

Recomendações Contextuais em Sistemas Inteligentes de Música: Proposta para Otimizar Engajamento e Satisfação no Spotify

André Felipe Albuquerque Silva¹, Martony Demes da Silva¹

¹Centro de Educação Aberta e a Distância (CEAD) – Universidade Federal do Piauí (UFPI)

Abstract. *This study analyzes how contextual personalization in music recommendation systems, such as Spotify, affects user engagement and satisfaction. The qualitative research combined walkthroughs of distinct consumption profiles and interviews with premium users. Preliminary results indicate that the algorithm performs better for linear profiles and shows limitations with eclectic users, offering repetitive or less relevant recommendations. These initial findings suggest the need to integrate contextual variables and enhance transparency, pointing toward more adaptive and user-centered recommendation systems.*

Resumo. *Este estudo analisa como a personalização contextual em sistemas de recomendação musical, como o Spotify, afeta o engajamento e a satisfação do usuário. A pesquisa qualitativa combinou walkthrough de perfis de consumo distintos e entrevistas com usuários premium. Os resultados preliminares indicam que o algoritmo funciona melhor para perfis lineares e apresenta limitações com usuários de comportamento eclético, oferecendo recomendações repetitivas ou pouco relevantes. Esses achados incipientes sugerem a necessidade de integrar variáveis contextuais e maior transparência, apontando caminhos para sistemas de recomendação mais adaptativos e centrados na experiência do usuário*

1. Introdução

Com o avanço dos serviços de streaming, o Spotify tornou-se um protagonista no ecossistema digital de consumo musical. Diante de um catálogo com milhões de faixas, o desafio da descoberta musical cresce proporcionalmente à variedade. Para enfrentar essa sobrecarga informacional, os sistemas de recomendação, baseados em técnicas avançadas de aprendizado de máquina, se consolidaram como ferramentas essenciais, moldando não apenas a experiência do usuário, mas também suas preferências e hábitos culturais [Zeng et al. 2024, Kischinhevsky et al. 2024].

Embora os algoritmos tenham evoluído, incorporando modelos de aprendizado profundo e técnicas de filtragem colaborativa, ainda resta uma lacuna quanto à personalização baseada em contexto de uso. Fatores como o estado emocional, o horário, a localização e o ambiente do usuário são pouco explorados ou mal interpretados pelas plataformas [Lozano Murciego et al. 2021, Amershi et al. 2019]. Pesquisas recentes apontam que a eficácia da recomendação depende mais do momento de consumo do que de gostos estáticos [de Freitas Lohmann 2018, Peral 2024].

Além disso, questões de transparência e explicabilidade dos modelos de ML têm impacto direto na confiança e satisfação do usuário, tema ainda pouco explorado em recomendações musicais [Doshi-Velez and Kim 2017, Nunes and Jannach 2020, Zhang et al. 2022]. Neste estudo, investiga-se como o Spotify utiliza (ou falha em utilizar) variáveis contextuais para oferecer recomendações e qual o papel das características dos modelos ML empregados nesse processo. O foco está em compreender, qualitativamente, de que forma a presença (ou ausência) de personalização contextual impacta o engajamento e a satisfação do usuário. O objetivo final é propor diretrizes que aproximem os sistemas de recomendação das experiências subjetivas dos usuários, contribuindo para uma tecnologia mais responsável, transparente e alinhada com valores humanos.

2. Metodologia

A pesquisa adota uma abordagem qualitativa e exploratória, com ênfase em métodos interpretativos, a fim de compreender as percepções dos usuários e o funcionamento prático da plataforma. O desenho metodológico é dividido em duas fases complementares.

Na primeira fase, utiliza-se o método walkthrough, conforme adaptado por [Peral 2024], com o objetivo de mapear a lógica interna do sistema de recomendação do Spotify, focando especialmente nos aspectos relacionados aos modelos de aprendizado de máquina e como eles processam dados contextuais. Serão criadas duas contas fictícias com perfis de consumo divergentes: um com escuta linear (foco em um único gênero) e outro com comportamento eclético. Ao longo de três semanas, será documentada a evolução das playlists e recomendações, especialmente a seção "Descobertas da Semana", a fim de avaliar a resposta algorítmica a esses comportamentos contrastantes, considerando limitações conhecidas de ML para perfis dinâmicos [Lozano Murciego et al. 2021, Amershi et al. 2019].

Na segunda fase, serão conduzidas entrevistas semiestruturadas com 8 a 10 usuários premium. As entrevistas explorarão cinco eixos temáticos: hábitos de consumo, percepção sobre recomendações, variedade musical, entendimento sobre o algoritmo e relação emocional com o conteúdo sugerido. Além disso, será explorada a percepção dos entrevistados quanto à transparência e confiança no sistema de recomendação, alinhando com pesquisas recentes em explicabilidade de ML [Nunes and Jannach 2020].

No eixo de compreensão do algoritmo, os entrevistados serão convidados a relatar exemplos concretos em que perceberam recomendações acertadas ou equivocadas, bem como sua percepção sobre a transparência e confiabilidade do sistema. Também será investigado como esse entendimento influencia o engajamento e a satisfação com o uso da plataforma.

As conversas serão transcritas e analisadas por codificação temática. A análise dos dados será triangulada, comparando as evidências empíricas do funcionamento da plataforma com os relatos subjetivos dos usuários, buscando alinhamentos ou dessonâncias. O objetivo é captar nuances da experiência algorítmica que não seriam detectáveis apenas por análise técnica.

