

 <p>ESCOLA DE COMUNICAÇÃO, ARTES E DESIGN FAMECOS PUCRS</p>	<h1>REVISTA FAMECOS</h1> <p>mídia, cultura e tecnologia</p> <p>Revista FAMECOS, Porto Alegre, v. 32, p. 1-18, jan.-dez. 2025 e-ISSN: 1980-3729 ISSN-L: 1415-0549</p>
<p>https://dx.doi.org/10.15448/1980-3729.2025.1.46406</p>	

SEÇÃO: CIBERCULTURA

Spotify e “Descobertas da Semana”: recomendação algorítmica como substrato de construção do gosto musical¹

Spotify y “Discover Weekly”: la recomendación algorítmica como sustrato de la construcción del gusto musical

Spotify and “Discover Weekly”: algorithmic recommendation as a substrate for music taste construction

Aléxis de Carvalho

Moreira¹

orcid.org/0009-0002-3739-128X
alekismoreira@id.uff.br

Beatriz Brandão

Polivanov²

orcid.org/0000-0002-1289-6604
beatrizpolivanov@id.uff.br

Recebido em: 12 jun.2024.

Aprovado em: 03 fev.2025.

Publicado em: 26 mar.2025.

Resumo: A partir dos Estudos de Plataforma, propomos uma análise dos processos de personalização estabelecidos pelo Spotify por meio de sua playlist “Descobertas da Semana” em relação aos seus ouvintes. Além de apresentar o modo como a plataforma define as canções que serão incluídas na playlist, analisamos o conteúdo de 2.215 tweets para compreender o que dizem os usuários sobre essas entregas. Nossos resultados apontam para pouco mais da metade das postagens (54,1% ou 1.199 tweets) com declarações de autoreconhecimento nas descobertas que realizam, 430 tweets neutros (19,4%), e 586 tweets (26,5%) que resistem e tensionam o modelo desenvolvido pelo Spotify, onde tais controvérsias complexificam a noção de gosto estabelecida pela plataforma. Concluímos apontando que os usuários adotam a lógica algorítmica como um elemento constituinte da elaboração do próprio gosto.

Palavras-chave: estudos de plataforma; Spotify; sistemas de recomendação; playlist descobertas da semana; X/Twitter.

Resumen: A partir de los Estudios de Plataforma, proponemos un análisis de los procesos de personalización establecidos por Spotify a través de su lista de reproducción “Discover Weekly” en relación con sus oyentes. Además de presentar cómo la plataforma define las canciones que se incluirán en la lista de reproducción, analizamos el contenido de 2.215 tweets para comprender lo que dicen los usuarios sobre estas entregas. Nuestros resultados indican que poco más de la mitad de las publicaciones (54.1% o 1.199 tweets) contienen declaraciones de auto-reconocimiento en los descubrimientos que realizan, 430 tweets neutros (19.4%), y 586 tweets (26.5%) que resisten y desafían el modelo desarrollado por Spotify, donde tales controversias complican la noción de gusto establecida por la plataforma. Concluimos señalando que los usuarios adoptan la lógica algorítmica como un elemento constituyente en la elaboración de su propio gusto.

Palabras clave: estudios de plataforma; Spotify; sistemas de recomendación; lista de reproducción discover weekly; X/Twitter.

Abstract: From Platform Studies, we propose an analysis of the personalization processes established by Spotify through its playlist “Discover Weekly” in relation to its listeners. In addition to presenting how the platform defines the songs that will be included in the playlist, we analyzed the content of 2,215 tweets to understand what users say about these deliveries. Our results indicate that just over half of the posts (54.1% or 1,199 tweets) contain statements of self-recognition in the discoveries they make, 430 neutral tweets (19.4%), and 586 tweets (26.5%) that



Artigo está licenciado sob forma de uma licença
[Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/).

¹ Este artigo é decorrente da dissertação de mestrado de Aléxis Moreira (2022) sob orientação da Prof^a Dr^a Beatriz Polivanov, e do trabalho apresentado pelos pesquisadores no GP Tecnologias e Culturas Digitais do 46º Congresso Brasileiro de Ciências da Comunicação, realizado em 2023. Os autores agradecem ao apoio recebido do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) Brasil - processo n. 407697/2023-3), bem como da Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) - Processo E-26/204.456/2024, para realização desta pesquisa.

² Universidade Federal Fluminense (UFF), Niterói, RJ, Brasil.

resist and challenge the model developed by Spotify, where such controversies complicate the notion of taste established by the platform. We conclude by pointing out that users adopt algorithmic logic as a constituent element in the elaboration of their own taste.

Keywords: platform studies; Spotify; recommender systems; discover weekly playlist; X/Twitter.

Introdução

A *playlist* "Descobertas da Semana" disponibiliza, todas as segundas-feiras, uma coleção de 30 canções definidas por técnicas algorítmicas associadas ao aprendizado de máquina. A lista de reprodução tem como proposta entregar aos atuais 615 milhões de usuários² do Spotify uma seleção de músicas personalizadas, nunca antes ouvidas na plataforma.

A forma como realizamos descobertas musicais utilizando *playlists* como esta apresenta novas propostas envolvendo processos de personalização e curadoria dos conteúdos diante do desenvolvimento de técnicas computacionais pautadas pela mineração de dados e perspectivas performativo-preditivas (Bruno, 2013). Fundamentados em uma base behaviorista (De Jong; Prey, 2022), os processos técnicos são utilizados por plataformas como o Spotify para a compreensão de padrões estatísticos sobre os comportamentos dos usuários e seus rastros digitais relacionados ao gosto (Airoldi, 2019).

Diante disso, nosso artigo tem como objetivos:

- a) mapear como as canções são selecionadas e entregues pelo sistema de recomendação (SR)³ do Spotify; e
- b) compreender o que os usuários estão percebendo e externalizando em postagens no X/Twitter sobre a experiência de fruição da *playlist*.

Nossa pesquisa se concentra em investigar como a concepção de gosto pautada pelo Spotify se relaciona com as preferências dos usuários e os significados que eles associam à curadoria

supostamente personalizada e praticada pela plataforma.

Propomos como hipótese que a plataforma alcança resultados favoráveis junto à maioria dos usuários devido às estratégias adotadas para fortalecer a nova etapa de seu modelo de negócio, iniciada entre 2013/2014, com foco na personalização (Eriksson *et al.*, 2019).

Como metodologia, definimos a análise do material tornado público pelo Spotify e os engenheiros envolvidos na construção da *playlist*, além da coleta – ao longo de dois anos (2019-2021) – de *tweets* que mencionassem a *playlist*. Utilizando a Análise de Conteúdo (Sampaio; Lycarião, 2021), classificamos os principais eixos de sentido que envolvem a perspectiva dos usuários sobre suas descobertas musicais.

Nos dados coletados é possível perceber disputas e controvérsias entre a forma como foram projetados esses sistemas e os aspectos subjetivos dos usuários. Para entender tais relações, contextualizamos, na próxima seção, o consumo de música na contemporaneidade, vinculado à ascensão das plataformas de streaming e seus SR, bem como a análise do funcionamento da *playlist* e suas perspectivas críticas. Nas seções seguintes, apresentamos uma abordagem teórica sobre o conceito de gosto musical, seguida do percurso metodológico para a coleta e análise das publicações do X/Twitter. Por fim, apresentamos os resultados, com destaque para evidências de uma *naturalização* dos sistemas algorítmicos de recomendação como constituintes da formação dos gostos dos usuários.

1 Virada curatorial e algorítmica

Ao considerarmos a quantidade de assinantes, o Spotify se destaca como a plataforma dominante no mercado de *streaming* de música, detendo uma fatia significativa das assinaturas (31,7%) – mais que o dobro do segundo lugar.⁴ Idealizada e criada em 2006, a partir de 2013/14 a empresa

² Disponível em: https://s29.q4cdn.com/175625835/files/doc_financials/2024/q1/Q1-2024-Shareholder-Deck-FINAL.pdf. Acesso em: 26 maio 2024.

³ A sigla "SR" será utilizada como referência aos Sistemas de Recomendação.

⁴ Disponível em: <https://www.midiaresearch.com/blog/global-music-subscription-market-sees-growth-led-by-emerging-markets-midia-research-q3-2023-report>. Acesso em: 26 maio 2024.

sueca passou pelo que alguns autores chamam de "virada curatorial e algorítmica" (Chodos, 2019; Morris, 2015), quando ocorreram investimentos em infraestrutura, além da aquisição de empresas especializadas em curadoria humana e algorítmica (Eriksson *et al.*, 2019).

