

PABLO CISNEROS ÁLVAREZ  
YOLANDA LÓPEZ LÓPEZ  
(COORDS.)

# Las tecnologías y la inteligencia artificial en la cultura actual

**EL NUEVO RETO DE LA SOCIEDAD**





# Las tecnologías y la inteligencia artificial en la cultura actual



Las tecnologías y la  
inteligencia artificial  
en la cultura actual  
*El nuevo reto de la sociedad*



PABLO CISNEROS ÁLVAREZ  
YOLANDA LÓPEZ LÓPEZ  
(coords.)

Ediciones Trea

Todos los trabajos del presente volumen han superado la revisión por pares ciegos. Los autores agradecen la financiación parcial recibida de la Universidad Internacional de La Rioja (UNIR).

© de los textos: los autores de cada capítulo, 2026

© de esta edición: Ediciones Trea, S. L.  
C/ Gran Capitán, 52  
33213 Gijón · Asturias · España  
Tfno. 985 303 801 · Fax 985 303 712  
trea@trea.es  
www.trea.es

Producción: Patricia Laxague Jordán  
Corrección: Almudena Zapatero  
Maquetación: Almudena Zapatero

Depósito legal: AS 00870-2026  
ISBN: 979-13-88179-24-2

Impreso en España — Printed in Spain

Todos los derechos reservados. No se permite la reproducción total o parcial de este libro, ni su incorporación a un sistema informático, ni su transmisión en cualquier forma o por cualquier medio, sea éste electrónico, mecánico, por fotocopia, por grabación u otros métodos, sin el permiso previo por escrito de Ediciones Trea, S. L.

La editorial, a los efectos previstos en el artículo 32.1 párrafo segundo del vigente TRLPI, se opone expresamente a que cualquiera de las páginas de esta obra o partes de ella sean utilizadas para la realización de resúmenes de prensa.

Cualquier forma de reproducción, distribución, comunicación pública o transformación de esta obra solo puede ser realizada con la autorización de sus titulares, salvo excepción prevista por la ley. Diríjase a CEDRO (Centro Español de Derechos Reprográficos) si necesita fotocopiar o escanear algún fragmento de esta obra ([www.conlicencia.com](http://www.conlicencia.com); 91 702 19 70 / 93 272 04 47).

# Índice

<b>Prólogo</b> .....	9
ANA CARRO ROSSELL	
<b>Introducción</b> .....	13
PABLO CISNEROS ÁLVAREZ Y YOLANDA LÓPEZ LÓPEZ	
<b>1. Sobre un posible canon algorítmico: la disputa sobre la mediación cultural</b> .....	17
VÍCTOR GUTIÉRREZ-SANZ	
<b>2. Los <i>backrooms</i>, los espacios liminales y el #nostalgia-core: una estética para el arte rupestre de la IA</b> .....	29
MIGUEL ANTÓN MORENO Y ENRIQUE FERRARI NIETO	
<b>3. Ecos del algoritmo: la IA en la música y el desafío de la autenticidad patrimonial</b> .....	47
BEATRIZ AMORÓS SÁNCHEZ Y VÍCTOR PADILLA MARTÍN-CARO	
<b>4. Cuerpos, códigos y memorias: inteligencia artificial y memoria viva en las artes escénicas</b> .....	65
ZOE MARTÍN LAGO, MARGA DEL HOYO VENTURA Y DIEGO PALACIO ENRÍQUEZ	
<b>5. Danza e inteligencia artificial: presente y futuro en la creación coreográfica</b> .....	81
ANA COLOMER-SÁNCHEZ	
<b>6. La luz que permanece: innovaciones tecnológicas en la preservación y difusión del patrimonio cinematográfico</b> .....	93
YOLANDA LÓPEZ LÓPEZ	
<b>7. Generación de imágenes con inteligencia artificial a partir de fotografías patrimoniales en las prácticas artísticas actuales</b> .....	107
DANIELA REYES-MARCOS, ALFONSO DA SILVA LÓPEZ Y PABLO MARTÍNEZ MUÑIZ	
<b>8. Procesos artísticos contemporáneos a la luz de la IA</b> .....	121
JORGE QUIJANO AHIJADO Y LAURA MIER VALERÓN	
<b>9. Auge y desafíos de las proyecciones inmersivas: reflexiones en torno a un nuevo espacio artístico</b> .....	139
PABLO CISNEROS ÁLVAREZ, YOLANDA LÓPEZ LÓPEZ Y JAVIER ARES YEBRA	

<b>10. Turismo cultural 4.0: museos, inteligencia artificial y experiencias inmersivas . . . . .</b>	<b>155</b>
TATIANA FERNÁNDEZ LLANES Y MYRIAM FERREIRA FERNÁNDEZ	
<b>11. Retos legales de los sistemas de IA en el patrimonio y la creación cultural españolas . . . . .</b>	<b>167</b>
CONCEPCIÓN CAGIDE TORRES	
<b>12. Reescribir el museo: inteligencia artificial y nuevas formas de significación social . . . . .</b>	<b>183</b>
CARMEN ARENAS-CARBELLIDO Y MAR RODRIGUEZ-BRIOSO	
<b>13. Inteligencia artificial y arqueología digital: nuevas formas de conservar, interpretar y difundir el patrimonio . . . . .</b>	<b>203</b>
CRISTINA DE JUANA-ORTÍN, RAQUEL RUBIO GONZÁLEZ Y ALEJANDRA SÁNCHEZ-POLO	
<b>14. Restauración virtual del patrimonio asistido por IA y experiencia perceptiva el usuario . . . . .</b>	<b>217</b>
MARÍA ÁVILA RODRÍGUEZ Y JORGE QUIJANO AHIJADO	
<b>15. La inteligencia artificial y el estudio de las emociones en los museos: un camino para mejorar la transferencia y la comunicación . . . . .</b>	<b>229</b>
TATIANA FERNÁNDEZ LLANES Y CRISTINA DE JUANA ORTIN	
<b>16. Del museo al videojuego y del videojuego al museo: modelado 3D y experiencias inmersivas en la educación del patrimonio . . . . .</b>	<b>241</b>
RUBÉN GREGORI, MARÍA ÁVILA RODRÍGUEZ Y AIDA FERRI RIERA	
<b>17. La inteligencia artificial como un componente esencial de los museos del futuro . . . . .</b>	<b>253</b>
PABLO CISNEROS ÁLVAREZ Y LAURA MIER VALERÓN	

