Posteriormente se sintetizó la información y se capturó en formato tabular, en las filas se colocaron los diferentes procesos fotográficos, en las columnas las diferentes características físicas a identificar y en las celdas en donde ambas se intersectan se colocaron las caracterís-

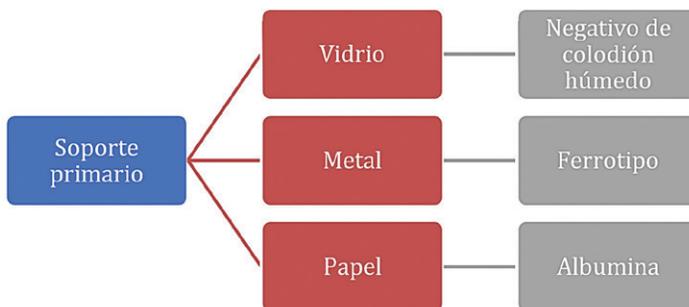
ticas concretas que definen a cada proceso. Por ejemplo, para el caso del proceso fotográfico negativo de colodión húmedo, la característica soporte primario corresponde a la opción vidrio, para el proceso ferrotipo corresponde a la opción metal y para el proceso albumina corresponde a la opción papel.

Tabla 3. Ejemplo de información en formato tabular.

	Soporte primario
Negativo de colodión húmedo	Vidrio
Ferrotipo	Metal
Albumina	Papel

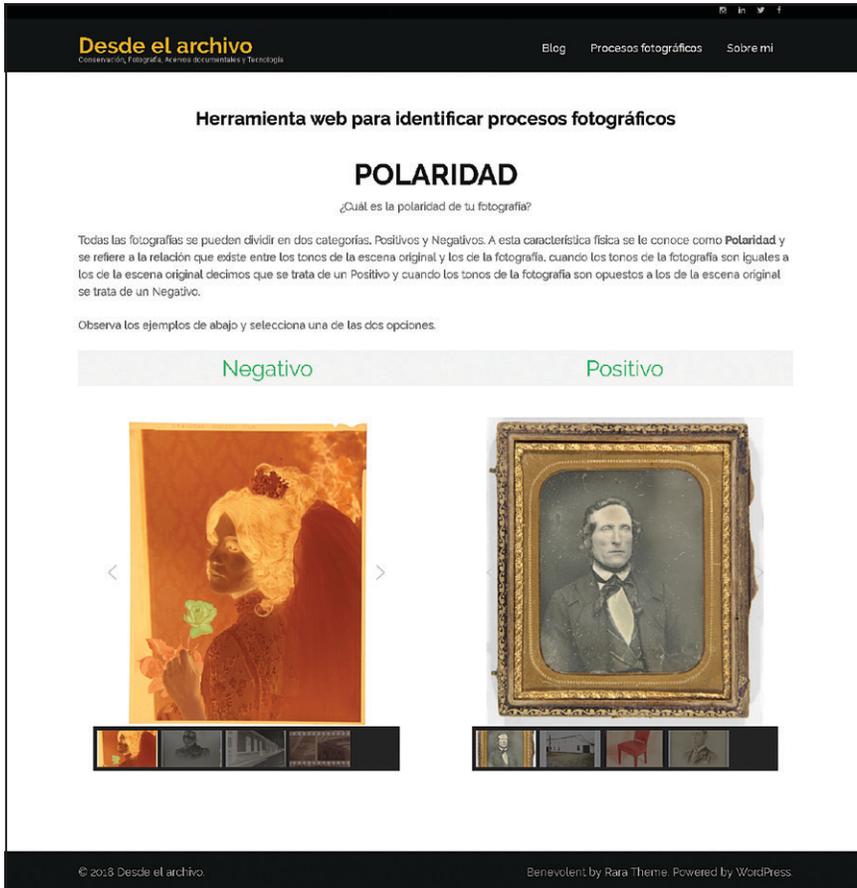
Esta misma información fue trasladada posteriormente a un árbol de decisiones, un modelo predictivo utilizado en las ciencias de datos para clasificar entidades con base en sus atributos; así el soporte primario que en la tabla se encontraba como encabezado de la segunda columna se convirtió en un nodo de decisión del cual se derivan tres ramas: vidrio, metal y papel, que corresponden a las opciones posibles para esa característica, finalmente los tres procesos fotográficos que en la tabla se encontraban en la primera columna se convierten en las hojas del árbol y corresponden a la clasificación final.

