



Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), enero-febrero 2025,
Volumen 9, Número 1.

https://doi.org/10.37811/cl_rcm.v9i1

**ALGORITMOS PREDICTIVOS Y
LA TECNOLOGÍA BLOCKCHAIN EN LA
DISTRIBUCIÓN MUSICAL: ECOSISTEMA
MÁS JUSTO Y EFICIENTE**

**PREDICTIVE ALGORITHMS AND BLOCKCHAIN
TECHNOLOGY IN MUSIC DISTRIBUTION: A FAIRER
AND MORE EFFICIENT ECOSYSTEM**

Raúl Jaime Maestre
ESIC Business & Marketing School, España

DOI: https://doi.org/10.37811/cl_rcm.v9i1.16765

Algoritmos Predictivos y la Tecnología Blockchain en la Distribución Musical: Ecosistema Más Justo y Eficiente

Raúl Jaime Maestre¹

raul.jaime@esic.edu

<https://orcid.org/0000-0003-3669-8992>

ESIC Business & Marketing School

España

RESUMEN

El sector de la distribución musical ha evolucionado rápidamente en las últimas décadas, impulsado por avances tecnológicos. Este artículo analiza en profundidad el impacto de los algoritmos predictivos y la tecnología blockchain en la distribución musical, explorando cómo estas herramientas pueden abordar problemas críticos como la centralización, la falta de transparencia y la distribución desigual de los ingresos. Además, se presenta una evaluación de los desafíos técnicos y regulatorios que surgen al integrar estas tecnologías en el sector musical, junto con un enfoque prospectivo sobre su adopción y las oportunidades que ofrecen para artistas, productores y consumidores.

Palabras claves: algoritmos, predictivo, blockchain, distribución, musical

¹ Autor principal

Correspondencia: raul.jaime@esic.edu

Predictive Algorithms and Blockchain Technology in Music Distribution: A Fairer and More Efficient Ecosystem

ABSTRACT

The music distribution sector has evolved rapidly in recent decades, driven by technological advancements. This article delves deeply into the impact of predictive algorithms and blockchain technology on music distribution, exploring how these tools can address critical issues such as centralization, lack of transparency, and the unequal distribution of revenue. Additionally, it presents an assessment of the technical and regulatory challenges that arise from integrating these technologies into the music sector, along with a forward-looking perspective on their adoption and the opportunities they offer for artists, producers, and consumers.

Keywords: algorithms, predictive, blockchain, distribution, musical

Artículo recibido 05 enero 2025

Aceptado para publicación: 15 febrero 2025



INTRODUCCIÓN

La industria musical ha sufrido una transformación radical con la llegada de la digitalización. Plataformas como Spotify, Apple Music y YouTube Music han democratizado el acceso global a la música, pero esta democratización ha venido acompañada de nuevos desafíos. Entre ellos, la falta de transparencia en la distribución de royalties, la centralización del poder en manos de grandes plataformas y la dificultad de los artistas independientes para acceder a sistemas de distribución justos. En este contexto, dos tecnologías emergen como herramientas claves: los algoritmos predictivos y la tecnología blockchain. Los algoritmos predictivos se basan en técnicas de aprendizaje automático, son esenciales para personalizar la experiencia del usuario y prever patrones de consumo (Tsotsou, 2020). La tecnología blockchain, por su parte, promete descentralización, transparencia y trazabilidad, características esenciales para un sector que busca equilibrar el equilibrio del poder entre artistas, productores y distribuidores (Maestre, 2023). Este artículo se explora cómo estas tecnologías están revolucionando el sector y analiza su impacto potencial en los próximos años.

Los objetivos de este estudio son:

- Explicar los algoritmos predictivos, la tecnología *blockchain* y su uso en el sector de la distribución musical.
- Presentar ejemplos reales del uso de los algoritmos predictivos y tecnología *blockchain* en 7 empresas del sector de la distribución musical.

METODOLOGÍA

La metodología usada es la de compilación de información mediante artículos académicos y científicos de los últimos 3 años para el primer apartado y, el estudio de casos y aplicabilidad para el segundo objetivo. La realización del marco teórico mediante la literatura actual -de los últimos 5 años- se hace necesaria para aportar conocimiento sobre la herramienta del *blockchain*, los *algoritmos predictivos* y su aplicabilidad en la industria de la distribución musical. Los casos reales se han trabajado desde la información aportada por las mismas empresas vía 2 canales: información en sus páginas web y contacto directo con las empresas, vía entrevistas.

Algoritmos predictivos y la tecnología blockchain en la distribución musical

Principios básicos de los algoritmos predictivos

Los algoritmos predictivos utilizan técnicas de inteligencia artificial (IA), como el aprendizaje automático (machine learning) y el aprendizaje profundo (deep learning), para analizar grandes volúmenes de datos y detectar patrones ocultos que a simple vista no se ven (Spotify Engineering, 2020). En la industria musical, estas herramientas son esenciales para:

- Personalizar las recomendaciones de canciones.
- Optimizar campañas de marketing.
- Anticipar el éxito potencial de un lanzamiento.

Los siguientes modelos se pueden considerar los más significativos

1. Filtros colaborativos: Utilizan datos de usuarios similares para predecir preferencias musicales.
2. Modelos de aprendizaje profundo (Deep learning): Redes neuronales analizan múltiples características de una canción (tempo, tono, ritmo, etc.) para identificar patrones asociados con el gusto del usuario.
3. Sistemas híbridos: Combinan datos de contenido (características de la música) y comportamiento del usuario para mejorar la precisión de las recomendaciones.

Filtros colaborativos para predecir preferencias musicales

En la distribución musical, los filtros colaborativos han conseguido ser en una de las herramientas más efectivas para personalizar la experiencia del usuario. Estos sistemas predictivos son utilizados por plataformas de streaming musical como Spotify, Apple Music y YouTube Music para recomendar canciones, artistas o listas de reproducción basándose en patrones de comportamiento de usuarios previos.

a) Introducción a los filtros colaborativos

Los filtros colaborativos son una técnica esencial dentro de los sistemas de recomendación que utilizan las plataformas musicales, las cuales utilizan patrones de comportamiento de los usuarios para predecir y recomendar contenido. A diferencia de los enfoques basados en contenido, los filtros colaborativos no analizan las características de las canciones (como el tempo, el género o la instrumentación), sino las interacciones de los usuarios con la música y entre ellos (Schafer et al., 2007).

En la distribución musical, estas interacciones pueden ser:

- Canciones reproducidas.
- Calificaciones o "likes".
- Canciones añadidas a listas de reproducción.
- Seguimiento de artistas o álbumes.