A evolução do modelo de negócio do Spotify pode ser interpretada como uma transição da ênfase inicial dada ao acesso amplo a uma vasta biblioteca de fonogramas, para uma abordagem centrada na entrega personalizada, fundamentada na curadoria e na capacidade preditiva dos algoritmos. Em 2014, buscando consolidar essa atualização em seu modelo de negócio, o Spotify adquiriu a empresa The Echo Nest. A compra agrega à plataforma métodos fundamentais para a construção da *playlist* "Descobertas da Semana".

Este artigo parte de duas premissas quanto ao funcionamento dos SR de música em plataformas como o Spotify. A primeira aborda o que De Marchi *et al.* (2021) destacam sobre a concepção de gosto subjacente às recomendações personalizadas. De acordo com os autores, a ótica dos desenvolvedores desses sistemas "tem nos avanços da neurologia o material para pensar outra concepção de gosto que está além das sustentadas tanto pela filosofia quanto pela sociologia" (De Marchi *et al.*, 2021, p. 16). Outros pesquisadores (De Jong; Prey, 2022), também relacionam essa perspectiva de gosto a uma base behaviorista, uma vez que se pautam por uma "abordagem neurológica do gosto" (De Marchi, *et al.*, 2021).

No contexto dos Estudos de Plataforma (De Waal; Poell; van Dijck, 2018; D'Andréa, 2020; Montardo, 2022), sobretudo se considerarmos a produção cultural (Poell; Nieborg; Duffy, 2022), o Spotify assume um papel editorial significativo (Gillespie, 2018) através da curadoria, recomendação e descoberta musical. Essa habilidade coloca a plataforma em posição de moldar as tendências de consumo dos usuários globais de música conforme seus próprios termos.

A partir disso, nossa segunda premissa se baseia nas análises dos pesquisadores Tiziano Bonini e Alessandro Gandini ao argumentarem que a curadoria realizada por

plataformas de streaming de música combinando algoritmos proprietários e curadores humanos constituem os "novos *gatekeepers*" em uma indústria anteriormente dominada por intermediários humanos, como programadores de rádio, jornalistas e outros especialistas (2019, p. 1, tradução nossa).⁵

Os autores examinam as variações na maneira como a curadoria de música se desenvolve no contemporâneo, distribuída entre "lógicas parcialmente editoriais, parcialmente algorítmicas, pelas quais a agência humana se mistura com o funcionamento automatizado de infraestruturas algorítmicas", funcionando como "novas formas de poder baseado nesta mistura" (Bonini; Gandini, 2019, p. 2, tradução nossa).⁶ Neste contexto, as técnicas de curadoria e personalização buscam estabelecer regimes de relevância quanto aos conteúdos apresentados, determinando quais materiais serão exibidos aos usuários, por meio de uma curadoria híbrida.

Em sua pesquisa, Marie Santini (2020) apresenta uma evolução dos SR, começando com uma primeira geração no final dos anos 1970. Uma segunda geração se desenvolve na década de 1990, culminando em sistemas que emergem na terceira geração, entre os anos 2000 e 2010, como o Spotify (Santini, 2020, p. 162). Nesta última, a autora identifica a integração das características dos dois métodos descritos a seguir, resultando no terceiro método – a "abordagem híbrida" –, mais sofisticado em termos de personalização das recomendações. Os três métodos são:

1. *Recomendações baseadas em conteúdo*: sistemas que recomendam itens similares aos que o mesmo usuário demonstrou preferência no passado;
2. *Recomendações colaborativas*: sistemas que recomendam ao usuário itens

⁵ Do original: music streaming platforms in combining proprietary algorithms and human curators constitute the 'new gatekeepers' in an industry previously dominated by human intermediaries such as radio programmers, journalists, and other experts.

⁶ Do original: consists of partly editorial, partly algorithmic logics whereby human agency blends with the automated functioning of algorithmic infrastructures in ways that exert new forms of power based on this intermingling.

avaliados no passado por pessoas com gostos e preferências similares;

3. *Abordagem híbrida*: sistemas que combinam o método colaborativo com o método baseado em conteúdo (Santini, 2020, p. 114).

Com a chegada da terceira geração, esses sistemas assumem uma posição estratégica como orientadores dos processos que direcionam o consumo de bens culturais. Santini argumenta ainda que "cada vez mais delegamos a esses algoritmos a capacidade de separar as 'boas' e 'más' informações, usando-os para determinar valor, autenticidade, legitimidade, origem e propriedade dos conteúdos" (Santini, 2020, p. 14).

Em sua etnografia, Nick Seaver (2022) identifica uma percepção por parte dos principais desenvolvedores de SR do mercado de que o acúmulo e o excesso de opções representariam um problema a ser solucionado por meio de entregas mais assertivas e individualizadas. Esse

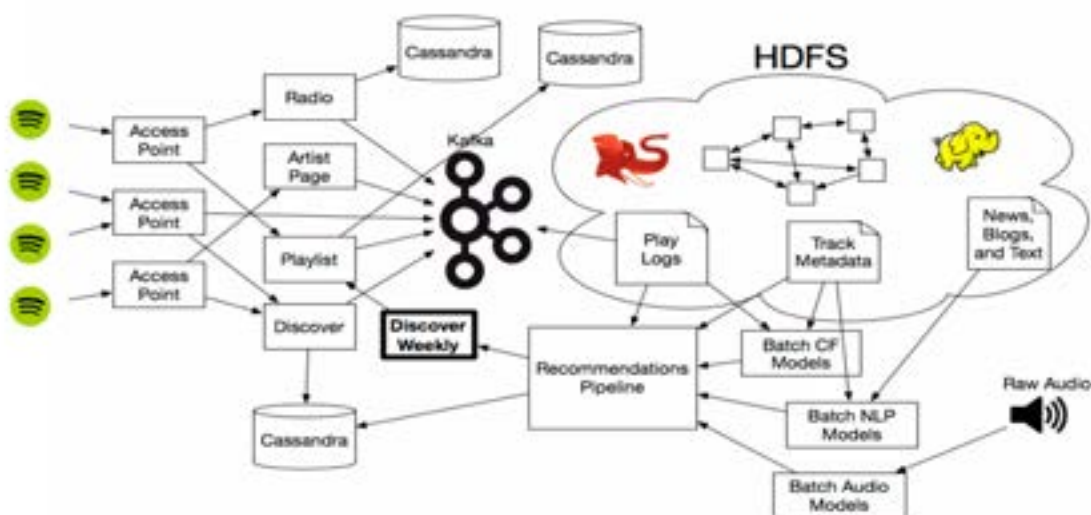
panorama reforça a busca por uma curadoria que atenda ao desejo de reconhecimento dos usuários, enquanto os mantêm engajados por mais tempo em um espaço dito "personalizado".

1.1 A construção da playlist "Descobertas da Semana"

O Spotify realiza a seleção das faixas que irão compor a *playlist* "Descobertas da Semana" utilizando três tecnologias. Uma delas é a Filtragem Colaborativa (*Collaborative Filtering*), apontada por Marie Santini no segundo método e amplamente utilizada em SR. As outras duas abordagens – Processamento de Linguagem Natural (*Natural Language Processing – NLP*)⁷, e a análise da faixa de áudio (*Audio Analysis*) – foram incorporadas ao Spotify após a aquisição da *The Echo Nest*, em 2014. Na Figura 1, apresentamos o fluxo de dados relacionado à curadoria algorítmica do SR do Spotify responsável pela *playlist*.⁸

Figura 1 – Fluxo de dados da *playlist* "Descobertas da Semana"

Discover Weekly Data Flow



Fonte: Slide 29 da apresentação de Chris Johnson.

⁷ O Processamento de Linguagem Natural (PLN) é um ramo da Ciência da Computação e da Inteligência Artificial que busca compreender e desenvolver aplicações envolvendo a compreensão e interpretação automatizada da linguagem humana.

⁸ Apresentação realizada pelo engenheiro Chris Johnson durante o evento "Austin Data Meetup - SXSW Edition", em 11 de março de 2016. Ressaltamos que a *playlist* – e os documentos relacionados – foram desenvolvidos entre 2014 e 2016, podendo ter sofrido alterações desde então. Disponível em: https://www.youtube.com/watch?v=HWFYA6NguAo&ab_channel=AustinDataMeetUp. Acesso em: 26 maio 2024. Os slides da apresentação encontram-se disponíveis em: <https://pt.slideshare.net/MrChrisJohnson/from-idea-to-execution-spotifys-discover-weekly>. Acesso em: 26 maio 2024.

A partir da imagem, vemos – agrupados sob a sigla “HDFS” – que as informações sobre faixas executadas por um usuário (“Play Logs”), os metadados associados às essas faixas (“Track Metadata”) e a análise textual realizada em sites, blogs, resenhas e críticas online (“News, Blogs and Text”) são as informações que alimentarão as três etapas que aparecem circuladas em vermelho na imagem. A partir disso, podemos perceber a centralidade desses processos em relação à alimentação do *pipeline*⁹ de recomendação (“Recommendations Pipeline”).