## Ecós del algoritmo: la IA en la música y el desafío de la autenticidad patrimonial

BEATRIZ AMORÓS SÁNCHEZ | VÍCTOR PADILLA MARTÍN-CARO

*Universidad Internacional de La Rioja*

**RESUMEN.** El capítulo examina cómo la generación musical con IA tensiona la autenticidad patrimonial de la música clásica y el fenómeno de falsificación estilística en repertorios consolidados como el Renacimiento, Barroco y Clasicismo. Tras revisar enfoques de generación en MIR y la opacidad de herramientas comerciales, se generaron tres piezas con Suno v5 Pro beta mediante *prompts* estilísticamente acotados y se seleccionaron seis obras históricas comparables. Se diseñó un test perceptivo en el que se presentaron nueve audios de un minuto a 206 participantes, que debían decidir si el origen era humano o IA. El porcentaje de acierto fue cercano al azar —con una media de 4,15 aciertos de 9—, con mayor dificultad en el bloque clásico —41,4 % de aciertos—, seguido del Barroco (46,4 %) y mayor acierto en el Renacimiento (50,3 %). También se concluyó que la escucha frecuente de música clásica mejoró el desempeño, la edad lo redujo y el uso habitual de IA no aportó ninguna ventaja. A partir de estos resultados, se subraya que la verosimilitud perceptiva no basta para garantizar autenticidad patrimonial, por lo que se requieren medidas de contextualización, transparencia y trazabilidad en el uso de música generada por IA, especialmente en entornos culturales y patrimoniales.

**PALABRAS CLAVE:** inteligencia artificial; generación musical; MIR; autenticidad patrimonial; música clásica.



### Introducción

La música histórica de siglos pasados, popularmente conocida como música clásica, constituye un patrimonio sonoro cuyo valor reside, además de en su calidad artística, en nociones como autoría, contexto y autenticidad, entendiendo la autenticidad

patrimonial como un atributo documental y como experiencia del oyente (International Council on Monuments and Sites [ICOMOS], 1994); pero ¿qué ocurre cuando el pasado puede ser recreado con apariencia convincente por sistemas de generación automática?

La generación automática de música mediante inteligencia artificial ha pasado, en poco tiempo, de ser un objeto de investigación especializado a convertirse en una práctica ampliamente difundida a través de herramientas comerciales (Casini y otros, 2025; Reuters, 2026) gracias a los modelos generativos de aprendizaje profundo, capaces de producir música perceptivamente coherente en representaciones simbólicas y en audio (Agostinelli y otros, 2023; Copet y otros, 2023). Así, la IA no solo interviene ya en procesos creativos contemporáneos, sino que se ha convertido en un agente capaz de imitar con notable verosimilitud estilos musicales asociados a tradiciones históricas consolidadas.

Desde la perspectiva del Music Information Retrieval (MIR), la generación musical ha desempeñado tradicionalmente un papel metodológico, orientado al análisis, la modelización y la comprensión de la música más que a la producción artística en sí misma. Los modelos generativos han sido empleados como herramientas para explorar hipótesis sobre estructura, expectativa, similitud y percepción musical, así como para generar datos sintéticos en contextos de escasez de anotaciones (Briot, Hadjeres y Pachet, 2020). Sin embargo, la aparición de sistemas comerciales de generación musical introduce un nuevo escenario.

Este nuevo contexto resulta especialmente relevante cuando se considera su impacto sobre el patrimonio sonoro. La música histórica, en particular la asociada a periodos como el Renacimiento, el Barroco o el Clasicismo, ha sido objeto de procesos de conservación, análisis y reinterpretación. La posibilidad de generar música que reproduce rasgos estilísticos de estos periodos plantea un desafío específico: la producción de productos sonoros que evocan el pasado sin estar anclados a una fuente histórica concreta ni a un proceso creativo humano reconocible.

En este marco se inscribe el concepto de falsificación estilística, entendido como la capacidad de un sistema de inteligencia artificial para generar música que imita un estilo histórico de forma suficientemente convincente como para dificultar su distinción perceptiva respecto a composiciones reales.

Si la música generada por IA es percibida como indistinguible de la música histórica, se plantean cuestiones fundamentales sobre los criterios mediante los cuales se evalúa la autenticidad sonora, la necesidad de transparencia en el uso de tecnologías generativas y los límites de la IA como herramienta de recreación patrimonial, especialmente en relación con la opacidad técnica y las dificultades de evaluación reproducible de estos sistemas (Sturm y otros, 2019). Del mismo modo, se considera de especial interés explorar si factores como el hábito de escucha especializada o la alfabetización

tecnológica actúan realmente como filtros críticos, o si la sofisticación de los modelos actuales ha logrado neutralizar estas variables demográficas y formativas.

Este capítulo aborda estas cuestiones desde una perspectiva empírica y perceptiva. A partir del uso de una plataforma comercial de generación musical basada en inteligencia artificial (Suno), se han producido piezas que imitan estilos característicos del Renacimiento, el Barroco y el Clasicismo. Estas obras se comparan con composiciones históricas reales mediante un test auditivo diseñado para analizar la capacidad de los oyentes para identificar el origen humano o algorítmico del material musical y reflexionar sobre los retos que esta plantea sobre autenticidad, autoría y experiencia estética en la era de la inteligencia artificial.

## Estado del arte

La generación automática de música mediante inteligencia artificial ha experimentado un crecimiento acelerado en los últimos años, impulsado tanto por avances en la investigación académica como por la aparición de herramientas comerciales de gran impacto mediático. En el ámbito del MIR, la generación musical no se concibe únicamente como un fin creativo, sino como un recurso metodológico para el análisis, la modelización y la comprensión de la música.

En este contexto, resulta esencial distinguir entre los objetivos, metodologías y criterios de evaluación de los modelos académicos y los sistemas comerciales. Mientras los primeros priorizan la interpretabilidad, la reproducibilidad y la evaluación controlada, los segundos se orientan principalmente hacia la calidad perceptiva y la experiencia de usuario, con un elevado grado de opacidad técnica. Este capítulo revisa los principales enfoques de generación musical desde la perspectiva MIR, diferenciando entre modelos simbólicos y de audio, y analizando posteriormente las herramientas comerciales más representativas y sus limitaciones analíticas.

## GENERACIÓN MUSICAL EN LA INVESTIGACIÓN ACADÉMICA

En la investigación académica, la generación musical se aborda fundamentalmente como un medio para el análisis y la validación de modelos musicales. Los modelos generativos permiten explorar hipótesis sobre estructura, expectativa, similitud y percepción, así como generar un volumen alto de datos para tareas MIR.