El objetivo principal es crear recomendaciones personalizadas que mejoren la experiencia del usuario y fomenten el descubrimiento de música, incentivando que el consumidor siga consumiendo lo que ofrece la plataforma musical.

Tipos de filtros colaborativos que se puede utilizar para predecir preferencias musicales

b) Filtros colaborativos basados en usuarios

Este enfoque se centra en encontrar similitudes entre usuarios. La idea básica es que los usuarios que han tenido comportamientos similares en el pasado probablemente tendrán gustos similares en el futuro.

Un ejemplo en música podría ser si dos usuarios suelen escuchar géneros similares o artistas comunes, las canciones que un usuario aún no ha explorado, pero que son populares entre los otros usuarios similares, se recomendarán (Spotify Engineering, 2017).

El modelo matemático que se puede aplicar en este caso es:

Sea u_i y u_j dos usuarios. La similitud entre ellos se mide comúnmente utilizando métricas como:

- Coeficiente de correlación de Pearson: Evalúa la relación entre sus patrones de interacción.
- Cosenos de similitud: Basado en los vectores de interacción (canciones reproducidas).

Filtros colaborativos basados en ítems

En lugar de buscar similitudes entre usuarios, este enfoque analiza las relaciones entre ítems (canciones, artistas o álbumes). Si dos canciones suelen ser reproducidas juntas por muchos usuarios, el sistema asume que son similares y las recomendará juntas (OpenAI, 2020).

Un ejemplo en música podría ser si un usuario escucha "*Bohemian Rhapsody*" de "the Queen", es probable que también reciba una recomendación para escuchar "*Don't Stop Me Now*", dado que ambas canciones son frecuentemente reproducidas juntas.

La ventaja que tenemos respecto al anterior filtro colaborativo es que este enfoque es más escalable en grandes sistemas, ya que las relaciones entre canciones cambian menos frecuentemente que las relaciones entre usuarios.

Filtros colaborativos basados en métodos híbridos

Los sistemas más avanzados combinan tanto los enfoques basados en usuarios como los basados en ítems. Además, integran información adicional como características del contenido musical (tempo, tonalidad, etc.), contexto del usuario (ubicación, momento del día) y tendencias globales (Park & Lee, 2017).

Un ejemplo en música podría ser si Spotify utiliza filtros colaborativos híbridos, combinando análisis de contenido, datos de comportamiento y métricas colaborativas para generar recomendaciones más precisas (Spotify Engineering, 2017).

Aplicaciones de los filtros colaborativos dentro de la distribución musical

Podemos encontrar los siguientes casos de aplicación de los filtros colaborativos dentro de la distribución musical (Spotify Engineering, 2020):

1. **Recomendar canciones y artistas:** Los filtros colaborativos permiten a las plataformas personalizar recomendaciones según el historial de interacción del usuario, mejorando la experiencia musical.
2. **Crear de listas de reproducción personalizadas:** Herramientas como “*Discover Weekly*” de Spotify, “*Mixes*” de YouTube Music o “*Replay 2024*” de Apple Music usan filtros colaborativos para generar listas de reproducción dinámicas adaptadas a los gustos individuales de cada usuario.
3. **Descubrir de nichos musicales:** Los filtros colaborativos son eficaces para exponer música de nicho a usuarios que tienen preferencias específicas, ayudando a artistas emergentes a alcanzar audiencias significativas que de otra manera no podrían haber llegado.
4. **Predecir tendencias y éxitos:** Analizando los patrones de consumo, los filtros colaborativos pueden identificar canciones o artistas con potencial para convertirse en éxitos antes de que alcancen una audiencia significativa.

Ventajas, limitaciones y avances recientes de los filtros colaborativos dentro de la distribución musical

La primera ventaja que nos podemos encontrar dentro de la aplicación de los filtros colaborativos sería la personalización, ya que los filtros colaborativos ofrecen recomendaciones basadas en interacciones reales, lo que aumenta la relevancia para los usuarios. Una segunda ventaja sería fomentar que el usuario descubra música nueva basada en los patrones de otros grupos con los mismos o similares gustos. La tercera ventaja sería la independencia del contenido, ya que no necesita analizar características de las canciones, lo que los hace aplicables a una variedad de formatos y géneros musicales (Koren et al, 2009).

Por otra parte, nos encontramos las limitaciones de los filtros colaborativos dentro de la distribución musical, y el primero que nos podemos encontrar sería el problema de arranque en frío, ya que los usuarios nuevos no van a tener historial musical y, por tanto, va a ser difícil generar recomendaciones. Además, que los ítems nuevos, es decir, canciones o artistas recién añadidos en las plataformas musicales no pueden ser recomendados hasta que tengan suficientes datos de interacción dentro de la misma. Una segunda limitación es el sesgo de popularidad, ya que los filtros colaborativos suelen posicionar mejor a canciones y artistas populares, entorpeciendo que llegue a los consumidores la música de nicho o los artistas independientes. Por último, nos podemos encontrar una última limitación que sería la sobre-recomendación, ya que la repetición de las recomendaciones similares puede generar al consumidor monotonía y puede limitar la variedad de la música que pueda llegar a escuchar.

Los avances recientes que se están trabajando para superar estas limitaciones dentro de los filtros colaborativos dentro de la distribución musical serían (Koren et al, 2009):

- Incorporación de técnicas de deep learning: Modelos de redes neuronales, como autoencoders y redes neuronales recurrentes (RNNs), están siendo utilizados para superar el problema del arranque en frío y mejorar la precisión de las recomendaciones. Estos modelos pueden integrar datos colaborativos con características del contenido musical, como el análisis de audio.
- Sistemas de aprendizaje federado: Para abordar los problemas de privacidad, se están desarrollando sistemas donde los datos del usuario se procesan localmente en sus dispositivos, y solo los resultados agregados se comparten con la plataforma.

- Diversificación mediante regularización: Técnicas de optimización han sido introducidas para reducir el sesgo hacia ítems populares, fomentando una mayor exposición a música menos conocida.

b) Modelos de aprendizaje profundos (deep learning) para predecir preferencias musicales

En los últimos años, el aprendizaje profundo (deep Learning) ha revolucionado la manera en que se desarrollan los sistemas predictivos, especialmente el sector de la distribución musical (Van de Oord et al., 2013). Este modelo permite analizar tanto datos colaborativos como características del contenido musical de una forma más eficiente y precisa que otros métodos. En este apartado se explora cómo los modelos de aprendizaje profundo (deep learning) se utilizan en la distribución musical, con un enfoque en arquitecturas como redes neuronales convolucionales (CNNs), redes recurrentes (RNNs), autoencoders y transformadores.