A Filtragem Colaborativa, representada por “Batch CF Models” na Figura 1, é a primeira técnica, que busca capturar as interações dos usuários na plataforma (“Play Logs”), incluindo eventos “positivos” – como salvar uma música em uma *playlist* pessoal, curtir álbuns e músicas, seguir um artista – e interações “negativas” – como avançar uma faixa ou clicar no botão “ocultar”, uma forma de indicar que a música presente na *playlist* “Descobertas da Semana” não representa

o gosto do usuário. Com base nesses dados, o Spotify cria perfis de gosto personalizados. Através da identificação de pontos em comum entre os usuários, o sistema sugere músicas que outras pessoas com gostos semelhantes apreciaram, mas que você ainda não conhece (Santini, 2020, p. 119).

No SR da plataforma, os rastros digitais relacionados às interações são representados por uma matriz de dois vetores: usuários e músicas. Cada linha da matriz representa um usuário, enquanto cada coluna representa uma música. Essa matriz binária indica a existência ou não de interações entre usuários e músicas, com valores 1 para interações presentes e 0 para interações ausentes. Comparando os vetores dos usuários, o sistema consegue identificar “perfis de gosto” semelhantes. Essa análise se baseia na busca por faixas apreciadas por usuários com perfis similares ao do usuário em questão, mas que ainda não foram ouvidas por ele (Ciocca, 2017; Whitman, 2012).

Figura 2 – Matriz de dois vetores (usuários e canções)

Implicit Matrix Factorization

- Aggregate all (user, track) streams into a large matrix
- Goal: Approximate binary preference matrix by inner product of 2 smaller matrices by minimizing the weighted RMSE (root mean squared error) using a function of plays, context, and recency as weight

$$\text{Users} \begin{pmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 & 1 & 1 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 0 & 1 \end{pmatrix} \approx \underbrace{\begin{pmatrix} \text{X} \\ \text{Y} \end{pmatrix}}_f \} f$$

Songs

$$\min_{x,y} \sum_{u,i} c_{ui} (p_{ui} - x_u^T y_i - \beta_u - \beta_i)^2 + \lambda (\sum_u \|x_u\|^2 + \sum_i \|y_i\|^2)$$

- $p_{ui} = 1$ if user u streamed track i else 0
- $c_{ui} = 1 + \alpha r_{ui}$
- x_u = user u 's latent factor vector
- y_i = item i 's latent factor vector
- β_u = bias for user u
- β_i = bias for item i
- λ = regularization parameter

[1] Hu Y. & Koren Y. & Volinsky C. (2008) Collaborative Filtering for Implicit Feedback Datasets 8th IEEE International Conference on Data Mining

Fonte: Slide 31 da apresentação de Chris Johnson.

⁹ O termo “*pipeline*” refere-se ao processo em que múltiplas instruções são executadas simultaneamente.

A partir da segunda tecnologia utilizada na construção da *playlist* – o Processamento de Linguagem Natural (“*Batch NLP Models*” na Figura 1) – a plataforma analisa e interpreta textos *online* de diversas fontes, como *sites*, artigos de notícias, *blogs*, periódicos, resenhas e críticas, para extrair informações relevantes sobre as músicas e os artistas presentes nos conteúdos. Neste processo, informações são extraídas de textos e agrupadas

em “vetores culturais” (Ciocca, 2017). Cada vetor cultural representa uma música ou artista e é composto por seus “termos principais”. Os termos são pontuados considerando sua frequência e relevância. A abordagem representa relações matemáticas entre palavras, onde a frequência e a força de associação com uma determinada canção/artista podem ser identificadas através da pontuação atribuída a cada termo.

Figura 3 – Modelos de PNL em notícias e blogs

NLP Models on News and Blogs



Fonte: Slide 33 da apresentação de Chris Johnson.


A última abordagem (“*Batch Audio Models*” na Figura 1) identifica similaridades entre canções através da análise do seu espectro sonoro (“*Raw Audio*”, ou “áudio bruto”). Cada faixa é processada por redes neurais convolucionais¹⁰, que calculam estatísticas a partir de características específicas como fórmula de compasso, andamento,

timbre, batida, frequência, amplitude, sílabas vocais, notas e outras variáveis mensuráveis por computador (Chodos, 2019; Ciocca, 2017; Whitman, 2005, 2012). A Figura 4 ilustra essa técnica, demonstrando como ela “varre” os arquivos de áudio por meio de camadas de redes neurais, identificando padrões e classificando as canções.

¹⁰ As chamadas redes neurais convolucionais (*Convolutional Neural Network - CNN*) atuam identificando as semelhanças subjacentes aos padrões acústicos contidos nas faixas. Inspiradas por processos biológicos, as camadas sucessivas, conforme a Figura 4 reproduz, estão empenhadas no refinamento e aprimoramento de identificação dos padrões.

Figura 4 – Aplicação de *Deep Learning*¹¹ sobre a faixa de áudio e a leitura do espectro sonoro.

Deep Learning on Audio



Fonte: Slide 35 da apresentação de Chris Johnson.

1.2 Perspectivas críticas

Ao considerarmos os problemas que podem surgir com a aplicação de cada uma das três técnicas apresentadas, ressaltamos o que identifica Marie Santini quanto à primeira delas, a Filtragem Colaborativa. A autora aponta três limitações, sendo elas:

1. *Problema do primeiro avaliador*: quando um novo item aparece no banco de dados, não existe maneira de este ser recomendado para o usuário até o momento em que mais informações sejam obtidas por meio de algum outro usuário. Esse problema é chamado de "Cold Start";
2. *Problema de pontuações esparsas*: o objetivo dos sistemas de filtragem colaborativa é ajudar pessoas a encontrar informação relevante, focando em itens utilizados ou adquiridos previamente por outros. Caso o número de usuários seja pequeno em relação ao volume de informações no sistema, existe um grande risco das pontuações tornarem-se muito esparsas;
3. *Similaridade*: caso um usuário tenha gostos que variam muito dos padrões de uso conhe-

cidos pelo sistema ou da média dos perfis de usuários de uma determinada comunidade, ele terá dificuldades para encontrar outros usuários com gostos similares. Sendo assim, as recomendações direcionadas a esse usuário podem se tornar repetitivas ou pouco relevantes. Ou seja, quanto maior a diferença de gosto entre os usuários, mais inadequadas tendem a ser as recomendações do sistema (Santini, 2020, p. 119).

O projeto *Forgotify* revelou que aproximadamente um quinto de todas as músicas disponíveis no Spotify nunca receberam reprodução dentro da plataforma.¹² Além disso, ao examinarmos as duas primeiras técnicas (FC e PLN), identificamos que ambas se relacionam com a percepção pública sobre um artista ou música, expressa nas interações dos usuários, ou na força de propagação de um conteúdo na internet. Assim, SR emergem como potenciais vetores de distorção, destacando as disparidades nos níveis de popularidade, influência e poder econômico entre os agentes. Além disso, a diversidade pode estar

¹¹ O aprendizado profundo de máquina (*Deep Learning*) constitui uma área do aprendizado de máquina (*Machine Learning*), no qual redes neurais artificiais – algoritmos concebidos para emular o funcionamento do cérebro humano – são treinadas. Elas utilizam vastas quantidades de dados e operam a partir de várias camadas.

¹² Disponível em: <https://www.tenhomaisdiscosqueamigos.com/2015/05/08/forgotify-aplicativo-reune-musicas-nunca-reproduzidas-no-spotify>. Acesso em: 26 maio 2024.

comprometida, já que tais tecnologias tendem a favorecer determinados tipos de conteúdo em detrimento de outros, reduzindo assim a variedade de experiências disponíveis para o público. Pesquisadores identificaram, por exemplo, um *viés sexista na plataforma* ao descobrirem “que a esmagadora maioria dos artistas recomendados pelo Spotify era do sexo masculino, sugerindo que a autoridade curatorial do Spotify é implantada de forma a manter o privilégio masculino nas indústrias da música” (Erikson *et al.*, 2019, p. 149, tradução nossa).¹³

Por meio de sua infraestrutura de dados, o Spotify elabora perfis comportamentais em seu SR. Técnicas como a Filtragem Colaborativa utilizam esse conhecimento para agrupar usuários e identificar as intersecções entre comportamentos de consumo. De acordo com Fernanda Bruno, os perfis construídos por sistemas algorítmicos não representam um

indivíduo específico, mas sim expressa relações entre indivíduos, sendo mais interpessoal do que intrapessoal. O seu principal objetivo não é produzir um saber sobre um indivíduo identificável, mas usar um conjunto de informações pessoais para agir sobre similares. O perfil atua, ainda, como categorização da conduta, visando à simulação de comportamentos futuros. Neste sentido, um perfil é uma categoria que corresponde à probabilidade de manifestação de um fator (comportamento, interesse, traço psicológico) num quadro de variáveis (2013, p. 161).