Figura 2. Ejemplo de información en formato de árbol de decisiones.



El modelo del árbol permitió elaborar un cuestionario (<http://desdeelarchivo.com/id-procesos-fotograficos/>) que a través de una serie de preguntas dirigidas guían al usuario paso a paso a través de la metodología hasta llegar al conjunto de fotografías que le permiten identificar el proceso fotográfico de su fotografía.

Figura 3. Interfaz de usuario de la página web.



En su estado actual el árbol cuenta con 40 nodos, 96 ramas y 30 hojas por lo que optimizarlo es sumamente importante. Para ello se propo-

ne también un análisis mediante conjuntos de datos representativos con diversas propiedades de las fotografías que serán procesados mediante herramientas y algoritmos de inteligencia artificial. El propósito es generar un árbol de decisiones alternativo a la metodología archivística para encontrar similitudes y determinar las propiedades de mayor relevancia al clasificar las fotografías.

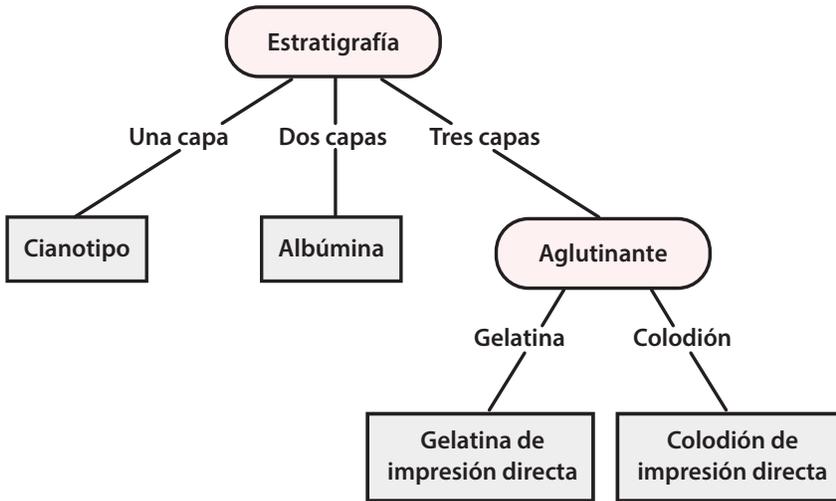
El tipo de análisis computacional propuesto deriva de una rama de la inteligencia artificial denominada Machine Learning (ML) o aprendizaje de máquina, donde el énfasis es aprender de los datos, sin que esta capacidad de aprendizaje esté explícitamente programada. Y de esta manera, utilizar los árboles de decisión como un modelo de predicción de un valor objetivo basado en un conjunto de datos variables.

La generación de árboles de decisión de manera automática o asistida por algoritmos computacionales permite desarrollar tareas de clasificación, cuya aplicación es realizar un análisis computacional para la identificación del proceso fotográfico en fotografías históricas del siglo XIX y XX. Al referirnos al término *identificación*, y bajo este contexto, es válido indicar que el término *predicción* es empleado como sinónimo, ya que el propósito es aproximar (con el menor margen de error posible) un conjunto de datos a un modelo de árbol de decisión que nos permita realizar dicha identificación fotográfica y además, brinde un punto de comparación en cuanto a las características físicas más relevantes de este conjunto particular de fotografías.

## HACER PREDICCIONES

Al revisar otro ejemplo simplificado de árbol de decisión para la identificación de procesos fotográficos, se aprecia la raíz en la parte superior y el árbol crece hasta los nodos terminales u hojas en la parte inferior. Esta representación es equivalente a tener el nodo raíz del lado izquierdo y hacerlo crecer hacia la derecha.