Trabajos de los últimos años como MusicLM (Agostinelli y otros, 2023) y MusicGen (Copet y otros, 2023) formulan explícitamente el problema de generación, describiendo arquitecturas, representaciones y datos de entrenamiento, y evaluando los resultados mediante métricas reproducibles y estudios perceptivos controlados. De

forma complementaria, se ha enfatizado la necesidad de *benchmarks* comparativos basados en preferencias humanas, con el fin de correlacionar métricas automáticas con juicios musicales reales (Grötschla et al., 2025). En el trabajo de Grötschla se generan 6000 piezas usando 12 modelos y participan 2500 personas. El claro vencedor es Suno v3.5 frente a Udio u otras plataformas. En este trabajo no se emplean ejemplos musicales concretos de la historia de la música, ni comparativas con obras de autores reales validadas por expertos, a modo de la clásica prueba del Test de Turing. V. Padilla y D. Conklin (2018) crearon y validaron un sistema de generación de música renacentista a través de un modelo probabilístico. En otros casos, la generación se emplea también para crear datos sintéticos, evaluar modelos de similitud o estructura musical y apoyar tareas MIR. A modo de ejemplo, Wu y otros (2022) proponen romper el cuello de botella de la falta de datos musicales estructurados a través de su Chamber Ensemble Generator (CEG) para generar un gran *dataset* de corales.

#### MODELOS CLÁSICOS DE GENERACIÓN MUSICAL DESDE LA PERSPECTIVA MIR

Desde el punto de vista del MIR, los modelos de generación musical pueden agruparse en dos grandes categorías: modelos simbólicos generativos y modelos de audio generativo, diferenciados principalmente por el tipo de representación musical.

##### *Modelos simbólicos generativos*

Los modelos simbólicos operan sobre representaciones discretas como MIDI, piano-rolls o secuencias de eventos musicales. Este enfoque ha sido central en la investigación MIR debido a su alineación directa con conceptos musicales explícitos como tonalidad, ritmo, métrica y forma (Müller, 2015). Una forma de trabajar con los diferentes parámetros musicales es la idea de *viewpoint* (D. Conklin e I. H. Witten, 1995), que se configura como una colección de vistas independientes de la superficie musical, modelando distintos aspectos de la música.

Haciendo algo de historia, los primeros modelos generativos se basaron en codificar sistemas basados en reglas. Los primeros ejemplos se remontan a 1958 y fueron el resultado de aplicar reglas de contrapunto (Hiller y Isaacson, 1958). Ejemplos en esta línea podemos encontrar hasta principios del siglo XXI (Phon-Amnuaisuk, 2002).

Un notable avance se produjo empleando enfoques probabilísticos y secuenciales —n-gramas y Modelos de Markov—. El principal inconveniente es su limitada capacidad para modelar estructura musical a largo plazo, aunque no necesita de reglas para extrapolar un estilo musical. Estos sistemas formalizan la música como un proceso predictivo estrechamente vinculado a la expectativa y la percepción musical (Pearce y Wiggins, 2012).

Los distintos modelos de redes neuronales, tanto supervisadas como no, consiguen resultados prometedores, aunque actúan como una caja cerrada, ajustando pesos en el entrenamiento. La adopción de arquitecturas Transformer supuso un avance decisivo al permitir la modelización de dependencias temporales extensas. Propuestas como Music Transformer introdujeron mecanismos de atención relativa para mejorar la coherencia estructural (Huang y otros, 2018), mientras que trabajos posteriores destacaron el papel crítico de la representación musical —por ejemplo, codificaciones métricas y basadas en compás— para capturar regularidades rítmicas y formales (Huang y Yang, 2020).

Los modelos simbólicos jerárquicos incorporaron variables latentes y múltiples escalas temporales, alineándose explícitamente con nociones musicológicas de forma y desarrollo. MusicVAE es representativo de este enfoque, al permitir interpolación, variación controlada y análisis estructural de secuencias musicales (Roberts y otros, 2018). No obstante, estos modelos requieren procesos adicionales de síntesis para producir audio perceptivamente realista.

### *Modelos de audio generativo*

Los modelos de audio generativo producen música directamente en el dominio acústico, priorizando el realismo tímbrico y la continuidad sonora. Este enfoque adquirió relevancia con la introducción de modelos autorregresivos capaces de modelar audio crudo, siendo WaveNet un punto de inflexión al demostrar la viabilidad de aprender distribuciones complejas de señal musical (Van den Oord y otros, 2016).

Las limitaciones computacionales y la dificultad para capturar estructura musical a largo plazo motivaron el desarrollo de modelos basados en *neural audio codecs*, que combinan autoencoders vector-cuantizados con modelos secuenciales. *Jukebox* ejemplifica este paradigma al introducir una jerarquía de representaciones discretas que permite generar canciones completas con voz y acompañamiento (Dhariwal y otros, 2020).

Más recientemente, los modelos de difusión en espacio latente se han consolidado como el enfoque dominante para la generación de audio musical de mayor duración, ofreciendo mayor estabilidad de entrenamiento, mejor control temporal y elevada calidad perceptiva. Iniciativas abiertas como Stable Audio Open (Evans y otros, 2024) ilustran este avance. Desde una perspectiva MIR, sin embargo, estos modelos presentan una baja interpretabilidad musical, lo que dificulta relacionar las salidas generadas con conceptos estructurales explícitos.

## HERRAMIENTAS COMERCIALES DE GENERACIÓN MUSICAL

En paralelo al desarrollo académico, han surgido herramientas comerciales de generación musical basadas en IA que han alcanzado una amplia difusión pública. Plataformas como Suno y Udio generan canciones completas, incluyendo instrumentación, voz y letra, a partir de descripciones textuales en lenguaje natural.

Desde un punto de vista técnico, estos sistemas pueden caracterizarse como modelos fundacionales texto-a-música en audio, diseñados para maximizar la calidad perceptiva y la experiencia de usuario, más que la interpretabilidad musical o la reproducibilidad científica. Aunque carecen de documentación técnica verificable, su funcionamiento puede describirse a alto nivel por analogía con modelos académicos como Jukebox, MusicLM y MusicGen. En términos generales, integran un codificador de texto, un modelo generativo central que opera sobre representaciones de audio *tokenizado* y un decodificador neuronal hacia señal acústica continua.