A *The Echo Nest* foi fundada em 2005 por Tristan Jehan e Brian Whitman, a partir de suas teses desenvolvidas no MIT sobre música e computação e com foco em soluções e aplicações comerciais (Jehan, 2005; Whitman, 2005). Ao buscar compreender como Whitman desenvolveu a aplicação da segunda tecnologia (PLN) para a música, Maria Eriksson identifica alguns problemas. Ao analisar a *web* para a criação de metadados musicais, o PLN se depara com diversos desafios que a au-

tora descreve como “links mortos, posts órfãos, confusão de nomes e repostagens” (2016, p. 13, tradução nossa).¹⁴ Eriksson encontrou apenas um site em italiano, evidenciando um viés do sistema para conteúdos em inglês. A autora também destaca a introdução de dados aleatórios e não intencionais provenientes de sites e *links* inexistentes, republicações que duplicam informações e confusões entre termos e nomes de artistas, causadas pela leitura automatizada. Apesar disso, Whitman (2012) defende que sua tecnologia é capaz de entender novos termos à medida que são incorporados ao ambiente digital, funcionando em diversos idiomas derivados do latim, representando, na visão do autor, uma perspectiva social do que se fala sobre música no ambiente digital.

Asher Tobin Chodos (2019) critica a tese de Whitman (cujo título é “Aprendendo o significado da música” – tradução livre¹⁵), por sua abordagem limitada na tentativa de ensinar máquinas a entenderem o significado da música. Chodos argumenta que Whitman falha em analisar profundamente a complexa captação e interpretação da informação cultural pelas máquinas, e que sua abordagem negligencia a construção de um diálogo substancial com perspectivas teóricas consolidadas.

Kate Crawford (2021) critica a forma como o PLN opera desde seus primórdios, em meados da década de 1980. Segundo a autora, as bases de dados utilizadas por esses sistemas eram compostas por arquivos de texto “vistos como coleções neutras de linguagem, como se houvesse uma equivalência geral entre as palavras em um manual técnico e como as pessoas escrevem para colegas via e-mail” (Crawford, 2021, p. 103, tradução livre)¹⁶. Essa prática persiste até hoje, com “feeds de mídia social [...] ingeridos para construir modelos preditivos de linguagem” (2021, p. 220, tradução livre)¹⁷. O SR do Spotify é

¹³ Do original: we found that an overwhelming majority of Spotify's recommended artists were male, suggesting that Spotify's curatorial authority is deployed in ways that maintain male privilege in the music industries.

¹⁴ Do original: dead links, orphan posts, name confusions, and re-posts.

¹⁵ Do original: Learning the meaning of music.

¹⁶ Do original: seen as neutral collections of language, as though there was a general equivalence between the words in a technical manual and how people write to colleagues via email.

¹⁷ Do original: social media feeds have been ingested to build predictive models of language.

um exemplo emblemático por se basear na coleta indiscriminada e não consentida de informações sobre música no ambiente digital, envolvendo críticas, resenhas, *blogs* e sites.

Destacamos, ainda, que apenas a terceira tecnologia – desenvolvida a partir da tese de Tristan Jehan (2005)¹⁸ – busca construir recomendações pautadas pela canção em si. Ainda assim, uma série de questões críticas quanto à leitura do espectro sonoro e à forma como o sistema aplica significação cultural a esses sinais precisam ser aprofundados no sentido de compreendermos melhor quais informações musicais são consideradas pertinentes e por quê. De todo modo, analisando o sistema de forma abrangente, percebemos uma simplificação epistemológica das nuances presentes na música e na subjetividade dos usuários, convertidas em sinais que requerem classificação e organização para serem utilizados na previsão – lógica central do aprendizado de máquina – e personalização das entregas.

2 Sobre o gosto musical: para além da distinção

Em suas obras sobre gosto, especialmente *A Distinção* (2017), Bourdieu (1965, 2007) descreve uma sociedade estruturada em três principais grupos sociais, cada um associado a um tipo específico de gosto: o gosto tido como legítimo, pertencente à burguesia; o gosto médio, relativo às classes médias, ou pequeno-burgueses; e o gosto popular, vinculado às classes populares. A classe dominante, representada pela burguesia, é descrita por Bourdieu como detentora de uma espécie de senso de distinção. Já as classes médias, estas teriam uma certa boa vontade cultural, enquanto as populares e mais baixas seriam confrontadas com a escolha do que é exclusivamente necessário.

A sociologia do gosto de Pierre Bourdieu constrói, a partir disso, uma abordagem que explicita hierarquias que classificam as distâncias entre classes sociais e cultura. A menor ou maior distância entre sujeitos e práticas representariam

estratégias de distinção social entre aqueles que possuem formas de consumo "elevado" e crítico, portanto os dominantes, e aqueles que possuem formas de consumo "vulgar", os dominados. Cada grupo estaria caracterizado por sua cultura específica relacionada à classe social a que pertence – o autor dá a esse processo o nome de homologia. Para Bourdieu, o gosto não é resultado de um eu subjetivo, mas das articulações sociais que se formam em processos de diferenciação. Esses processos são responsáveis por tornar um determinado tipo de gosto legítimo ou ilegítimo, provocando distinção entre os indivíduos e as classes sociais.

Na década de 1980, os meios de comunicação e suas práticas de consumo cultural ganham protagonismo, desafiando as hierarquias e os valores propostos por Bourdieu. Isso leva autores como Paul DiMaggio (1987), Lawrence W. Levine (1988), Richard A. Peterson (1992, 1997) a reavaliarem as ideias de Bourdieu sobre distinção e julgamento estético. Esses autores argumentam que as Indústrias Culturais e os meios de comunicação passaram a ter maior penetração social, assumindo um papel predominante na legitimação dos bens culturais e simbólicos, além de funcionarem como instâncias que orientam as condutas dos indivíduos e deslocam a autoridade cultural. Com a transformação nos meios de produção, distribuição e acesso à cultura, os autores demonstraram que as formas de consumo cultural não poderiam mais se basear na distinção entre culturas legítimas e ilegítimas, ou nos gostos elitistas e populares, como propunha Bourdieu.

Richard A. Peterson (1992) propôs duas categorias explicativas para os novos usos sociais e preferências culturais: *omnívoros* e *unívoros*. Peterson utiliza uma "metáfora zoológica" para aproximar sua abordagem da teoria do capital cultural e do espaço social dos estilos de vida de Bourdieu. Os *omnívoros* seriam os indivíduos que consomem uma ampla variedade de bens culturais, incluindo os mais e os menos legítimos, enquanto os *unívoros* consumiriam apenas

¹⁸ A abordagem compreende a possibilidade de um computador receber um sinal sonoro e aplicar sentido e gradações a ele.

um ou poucos gêneros. Peterson sugere uma mudança nas categorias de consumo de elite e massa, propondo a oposição entre omnívoros e unívoros, com as classes superiores se caracterizando por um consumo eclético e as classes baixas por preferências culturais mais limitadas. Posteriormente, Peterson revisa suas conclusões, reconhecendo que ambos os perfis de consumo podem ser encontrados em todas as classes sociais, e incluindo a ideia de que indivíduos podem limitar seu consumo cultural devido a crenças religiosas, condições morais, ascetismo cultural ou à lógica dos fãs, resultando em uma restrição consciente.

Alguns sociólogos, como Antoine Hennion (2001, 2011), adotaram abordagens diferentes das tradicionais hierarquias culturais, rejeitando a noção de legitimidade como um reflexo da arbitrariedade do sociólogo. Em contraponto, Hennion propõe a ideia de "performance de gosto", que destaca o papel das materialidades dos bens culturais e corpos na construção do gosto e atividades performativas que transformam e engajam os indivíduos. Para ele, degustar não é um processo passivo, mas uma prática ativa que envolve mediações entre objetos e sujeitos. Hennion também vê o gosto como uma atividade reflexiva e coletiva, e utiliza a Teoria Ator-Rede para explorar os vínculos entre "amadores" e seus objetos de adoração, tratando-os como atores não humanos relevantes. Em suas análises, ele defende que o gosto é algo processual, não dado ou fixo, e que deve ser entendido a partir de quatro elementos essenciais: os objetos degustados, os coletivos de "amadores", os dispositivos de degustação e o corpo que experimenta. Esses componentes formam uma "armadura mínima" que guia a fruição, moldada pelas experiências dos "amadores".

