

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
COORDENÇÃO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

DISSERTAÇÃO DE MESTRADO

**GERAÇÃO AUTOMÁTICA DE PLAYLISTS: ENTENDENDO AS
PERCEPÇÕES E EXPECTATIVAS DE CRIADORES HUMANOS**

MESTRANDO

VÍTOR DE SOUZA AMARAL

ORIENTADOR

NAZARENO ANDRADE

CAMPINA GRANDE
FEVEREIRO - 2016

Resumo

Uma playlist pode ser definida como qualquer sequência de músicas para ser executada tipicamente de forma ordenada sem que seja necessário ao usuário ter que selecionar individualmente as músicas enquanto elas vão sendo tocadas. Muitos softwares são capazes de montar playlists de forma automática baseando-se nos mais diversos modelos, sendo este um aspecto muito importante de aplicações como Last.fm, Deezer, Spotify, etc. Muitos pesquisadores na área de Recuperação de Informação Musical (MIR) têm dedicado esforços no desenvolvimento de modelos geradores cada vez melhores, entretanto as atuais formas de validação são reconhecidamente ineficientes e métodos considerados padrão possuem graves limitações. Neste trabalho, investigamos as percepções de DJs (pessoas que criam playlists para discotecagem em festas) sobre playlists automaticamente geradas por dois modelos diferentes, focando nas características relacionadas à criação de playlists identificadas nas amostras apresentadas, nas expectativas em relação a playlists geradas automaticamente em contraponto às criadas por outras pessoas e se e de qual forma percebe-se diferenças entre os itens criados pelos diferentes geradores. Foi realizada uma pesquisa qualitativa onde DJs de diversas localidades participaram de *in-depth interviews*. Foram colhidos relatos de experiências relacionadas à criação de playlists para discotecagem ou outras ocasiões, do uso de softwares para edição, execução e geração de playlists e dos hábitos de consumo de playlists. Entrevistados foram também apresentados a amostras de playlists de dois geradores e suas impressões foram colhidas. Concluímos que, ainda que de forma não explícita, os entrevistados conseguiram caracterizar e dar contexto aos diferentes geradores. Além disso playlists são percebidas como mais humanas quando eles conseguem identificar uma única motivação forte, uma única temática que norteia o agrupamento e encadeamento de músicas e que playlists menos homogêneas não são necessariamente percebidas como playlists ruins e são muitas vezes entendidas como surpresas positivas.

Agradecimentos

Em primeiro lugar devo agradecer a meu orientador Nazareno Andrade, por toda aquela conversa de sempre de ter me guiado pelo caminho das pedras da pesquisa científica, mas principalmente por ter sido uma pessoa de extrema paciência e compreensão nestes 3 anos que passamos trabalhando juntos. Também por ter me permitido a oportunidade de explorar a grande área da computação sob ópticas menos ortodoxas, o que me possibilitou realizar este estudo que envolve música e ciências sociais, duas áreas que sempre me foram de grande interesse pessoal e que pude trazer para minha vida profissional.

Me deixa meio angustiado agradecer aos amigos que estiveram presentes durante esta etapa de minha vida porque é uma quantidade razoável de gente e fica complicado incluir todo mundo. Então agradeço aqui àquelas mais constantes durante este período de fim de mestrado: Dinart Filho, Rafaella Ryon, Rebeca Afonso, Iara Ribeiro, Isa Araújo, Naila Souza e Amanda Closs, presentes em todos os momentos e todos os humores, nem que seja por Snapchat. Otacílio Lacerda, Jessica Farias, Laryssa Tertuliano, Suyvia Pinheiro e Thais Fernandas, especialistas em resgate de *bads*. Aos colegas do LSD, em especial Mariana Souto, Aline Marques, Pâmela Oldufre, Nigini Abílio, Jefferson Neves e galera da Volúpia pelos debates que iam de trabalho, passando pelos paradigmas político-sociais e terminando no *look* do dia. Não posso esquecer também Adabriand Furtado e Lesandro Ponciano pelos inspirados debates acadêmicos. À galera CERC que está comigo desde o fim dos anos 90. Sintam-se agradecidos também todos os meus amigos do ciclo das danças, atividade esta tão importante para minha pessoa. E finalmente à família sempre presente.