Las diferencias entre plataformas se observan principalmente en el énfasis arquitectónico. La evidencia empírica sugiere que Suno prioriza enfoques autorregresivos optimizados para la alineación entre letra y voz, mientras que Udio muestra mayor estabilidad formal en piezas largas, compatible con arquitecturas híbridas o de refinamiento latente.

Desde la perspectiva del MIR, estas herramientas comerciales presentan limitaciones sustanciales. La ausencia de representaciones musicales explícitas, de anotaciones estructurales y de acceso a los estados internos del modelo impide su uso directo para tareas de análisis, similitud musical o descubrimiento de patrones. Asimismo, la opacidad de los datos de entrenamiento y de los protocolos de evaluación dificulta la comparación reproducible con modelos académicos (Sturm y otros, 2019).

## Metodología

### DISEÑO DE LA INVESTIGACIÓN

Estudio experimental cuyo objetivo principal consiste en evaluar hasta qué punto oyentes humanos son capaces de distinguir entre música histórica real y música generada mediante inteligencia artificial. El diseño combina procedimientos cuantitativos y cualitativos, lo que permite abordar tanto la medición objetiva de tasas de acierto como el análisis interpretativo de los criterios empleados por los oyentes en sus decisiones.

## SELECCIÓN DE ESTILOS MUSICALES

El experimento se centra en tres estilos musicales históricamente consolidados: Renacimiento, Barroco y Clasicismo. La elección de estos periodos responde a que son estilos ampliamente reconocibles desde el punto de vista musicológico y perceptivo, con rasgos formales relativamente estables y bien documentados; son repertorios frecuentemente utilizados en multitud de contextos y presentan diferencias claras en términos de textura, estructura formal, tratamiento melódico y organización armónica, lo que permite explorar posibles variaciones en la percepción de autenticidad según el lenguaje musical imitado.

## GENERACIÓN DE OBRAS MEDIANTE INTELIGENCIA ARTIFICIAL

La creación de las obras generadas por IA se hizo con Suno (versión v5 Pro beta) por su amplia difusión pública, facilidad de uso y capacidad para generar piezas completas a partir de descripciones textuales.

Para cada uno de los tres estilos seleccionados —Renacimiento, Barroco y Clasicismo— se generó una pieza musical específica, con una duración aproximada similar a la de las obras históricas de referencia. El proceso de generación se basó en la elaboración de *prompts* textuales diseñados para inducir características estilísticas coherentes con cada periodo. Estos *prompts* incluían referencias explícitas a elementos musicales específicos y a compositores y colecciones concretas, con el propósito de acotar el marco idiomático. Los *prompts* utilizados, elaborados en inglés, con asistencia de ChatGPT y adaptados para Suno v5 Pro beta, fueron los siguientes:

### Renacimiento:

Italian madrigal in the style of Monteverdi's Second Book (1590). Late Renaissance polyphony with refined imitative counterpoint, modal harmony, and careful voice leading. Subtle text expression and restrained word painting, mostly balanced textures with occasional homophonic clarity. Controlled dissonance, smooth melodic lines, poetic Italian text.<sup>1</sup>

### Barroco:

Baroque concerto grosso for string orchestra in the style of Vivaldi. Clear contrast between concertino (solo violins and continuo) and ripieno. Energetic ritornello form,

<sup>1</sup> «Madrigal italiano en el estilo del *Segundo Libro* de Monteverdi (1590). Polifonía tardorenacentista con contrapunto imitativo refinado, armonía modal y una conducción de voces cuidadosa. Expresión textual sutil y pintura de palabras contenida, con texturas mayormente equilibradas y ocasionales pasajes de claridad homofónica. Disonancia controlada, líneas melódicas fluidas y texto poético en italiano».

driving rhythms, tonal harmony, sequential passages, and virtuosic solo writing. Bright, lively character, crisp articulation, Baroque phrasing.<sup>2</sup>

#### Clasicismo:

First movement of a Classical symphony in the style of Haydn. Allegro tempo, clear sonata form, strong thematic contrasts, and motivic development. Predominantly homophonic texture with light contrapuntal exchanges, diatonic tonal harmony, rhythmic energy, and dynamic contrasts. Full Classical orchestra, elegant phrasing, clarity and balance, no Romantic intensity.<sup>3</sup>

En el estilo renacentista, los *prompts* se orientaron a la estética del madrigal italiano de finales del renacimiento, incorporando referencias a polifonía imitativa, armonía modal, conducción de voces y un tratamiento expresivo del texto mediante *word painting* contenido, con alternancia puntual de pasajes más homofónicos. Asimismo, se especificó la presencia de texto poético en italiano y el empleo de disonancias controladas, con el fin de inducir rasgos propios del lenguaje vocal del periodo.

Para el estilo barroco, los *prompts* describieron un *concerto grosso* para cuerda, enfatizando la oposición entre concertino (solistas y continuo) y *ripieno*, la organización formal en *ritornello*, la presencia de secuencias y la escritura de carácter virtuosístico, junto con indicaciones sobre energía rítmica, articulación y fraseo característicamente barrocos.

En el caso del clasicismo, se priorizaron descriptores vinculados a una sinfonía clásica (primer movimiento) en tempo allegro, con forma sonata, contrastes temáticos y desarrollo motivico, así como una textura principalmente homofónica con intercambios contrapuntísticos ligeros. También se incluyeron indicaciones relativas a la armonía diatónica, el equilibrio formal y la claridad de fraseo, además de la referencia a una orquesta clásica completa, evitando explícitamente rasgos expresivos asociados al romanticismo.

<sup>2</sup> «*Concerto grosso* barroco para orquesta de cuerdas en el estilo de Vivaldi. Contraste nítido entre el *concertino* (violines solistas y continuo) y el *ripieno*. Forma de *ritornello* enérgica, ritmos impulsores, armonía tonal, pasajes secuenciales y escritura solista virtuosística. Carácter brillante y vivaz, articulación precisa y fraseo barroco».

<sup>3</sup> «Primer movimiento de una sinfonía clásica en el estilo de Haydn. Tempo *allegro*, forma sonata clara, marcados contrastes temáticos y desarrollo motivico. Textura predominantemente homofónica con ligeros intercambios contrapuntísticos, armonía tonal diatónica, energía rítmica y contrastes dinámicos. Orquesta clásica completa, fraseo elegante, claridad y equilibrio, sin intensidad romántica».