Afiliamo-nos a esta perspectiva neste trabalho,

entendendo a plataforma de *streaming* musical Spotify como um dispositivo de degustação, um ator não humano, relevante nas performances de gosto na contemporaneidade e focando em um grupo específico de "amadores": usuários da plataforma Spotify que comentam sobre recomendações recebidas usando para tal a plataforma de rede social X/Twitter.

3 Procedimentos metodológicos

Para compreender a relação entre a personalização das entregas e o que os usuários dizem sobre a *playlist*, coletamos postagens realizadas na plataforma X/Twitter, por meio da ferramenta Netlytic¹⁹, considerando o período de dois anos – abril de 2019 e abril de 2021. Após a coleta e limpeza dos dados, identificamos 2.215 postagens pertinentes ao estudo. Em seguida, empreendemos a Análise de Conteúdo (Sampaio; Lycarião, 2021) das publicações.

Com a análise dos *tweets* buscamos entender em que medida a noção de gosto pautada pelo SR da plataforma contrasta com as preferências dos usuários. Entendemos os *tweets* a partir da necessidade dos sujeitos de performar fenômenos discursivos nos quais buscam refletir sobre si mesmos e suas identidades.

A partir disso, a análise buscou identificar os sentidos que os usuários dão a essa relação e qual a valência presente nas publicações. Portanto, categorizamos os *tweets* em três macroposicionamentos: o de corroborar as recomendações ("favoráveis"); o de refutá-las ("contrários"); e aqueles posicionamentos considerados "neutros". Posteriormente, visando dar especificidade aos eixos de sentido, cada categoria foi subdividida em quatro categorias menores, totalizando 12 subcategorias. Todas foram testadas previamente²⁰, para que, posteriormente, os *tweets* fossem

¹⁹ Para o monitoramento e captura foram considerados os termos: descoberta, semana, spotify, discover, weekly e playlist. Juntos, numa estrutura de co-ocorrência utilizando operadores booleanos – "e" (*and*), "ou" (*or*) e "não" (*not*) –, tornaram viável a captura de *tweets* de usuários que fizessem postagens em torno do recorte da pesquisa. Cabe destacar que o acesso à API gratuita do X/Twitter foi descontinuado em julho de 2023. Atualmente a plataforma disponibiliza apenas planos pagos para a coleta. Disponível em: <https://netlytic.org>. Acesso em: 26 maio 2024.

²⁰ Buscamos mapear categorias identificadas a partir de uma primeira leitura após um ano de coleta, onde classificamos 445 *tweets*. Essa abordagem exploratória destacou categorias dedutivas iniciais e que serviram de base para a categorização final.

categorizados²¹ duas vezes por um único codificador, em momentos diferentes e distantes no tempo por duas semanas.²²

Cabe considerar aqui as limitações de amostragem no uso de ferramentas como o Netlytic para a coleta de dados do X/Twitter. Durante o período em que a API gratuita estava acessível, a plataforma fornecia apenas 1% do conteúdo relacionado a um determinado tema (Howard; Neudert; Kollanyi, 2019). Embora o X/Twitter não revele os índices de amostra das entregas

(Blank, 2017), a análise de dados provenientes da plataforma mostrou-se útil em diversos estudos. No entanto, é fundamental considerar que tais resultados não são representativos da população como um todo.

4 Resultados

No Quadro 1, fornecemos um resumo das categorias identificadas²³ junto à quantidade de *tweets* atribuídos a cada uma delas:

Quadro 1 – Resultados da Análise de Conteúdo dos *tweet* (macro e microcategorias)

CÓD.	MACRO	COD.	MICROCATEGORIA	TWEETS
01	Neutros 430 <i>tweets</i> 19,4%	0101	Sem valoração	109 (4,9%)
		0102	Perspectiva técnica	35 (1,6%)
		0103	Manipulação algorítmica e empreendedorismo de si	29 (1,3%)
		0104	Outros	257 (11,6%)
02	Favoráveis 1.199 <i>tweets</i> 54,1%	0201	Exaltação e entusiasmo	428 (19,3%)
		0202	Corroboração explícita da lógica algorítmica	305 (13,8%)
		0203	Humor, comicidade e sarcasmo – positivo	233 (10,5%)
		0204	Outros	233 (10,5%)
03	Contrários 586 <i>tweets</i> 26,5%	0301	Ironia, dubiedade, duplo sentido e sarcasmo – negativo	119 (5,4%)
		0302	Quebra de expectativa, decepção, questionamento	296 (13,4%)
		0303	Negação, enfrentamento, refutação	118 (5,3%)
		0304	Outros	53 (2,4%)

Fonte: Autores.

A macrocategoria "Favoráveis" demonstra que mais da metade das postagens (54,1%, ou 1.199 *tweets*) expressam satisfação com a experiência, indicando um alinhamento quanto às preferências e gostos dos usuários. Também identificamos um percentual de discordância significativo (26,5% considerados "contrários"), com inúmeros relatos que evidenciam alguma forma de dissonância na performance do sistema e na compreensão dos gostos dos ouvintes. Outros 19,4% foram enquadrados numa perspectiva neutra, com destaque para comentários técnicos sobre a *playlist*, além de perspectivas de manipulação dos resultados.

4.1 Macrocategoria 01: "Neutros"

Das postagens analisadas, 430 *tweets* (19,4%) foram classificados como "neutros" e subdivididos em quatro categorias menores. Na microcategoria 0101 ("Sem valoração") incluímos os *tweets* que não apresentaram avaliação das recomendações em relação às preferências dos usuários. Exemplos como: "Meu *discover weekly* do spotify nunca teve uma linearidade de tipo musical. Ele vai muito facilmente do sertanejo ao indie de uma semana a outra", demonstram que nem sempre é possível compreender se o comentário é sobre a compreensão e assertividade daquilo que o

²¹ O livro de códigos encontra-se disponível em: <https://docs.google.com/document/d/1FSbk5fWjEZdaCflhvb5zFbdseSQ5khSzJ-jkVfvmvujWE/edit?usp=sharing>. Acesso em: 26 maio 2024.

²² Realizamos um teste para avaliar a precisão entre os resultados obtidos na primeira e segunda categorização, alcançando um índice de concordância de 90,1%. Os resultados do teste apresentaram 0,843 para alfa de Krippendorff.

²³ A planilha com os dados coletados encontra-se disponível em: https://docs.google.com/spreadsheets/d/1KVdw8iK7XFHmVcPsS-sn_ORYirhVsEVJG3-ku6T42hTE/edit?usp=sharing. Acesso em: 26 maio 2024.

usuário gosta e anseia.

Outros exemplos classificados nessa microcategoria trazem questionamentos, mas também não apresentam uma relação clara entre o gosto do ouvinte e as entregas da plataforma: "pq so tem nome de droga nas mias descoberta da semana"; "pq todo mundo decidiu falar da *playlist* descoberta da semana no twitterrr". Algumas postagens incluem comentários que demonstram interesse na *playlist* de outros usuários. Muitos perfis simplesmente mencionavam que estavam ouvindo a *playlist*, enquanto outros compartilhavam links para suas próprias "Descobertas da Semana".

Trinta e cinco (35) postagens foram categorizadas como "*Perspectiva técnica*" (0102), o que representa 1,6% do total de postagens analisadas. Nesta categoria, alguns *tweets* estabelecem comparações entre plataformas: "a Amazon tem esse rolê de radar de novidade e descobertas da semana, igual Spotify?". Muitos envolvem questões técnicas direcionadas ao perfil oficial do Spotify. Ocasionalmente, essas mensagens recebiam respostas de um perfil administrado pela empresa (@SpotifyAjuda).

A microcategoria "*Manipulação Algorítmica e Empreendedorismo de Si*" (0103) apresenta postagens que complexificam a lógica da coleta de dados relacionados aos comportamentos. Apesar de representarem uma parcela reduzida do total (1,3%, ou 29 *tweets*), identificamos que os usuários buscam construir modos de "manipular" o SR do Spotify e suas entregas, como neste exemplo: "Depois de meses ensinando o spotify as música que eu gosto, vou dar mais uma chance pro *discover weekly*". Outras postagens evidenciam um certo "empreendedorismo de si", onde os usuários buscam ensinar como são suas preferências e, portanto, como suas descobertas devem ser, como neste exemplo: "sempre bom lembrar que segunda é dia de *discover weekly* no spotify mas só pros que sabem usar o algoritmo direitinho como eu".