Figura 4. Ejemplo sencillo de árbol de decisión con nodo raíz en la parte superior.



Es interesante notar que cada uno de los nodos intermedios (en color rosa) del árbol de decisión representa una característica física de la fotografía mientras que las hojas (en color gris) representan procesos fotográficos que determinan de manera definitiva la categoría a la que pertenece. Como se puede apreciar, utilizar esta estructura de datos para tareas de clasificación es bastante claro e intuitivo, en contraste con otros modelos como las redes neuronales, considerados modelos de *caja negra* ya que usualmente es difícil de explicar en términos simples por qué y cómo son hechas las predicciones o clasificaciones (Gerón, 2017).

#### VENTAJAS Y LIMITACIONES

Como se ha mostrado, una ventaja importante de los árboles de decisión es que el proceso de clasificación es lo suficiente fácil de llevar a cabo teniendo la estructura del árbol, y se puede realizar manualmente sin la necesidad de una computadora. Los datos de entrada que se procesan usualmente derivan de conjuntos o bases de datos que requieren poca intervención y se pueden exportar en formatos de archi-

vo convenientes como CSV (valores separados por coma). Otra ventaja importante es que el desempeño es bueno con cantidades razonables de poder de cómputo; si se tiene un conjunto de datos grande, el proceso de aprendizaje y construcción del modelo es manejable (Bell, 2015).

A pesar de las ventajas también es importante identificar inconvenientes, y uno de los más importantes es el hecho de que se pueden crear modelos muy complejos generados a partir de conjuntos de datos complejos. La manera de contrarrestar este efecto es revisar y acotar los valores a usar en categorías, lo cual producirá un modelo más refinado y concreto. Hay que estar consciente de que este proceso no siempre es viable, de ser el caso, el modelo resultante puede ser mucho más grande de lo esperado. Puede ser que utilizar otro método de inteligencia artificial se adapte mejor a las necesidades del conjunto de datos, por ejemplo, redes neuronales o máquinas de soporte vectorial.

## ALGORITMOS

### ID3

El algoritmo ID3 (Iterative Dichotomiser 3) fue inventado por Ross Quinlan, investigador en ciencias de la computación en el área de minería de datos y teoría de la decisión, para crear árboles a partir de bases de datos. Al calcular la entropía --unidad de medida del desorden en un conjunto de datos, según la teoría de la información-- para cada atributo del conjunto de datos, esto permite dividir en subconjuntos basados en el valor de mínima entropía, y construir de manera recursiva cada nodo del árbol de decisión.

En conjunción, ID3 utiliza también el método de ganancia de información, la medida de las diferencias de entropía antes y después de que un atributo divide en subconjuntos de datos, para determinar el nodo raíz en cada llamada recursiva del algoritmo.

### C4.5

Ross Quinlan efectuó mejoras en su algoritmo original y creó el algoritmo C4.5 que de igual manera emplea el método de ganancia de

información, pero hace más evidente que el árbol resultante puede ser usado como modelo de clasificación.

Entre las mejoras más notables respecto a ID3 se encuentra la habilidad de trabajar con atributos continuos, como valores numéricos o fechas. También permite trabajar con valores de atributos vacíos o “huecos” en la base de datos sin que esto afecte la ganancia de información de un atributo durante la construcción del árbol. Y por último, el árbol creado con C4.5 es recortado después de su creación, es decir, algunas ramificaciones del árbol son modificadas por nodos terminales cuando contribuyen a simplificar el árbol (Bell, 2015).

## PROCESO DE GENERACIÓN AUTOMÁTICA DE ÁRBOLES DE DECISIONES

Es usual en el área de ML, que el ciclo de acciones a tomar para generar modelos a partir de conjuntos de datos involucra los siguientes pasos: obtención de datos, preparación de éstos, ejecución de la heurística o algoritmo y presentar los resultados.