## SELECCIÓN DE OBRAS

Por otro lado, se seleccionaron seis obras históricas reales representativas de los periodos analizados, dos por cada periodo. La selección se guio por los siguientes criterios: que tuvieran representatividad estilística del periodo representado; que tuvieran correspondencia de género y formación con los estímulos generados por IA (madrigales, *concerti grossi* y sinfonías clásicas); y que hubiera grabaciones de alta calidad y de acceso público. Además, se evitaron fragmentos extremadamente conocidos que pudieran ser identificados por reconocimiento previo más que por criterios sonoros.

En todos los casos, las grabaciones reales seleccionadas corresponden a interpretaciones profesionales, algunas de ellas vinculadas a prácticas interpretativas históricamente informadas, lo que contribuye a preservar rasgos tímbricos y de articulación acordes con el imaginario sonoro de cada periodo. Las obras seleccionadas para el estudio fueron las indicadas en la tabla 1.

Nombre y estilo	Compositor	Obra
Renacimiento 1	C. Monteverdi	<i>Madrigales (Libro II): «E dicea l'una l'una sospirando allora»</i>
Renacimiento 2	C. Gesualdo	<i>Sesto libro di madrigali: IV. «Resta di darmi noia»</i>
Renacimiento 3	IA (Suno)	-
Barroco 1	G. F. Händel	<i>Concerto grosso, Op. 6, No. 1 in G major, HWV 319</i>
Barroco 2	IA (Suno)	-
Barroco 3	A. Corelli	<i>Concerto grosso in D major: IV. Allegro</i>
Clasicismo 1	J. C. Bach	<i>Sinfonía en Sol mayor, Op. 6, No. 1: I. Allegro con brio</i>
Clasicismo 2	C. P. E. Bach	<i>Symphony in A major, Wq 182:4 (H 660)</i>
Clasicismo 3	IA (Suno)	-

Tabla 1. Obras seleccionadas para el estudio. Elaboración propia.

## PREPARACIÓN Y PRESENTACIÓN DE LOS FRAGMENTOS SELECCIONADOS

Con el fin de homogeneizar los cortes, se seleccionaron para la escucha los inicios de las obras —1 minuto aproximadamente—, de modo que todos los fragmentos partieran de un punto musical comparable. Por otro lado, para garantizar una captura uniforme y favorecer que la calidad y el nivel de volumen resultaran lo más similares posible, el audio se obtuvo mediante grabación de pantalla en macOS a partir de la reproducción en YouTube —obras históricas— o en Suno —piezas generadas por IA—, utilizando

la herramienta de captura del sistema ( $\mathbb{H} + \hat{u} + 5$ ). Posteriormente, los fragmentos se presentaron sin información identificativa —ni título, compositor o intérpretes—, se conservó únicamente el audio capturado, acompañado de un fondo negro y del nombre asignado a cada fragmento —Renacimiento 1-3, Barroco 1-3, Clasicismo 1-3—.

#### DISEÑO DEL CUESTIONARIO PERCEPTIVO

El cuestionario se diseñó como una prueba individual de escucha mediante Microsoft Forms. Al inicio, se incluyó un consentimiento informado y se explicitó que la participación era voluntaria y anónima, que no se recogían datos identificativos y que la información se utilizaría exclusivamente con fines de investigación.

Después, se recogieron datos personales y de hábitos mediante cinco preguntas: sexo, edad, nivel de estudios, así como frecuencia de escucha de música clásica y uso habitual de herramientas de IA.

En tercer lugar, se administró la prueba perceptiva de escucha de los 9 fragmentos. Cada uno se presentó de forma individual y, tras su escucha, los participantes respondieron dos preguntas de percepción: atribución del origen del estímulo y grado de seguridad asociado a la respuesta —escala Likert de 1 a 5—. Así, este bloque sumó 18 preguntas. Finalmente, se incluyó una pregunta abierta final, opcional, para recoger comentarios cualitativos sobre los criterios empleados en la toma de decisión.

#### PARTICIPANTES Y PROCEDIMIENTO

El estudio contó con la participación de 206 personas, la encuesta se difundió mediante canales privados y redes personales de los investigadores. El cuestionario permaneció abierto durante una semana, y el tiempo medio de realización del test fue de quince minutos.

### Resultados

De 206 participantes, 121 fueron mujeres (58,7 %) y 85 hombres (41,3 %), con una edad media de 45,7 años (rango: 18-79). La mayoría residentes en España (94,2 %), aunque también se contó con participantes de Argentina, Colombia, El Salvador, Cuba, Países Bajos, Francia o Montenegro. Además, la muestra presentó un nivel educativo elevado, destacando el Máster universitario (41,3 %), el grado/licenciatura (29,1 %) y el doctorado (12,1 %).

En relación con las variables de interés musical y tecnológico, se observó una familiaridad heterogénea con la música clásica: un 57,3 % de los participantes reportó




Fig. 1. Distribución del número de aciertos. Fuente: elaboración propia.

escucharla con frecuencia o muy habitualmente, frente a un 12,6 % que indicó no escucharla nunca o casi nunca. Respecto al uso de herramientas de IA, la distribución fue amplia, destacando que casi la mitad de la muestra (49,1 %) las utiliza con una frecuencia diaria o semanal; y un 18 % indicó no utilizarlas en absoluto.

En general, los datos muestran que fue muy difícil distinguir entre composiciones humanas históricas y piezas generadas por IA. La precisión en la identificación de la autoría fue del 46,1 %, lo que equivale a 4,15 aciertos de un total de 9. Ningún participante identificó correctamente todos los fragmentos, y un 3,9% de la muestra no obtuvo ningún acierto en los 9 fragmentos. Tal como se aprecia en la Figura 1, la distribución de aciertos se concentró en valores intermedios, con un máximo de 7 aciertos y ausencia de participantes con 8 o 9 aciertos. Asimismo, resulta relevante el uso de la opción de incertidumbre («No estoy seguro/a»), seleccionada en el 12,6 % de las respuestas. Si excluimos esta respuesta y consideramos únicamente las decisiones entre «humana» e «IA», la tasa de acierto fue del 52,6 %, un valor solo ligeramente por encima de lo esperable por azar (50 %). Por lo tanto, estos resultados sugieren que, en las condiciones del estudio y con la muestra analizada, los oyentes no disponen de criterios claros y consistentes para diferenciar el origen de la música; a su vez, apuntan a que la IA puede generar fragmentos verosímiles y estilísticamente coherentes en estilos renacentistas, barrocos y clásicos.