Também enquadramos nessa macrocategoria 257 *tweets* (11,6% – microcategoria 0104, "*Outros*") que apresentaram duplo sentido embora, por

vezes, existisse alguma perspectiva – indeterminável – de valorização. Este exemplo demonstra que, apesar de falar sobre a relação com as músicas presentes na *playlist*, não fica claro se a plataforma teria sugerido uma canção que se relaciona com as preferências do ouvinte: "90% das musicas da *playlist* de descoberta da semana no spotify sao gospeis. Ok @deus entendi".

4.2 Macrocategoria 02: "*Favoráveis*"

Enquadrados na macrocategoria "*Favoráveis*" os 1.199 *tweets* que afirmam ter uma experiência positiva com as entregas. Constatamos que o Spotify busca induzir uma sensação de prazer durante a experiência de escuta da *playlist*. Esse prazer seria gerado pelo reconhecimento do usuário nas músicas que a plataforma "descobre" e recomenda. O prazer a partir do reconhecimento, no contexto de uma sociedade de consumo permeada por inúmeros estímulos, surge das relações afetivas que esses sistemas buscam induzir e explorar. Observamos que as estratégias do Spotify para alcançar altos índices de retenção e engajamento mostram-se efetivas até certo ponto, conforme evidenciado pelo percentual de 54,1%.

Em "*Exaltação e Entusiasmo*" (0201), classificamos as 428 postagens (19,3%) que empregaram estratégias discursivas fundamentadas em expressões entusiasmadas, limitando-se a isso. As postagens tendem a ser simples, não oferecendo espaço para análises mais aprofundadas, como este exemplo demonstra: "A descoberta dessa semana veio uma coisa linda só. obrigada, Spotify". Consideramos como "exaltação e entusiasmo" as mensagens que empregaram recursos de linguagem que buscavam manifestar prazer e satisfação com as descobertas proporcionadas pela plataforma.

Classificamos 305 *tweets* (13,8%) como "*Corroboração Explícita da Lógica Algorítmica*" (0202). As postagens incluídas nessa categoria diferenciam-se da anterior por não deixarem dúvidas quanto à assertividade das recomendações em relação aos gostos dos ouvintes, como neste exemplo: "Nossa eu fico chocado como a descoberta da

semana no Spotify acerta em cheio as músicas que eu curto". Os *tweets* destacam de maneira mais consistente e consciente a precisão do SR do Spotify. Também identificamos uma conexão estreita com a marca, demonstrada pelo fato de os ouvintes frequentemente mencionarem o Spotify em postagens como: "Daí vem o @Spotify com 'descoberta da semana' e me dá vários gêneros de músicas que eu gosto pra eu ouvir *lemojis* de coração!".

A maneira como os ouvintes se referem ao algoritmo revela uma relação afetiva explícita em exemplos como: "nossa descoberta da semana estão perfeitas obrigada algoritminho" e "fui ouvir pela primeira vez a *playlist* 'Descobertas da semana' que o Spotify faz em cima do meu algoritmo e eu tô MORANDO nela". Reforçando a ideia de "personalização", o emprego de palavras como "minha", "meu" ou "pra mim" evidencia a sensação de pertencimento dos ouvintes: "Adoro a *playlist* que o Spotify faz pra mim como 'Descobertas da Semana' *lemojis* sorrindo!"; "minha descobertas da semana do Spotify tá simplesmente de parabéns"; "meu descobertas da semana tá pft".

Os 233 *tweets* (10,5%) que continham traços de "Humor, Comicidade e Sarcasmo" (0203) traziam narrativas que acrescentavam aspectos cômicos a partir de uma experiência declaradamente positiva em relação à acurácia da *playlist*, como estes exemplos demonstram: "eu salvei essa música do perfil do rm e hoje vi ela no meu *discover weekly* Spotify. nunca critiquei"; "Eu adoro que minha seção do descobertas da semana do Spotify é um tiro atrás do outro kkkkk".

Afirmativas dos usuários de que a *playlist* "finalmente" acertou foram recorrentes nesta microcategoria. Entendemos o uso deste advérbio como um recurso discursivo carregado de ironia, mas ainda assim dentro de um espectro positivo, como apontam os exemplos: "Finalmente o Spotify acertou no meu Descobertas da Semana"; "Spotify finalmente calibrou as minhas 'Descobertas da Semana' né, amém".

Na última microcategoria de postagens favoráveis, enquadramos 233 *tweets* (10,5%) classificados como "Outros" (0204). A categoria abrange posta-

gens que contêm relatos e experiências diversas que não se encaixam nas categorias anteriores, mas que, ainda assim, ressaltam a precisão do SR. Alguns exemplos classificados aqui são: "@RT eu senti uma melhora nas descobertas da semana"; "O que mais escuto no Spotify é o Descobertas da Semana. Semana passada tinha música da Karol Conká, nessa eles colocaram do Projota".

4.3 Macrocategoria 03: "Contrários"

Um espectro significativo dos dados contesta a experiência, apresentando situações que demonstram controvérsias quanto à forma como o Spotify percebe seus ouvintes. Do total da coleta, 26,5% (586 *tweets*) – um quarto das mensagens – afirmam ter algum tipo de problema com a *playlist* e a percepção de gosto da plataforma, apontando para o que Polivanov e Carrera têm denominado de "rupturas de performance". Essas rupturas dizem respeito a "intencionalidades, potencialidades na construção e apresentação de si que não foram de fato atingidas" (Polivanov; Carrera, 2019, p. 76).

Neste artigo identificamos casos de resistência às entregas do SR do Spotify a partir do que entendemos serem *rupturas na performance do sistema*, segundo a visão dos usuários. Isto é, indicações de músicas que não seriam condizentes com a "coerência expressiva" dos sujeitos (Polivanov, 2014) que, uma vez confrontados com as descobertas e recomendações, colocam em questão aquilo que entendem de si mesmos. Essas categorias, portanto, refletem o desconforto causado pela entrega inadequada do que o SR do Spotify considera uma "boa" recomendação ou descoberta.

Detectamos em 119 *tweets* (5,4%) uma abordagem negativa, utilizando recursos discursivos que remetem à "Ironia, Ambiguidade, Duplo Sentido e Sarcasmo" (0301). Os exemplos trazem postagens que tendem a explorar o humor na forma como criticam as músicas recomendadas: "Caraca, essa Descoberta da Semana do Spotify mandou só os kpop clássico, 2pm, shinhwa, b1a4, beast, pena que não gosto de nenhum kkk"; "tem semanas que o Spotify acerta direitinho nas descobertas

da semana. essa semana não."

Algumas recomendações sugerem músicas já familiares, quando deveriam se concentrar em apresentar apenas novas descobertas na plataforma: "Descobertas da Semana do spotify tá com várias músicas que já conheço, não sabia que tinha mudado pra Conhecidos da Semana". Outros exemplos trazem usuários que receberam recomendações tão ruins que passaram a questionar seus próprios gostos: "minha *playlist* de descoberta da semana do spotify é tao ruim que me faz questionar se o que eu ouço intencionalmente é bom"; "Meu *Discovery Weekly* está sempre uma merda. Será que eu que estou ouvindo muita música ruim? Ou será o algoritmo do Spotify não me compreende mais?".

Nos 296 *tweets* (13,4%) classificados como "Quebra de Expectativa, Decepção, Questionamento" (0302), as postagens apontam para incoerências e rupturas na performance do SR do Spotify. Vários *tweets* apontavam que o SR errou naquela semana, ou em relação a uma música específica, evidenciando problemas que não eram necessariamente recorrentes, mas que podiam indicar uma tendência preocupante. Em diversos casos, o uso de expressões que indicam um erro isolado, como "essa semana" ou "desta vez", sugere que a *playlist* acertou em outras ocasiões, mas tem enfrentado dificuldades recentes. Decepções e quebras de expectativas com as entregas aparecem em exemplos como: "a minhas descobertas da semana essa semana veio fraquinha"; "Descoberta da semana no meu spotify tá oh uma bosta"; "Descobertas da semana não deu uma dentro kkkkkk". Algumas publicações levantam questionamentos sobre como a curadoria da *playlist* opera, mencionando diretamente o perfil do Spotify: "@spotify se faz meses que uma banda está bloqueada de reproduzir músicas no meu perfil, por que vocês a colocam no *discover weekly* para mim???".

Dentre os 118 *tweets* (5,3%) categorizados como "Negação, Enfrentamento, Refutação" (0303), identificamos usuários que contestam as recomendações, negando a capacidade do sistema de funcionar adequadamente, como exemplificado

a seguir: "A rádio do iTunes de uns 6 anos atrás, que não tinha dados meus pra fazer um algoritmo condizente com meu gosto musical, me passava mais músicas que eu gostava do que a merda do algoritmo do @Spotify. *Release radar* e *discover weekly* sao sempre um compilado de músicas horrorosas".