Se emplea el software de código abierto WEKA (<https://www.cs.waikato.ac.nz/ml/weka>) para la generación de árboles de decisión. Dicho software cuenta con una colección de algoritmos y herramientas de pre procesamiento de datos que permiten trabajar de manera flexible con conjuntos de datos, facilita la experimentación, la obtención de resultados estadísticos y visualización tanto de los datos de entrada como de los resultados obtenidos.

## OBTENCIÓN DE DATOS

Los datos que se emplearon en este trabajo son una acotada selección de diversas características fotográficas de la colección de estudio perteneciente al área de conservación del Archivo Fotográfico Manuel Toussaint del Instituto de Investigaciones Estéticas de la UNAM. Todas las características físicas de los procesos fotográficos a identificar se registraron en una hoja de cálculo que sirve de insumo inicial en esta etapa del proceso.

Figura 5. Muestra de la hoja de cálculo que da cuenta de las propiedades y atributos fotográficos.

Clasificaciones		Atributos comunes			Atributos particulares								
Proceso	Tipología	Soporte	Iluminación	Polaridad	Tono	Fecha	Estradiografía	Magnificación	Tonalidad	Brillo	Superficie	Particularidades Objeto	Texto
Daguerotipo	Imagen de cámara	Metal	Reflexión	Positivo	Monocromático	1839 - 1860			Neutro	Muy brillante	Positivo-negativo		Delatamiento de plata, corrosión de cobre.
Autrotipo	Imagen de cámara	Mdfro	Reflexión	Positivo	Monocromático	1851 - 1855			Café	Brillante	Luces lechosas		
Fenotipo	Imagen de cámara	Metal	Reflexión	Positivo	Monocromático	1855 - 1890			Café	Sem mate	Magnético		Corrosión, falantes, craqueladuras
Cianotipo	Impresión	Papel	Reflexión	Positivo	Monocromático	1840 - 1820		Fibras visibles	Can	Mate			
Alburtina	Impresión	Papel	Reflexión	Positivo	Monocromático	1851 - 1890		Fibras visibles	Amarillo, Café, Sem mat, rojo		Soporte primario delgado, Soporte secundario grueso		Craqueladura amarrillamiento pérdida de densidad en las luces y sombras
Carbón	Impresión	Papel	Reflexión	Positivo	Monocromático	1850 - 1840		No se ven fibras	Otro		Relieve en sombras		
Colodión de impresión de seda	Impresión	Papel	Reflexión	Positivo	Monocromático	1855 - 1910		Tres	Purpura, Rojo, Brillante	Textura lisa			Abrusiones, pérdida de densidad en las luces
Plata gelatina de impresión	Impresión	Papel	Reflexión	Positivo	Monocromático	1855 - 1910		Tres	Amarillo	Brillante	Texturas		pérdida de densidad en las luces
Seda	Impresión	Papel	Reflexión	Positivo	Monocromático	1855 - 1910		Tres	Otro				
Soporte lacromatado	Impresión	Papel	Reflexión	Positivo	Monocromático	1890 - 1930		Una	Neutro				Ghosting
Panotipo	Impresión	Papel	Reflexión	Positivo	Monocromático	1890 - 1930		Una	Neutro				
Plata gelatina	Impresión	Papel	Reflexión	Positivo	Monocromático	1890 - 2018		No se ven fibras	Neutro, Café	Sem mate	Texturizado	Soporte primario grueso, Soporte secundario grueso y ludoaciano	
Colodión mate de impresión de seda	Impresión	Papel	Reflexión	Positivo	Monocromático	1855 - 1910		Tres	Neutro, Café, purpura (oro)				
Difusión de plata	Impresión	Papel	Reflexión	Positivo	Monocromático	1942 - 2018		Tres	Neutro	Lisa	Lisa	Pesetas, borde irregular o perforado, superficie con restos de adhesivo.	Polaroid
Comógeno	Impresión	Papel	Reflexión	Positivo	Policromático	1940 - 2018		Tres		Brillante	Lisa o texturizada	Papel de fibra, RC, acetato pigmentado	< 1.980 amarellamiento, pérdida de balance de color y deterioramiento de colorantes
Difusión de colorantes por transferencia	Impresión	Papel	Reflexión	Positivo	Policromático	1953 - 2018		Tres		Brillante	Lisa	Pesetas, borde irregular o perforado, superficie con restos de adhesivo.	Polaroid
Blanqueo de colorantes	Impresión	Papel	Reflexión	Positivo	Policromático	1963 - 2018		Tres		Brillante	Lisa.	Marco blanco con contenido de quincea de procesado.	Polaroid
Difusión de colorantes por transferencia interna	Impresión	Papel	Reflexión	Positivo	Policromático	1972 - 2018		Tres		Brillante	Lisa.		Polaroid
Colodión lúmbido	Negativo	Mdfro	Transmisión	Negativo	Monocromático	1851 - 1855			Café		Agujante irregular, Benzil	Mdfro grueso e irregular	Abrasion
Gelatina seca	Negativo	Mdfro	Transmisión	Negativo	Monocromático	1880 - 1925			Neutro		Agujante irregular	Mdfro delgado y recto	
Plata gelatina Nitro de celulo	Negativo	Plástico	Transmisión	Negativo	Monocromático	1889 - 1950					ludaciano "v"	Mirra diformico.	
Plata gelatina Acetato de celulo	Negativo	Plástico	Transmisión	Negativo	Monocromático	1935 - 2018					ludaciano "v"	Safety	
Papel gelatino Poliester	Negativo	Plástico	Transmisión	Negativo	Monocromático	1955 - 2018					ludaciano "v"	Safety	
Comógeno Acetato de celulo	Negativo	Plástico	Transmisión	Negativo	Policromático	1942 - 2018					Brañagosa	Safety	
Comógeno Poliester	Negativo	Plástico	Transmisión	Negativo	Policromático	1955 - 2018					Brañagosa	Safety	
Plata gelatina Mdfro	Transparencia	Mdfro	Transmisión	Positivo	Monocromático	1839 - 1840							
Plata gelatina Acetato de celulo	Transparencia	Plástico	Transmisión	Positivo	Monocromático	1935 - 2018							
Plata gelatina Poliester	Transparencia	Plástico	Transmisión	Positivo	Monocromático	1955 - 2018							
Proceso activo	Transparencia	Mdfro	Transmisión	Positivo	Policromático	1907 - 1935			Retículo		Lineas rectas paralelas	Brañagosa	Delatamiento, puntos verdes
Comógeno Acetato de celulo	Transparencia	Plástico	Transmisión	Positivo	Policromático	1935 - 2018							
Comógeno Poliester	Transparencia	Plástico	Transmisión	Positivo	Policromático	1955 - 2018							