Al desglosar los resultados por periodo histórico y tipo de autoría, se observaron diferencias: el bloque renacentista presentó la mayor tasa media de aciertos (50,3 %), seguido del barroco (46,4 %), mientras que el bloque clásico resultó el más exigente para los participantes, con la tasa de acierto más baja (41,4 %). En este sentido, la

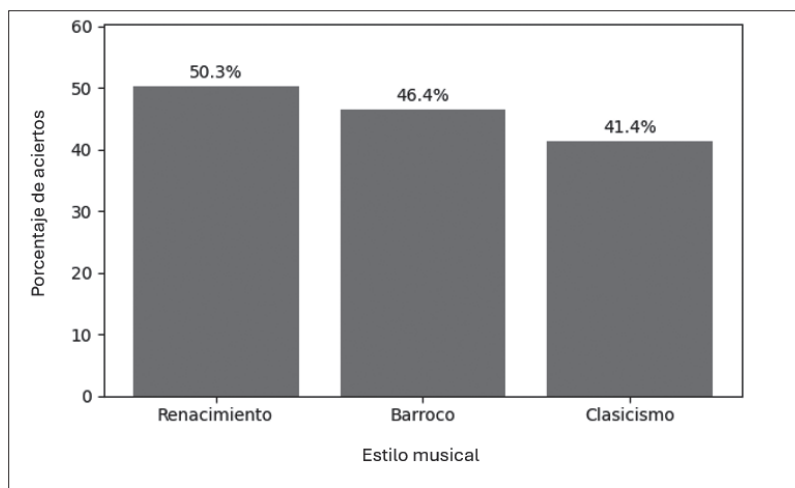


Fig. 2. Porcentaje de aciertos por estilo. Fuente: elaboración propia.

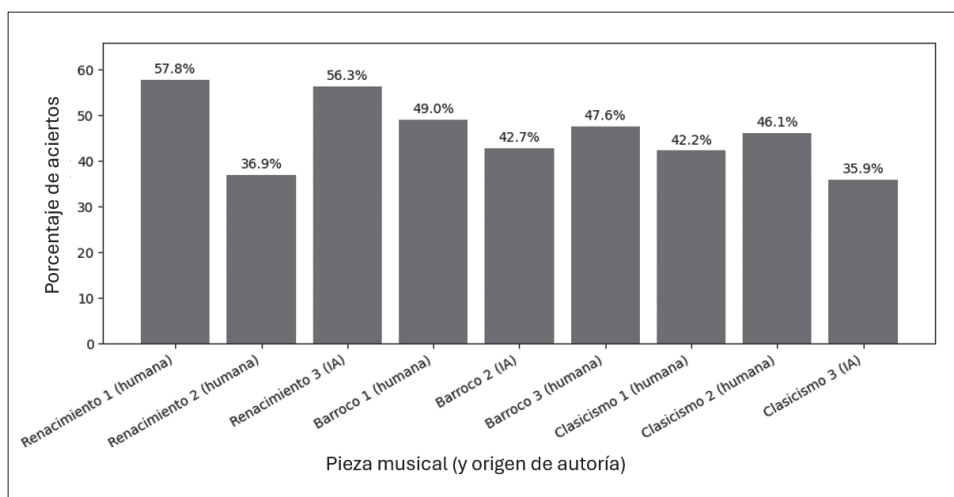


Fig. 3. Porcentaje de aciertos en la identificación de la autoría. Fuente: elaboración propia.

pieza *Clasicismo 3* —generada por IA— obtuvo la tasa de acierto más baja (35,9 %), compatible con una imitación estilística especialmente verosímil en la pieza de estilo clásico generada por la IA.

Por otra parte, *Renacimiento 1* (madrigal de Claudio Monteverdi) y *Renacimiento 3* —generada por IA— fueron las piezas en las que la autoría se identificó correctamente con mayor precisión, con tasas de acierto del 57,8 % y 56,3 %, respectivamente. Al respecto, las observaciones cualitativas apuntan a que rasgos interpretativos como el timbre vocal, las respiraciones —o la ausencia de ellas— y la forma de acentuar el

texto al cantar —énfasis en determinadas sílabas y palabras— podrían haber influido en los juicios de atribución de autoría.

Asimismo, no se encontraron diferencias sustanciales en la tendencia a confundir obras reales y artificiales: las obras humanas fueron clasificadas erróneamente como IA en el 40,1 % de los casos, y las obras generadas por IA fueron clasificadas erróneamente como humanas en el 43,9 % de los casos.

Se analizó también el grado de confianza declarado por los participantes en sus respuestas, con el fin de valorar hasta qué punto la percepción de seguridad se asociaba con un mejor desempeño. La confianza media declarada por los participantes se situó en un nivel intermedio —media = 3,01 en escala de 1 a 5— y sentirse seguro no garantizó acertar y sentirse inseguro no implicó necesariamente fallar.

Finalmente, los análisis exploratorios sugieren que algunas características de los participantes se relacionan con la capacidad de discriminación. En primer lugar, el hábito de escucha de música clásica se asoció con un mejor desempeño: quienes escuchan música clásica con mayor frecuencia tendieron a acertar más que quienes la escuchan de forma ocasional. En segundo lugar, la edad mostró una relación negativa con el rendimiento: a medida que aumenta la edad, la tasa de aciertos tiende a disminuir. Por último, no se observaron diferencias relevantes en el desempeño en función del uso habitual de herramientas de IA.

Variable	Categoría	N.º de personas (%)	Precisión Media (M)	Desviación estándar (DE)
Global	–	206 (100 %)	0,46	0,18
Sexo	Mujer	121 (58,7 %)	0,47	0,17
	Hombre	85 (41,3 %)	0,45	0,19
Nivel de estudios	Grado/Licenciatura	60 (29,1 %)	0,43	0,18
	Máster	85 (41,3 %)	0,50	0,17
	Doctorado	25 (12,1 %)	0,44	0,20
	Otros (Bach/FP)	36 (17,5 %)	0,42	0,18
Escucha música clásica	Muy habitualmente	65 (31,6 %)	0,50	0,16
	Con frecuencia	53 (25,7 %)	0,51	0,17
	Ocasionalmente	62 (30,1 %)	0,40	0,18
	Nunca o casi nunca	26 (12,6 %)	0,42	0,20
Uso de IA	A diario	50 (24,3 %)	0,46	0,17

Variable	Categoría	N.º de personas (%)	Precisión Media (M)	Desviación estándar (DE)
	Semanalmente	51 (24,8 %)	0,47	0,19
	Varias veces al mes	45 (21,8 %)	0,45	0,18
	Alguna vez al año	23 (11,2 %)	0,48	0,18
	Ninguno	37 (18 %)	0,46	0,18

Tabla 2. Perfil de la muestra y relación con el acierto. Nota: M= Media de precisión (proporción 0-1); DE = Desviación estándar.