Nestes *tweets*, observamos o uso frequente de palavras que pertencem a um espectro semântico negativo, tais como "bosta" (7 vezes), "merda" (6), "lixo" (5), "ruim" (5) e "horível" (3). Nos exemplos a seguir, ilustramos o emprego dessas palavras: "Ouvindo uma *playlist* feito pela Grimes já que o algoritmo do Spotify é um lixo e não me passa 1 música boa no *discover weekly*"; "Aqui está uma *playlist* para você... É o que o @SpotifyBR me manda toda segunda. O algoritmo dessa empresa fuma crack só pode. Um lixo essas Descobertas da Semana de Spotify. [link](#)"; "hora de ouvir as merda q o spotify coloca no *discover weekly*"; "O pior de tudo são essas músicas de 'descoberta da semana' que o spotify manda kkkkk"; "Normalmente a *playlist* semanal 'Descobertas da Semana' do Spotify é terrível, mas essa semana ela se superou, e não no bom sentido"; "Mais uma vez a *playlist* 'descobertas da semana' só com música bosta [link](#)".

Por fim, na categoria "Outros" (0304) identificamos 53 postagens (2,4%) que, além de carregarem uma conotação negativa, traziam relatos de experiências que não se relacionam com as categorias anteriores, mas ainda assim demonstram uma problemática quanto à acurácia por parte do SR. Aqui, são evocadas emoções negativas relacionadas à tristeza, depressão e apatia, como neste exemplo em que o usuário associa a qualidade da *playlist* à sua semana, transmitindo um clima negativo para os demais dias: "sabia que minha semana ia ser uma bosta quando meu *discover weekly* do spotify so veio música ruim". Neste outro exemplo, o comentário expressa a sensação de tristeza diante da experiência, sem especificar se isso foi apenas naquela semana ou algo recorrente: "Eu fico muito triste quando minhas descobertas da semana do Spotify não são boas...". Por outro lado, este *tweet* ressalta

consequências negativas durante a audição da *playlist* que, ao que parece, não foram antecipadas: "o foda de começar a descobrir música pelo descobertas da semana é que eu vou perdendo a vinculação com os artistas e só conheço uma ou duas músicas de cada".

Através da seleção de exemplos, procuramos destacar a diversidade de modos pelos quais os usuários constroem narrativas sobre as sugestões e recomendações que recebem. As relações observadas na interação entre o sistema e os usuários apontam para confirmações e contravérsias quanto aos processos de representação algorítmica em contraposição às identidades dos usuários. Nossa análise, portanto, buscou destacar a presença da naturalização e aceitação das descobertas, bem como dos conflitos e tensões que surgem das subjetividades individuais, mediadas por sistemas pautados pela curadoria e recomendação.

Conclusões

A mineração de dados, facilitada por amplas infraestruturas físicas e computacionais, juntamente com as interfaces e suas possibilidades de escolha e interação, combinadas com algoritmos avançados de aprendizado de máquina, conferiram aos SR uma capacidade de atuação em grande escala. No caso do Spotify, esses sistemas apresentam-se como soluções comerciais responsáveis por coletar, classificar e organizar fluxos de faixas e metadados, bem como as interações dos usuários. Essas informações são então utilizadas para criar perfis de preferências individuais e personalizar a entrega de conteúdo musical.

Em nossa análise, percebemos uma concepção específica de gosto, fundamentada na racionalidade e na simplificação epistemológica, e posta em prática a partir do SR do Spotify para a confecção da *playlist* "Descobertas da Semana". Concordamos com De Marchi et al. ao destacarem que esses ambientes são moldados a partir de uma "concepção neurológica do gosto", interpretando o consumo musical através de uma ótica funcionalista e que visa estimular determinadas

emoções. Na perspectiva dos autores, o gosto é percebido pela plataforma "como resultado, prioritariamente, de processos bioquímicos ativados por estímulos e processados pelo cérebro" (De Marchi et al., 2021, p. 18).

Ao identificarmos que existem poucas pesquisas que se concentram nas perspectivas dos usuários (Hesmondhalgh et al., 2023), buscamos apresentar uma contribuição para os Estudos de Plataforma, especialmente no contexto do consumo de música no Brasil. Nossos achados indicam que em grande parte das postagens (54,1%, totalizando 1.199 *tweets*) há uma notável correspondência entre como os usuários se percebem e como são enquadrados para receber suas descobertas, demonstrando que os usuários adotam a lógica algorítmica como um elemento constituinte da elaboração do próprio gosto.

Outros 26,5% dos *tweets* demonstram resistência ao modelo de gosto imposto pela plataforma. As 586 postagens contrárias revelam conflitos e expressões de descontentamento decorrentes de confrontos diante da "identidade" refletida nas recomendações. Essa insatisfação evidencia uma lacuna na atuação do sistema em relação à compreensão das preferências dos usuários. O fato de um quarto das postagens não se sentir representado revela uma discrepância significativa entre os algoritmos empregados pela plataforma, seu objetivo de personalização e as expectativas dos usuários.

Também é relevante notar que em muitos dos comentários, o "algoritmo" emerge como uma "entidade" que provoca reflexão nos usuários sobre suas próprias identidades. A forma como se dirigem ao algoritmo corresponde ao que Willian Araújo e João Carlos Magalhães propõem ao afirmarem que

a despeito de sua função infraestrutural, eles [os algoritmos] parecem ter também se tornado produtos culturais, que, mesmo sendo materialmente dispersos e invisíveis a olho nu, podem ser consumidos, circulados, discutidos, representados (Araújo; Magalhães, 2018, p. 22).

Nesse sentido, defendemos que as próprias plataformas de escuta musical são mediadoras

relevantes do gosto na contemporaneidade, devendo ser tratadas como agentes não humanos que afetam nossas performances de gosto e com os quais os usuários dialogam sobre suas preferências, seja confrontando as sugestões dadas pelos algoritmos, ou corroborando-as, visando aprimorá-las ou questionando sua atuação, dentre outras narrativas possíveis.

Salientamos, assim, também os *tweets* categorizados como "neutros", nos quais, em certas categorias (0102 e 0103), encontramos usuários que de certa forma tratam a *playlist* como um objeto de "estudo". Seja fazendo comentários técnicos, ou sugerindo que as entregas são passíveis de manipulação – como se fosse um projeto no qual o usuário deve se dedicar, visando "instruir" o algoritmo (conforme refletem Moreira; Araujo; Polivanov, 2024).

Destacamos nossa contribuição a partir dos esforços empreendidos aqui, uma vez que abordam a perspectiva dos usuários de sistemas de recomendação de plataformas de streaming de música. Reconhecemos que a representatividade em nossa análise foi um aspecto crítico, embora essa limitação possa ser parcialmente superada por meio de uma sugestão metodológica envolvendo entrevistas em profundidade com os perfis identificados. Isso pode proporcionar uma compreensão qualitativa do fenômeno, considerando as complexidades para além de um *tweet*.

Nos últimos dez anos, a chamada "indústria fonográfica digital" (De Marchi, 2023) consolidou-se e estruturou uma espécie de naturalização da atuação ativa dos usuários em seus processos de entregas personalizadas e no subsequente refinamento dessas entregas, viabilizado pela coleta extensiva de dados. Assim, trouxemos uma perspectiva empírica e reflexões que demonstram como uma parcela dos usuários do Spotify tem adotado e naturalizado a lógica algorítmica como substrato de construção do seu próprio gosto musical.