Introducción a los modelos de aprendizaje profundo (deep learning)

La distribución musical digital se basa en la personalización de las experiencias de los usuarios, principalmente a través de sistemas de recomendación en plataformas como Spotify, Apple Music y YouTube Music. Mientras que los métodos tradicionales, como los filtros colaborativos, se centran en patrones de comportamiento, los modelos de aprendizaje profundo, conocidos como “deep learning”, tienen la capacidad de analizar tanto los datos colaborativos como el contenido musical, incluyendo características de sonoridad, letras, y metadatos. Esto los convierte en herramientas más robustas y versátiles para generar predicciones.

El aprendizaje profundo (deep learning) se basa en redes neuronales artificiales de múltiples capas que pueden modelar relaciones complejas en los datos. En el caso de la música, estas relaciones incluyen las interacciones entre usuarios y canciones, así como patrones ocultos en los propios datos musicales (Van de Oord et al., 2013).

Tipos de modelos de aprendizaje profundo (deep learning) aplicados en la distribución musical

Redes neuronales convolucionales (CNNs)

Las redes neuronales convolucionales son útiles para analizar datos estructurados en forma de imágenes o señales, como los espectrogramas de audio.



En el caso de la música, las redes neuronales convolucionales (CNNs) pueden procesar representaciones visuales de las señales de audio para extraer características como el timbre, la tonalidad y el ritmo dentro de una canción (Hershey et al., 2017).

Las principales aplicaciones de las redes neuronales convolucionales en música

1. **Análisis de audio:** Las CNNs pueden identificar similitudes entre canciones basándose en su contenido sonoro, ayudando a recomendar música con características similares.
2. **Clasificación de género o estado de ánimo:** Utilizando espectrogramas, las redes neuronales convolucionales (CNNs) pueden categorizar canciones según géneros o emociones.
3. **Detección de patrones específicos:** Podemos poner el ejemplo de poder identificar ritmos característicos de un género como el reguetón, música clásica o el jazz.

Un ejemplo de lo que se han comentado sería que Spotify utiliza las redes neuronales convolucionales (CNNs) para analizar espectrogramas y generar recomendaciones basadas en características de sonoridad, combinándolas con datos colaborativos.

Redes neuronales recurrentes (RNNs)

Las redes neuronales recurrentes (RNNs) se pueden utilizar para trabajar con datos secuenciales, como el comportamiento del usuario (listas de reproducción, historial de reproducción) o las letras de las canciones. Estas redes pueden identificar dependencias temporales y patrones en datos ordenados cronológicamente (He & Chua, 2017).

Las principales aplicaciones de las redes neuronales recurrentes en música:

1. **Modelado de comportamiento de usuario:** Las redes neuronales recurrentes (RNNs) pueden predecir qué canción reproducirá un usuario después, basándose en su historial.
2. **Generación de música:** Redes como las redes neuronales recurrentes (RNNs) (o su variante de la memoria a corto-largo plazo (LSTM)) pueden generar composiciones musicales aprendiendo de piezas existentes.
3. **Análisis de letras:** Pueden identificar emociones, temas o patrones líricos en las canciones para mejorar las recomendaciones.

Un ejemplo de lo que se han comentado sería que YouTube Music emplea modelos basados en redes neuronales recurrentes (RNNs) para predecir las canciones más relevantes para los usuarios en función del contexto temporal (hora del día, ubicación, etc.).

Autoencoders

Los autoencoders son redes neuronales diseñadas para aprender una representación comprimida de los datos (codificación) y reconstruirlos con la mínima pérdida de información. Esto permite capturar patrones latentes útiles para recomendaciones (Liang et al, 2018).

Las principales aplicaciones de los autoencoders en música

1. Reducción de dimensionalidad: En datasets musicales masivos, los autoencoders se utilizan para identificar características latentes de las canciones o usuarios.
2. Recomendación personalizada: Combinando características latentes de usuarios y canciones, los autoencoders generan recomendaciones más precisas.

Un ejemplo de lo que se han comentado sería que los autoencoders son utilizados en plataformas como Deezer para aprender representaciones latentes tanto de canciones como de usuarios, permitiendo recomendaciones híbridas basadas en contenido y comportamiento.

Modelos basados en transformadores

Los transformadores, como los modelos utilizados en NLP (procesamiento del lenguaje natural), han ganado popularidad en música debido a su capacidad para manejar datos secuenciales con gran eficiencia. Modelos como representaciones de codificador bidireccional de transformer (BERT) o “generative pre-trained transformer” GPT pueden ser adaptados para tareas relacionadas con la música (Dieleman & Scharuwen, 2014).

Las principales aplicaciones de los modelos basados en transformadores en música

1. Análisis lírico avanzado: Los transformadores pueden analizar letras y extraer temas, emociones o estilos.
2. Recomendaciones contextuales: Usando datos secuenciales del usuario, pueden predecir preferencias futuras basadas en patrones históricos.
3. Generación de música: Modelos como los que se utilizan en Jukebox de OpenAI utilizan transformadores para generar música original con diferentes estilos y características.

Un ejemplo de lo que se han comentado sería que Jukebox de Open AI utiliza una arquitectura basada en transformadores para generar canciones completas, incluyendo melodías y letras.

Ventajas, limitaciones y avances recientes del aprendizaje profundo (deep learning) dentro de la distribución musical

La primera ventaja que nos podemos encontrar en la utilización del aprendizaje profundo (deep learning) dentro de la distribución musical sería la posibilidad de un análisis integral, ya que los modelos pueden procesar tanto datos colaborativos como las características del contenido, es decir, el audio y la letra. Una segunda ventaja que nos podemos encontrar es la mayor precisión de las redes de aprendizaje profundo (deep learning), ya que identifican los patrones más complejos que en otros métodos. Una tercera ventaja sería la personalización avanzada, ya que estos modelos permiten generar recomendaciones muy específicas al historial del usuario y a sus preferencias. La cuarta ventaja sería la adaptación al contexto que tienen estos modelos, ya que pueden incluir variables a nivel de contexto (ubicación, dispositivo utilizado u hora del día de reproducción) para poder mejorar así las recomendaciones (Choi et al., 2017).

Por otra parte, existen limitaciones y desafíos a la hora de utilizar estos métodos, el primero que nos podemos encontrar son los costes a nivel computacional de poder entrenar estos modelos, ya que requieren un gran volumen de datos y recursos a nivel computacional. Una segunda limitación nos la encontramos en los problemas de interpretación a la hora de tomar decisiones de estos modelos, lo que puede limitar la aceptación por parte del usuario de la plataforma. Una tercera limitación sería que estos modelos dependen de los datos, ya que necesitan una gran cantidad de datos etiquetados para que sea un modelo efectivo, lo que ser desfavorable en el caso de las canciones menos conocidas o para aquellos artistas que estén en su inicio de carrera. La última limitación será la privacidad de los usuarios, ya que un análisis tan profundo de su comportamiento puede generar preocupación dentro de la privacidad de estos (Choi et al., 2017).