## Discusión

Los resultados del estudio confirman de manera consistente la dificultad de los oyentes para discriminar entre música histórica real y música generada por inteligencia artificial cuando esta imita estilos consolidados del Renacimiento, el Barroco y el Clasicismo. La precisión media observada, próxima al azar, sugiere que, en condiciones de escucha descontextualizada y sin información previa, la percepción de autenticidad sonora no depende de manera robusta del origen humano o algorítmico del material musical.

La variabilidad observada entre estilos sugiere, además, que la eficacia de la imitación algorítmica no es homogénea. El menor acierto en el bloque clásico apunta a que los modelos actuales pueden capturar con especial eficacia los rasgos superficiales y formales asociados al clasicismo —claridad temática, simetría formal, homofonía predominante...—, lo que podría favorecer una atribución errónea de autoría humana. Por el contrario, en el repertorio renacentista, ciertos elementos interpretativos —especialmente relacionados con la voz humana, la respiración, el empleo del texto...— parecen haber actuado como pistas perceptivas más informativas, tal como reflejan los comentarios cualitativos de los participantes.

Los análisis exploratorios muestran que factores como el hábito de escucha de música clásica sí influyen parcialmente en la capacidad de discriminación, mientras que la familiaridad con herramientas de IA no aporta ventajas significativas. Este resultado cuestiona la suposición de que la alfabetización tecnológica actúa como un filtro crítico y sugiere que el conocimiento estilístico y la experiencia auditiva acumulada siguen siendo más relevantes que la familiaridad con la tecnología en sí.

Desde la perspectiva del MIR, la generación se ha empleado históricamente como herramienta metodológica, orientada a modelar regularidades y expectativas. El uso de sistemas comerciales como Suno desplaza el foco hacia el realismo perceptivo,

incluso a costa de la interpretabilidad y la trazabilidad musical. La incapacidad de los oyentes para distinguir el origen de las obras refuerza la idea de que la evaluación perceptiva, por sí sola, resulta insuficiente para establecer criterios de autenticidad o autoría en contextos patrimoniales.

## Conclusiones

Este estudio ha explorado empíricamente los límites de la imitación estilística en la generación musical mediante inteligencia artificial y sus implicaciones para la noción de autenticidad en el patrimonio sonoro. A través de un test perceptivo con más de doscientos participantes, se ha demostrado que la música generada por IA puede resultar perceptivamente indistinguible de composiciones históricas reales cuando imita estilos musicales consolidados como el Renacimiento, el Barroco y el Clasicismo.

Los resultados ponen de manifiesto que la autenticidad sonora, entendida como experiencia perceptiva del oyente, no coincide necesariamente con la autenticidad patrimonial basada en criterios históricos, documentales y autorales. Esta divergencia obliga a reconsiderar los marcos conceptuales desde los que se evalúa y se comunica el patrimonio musical en entornos mediados por tecnología. En particular, la posibilidad de generar artefactos sonoros verosímiles sin anclaje histórico cuestiona la suficiencia de la escucha como criterio de autenticidad y subraya la importancia de la contextualización, la transparencia y la trazabilidad en el uso de música generada por IA.

Desde el ámbito del Music Information Retrieval, el trabajo evidencia una bifurcación creciente entre los objetivos tradicionales de la investigación académica —interpretabilidad, reproducibilidad y análisis estructural— y las dinámicas de las herramientas comerciales de generación musical, orientadas prioritariamente al realismo perceptivo. Esta división no solo afecta a la evaluación científica de los modelos, sino también a su impacto cultural y patrimonial, especialmente cuando estas tecnologías se incorporan a museos, archivos, exposiciones o experiencias educativas.

Entre las limitaciones del estudio se encuentran el uso de un único sistema comercial de generación, la ausencia de control exhaustivo sobre los datos de entrenamiento y la imposibilidad de acceder a representaciones musicales internas del modelo.

Otro aspecto a considerar es el peso diferencial que pueden haber tenido en las respuestas factores como la composición, la interpretación y la producción sonora de los estímulos. Mientras que las obras generadas mediante Suno se presentan como productos sonoros cerrados, las obras históricas reales son el resultado de procesos complejos y acumulativos que involucran, a lo largo de siglos, decisiones compositivas,

interpretativas y técnicas. El hecho de que, pese a esta asimetría en los procesos de producción, ambos tipos de estímulos resulten perceptivamente difíciles de distinguir pone de relieve la eficacia de los sistemas generativos actuales y abre un debate más amplio sobre la redefinición de la autenticidad musical y el impacto de la inteligencia artificial en los ecosistemas culturales y patrimoniales, un debate que excede los objetivos del presente trabajo.

Como líneas futuras de investigación, se plantea la necesidad de profundizar en el análisis de los criterios perceptivos empleados por los oyentes, de comparar distintos sistemas generativos y de explorar el papel del contexto informativo en la percepción de autenticidad. Asimismo, resulta especialmente pertinente investigar cómo integrar de manera crítica y responsable la generación musical por IA en entornos patrimoniales, evitando tanto la sustitución acrítica de fuentes históricas como el rechazo simplista de estas tecnologías. La generación musical por inteligencia artificial no solo representa un avance técnico, sino un desafío conceptual para nuestra comprensión del patrimonio musical. Reconocer sus capacidades, límites e implicaciones resulta indispensable para articular una relación equilibrada entre innovación tecnológica, rigor musicológico y responsabilidad cultural en la era de los algoritmos.