Complementarmente, considera-se a possibilidade de utilizar bases de dados públicas relacionadas ao Spotify, como o Million Playlist Dataset, bem como dados coletados por meio da API da plataforma, desde que tratados de forma agregada e anonimizada.

dos. Esse recurso pode enriquecer a análise qualitativa ao oferecer evidências adicionais sobre padrões de consumo

3. Resultados Preliminares

Até o momento, a análise via método walkthrough indica que o algoritmo do Spotify responde de forma mais eficaz a perfis com consumo musical linear, apresentando sugestões consistentes com os gêneros ouvidos. Por outro lado, perfis com escuta variada tendem a receber recomendações repetitivas ou pouco alinhadas ao comportamento exploratório, sugerindo limitação na interpretação contextual do algoritmo, fato alinhado a desafios recentes em sistemas ML quanto à personalização em ambientes dinâmicos e contextuais [Zeng et al. 2024, Kischinhevsky et al. 2024]. A Figura 1 apresenta o comparativo das playlists.

	Perfil Linear (Foco em um gênero)	Perfil Eclético (Vários gêneros)
Semana 1	 15 faixas (80% rock, 20% pop)  90% alinhamento com histórico	 15 faixas (rock, sertanejo, MPB, eletrônico)  40% repetidas de semanás anteriores
Semana 2	 15 faixas (85% rock, 15% pop)  pequena variação de artistas	 15 faixas (muitos gêneros)  50% repetidas, baixa diversidade
Semana 3	 15 faixas (80% rock, 20% pop)  coerência e consistência	 15 faixas (mix irregular, pop e eletrônico domínm)  recomendação desalinhada ao histórico recente

Figure 1. Comparação das playlists “Descobertas da Semana” para perfis Linear (foco em um único gênero) e Eclético (múltiplos gêneros) ao longo de três semanas. (do Autor)

Observa-se ainda que recursos como “Descobertas da Semana” apresentam menor diversidade para usuários ecléticos, o que pode reduzir o engajamento e aumentar o cansaço algorítmico. Esses dados reforçam a hipótese de que os sistemas atuais ainda não integram variáveis contextuais de forma significativa e ressaltam a necessidade de modelos ML mais robustos e contextualmente sensíveis [Lozano Murciego et al. 2021].

4. Conclusão e Trabalhos Futuros

Esta pesquisa evidencia a necessidade de aprimoramento nos sistemas de recomendação musical para incorporar variáveis contextuais que refletem mais fielmente o momento de consumo do usuário. A análise preliminar mostra que o modelo atual privilegia padrões previsíveis, limitando a experiência de descoberta musical em perfis mais dinâmicos.

Espera-se que usuários com maior clareza sobre o funcionamento do algoritmo demonstrem maior engajamento e satisfação. Hipotetiza-se também que a incorporação de variáveis contextuais (como horário e ambiente de escuta) reduza a repetição e o cansaço algorítmico, ampliando a diversidade percebida nas recomendações. Por fim, supõe-se que maior transparência algorítmica aumente a confiança do usuário e contribua para uma relação mais positiva com a plataforma. Como atividades conclusivas, propõe-se:

- Expandir a base empírica com entrevistas longitudinais para avaliar mudanças no comportamento ao longo do tempo;
- Investigar a aplicação de dados externos (como clima, geolocalização e biometria emocional) nas recomendações personalizadas por meio de modelos multimodais de ML;
- Realizar testes com diferentes níveis de transparência algorítmica para verificar como o entendimento do usuário sobre o sistema impacta sua satisfação e confiança, alinhando-se ao campo da IA explicável (XAI).

Esse conjunto de diretrizes pretende aproximar a tecnologia da complexidade e da subjetividade da experiência musical, contribuindo para a evolução dos sistemas inteligentes de recomendação.

References

- Amershi, S. et al. (2019). Guidelines for human-ai interaction. *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pages 1–13.
- de Freitas Lohmann, A. (2018). *Sistemas de recomendação em sites de notícias: contextualização como proposta para o engajamento de usuários*. PhD thesis, Universidade do Estado do Rio de Janeiro. Acesso em: 7 out. 2025.
- Doshi-Velez, F. and Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.
- Kischinhevsky, M., Ferreira, G., and Ítala Maduell Vieira (2024). Serendipity on radio and streaming: Between musical discovery and recognition. *New Media & Society*, 26(11):6533–6551.
- Lozano Murciego, Á., Jiménez-Bravo, D. M., Valera Román, A., De Paz Santana, J. F., and Moreno-García, M. N. (2021). Context-aware recommender systems in the music domain: A systematic literature review. *Electronics*, 10(13):1555.
- Nunes, I. and Jannach, D. (2020). A systematic review and taxonomy of explanations in decision support and recommender systems. *arXiv preprint arXiv:2006.08672*.
- Peral, O. R. L. (2024). *Sistemas de recomendação do Spotify na descoberta e consumo musical*. ISCTE, Lisboa.
- Zeng, Z. et al. (2024). A survey of music recommendation systems. *ACM Computing Surveys*. to appear / in press.
- Zhang, Y. et al. (2022). A survey on trustworthy recommender systems. *arXiv preprint arXiv:2207.12515*.