Los avances recientes que se están trabajando para superar estas limitaciones dentro de los modelos de aprendizaje profundo (deep learning) dentro de la distribución musical serían:

- Modelos de aprendizaje federado: Permiten entrenar modelos de aprendizaje profundo (deep learning) sin necesidad de centralizar los datos de los usuarios, preservando la privacidad.

- Redes generativas adversarias (GANs): Utilizadas para la generación de música y el enriquecimiento del conjunto de datos (datasets) musicales.
- Integración multimodal: Combina datos de audio, texto (letras), y comportamiento del usuario para generar recomendaciones más precisas.

c) Sistemas híbridos para predecir preferencias musicales

La distribución musical se enfrenta a desafíos complejos como la personalización precisa, la recomendación contextual y la diversidad en las sugerencias. Para abordar estas necesidades, los sistemas híbridos de recomendación han surgido como una solución que combina múltiples enfoques de algoritmos predictivos. Estos sistemas integran filtros colaborativos, filtrado basado en contenido y técnicas avanzadas como el aprendizaje profundo y la tecnología de redes neuronales para mejorar la precisión y la relevancia en la recomendación musical.

En este apartado se exploran los sistemas híbridos y su aplicación en la distribución musical, analizando sus métodos, beneficios y desafíos, junto con ejemplos prácticos de su uso en plataformas como Spotify, Deezer y Apple Music (Burke, 2002).

Introducción a los sistemas híbridos

Los sistemas de recomendación son esenciales en el sector de la distribución musical para conectar a los usuarios con contenidos relevantes en un entorno con millones de opciones disponibles, tanto en canciones como en cantantes. Los enfoques individuales, como los filtros colaborativos y el filtrado basado en contenido, tienen limitaciones (Burke, 2002):

- Filtros colaborativos: Son susceptibles al problema de los usuarios o ítems nuevos (el *cold start problem*).
- Filtrado basado en contenido: Puede carecer de diversidad, recomendando canciones similares a las escuchadas previamente.

Los sistemas híbridos combinan mejor los diferentes enfoques y, en muchos casos, incluyen enfoques avanzados como el aprendizaje profundo o los modelos probabilísticos, logrando recomendaciones más personalizadas y diversificadas.

Definición de los sistemas híbridos

Los sistemas híbridos de recomendación son algoritmos que combinan dos o más enfoques para aprovechar las fortalezas de cada uno y disminuir sus debilidades. En la distribución musical, los sistemas híbridos suelen combinar:

1. Filtrado colaborativo basado en usuarios y/o ítems: Recomendaciones basadas en patrones de interacción entre usuarios o canciones.
2. Filtrado basado en contenido: Análisis de características intrínsecas de las canciones, como género, ritmo, tonalidad o letras.
3. Modelos avanzados: Métodos como autoencoders, transformadores y sistemas de aprendizaje profundo (deep learning).

Dentro del sector de distribución musical las siguientes plataformas musicales utilizan sistemas híbridos (Aguiar & Waldfogel, 2018):

- Spotify: Utiliza un sistema híbrido que combina filtros colaborativos, análisis de contenido y modelos de aprendizaje profundo. Por ejemplo, la lista “*Discover Weekly*” personaliza recomendaciones basándose en interacciones pasadas y características del contenido musical.
- Deezer: Combina datos acústicos con preferencias colaborativas para crear recomendaciones altamente personalizadas y listas de reproducción temáticas.
- Apple Music: Integra datos contextuales (hora del día del uso de la plataforma, actividad del usuario) con modelos colaborativos para ajustar recomendaciones según el estado de ánimo o momento específico.
- Pandora: Utiliza el “*Music Genome Project*”, un enfoque basado en contenido que analiza más de 450 atributos de canciones. Este sistema se combina con datos colaborativos para generar recomendaciones híbridas.

Tipos de modelos de sistemas híbridos aplicados en la distribución musical

Existen varias formas de combinar diferentes enfoques en sistemas híbridos. A continuación, se describen las técnicas más relevantes y sus aplicaciones en el contexto de la distribución musical (Ernst & Young, 2020).

Enfoque secuencial

En este enfoque, los resultados de un sistema de recomendación alimentan a otro. Podemos establecer como ejemplo de aplicación el siguiente:

1. Un sistema de filtrado colaborativo identifica una lista inicial de canciones recomendadas basándose en las preferencias del usuario.
2. Posteriormente, un modelo de filtrado basado en contenido refina estas recomendaciones evaluando similitudes acústicas, líricas o metadatos.

La aplicación en la distribución musical puede ser que Spotify utiliza este enfoque para personalizar sus listas de reproducción como “*Discover Weekly*”. Inicialmente, los filtros colaborativos sugieren canciones populares entre usuarios similares, pero las recomendaciones finales se ajustan analizando el contenido acústico y la singularidad de las pistas seleccionadas (Spotify Engineering, 2017).

Enfoque ponderado

Combina los resultados de varios sistemas asignando un peso a cada enfoque según su importancia en el contexto.

Un ejemplo de aplicación del enfoque ponderado sería cuando un sistema híbrido puede asignar un peso del 60% al filtrado colaborativo y del 40% al filtrado basado en contenido. Esto es útil en plataformas como Deezer, donde la experiencia del usuario se construye equilibrando datos personales y análisis acústico de las canciones.

Enfoque basado en características (Feature Engineering).

Los sistemas híbridos pueden combinar las características generadas por diferentes algoritmos en un único modelo de predicción. Por ejemplo, un modelo podría combinar los siguientes elementos (Spotify Engineering, 2020):

1. Características colaborativas: Relación entre usuarios y canciones.
2. Características acústicas: Timbre de voz, melodía y espectrogramas.
3. Datos contextuales: Hora del día de utilización de la plataforma, ubicación geográfica del usuario y actividad del usuario.

Un ejemplo de aplicación del enfoque basado en características (feature engineering) sería cuando Apple Music utiliza características contextuales junto con datos colaborativos para sugerir canciones

que coincidan con el estado de ánimo o actividad del usuario, como una lista para hacer ejercicio o relajarse.