## Bibliografía

- AGOSTINELLI, A., T. I. DENK, Z. BORSOS, J. ENGEL, M. VERZETTI, A. CAILLON, Q. HUANG, A. JANSEN, A. ROBERTS, M. TAGLIASACCHI, M. SHARIFI, N. ZEGHIDOUR y C. FRANK (2023). *MusicLM: Generating music from text* [Preprint]. arXiv. Disponible en línea en <<https://doi.org/10.48550/arXiv.2301.11325>>.
- BRIOT, J.-P., G. HADJERES y F. PACHET (2020). *Deep learning techniques for music generation*. Springer.
- CASINI, L., L. CROS VILA, D. DALMAZZO, A.-K. KAILA y B. L. T. STURM (2025). *Data-driven analysis of text-conditioned AI-generated music: A case study with Suno and Udio* [Preprint]. arXiv. Disponible en línea en <<https://doi.org/10.48550/arXiv.2509.11824>>.
- CONKLIN, D. e I. H. WITTEN (1995). «Multiple viewpoint systems for music prediction», *Journal of New Music Research*, 24(1), 51-73. Disponible en línea en <<https://doi.org/10.1080/09298219508570672>>.
- COPET, J., F. KREUK, I. GAT, T. REMEZ, D. KANT, G. SYNNAEVE, Y. ADI y A. DÉFOSSEZ (2023). *Simple and controllable music generation* [Preprint]. arXiv. Disponible en línea en <<https://doi.org/10.48550/arXiv.2306.05284>>.
- DHARIWAL, P., H. JUN, C. PAYNE, J. W. KIM, A. RADFORD e I. SUTSKEVER (2020). *Jukebox: A generative model for music* [Preprint]. arXiv. Disponible en línea en <<https://doi.org/10.48550/arXiv.2005.00341>>.

- EVANS, Z., J. D. PARKER, C. J. CARR, Z. ZUKOWSKI, J. TAYLOR y J. PONS (2024). *Stable Audio Open* [Preprint]. arXiv. Disponible en línea en <<https://doi.org/10.48550/arXiv.2407.14358>>.
- GRÖTSCHLA, F., A. SOLAK, L. A. LANZENDÖRFER y R. WATTENHOFER (2025). «Benchmarking music generation models and metrics via human preference studies», *2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1-5). IEEE. Disponible en línea en <<https://doi.org/10.1109/ICASSP49660.2025.10887745>>.
- HILLER, L. A. y L. M. ISAACSON (1958). «Musical composition with a High-Speed digital computer». *Journal of the Audio Engineering Society*, 6(3), 154-160.
- HUANG, Y. S. e Y. H. YANG (octubre de 2020). «Pop music transformer: Beat-based modeling and generation of expressive pop piano compositions», *Proceedings of the 28th ACM international conference on multimedia*, pp. 1180-1188.
- INTERNATIONAL COUNCIL ON MONUMENTS AND SITES (1994). *The Nara document on authenticity*. Disponible en línea en <<https://whc.unesco.org/document/116018>>.
- MÜLLER, M. (2021). *Fundamentals of music processing: Using Python and Jupyter notebooks* (2.ª ed.). Springer Cham. Disponible en línea en <<https://doi.org/10.1007/978-3-030-69808-9>>.
- PADILLA, V. y D. CONKLIN (2018). «Generation of Two-Voice Imitative Counterpoint from Statistical Models», *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(3), 22-33. Disponible en línea en <<https://doi.org/10.9781/ijimai.2018.10.002>>.
- PEARCE, M. (2005). *The construction and evaluation of statistical models of melodic structure in music perception and composition*. City University, Londres.
- PEARCE, M. y G. WIGGINS (2012). «Auditory expectation», *Topics in Cognitive Science*, 4(4), 625-652.
- PHON-AMNUAISUK, S. (2002). «Control language for harmonisation process», en C. Anagnostopoulou, M. Ferrand y A. Smaill (eds.), *Music and artificial intelligence: ICMAI 2002* (Lecture Notes in Computer Science, Vol. 2445, pp. 155-167). Springer. Disponible en línea en <[https://doi.org/10.1007/3-540-45722-4\\_15](https://doi.org/10.1007/3-540-45722-4_15)>.
- REUTERS (29 de enero de 2026). «Deezer licenses AI music detection tool to French royalty agency Sacem, plans wider rollout». Disponible en línea en <<https://www.reuters.com/business/media-telecom/deezer-licenses-ai-detection-tool-french-royalty-agency-sacem-plans-wider-roll-2026-01-29/>>.
- ROBERTS, A., J. ENGEL, C. RAFFEL, C. HAWTHORNE y D. ECK (julio de 2018). «A hierarchical latent vector model for learning long-term structure in music», en *International conference on machine learning*, pp. 4364-4373. PMLR.
- STURM, B. L. T., M. IGLESIAS, O. BEN-TAL, M. MIRON y E. GÓMEZ (2019). «Artificial Intelligence and Music: Open Questions of Copyright Law and Engineering Praxis», *Arts*, 8(3), 115. Disponible en línea en <<https://doi.org/10.3390/arts8030115>>.
- STURM, B. L. T., O. BEN-TAL, Ú. MONAGHAN, N. COLLINS, D. HERREMANS, E. CHEW y

- F. PACHET (2019). «Machine learning research that matters for music creation: A case study», *Journal of New Music Research*, 48(1), 36-55. Disponible en línea en <<https://doi.org/10.1080/09298215.2018.1515233>>.
- VAN DEN OORD, A., S. DIELEMAN, H. ZEN, K. SIMONYAN, O. VINYALS, A. GRAVES, N. KALCHBRENNER, A. SENIOR y K. KAVUKCUOGLU (2016). *WaveNet: A generative model for raw audio* [Preprint]. arXiv. Disponible en línea en <<https://doi.org/10.48550/arXiv.1609.03499>>.
- WU, Y., J. GARDNER, E. MANILOW, I. SIMON, C. HAWTHORNE y J. ENGEL (2022). «The Chamber Ensemble Generator: Limitless High-Quality MIR Data via Generative Modeling», *ArXiv, abs/2209.14458*.



Este libro expone una reflexión crítica y multidisciplinar sobre el impacto de las tecnologías emergentes, especialmente la inteligencia artificial en la cultura contemporánea. A través de una serie de capítulos escritos por especialistas y doctores en filosofía, derecho, museología, artes visuales, escénicas o digitales se analiza cómo la IA está transformando los procesos de creación, conservación y mediación del patrimonio cultural.

Aborda cuestiones fundamentales como la autoría en la era de la IA, la reconfiguración de la experiencia estética, la preservación del patrimonio sonoro y escénico, la fotografía patrimonial, la educación museística, la inclusión social, las exposiciones inmersivas, la arqueología digital y los desafíos éticos que todo ello supone. Asimismo, se presentan estudios de caso y proyectos innovadores que ya están implementando tecnologías inteligentes. La obra ofrece una mirada crítica y propositiva sobre los retos y oportunidades que plantea la IA en el ámbito cultural, promoviendo un diálogo entre disciplinas y agentes del sector para imaginar juntos los museos y espacios culturales del futuro.