Figura 6. Mismo conjunto de datos en diferentes formatos, de izquierda a derecha se muestra una hoja de cálculo, un archivo CSV y un archivo ARFF.

A	B	C	D
1	Proceso	Tipología	Agulante
2	Albúmina	Impresión	Brillo
3	Albúmina	Impresión	Albúmina
4	Albúmina	Impresión	Semi mate
5	Albúmina	Impresión	Semi mate
6	Albúmina	Impresión	Brillante
7	Albúmina	Impresión	Semi mate
8	Albúmina	Impresión	Mate
9	Albúmina	Impresión	Semi mate
10	Albúmina	Impresión	Brillante
11	Albúmina	Impresión	Semi mate
12	Albúmina	Impresión	Semi mate
13	Albúmina	Impresión	Semi mate
14	Albúmina	Impresión	Semi mate
15	Albúmina	Impresión	Semi mate
16	Albúmina	Impresión	Semi mate
17	Albúmina	Impresión	Semi mate
18	Albúmina	Impresión	Semi mate
19	Albúmina	Impresión	Semi mate
20	Albúmina	Impresión	Semi mate
21	Albúmina	Impresión	Semi mate
22	Albúmina	Impresión	Semi mate
23	Albúmina	Impresión	Semi mate
24	Albúmina	Impresión	Semi mate

## PREPARACIÓN DE LOS DATOS

De las 27 columnas originales de la hoja de cálculo, se mantienen 15 columnas o atributos que representan conjuntos de información lo más acotados posibles en un rango de valores bien identificado. Las razones principales para descartar algunas de las columnas son la ausencia de información en campos opcionales (por ejemplo, subtipo de soporte), y la dispersión de datos en el caso de las columnas donde se escriben comentarios o anotaciones que suelen ser únicos (por ejemplo, particularidades del objeto fotográfico).