Enfoque basado en aprendizaje profundo (deep learning)

El deep learning permite integrar múltiples fuentes de datos (interacciones usuario con canción, características de audio, letras, etc.) en un único modelo. Por ejemplo, un modelo podría combinar los siguientes elementos (Van den Oord et al., 2013):

1. Redes neuronales convolucionales (CNNs) procesan características acústicas de las canciones.
2. Redes neuronales recurrentes (RNNs) modelan secuencias de interacción del usuario.
3. Autoencoders combinan estas representaciones para predecir las preferencias musicales.

Un ejemplo de aplicación del enfoque basado en aprendizaje profundo (deep learning) sería cuando YouTube Music implementa modelos híbridos basados en deep learning para predecir canciones relevantes según el historial del usuario y sus preferencias implícitas.

Ventajas, limitaciones y avances recientes de los sistemas híbridos dentro de la distribución musical

La primera ventaja de la utilización de sistemas híbridos dentro de la distribución musical sería una mayor precisión, ya que estos modelos combinan múltiples de fuentes de información para mejorar la calidad de las recomendaciones. La segunda ventaja sería reducir el problema del inicio frío, ya que disminuyen las limitaciones asociadas con usuarios o nuevas canciones, integrando características dentro del modelo del contenido. La tercera ventaja sería la diversificación, ya que se generar recomendaciones más variadas y así se consigue un equilibrio entre las preferencias previas con los descubrimientos de nuevas canciones o autores. La última ventaja sería la contextualización por la incorporación de datos para ofrecer recomendaciones más ajustadas a los gustos del usuario (Zhou et al, 2008).

Por el contrario, la primera limitación o desafío sería la complejidad a nivel computaciones, ya que se tienen que combinar múltiples algoritmos y esto genera altos costes a nivel computacional.

La segunda limitación sería la recogida de datos, ya que los sistemas híbridos dependen de grandes volúmenes de datos, siempre de calidad, lo que se hace difícil obtener en casos de nuevos artistas o canciones que no son tan conocidas.

La última limitación, los mismo que pasaba con anteriores modelos, será la privacidad de los usuarios, ya que un análisis tan profundo de su comportamiento puede generar preocupación dentro de la privacidad de estos.

La tecnología blockchain en la distribución musical

La tecnología blockchain ha surgido como una herramienta transformadora en múltiples sectores e industrias, incluida en la distribución musical. En el sector de la distribución musical, la tecnología blockchain aborda problemas históricos como la centralización, la falta de transparencia en la gestión de derechos, y la distribución desigual de ingresos entre artistas, productores y plataformas (Jaime, 2019). El sector de la música ha pasado de depender de ventas físicas a un modelo de streaming dominado por plataformas centralizadas como Spotify, Apple Music y YouTube. Estas plataformas, aunque efectivas para la distribución, son frecuentemente criticadas por:

1. Modelos de ingresos centralizados: Los artistas suelen recibir un porcentaje reducido de las ganancias.
2. Falta de transparencia: Es difícil rastrear los flujos de ingresos y derechos de autor.
3. Intermediarios innecesarios: La cadena de valor está fragmentada, con múltiples participantes tomando una parte de los ingresos.

La tecnología blockchain ofrece una solución a estos problemas mediante un sistema descentralizado y transparente que optimiza la distribución de ingresos, el registro de derechos de autor y el acceso directo entre artistas y consumidores (Matulich & Currie, 2021).

Por tanto, podemos tener en cuenta que la tecnología blockchain tiene su aplicación en la música incluyendo lo siguiente:

1. Contratos inteligentes (Smart Contracts): Automatizan pagos y distribuyen ingresos de manera instantánea según los términos acordados entre artistas, productores y demás participantes.
2. Gestión de derechos de autor: Un registro descentralizado asegura la trazabilidad y autenticidad de los derechos asociados a una canción.
3. Monetización directa: Los artistas pueden recibir pagos directamente de los consumidores sin intermediarios, reduciendo costes y aumentando ingresos.

a) Aplicaciones de la tecnología blockchain en la distribución musical

Gestión de los derechos de autor y las licencias

Uno de los grandes retos en la industria musical es la complejidad de la gestión de derechos de autor.

La tecnología blockchain permite crear un registro único e inmutable que almacena información sobre:

- Propietarios de derechos de autor (compositores, letristas y productores).
- Licencias para su uso.
- Historial de transacciones relacionadas con la obra.

Un ejemplo de la aplicación de la gestión de los derechos de autor y las licencias es la plataforma MediaChain, adquirida por Spotify, utiliza la tecnología blockchain para identificar y rastrear derechos de autor en canciones, asegurando que los creadores reciban el dinero.

Contratos inteligentes para distribución de ingresos

Los contratos inteligentes (smart contracts) son programas que ejecutan automáticamente acuerdos predeterminados sin necesidad de intermediarios (Jaime, 2020). En la distribución musical, estos contratos pueden ser los siguientes:

- Dividir ingresos de streaming o ventas entre los participantes (artistas, productores o sellos discográficos).
- Ejecutar pagos en tiempo real cuando se cumple una condición, como una reproducción en una plataforma de streaming.

Un ejemplo de la aplicación de la gestión de los derechos de autor y las licencias es Ujo Music, una plataforma basada en Ethereum, permite a los artistas distribuir música y recibir pagos instantáneos utilizando contratos inteligentes (Nguyen, 2016).

Seguimiento directo y financiación descentralizada

Con la tecnología blockchain, los artistas pueden interactuar directamente con sus fans, eliminando intermediarios y reteniendo una mayor proporción de los ingresos (Tapscott & Tapscott, 2016). Los modelos que se pueden utilizar para esto:

- Tokens no fungibles (NFTs): Los artistas pueden vender canciones, álbumes o incluso derechos exclusivos a través de NFTs.

- Crowdfunding basado en la tecnología blockchain: Los fans pueden financiar proyectos musicales a cambio de tokens o participaciones en futuros ingresos.

Un ejemplo de la aplicación de la gestión de los derechos de autor y las licencias se pueden aplicar para los artistas como “Kings of Leon” han lanzado álbumes en forma de NFTs, ofreciendo versiones exclusivas de sus canciones y acceso a contenido adicional (Xu et al., 2021).

Reproducción y streaming descentralizado

La tecnología blockchain también está transformando las plataformas de streaming, permitiendo modelos descentralizados donde:

- Los artistas reciben una mayor proporción de los ingresos.
- Los usuarios pueden pagar directamente por las canciones que consumen contenido, sin necesidad de suscripciones.