Referências

- AIROLDI, M. Digital traces of taste: methodological pathways for consumer research. **Consumption Markets & Culture**, [s. l.], v. 24, n. 1, p. 97-117, 2019. <https://doi.org/10.1080/10253866.2019.1690998>.
- ARAUJO, W. F.; MAGALHÃES, J. C. Eu, eu mesmo e o algoritmo: como usuários do Twitter falam sobre o "algoritmo" para performar a si mesmos. In: ENCONTRO ANUAL DA COMPOS, 27., 2018, Belo Horizonte. **Anais [...]**. Belo Horizonte: Pontifícia Universidade Católica de Minas Gerais, 2018.
- BLANK, G. The digital divide among Twitter users and its implications for social research. **Social Science Computer Review**, [s. l.], v. 35, n. 6, p. 679-697. 2017.
- BONINI, T.; GANDINI, A. "First Week Is Editorial, Second Week Is Algorithmic": Platform Gatekeepers and the Platformization of Music Curation. **Social Media and Society**, [s. l.], v. 5/4, p. 1-11, 2019.
- BOURDIEU, P. **A distinção: crítica social do julgamento**. 2. ed. rev. 4. reimpr. Porto Alegre, RS: Zouk, 2017.
- BOURDIEU, P. BOLTANSKI, L.; CASTEL, R.; CHAMBOREDON, J. C. **Une Art Moyen: essai sur les usages sociaux de la photographie**. Paris, Editions de Minuit, 1965.
- BOURDIEU, P. DARBEL, A. **O Amor pela Arte: os museus de arte na Europa e seu público**. 2 ed. Porto Alegre: Zouk, 2007.
- BRUNO, F. **Máquinas de ver, modos de ser: vigilância, tecnologia e subjetividade**. Porto Alegre: Sulina, 2013.
- CHODOS, A. T. What Does Music Mean to Spotify? An Essay on Musical Significance in the Era of Digital Curation. **INSAM Journal of Contemporary Music, Art and Technology**, [s. l.], v. 1, n. 2, jul. 2019.
- CIOCCA, S. How Does Spotify Know You So Well? In: **Medium**. [s. l.], 2017. Disponível em: <https://medium.com/s/story/spotifys-discover-weekly-how-machine-learning-finds-your-new-music-19a41ab76efe#:~:text=Instead%2C%20Spotify's%20data%20is%20implicit,after%20listening%20to%20a%20song>. Acesso em: 26 maio 2024.
- CRAWFORD, K. **Atlas of AI: Power, Politics, and the Planetary Costs of Artificial Intelligence**. New Haven: Yale University Press, 2021.
- D'ANDRÉA, C. **Pesquisando plataformas online: conceitos e métodos**. Salvador: EDUFBA, 2020.
- DE JONG, M., PREY, R. The Behavioral Code: Recommender Systems and the Technical Code of Behaviorism. **Philosophy of Engineering and Technology**, Cham, v. 41, Springer 2022. https://doi.org/10.1007/978-3-031-07877-4_8.
- DE MARCHI, L.; FERREIRA, G.; KISCHINHEVSKY, M.; SALDANHA, R. M. O gosto algorítmico: A lógica dos sistemas de recomendação automática de música em serviços de streaming. **Revista Fronteiras – Estudos Midiáticos**, [s. l.], v. 23, n. 3, p. 16-26, set./dez. 2021.

DE MARCHI, L.; FERREIRA, G.; KISCHINHEVSKY, M.; SALDANHA, R. M. **A indústria fonográfica digital: formação, lógica e tendências**. 1. ed. Rio de Janeiro: Mauad X, 2023.

DE WAAL, M.; POELL, T.; VAN DIJCK, J. **The platform society: public value in a connected world**. Nova York, NY: Oxford University Press, 2018.

DIMAGGIO, P. Classification in art. **American Sociological Review**, [s. l.], n. 52, Aug. 1987.

ERIKSSON, M. Close Reading Big Data: The Echo Nest and the Production of (Rotten) Music Metadata. **First Monday**, [s. l.], v. 21, n. 7, 2016.

ERIKSSON, M.; FLEISCHER, R.; JOHANSSON, A.; SNICKARS, P.; VONDERAU, P. **Spotify Teardown: inside the black music of streaming music**. Cambridge, MA: MIT Press, 2019.

GILLESPIE, T. A Relevância dos Algoritmos. **Parágrafo**, São Paulo, v. 6, n. 1, p. 95-121, jan./abr. 2018.

HENNION, A. Music Lovers. Taste as performance. **Theory, Culture, Society**, [s. l.], v. 5, n. 18, p. 1-22, 2001.

HENNION, A. Pragmática do Gosto. **Desigualdade & Diversidade**, Rio de Janeiro, n. 8, p. 253-277, jan./jul., 2011.

HESMONDHALGH, D.; VALVERDE, R. C.; KAYE, D. B. V.; LI, Z. **The impact of algorithmically driven recommendation systems on music consumption and production - a literature review**. GOV.UK, 2023. Disponível em: <https://www.gov.uk/government/publications/research-into-the-impact-of-streaming-services-algorithms-on-music-consumption/the-impact-of-algorithmically-driven-recommendation-systems-on-music-consumption-and-production-a-literature-review>. Acesso em: 30 maio. 2024.

NEUDERT, L.-M.; HOWARD, P.; KOLLANYI, B. Sourcing and Automation of Political News and Information During Three European Elections. **Social Media + Society**, [s. l.], v. 5, n. 3, 2019.

LEVINE, L. W. **Highbrow/Lowbrow: the emergence of cultural hierarchy in America**. Cambridge, MA: Harvard University Press, 1988.

MONTARDO, S. P. (org.). **Sobre plataformas digitais: apropriações interdisciplinares dos Estudos de Plataforma**. Porto Alegre, RS: Editora Fi, 2022.

MOREIRA, A. C.; ARAUJO, W. F.; POLIVANOV, B. Escuta datificada de música: educabilidade algorítmica e performance de gosto em plataformas de streaming musical. **Galáxia**, São Paulo, 2024. No prelo.

MORRIS, J. W. Curation by Code: Infomediaries and the Data Mining of Taste. **European Journal of Cultural Studies**, [s. l.], v. 18, n. 4-5, p. 446-463, 2015.

POELL, T.; NIEBORG, D. B.; DUFFY, E. **Platforms and cultural production**. Polity Press, 2022.

PETERSON, R. A. Understanding Audience Segmentation: from elite and mass to omnivore and univore. **Poetics** 21, [s. l.], n. 4, p. 243-258, 1992.

PETERSON, R. The rise and fall of highbrow snobbery as a status maker. **Poetics** 25, [s. l.], p. 75-92, 1997.

POLIVANOV, B. **Dinâmicas identitárias em sites de redes sociais: estudo com participantes de cenas de música eletrônica no Facebook**. Rio de Janeiro: Multifoco, 2014.

POLIVANOV, B.; CARRERA, F. Rupturas performáticas em sites de redes sociais: um olhar sobre fissuras no processo de apresentação de si a partir de e para além de Goffman. **Intexto**, Porto Alegre, n. 44, p. 74-98, jan./abr. 2019.

SAMPAIO, R. C.; LYCARIÃO, D. **Análise de conteúdo categorial: manual de aplicação**. Brasília: Enap, 2021.

SANTINI, R. M. **O Algoritmo do Gosto: os sistemas de recomendação online e seus impactos no mercado cultural**. 1. ed. Curitiba: Appris, 2020. v. 1.

SEAVER, N. **Computing Taste: algorithms and the makers of music recommendation**. Chicago: University of Chicago Press, 2022.

TRISTAN, J. **Creating music by listening**. 2005. Tese (Doutorado em Media Arts and Sciences, School of Architecture and Planning) – Massachusetts Institute of Technology, 2005.

WHITMAN, B. **Learning the meaning of music**. 2005. Tese (Doutorado em Media Arts and Sciences, School of Architecture and Planning) – Massachusetts Institute of Technology, 2005.

WHITMAN, B. How music recommendation works – and doesn't work. Variogram. In: **Brian Whitman**. [S. l.], 11 dez. 2012. Disponível em: <https://notes.variogram.com/2012/12/11/how-music-recommendation-works-and-doesnt-work>. Acesso em: 30 maio 2024.

Aléxis de Carvalho Moreira

Mestre pelo Programa de Pós-Graduação em Comunicação da Universidade Federal Fluminense (PPGCOM/UFF), em Niterói, RJ, Brasil; com financiamento da CAPES e do programa FAPERJ Nota 10. Doutorando pelo PPGCOM/UFF, com financiamento CAPES. Pesquisador Associado do Laboratório de Estudos de Internet e Mídias Sociais (NetLab/UFRJ).

Beatriz Brandão Polivanov

Doutora e mestre pelo Programa de Pós-Graduação em Comunicação (PPGCOM) da Universidade Federal Fluminense (UFF), em Niterói, RJ, Brasil; com pós-doutorado pelo Department of Art and Communication History da McGill University, Canadá; bacharel em Letras e licenciada em Educação pela Universidade Federal do Rio de Janeiro (UFRJ), no Rio de Janeiro, RJ, Brasil. Docente permanente do PPGCOM e do Departamento de Estudos Culturais e Mídia da UFF. Coordenadora do grupo de pesquisa MiDiCom (UFF/CNPq). Pesquisadora com financiamento da FAPERJ e CNPq.

Endereços para correspondência**Alékis de Carvalho Moreira**

Travessa Manoel Continentino, 02, Ap. 501

São Domingos, 24210-150

Niterói, RJ, Brasil

Beatriz Brandão Polivanov

Campus do Gragoatá

R. Visconde do Rio Branco, s/n

São Domingos, 24210-201

Niterói, RJ, Brasil

*Os textos deste artigo foram revisados pela SK
Revisões Acadêmicas e submetidos para validação
do(s) autor(es) antes da publicação.*