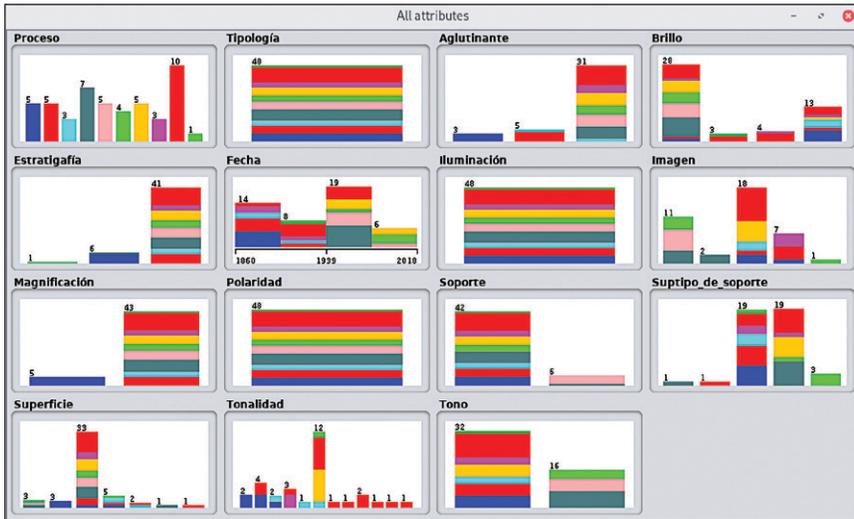
El método de almacenamiento nativo de WEKA es a través de archivos en formato ARFF. Este formato es muy similar a un archivo con formato de valores separado por coma (CSV), con la diferencia de que se le agregan encabezados que dan cuenta de las columnas o atributos, así como de los valores que pueden tener.

Este proceso de conversión de formato es simple de llevar a cabo gracias a que diversos programas permiten exportar bases de datos u hojas de cálculo en el formato CSV. Sin embargo, esta tarea se dificulta si los datos no están estandarizados, contienen errores ortográficos u otras inconsistencias. Por tal razón, la importancia de definir un vocabulario común es vital para un correcto funcionamiento del algoritmo y a su vez, para mantener consistencia e integridad de los datos.

## EJECUCIÓN DEL ALGORITMO

Para utilizar el algoritmo C4.5 en WEKA, se hace uso de la versión de código abierto llamada algoritmo J4.8 (versión ligeramente mejorada del algoritmo C4.5 revisión 8 que está implementando en el lenguaje de programación Java). Con esto en consideración, el procedimiento es bastante directo, el primer paso consiste en seleccionar el archivo ARFF desde el explorador de WEKA para apreciar el conjunto de datos en su totalidad.

Figura 7. Gráficas de todas las propiedades a utilizar. Cada color representa un proceso fotográfico diferente.



En seguida se selecciona la pestaña de clasificación y se selecciona de la lista de opciones el algoritmo J48, se asignan los parámetros correspondientes, se selecciona el atributo o columna que representa las clases (en este caso el proceso fotográfico), se ejecuta el algoritmo y se observan los resultados que se obtienen.

Es crucial determinar los parámetros adecuados para obtener el mejor árbol de decisión. Si bien la cantidad de parámetros es acotada, son suficientes para generar diversidad de resultados que solamente pueden ser considerados mejores o peores, en comparación con el porcentaje de registros clasificados correctamente, según un conjunto de prueba (el cual puede ser el mismo conjunto de datos).