Un ejemplo de la aplicación de la gestión de los derechos de autor y las licencias son las plataformas como Audius y Opus utilizan la tecnología blockchain para permitir el streaming descentralizado de música, asegurando que los artistas retengan hasta el 90% de los ingresos generados (Audius Blog, 2022).

b) Limitaciones de la tecnología blockchain en de la distribución musical

Las plataformas blockchains actuales, como Bitcoin o Ethereum, se enfrentan a los problemas de la escalabilidad que pueden limitar la acogida masiva en las plataformas musicales. Añadiendo a la falta de estandarización, ya que no existe un estándar para la gestión de los derechos musicales en la tecnología blockchain, lo que dificulta la interoperabilidad entre las diferentes plataformas. Y los costes asociados, ya que las tarifas de transacción, por ejemplo, el gas que se utiliza en la plataforma de Ethereum puede tener un coste alto, especialmente para artistas independientes. Por otra parte, los grandes sellos discográficos y plataformas centralizadas de música pueden resistirse a la adopción de la tecnología blockchain, ya que amenazan su modelo de negocio. Por último, aunque la tecnología blockchain se caracteriza para la transparencia, la exposición de los datos de cada una de sus transacciones puede plantear problemas sobre la privacidad de los artistas y los usuarios de las plataformas (Pasick, 2016).

La sinergia entre los algoritmos predictivos y la tecnología blockchain en la distribución musical

La integración de algoritmos predictivos con tecnología blockchain representa un avance que aborda ciertos retos en la distribución musical. Esta sinergia no solo mejora la eficiencia y precisión de las plataformas de distribución, sino que también introduce transparencia, seguridad y equidad en la monetización y gestión de derechos de autor. Ya que, en el sector musical, la innovación tecnológica ha transformado radicalmente la forma en que se consume y distribuye la música. Mientras que los algoritmos predictivos permiten personalizar recomendaciones y predecir tendencias en el consumo musical, la tecnología blockchain proporciona un marco descentralizado y seguro para gestionar derechos y pagos. Combinadas, las dos tecnologías optimizan tanto la experiencia del usuario como los procesos internos de la industria (Raffone & Bolici, 2020).

a) Sinergia entre algoritmos predictivos y la tecnología blockchain

La combinación de estas tecnologías ofrece una solución integral a los problemas del sector musical, integrando la capacidad predictiva de los algoritmos con la transparencia y seguridad de la tecnología blockchain (Raffone & Bolici, 2020).

Gestión optimizada de ingresos

El problema actual dentro de la gestión de los ingresos es que en las plataformas de streaming tradicionales, la distribución de ingresos se basa en modelos centralizados que suelen ser opacos y desfavorables para los artistas independientes.

La solución que aportan los algoritmos predictivos analiza el consumo de los usuarios en tiempo real, mientras que los contratos inteligentes en la tecnología blockchain garantizan una distribución justa de los ingresos basada en los datos generados.

Un ejemplo de la aplicación entre algoritmos predictivos y la tecnología blockchain en la gestión optimizada de los ingresos es que las plataformas podrían calcular los ingresos generados por un artista en tiempo real y ejecutar pagos automáticos utilizando contratos inteligentes.

Recomendaciones personalizadas con compensación justa

El problema actual es que, aunque los sistemas de recomendación ofrecen contenido personalizado, no siempre garantizan que los artistas reciban una compensación adecuada por el uso de sus obras.

La solución es que los algoritmos predictivos generan recomendaciones, mientras que la tecnología blockchain registra cada reproducción en un libro mayor transparente, asegurando que los artistas sean remunerados de acuerdo con el uso real de sus canciones.

Un ejemplo de la aplicación entre algoritmos predictivos y la tecnología blockchain en las recomendaciones personalizadas con compensación justa es que un usuario que escuche una canción recomendada podría activar automáticamente un contrato inteligente (smart contract) que compense al artista con micropagos basados en criptomonedas.

Predicción de tendencias para monetización anticipada

El problema actual es identificar tendencias emergentes puede ser ineficaz o demorado en los sistemas actuales.

La solución es los algoritmos predictivos identifican canciones o géneros con potencial de popularidad, y los artistas pueden tokenizar estas canciones en blockchain para monetizarlas anticipadamente mediante crowdfunding o NFTs.

Un ejemplo de la aplicación entre algoritmos predictivos y la tecnología blockchain en la predicción de tendencias para monetizar de forma anticipada es que Un artista emergente podría financiar la producción de su próximo álbum emitiendo NFTs basados en predicciones de éxito generadas por algoritmos.

Trazabilidad y autenticidad en recomendaciones

El problema actual es que las plataformas pueden ser acusadas de manipular las recomendaciones basándose en intereses comerciales.

La solución se encuentra en los datos de las recomendaciones generadas por algoritmos predictivos pueden registrarse en blockchain, garantizando su trazabilidad y evitando manipulaciones.

Un ejemplo de la aplicación entre algoritmos predictivos y la tecnología blockchain en la trazabilidad y autenticidad en recomendaciones es el registro en la plataforma blockchain podría demostrar que una recomendación se basó exclusivamente en las preferencias del usuario y no en acuerdos comerciales con terceros.

b) Beneficios, retos y desafíos de la sinergia entre los algoritmos predictivos y la tecnología blockchain

El primer beneficio es la transparencia total de la tecnología blockchain, ya que asegura que los datos generados por algoritmos predictivos sean rastreables y verificables.

El segundo beneficio estaría en la distribución justa de los ingresos, ya que la combinación de datos de consumo predictivos y contratos inteligentes permite una compensación más equitativa.

El tercer beneficio es la eliminación de costes de intermediarios, ya que los artistas pueden interactuar directamente con sus audiencias, eliminando esos costes de intermediación.

Por último, se han creado nuevos modelos de monetización, ya que los artistas pueden aprovechar la predicción de tendencias para lanzar campañas de crowdfunding basadas en la tecnología blockchain (O'Dair & Beaven, 2019).

Por lo contrario, nos podemos como un reto a superar los costes de implementación, ya que hacer una integración la tecnología blockchain y algoritmos predictivos puede ser costoso, especialmente para pequeñas plataformas o artistas independientes. Otro reto es la interoperabilidad, ya que es necesario desarrollar estándares para garantizar que los datos generados por algoritmos sean compatibles con diferentes plataformas de blockchains.

El registro de datos en la plataforma blockchain debe equilibrarse con la protección de la privacidad del usuario. Por última, la complejidad técnica que exista a la hora de integrar los algoritmos avanzados y sistemas descentralizados requiere conocimientos técnicos significativos y un mantenimiento continuo (O'Dair, 2019).

RESULTADOS

Proyectos de algoritmos predictivos y tecnología blockchain en el sector de la distribución musical

En la Tabla 1, se muestran comparativamente los proyectos en el sector de la distribución musical comentados, analizando en detalle las tecnologías utilizadas en cada uno.

Tabla 1. Proyectos en el sector de la distribución musical

| Plataforma | Uso de blockchain | Uso de algoritmos predictivos | Modelo de monetización | Ventajas | Desafíos |
|---------------|--|---|--|--|---|
| Audius | Utiliza Ethereum y Solana para almacenamiento de metadatos y pagos descentralizados con el token \$AUDIO | Algoritmos de recomendación basados en redes neuronales y análisis de patrones de escucha | Tokenización con \$AUDIO, pagos directos a artistas sin intermediarios | Transparencia, descentralización, pagos rápidos, comunidad participativa | Adopción masiva, competencia con plataformas tradicionales, educación del usuario |

| | | | | | |
|------------------------------|---|--|---|---|--|
| Mycelia (Imogen Heap) | Usa contratos inteligentes para la gestión de derechos y distribución de ingresos | No implementa modelos predictivos de recomendación | Gestión de licencias y microtransacciones automatizadas para artistas | Transparencia en derechos de autor y pagos inmediatos a creadores | Escalabilidad, integración con la industria tradicional |
| Opus | Basado en Ethereum y IPFS para almacenamiento descentralizado de música | No implementa algoritmos avanzados de recomendación | Modelo basado en micropagos con criptomonedas | Reducción de costes operativos, mayor control para artistas | Costes de transacción en Ethereum, adopción de criptomonedas |
| Musicoin | Usa contratos inteligentes para pagos por reproducción a los artistas | No implementa algoritmos de recomendación | Sistema de recompensas con el token MUSIC | Pagos directos y automatizados, sin intermediarios | Volatilidad del token, adopción masiva |
| ROCKI | Blockchain para derechos de autor y monetización con NFTs musicales | Algoritmos de personalización para identificar nuevos talentos | Token ROCKI y NFTs musicales para distribución de regalías | Diversificación de ingresos para artistas, monetización creativa | Adopción de NFTs en la industria musical, regulaciones |
| Ujo Music | Uso de Ethereum para registro de derechos y pagos automáticos | No utiliza algoritmos predictivos | Microtransacciones con smart contracts | Transparencia total en la distribución de ingresos | Costes de gas en Ethereum, falta de integración con plataformas de streaming |
| Revelator | Usa blockchain para la gestión de derechos y distribución de regalías | Algoritmos de análisis de mercado y optimización de ingresos para artistas | Plataforma SaaS con servicios de distribución digital | Optimización financiera para artistas, informes detallados en tiempo real | Requiere integración con grandes sellos y distribuidores |

Fuente: Elaboración propia

DISCUSIÓN

El futuro de los algoritmos predictivos y la tecnología blockchain en la distribución musical

Para maximizar el potencial de esta sinergia tecnológica, se identifican las siguientes líneas de investigación futuras.

a) Modelos híbridos de predicción y la tecnología blockchain

Aunque blockchain y algoritmos predictivos han demostrado su efectividad individual, su combinación aún está en etapas tempranas de desarrollo.



El objetivo es investigar cómo integrar modelos predictivos basados en aprendizaje profundo directamente en sistemas descentralizados para mejorar la personalización sin comprometer la privacidad del usuario. Un ejemplo sería desarrollar sistemas que permitan a los usuarios compartir datos anonimizados para entrenar algoritmos predictivos mientras mantienen el control total sobre su información a través de blockchain (Xu et al., 2021).

b) Evolución de NFTs musicales con datos predictivos

Los NFTs ya se utilizan para monetizar contenido, pero su integración con algoritmos predictivos puede revolucionar su uso.

El objetivo es investigar cómo los datos generados por algoritmos pueden respaldar la creación de NFTs dinámicos que se revaloricen en función de tendencias o popularidad. Un ejemplo sería un NFT de una canción podría aumentar su valor si los algoritmos predicen y validan su crecimiento en popularidad (Xu et al., 2021).

c) Impacto de la descentralización en la sostenibilidad económica

La eliminación de intermediarios modifica la estructura económica de la industria musical.

El objetivo es analizar cómo los sistemas descentralizados afectan la sostenibilidad económica de los artistas y las plataformas, incluyendo el impacto de criptomonedas volátiles como método de pago. Un ejemplo sería los modelos económicos que incorporen criptomonedas estables (stablecoins) o sistemas de gobernanza comunitaria para proteger los ingresos de los artistas (Xu et al., 2021).

d) Regulación e interoperabilidad tecnológica

La falta de normativas claras y estándares técnicos limita la adopción masiva de estas tecnologías.

El objetivo es explorar cómo desarrollar estándares de interoperabilidad entre diferentes plataformas blockchains y sistemas de recomendación para crear un ecosistema más cohesivo y accesible. Un ejemplo serían los proyectos que permitan a los artistas registrar sus derechos en una red blockchain y distribuir su música en múltiples plataformas sin necesidad de replicar los datos (Tsotsou, 2020).

e) Privacidad y ética en el uso de datos

Los algoritmos predictivos dependen de grandes volúmenes de datos, lo que plantea preocupaciones sobre la privacidad de los usuarios.

El objetivo es investigar cómo utilizar tecnologías como el aprendizaje federado y zk-SNARKs (Zero-Knowledge Succinct Non-Interactive Arguments of Knowledge) para entrenar modelos predictivos respetando la privacidad del usuario. Un ejemplo sería un sistema en el que los usuarios puedan entrenar localmente algoritmos predictivos sin compartir datos sensibles con terceros.

(Tsiotsou, 2020)

f) Automatización total del ecosistema musical

La integración de la tecnología blockchain y algoritmos predictivos puede automatizar toda la cadena de valor musical.

El objetivo es diseñar sistemas que gestionen automáticamente desde la creación de música hasta la distribución y la monetización. Un ejemplo es las plataformas donde los artistas suben su música, los algoritmos analizan su potencial, y los contratos inteligentes (smart contracts) gestionan pagos y promoción (Tsiotsou, 2020).

g) Análisis del impacto social y cultural

Las tecnologías disruptivas pueden transformar profundamente la dinámica social y cultural de la música.

El objetivo es investigar cómo la descentralización y la personalización afectan el acceso global a la música, la diversidad cultural y la creación artística. Un ejemplo serían los estudios sobre cómo estas tecnologías empoderan a los artistas independientes de regiones subrepresentadas en los mercados globales (Tsiotsou, 2020).

CONCLUSIONES

La combinación de algoritmos predictivos y la tecnología blockchain tiene el potencial de revolucionar la distribución musical, abordando problemas históricos como la centralización, la opacidad en la gestión de derechos y la distribución desigual de ingresos. Sin embargo, su implementación exitosa requiere superar desafíos técnicos, regulatorios y culturales.

a) Redefinición del modelo de distribución musical

La integración de la tecnología blockchain y algoritmos predictivos está rediseñando el paradigma de la distribución musical.