Los parámetros más significativos empleados para lograr un árbol de decisión suficientemente compacto, pero que logre clasificar correctamente la mayor cantidad de elementos no siempre es evidente y requiere de experimentación y múltiples ejecuciones del algoritmo.

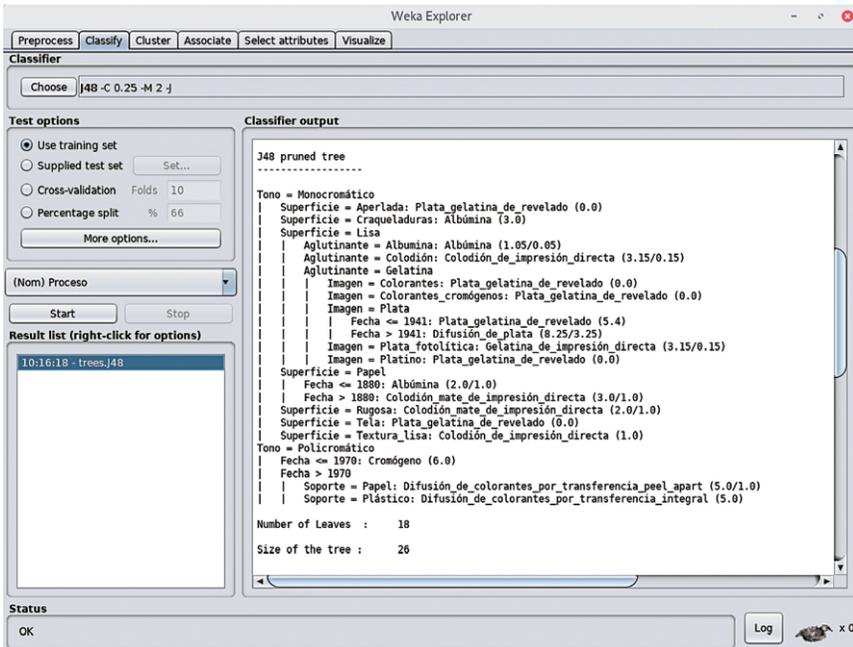
Tabla 4. Descripción de los parámetros relevantes en el algoritmo J4.8

Parámetro	Descripción	Valor usado
Unpruned tree (unpruned)	Usar árbol de decisión sin poda o recortes (genera árboles más grandes).	False
Reduced-error pruning (reducedErrorPruning)	Determina si se utiliza un método alternativo de poda (no necesariamente con mejores resultados).	False
Pruning confidence (confidenceFactor)	Factor que se utiliza para podar o recortar el árbol; a menor valor mayor poda.	0.25
Minimum number of instances (minNumObj)	Establece el mínimo número de instancias por hoja o el número mínimo de ramificaciones.	2
MDL-correction (useMDLcorrection)	Ajuste basado en MDL (mínima longitud de descripción) para calcular ganancia de información.	False

## RESULTADOS

El resultado es un árbol de 26 nodos, 25 ramas y 18 son nodos terminales u hojas, que permiten clasificar fotografías según los 15 atributos que se definieron en la base de datos. Se tiene un porcentaje de instancias clasificadas correctamente de 85.41%, que es el porcentaje más alto que se alcanzó con los parámetros que ya se mencionaron. Esto no representa un árbol ideal que clasifique correctamente el 100% de las muestras pero da cuenta de una estructura diferente a la concebida de manera no-automatizada y hace evidente, al recorrer el árbol desde la raíz hasta una hoja, que hay características de la fotografía que tienen mayor peso para lograr una rápida clasificación de la misma.

Figura 8. Resultados mostrados en WEKA. Se aprecia una versión textual del árbol de decisión generado.



## CONCLUSIONES

Los conocimientos, experiencia y habilidades de especialistas, combinados con técnicas computacionales, nos permitieron obtener una metodología más robusta que cualquiera de estas dos opciones por separado. Se evidenciaron las diferencias entre las posibles maneras de construir un árbol de decisión y se revaloró la importancia de algunas características físicas de la fotografía. Una de las finalidades, buscar un balance entre un árbol compacto autogenerado y uno creado, a partir de la experiencia profesional, a fin de enriquecer también la práctica docente y de investigación.

A mayor cantidad de datos disponibles, el árbol de decisiones producido de manera automática, genera un modelo más refinado para contemplar diversos casos y mejorar la clasificación. Pero se debe



tener cuidado con el problema del sobreajuste de datos, para lo cual se recomienda que los datos sean suficientemente representativos de las características físicas en las fotografías. Por lo tanto, no se debe descartar la opción de eliminar o agregar atributos y columnas en futuros procedimientos, ya que la experimentación y la comparación de diferentes versiones de árboles de decisión es de suma importancia en la labor comparativa.

Futuros trabajos encaminados en la misma temática pueden llegar a considerar una interfaz web a la que se le suministre el resultado de la generación automática de árboles de decisión, para mejorar la experiencia de usuario, e identificar de manera más rápida el proceso fotográfico, sin dejar de lado la parte didáctica con las explicaciones que ya se tienen. Así también, incluir otros tipos de análisis computacionales, como el uso de otras técnicas de Machine Learning o de análisis digital de la imagen asistida con herramientas de inteligencia artificial.

## BIBLIOGRAFÍA

- Aasbø, Kristin, y Edwin Klijn. (2003). *Sepiades: recommendations for cataloguing photographic collections : advisory report by the SEPIA Working Group on Descriptive Models for Photographic Collections*. Amsterdam: European Commission on Preservation and Access.
- Barra Moulain, Paula Alicia e Ignacio Gutiérrez Rubalcava. (2005). *Normas catalográficas del Sistema Nacional de Fototecas del INAH*. México: Instituto Nacional de Antropología e Historia.
- Bell, Jason. (2015). *Machine Learning: Hands-On for Developers and Technical Professionals*. [S.I.]: John Wiley.
- Boadas i Raset, Joan, Lluís-Esteve Casellas y M. Àngels Suquet i Fontana. (2001). *Manual para la gestión de fondos y colecciones fotográficas*. Girona: CCG Ediciones.

Comité Técnico de Normalización Nacional de Documentación. (2016). Norma Mexicana NMX-R-069-SCFI-2016. Documentos fotográficos. Lineamientos para su Catalogación. México: Secretaría de Economía.

Witten, Ian H., y Eibe Frank. (2016). *Data Mining: Practical Machine Learning Tools and Techniques, Fourth Edition*. San Diego: Elsevier Science & Technology Books.

Géron, Aurélien. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow. Concepts, Tools, and Techniques to Build Intelligent Systems*. 1st ed. Sebastopol, CA: O'Reilly.

\_\_\_\_\_. (2019). *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*.

Heredia Herrera, Antonia. (1995). *Archivística general: teoría y práctica*. Sevilla: Diputación Provincial.

Image Permanence Institute. Graphics Atlas: Search Process. <http://www.graphicsatlas.org/identification/>.

Quinlan, Ross. (1986). *Induction of Decision Trees*. Machine Learning 1. 81-106. doi: <https://doi.org/10.1007/BF00116251>.

Reilly, James. (1986). *Care and identification of 19th-century photographic prints*. Rochester: Eastman Kodak Company.

***Inteligencia artificial y datos masivos en archivos digitales sonoros y audiovisuales.*** Instituto de Investigaciones Bibliotecológicas y de la Información/UNAM. La edición consta de 100 ejemplares. Coordinación editorial, Israel Chávez Reséndiz; revisión e especializada, Angélica Valenzuela y Valeria Guzmán González; revisión de pruebas, Valeria Guzmán González; formación editorial, Oscar Fernando Arcos Casañas. Fue impreso en papel cultural de 90 gr. en los talleres de Grupo Fogra. Año de Juárez 223. Col. Granjas San Antonio. Alcaldía Iztapalapa. Ciudad de México. Se terminó de imprimir en 2020.