La tecnología blockchain aporta transparencia y descentralización, mientras que los algoritmos predictivos permiten personalización y optimización de las recomendaciones y tendencias (Matulich & Currie, 2021). Este modelo ha mostrado un impacto positivo al:

Garantizar una distribución más justa de ingresos mediante contratos inteligentes.

Personalizar la experiencia del usuario y fomentar descubrimientos musicales relevantes.

Democratizar el acceso de artistas independientes al mercado global sin depender de intermediarios.

b) Mayor equidad y transparencia

La tecnología blockchain elimina las prácticas opacas en la gestión de derechos y compensaciones. Los contratos inteligentes (smart contracts) automatizan procesos de pago basados en métricas reales, reduciendo los tiempos y errores en los pagos (Xu et al., 2021).

c) Eficiencia impulsada por datos

Los algoritmos predictivos permiten identificar patrones de consumo y tendencias emergentes con alta precisión, ofreciendo a los artistas y productores herramientas para tomar decisiones informadas sobre sus estrategias creativas y comerciales (Matulich & Currie, 2021).

d) Nuevos modelos de monetización

La tokenización de activos musicales y la creación de NFTs (Non-Fungible Tokens) han abierto caminos alternativos para financiar proyectos musicales, crear ingresos recurrentes y conectar directamente a artistas con sus audiencias (Matulich & Currie, 2021).

e) Retos significativos en su implementación

A pesar de los beneficios evidentes, persisten desafíos como (Xu et al., 2021):

Costes elevados de implementación tecnológica.

La escalabilidad de la tecnología blockchain frente a altos volúmenes de usuarios.

Resistencia cultural y educativa, especialmente en la adopción de criptomonedas y tecnologías descentralizadas.

La necesidad de regulación clara y equilibrada que proteja a los usuarios y fomente la innovación.

REFERENCIAS BIBLIOGRAFICAS

- Aguiar, L., & Waldfogel, J. (2018). "Quality Predictability and the Welfare Benefits from New Products: Evidence from the Digitization of Recorded Music". *Journal of Political Economy*, 126(2), 492-524.
- Audius Blog. (2022). *Audius Governance Takeover Post-Motem 7/23/22*. Disponible: <https://blog.audius.co/article/audius-governance-takeover-post-mortem-7-23-22>
- Choi, K., Fazekas, G., Sandler, M., & Cho, K. (2017). *Convolutional recurrent neural networks for music classification*. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- Dieleman, S., & Schrauwen, B. (2014). *End-to-end learning for music audio*. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- Ernst & Young. (2020). "Blockchain in the Media and Entertainment Industry: The Future of Music Distribution". *EY Insights*.
- Hershey, S., Chaudhuri, S., Ellis, D. P., Gemmeke, J. F., Jansen, A., Moore, R. C., ... & Wilson, K. (2017). *CNN architectures for large-scale audio classification*. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- He, X., & Chua, T. S. (2017). *Neural Collaborative Filtering*. Proceedings of the 26th International Conference on World Wide Web.
- Jaime Maestre, R. (mayo de 2019). La Blockchain revolucionarà la comunicació de l'empresa. Comunicació: Revista de Recerca i d'Anàlisi, 36(1), pp 95-116.
- Jaime Maestre, R. (2020). Un ejemplo de educación financiada mediante criptomoneda: la ICO de la IEBS Business School. *Tecnología, Ciencia y Educación*, 15, 143-163.
- Koren, Y., Bell, R., & Volinsky, C. (2009). *Matrix Factorization Techniques for Recommender Systems*. *Computer*, 42(8), 30-37.
- Liang, D., Krishnan, R. G., Hoffman, M. D., & Jebara, T. (2018). *Variational Autoencoders for Collaborative Filtering*. Proceedings of the 2018 Web Conference, 689-698.



- Maestre, R.J., Bermejo Higuera, J., Gámez Gómez, N. *et al.* The application of blockchain algorithms to the management of education certificates. *Evol. Intel.* 16, 1967–1984 (2023). <https://doi.org/10.1007/s12065-022-00812-0>
- Matulich, E., & Currie, E. (2021). *Blockchain and the Music Industry: The Future of Streaming and Royalties*. *Journal of Business and Economics*, 12(3), 15–25.
- Nguyen, Q. K. (2016). *Blockchain and Its Integration with AI: Opportunities for Music Distribution*. *International Journal of Emerging Technology*.
- O'Dair, M., & Beaven, Z. (2019). *Blockchain and the Music Industry: Technology, Power and Innovation*. *Progress in Informatics*, 16(1), 21–39.
- O'Dair, M. (2019). *Distributed Creativity: How Blockchain Technology Will Transform the Creative Economy*. Palgrave Macmillan.
- OpenAI. (2020). *Jukebox: A generative model for music*.
- Park, S. H., & Lee, J. H. (2017). *Hybrid music recommendation using content-based and collaborative filtering*. *Expert Systems with Applications*, 71, 117–128.
- Pasick, A. (2016). "How Blockchain Can Fix the Music Industry". *Quartz*.
- Raffone, G., & Bolici, F. (2020). *The Promise of Blockchain for Music Distribution: Opportunities and Challenges*. *International Journal of Information Management*, 51, 102–115.
- Schafer, J. B., Frankowski, D., Herlocker, J., & Sen, S. (2007). *Collaborative Filtering Recommender Systems*. In *The Adaptive Web* (pp. 291-324). Springer.
- Spotify Engineering. (2017). *Discover Weekly: How Machine Learning Finds Your Next Favorite Song*. Spotify Tech Blog.
- Spotify Engineering. (2020). "How We Personalize Music Recommendations Using Machine Learning". *Spotify Tech Blog*.
- Tapscott, D., & Tapscott, A. (2016). *Blockchain Revolution: How the Technology Behind Bitcoin is Changing Money, Business, and the World*. Penguin.
- Tsiotsou, R. (2020). "Emerging Consumer Trends in the Music Industry". *Journal of Music Business Research*, 9(1), 22-39.

- Van den Oord, A., Dieleman, S., & Schrauwen, B. (2013). *Deep content-based music recommendation*. In *Advances in Neural Information Processing Systems (NeurIPS)*.
- Xu, W., et al. (2021). "Blockchain Applications in Copyright Protection: A Case Study in the Music Industry". *Future Internet*, 13(3), 62.
- Zhou, Y., Wilkinson, D., Schreiber, R., & Pan, R. (2008). *Large-Scale Parallel Collaborative Filtering for the Netflix Prize*. In *Proceedings of the 4th International Conference on Algorithmic Aspects in Information and Management*, 337-348.