Este trabalho não teria sido possível sem os DJs que se propuseram a serem entrevistados por mim, mesmo aqueles cuja entrevista não foi possível no fim das contas. Alguns já amigos, outros que se tornaram. Também agradeço a Flávio Figueiredo e Brian McFee pela importante ajuda com seus modelos geradores. Ao pessoal do Transcribe que me forneceu gratuitamente sua ferramenta de transcrição que quebrou um galho enorme na hora de encarar os áudios das entrevistas e ao pessoal do Zencastr e seu suporte eficiente. Por fim, agradeço a CAPES pelo apoio financeiro que me foi concebido.

Lista de Figuras

1	Modelo de Hipergrafos: hiper-arestas derivadas dos descritores (neste exemplo: época, estilo musical e <i>features</i> de áudio) e músicas como vértices. . .	9
2	TribeFlow: Alice escolhe aleatoriamente um ambiente latente de acordo com suas preferências, navega um pouco e aleatoriamente salta para outro ambiente.	10
3	<i>Hit-Rate</i> : transições iguais às do conjunto de testes são consideradas <i>hits</i> , diferentes são consideradas <i>misses</i>	11
4	Modelo teórico inicial (<i>framework</i> conceitual)	18
5	Interface do Foobar 2000, player utilizado nas entrevistas presenciais. . . .	26
6	Interface do Foobar 2000, detalhe da exibição de playlists.	26
7	Diagrama de relações entre códigos e conceitos	42

Conteúdo

1	Introdução	1
1.1	Contextualização	1
1.2	Justificativa	3
1.3	Objetivos	5
2	Fundamentação Teórica	7
3	Definições	13
3.1	Definição de gosto	13
3.2	Definição de playlist	13
3.3	Definição de DJ	14
3.4	Definição de gerador automático de playlists e de modelo gerador	15
4	Metodologia e técnicas de pesquisa	16
4.1	Da pesquisa qualitativa	16
4.2	Ciclo de Design	16
4.2.1	Da formulação de perguntas de pesquisa qualitativas	16
4.2.2	Do desenvolvimento do modelo teórico	17
4.2.3	Da escolha da metodologia de campo	18
4.3	Ciclo Etnográfico	18
4.3.1	Do recrutamento de participantes	19
4.3.2	Do design da ferramenta de pesquisa	20
4.3.3	Das entrevistas realizadas	22
4.3.4	Playlists utilizadas	23
4.4	Ciclo Analítico	26
4.4.1	Do tratamento de dados	27
4.4.2	Do desenvolvimento de códigos	27
5	Análise de dados	31
5.1	Quais são as diferentes expectativas para playlists geradas automaticamente ou por humanos?	31

5.2	Quais são as características relacionadas à criação de playlist que os DJs conseguem identificar nas amostras de playlists automaticamente geradas?	35
5.3	Se e como os DJs percebem as diferenças entre os modelos usados para gerar as playlists?	38
5.4	Quais são as percepções de DJs acerca de playlists geradas por geradores automáticos?	41
6	Discussão e conclusões	44
7	Limitações e trabalhos futuros	46
A	Guia de entrevista	50
B	Playlists utilizadas	51

1 Introdução

1.1 Contextualização

Muitos sites permitem hoje que seus usuários escutem, editem, classifiquem e compartilhem playlists com outros usuários (e.g.: 8tracks¹, Art of The Mix², etc), sendo responsáveis por criarem e popularizarem vastas comunidades focadas nestas atividades. Pessoas utilizam tais sistemas criando listas sob as mais diversas ópticas: seja a partir de ideias simples como organizar suas músicas favoritas por estilo ou por época, chegando a ideias mais artísticas e criativas como listas baseadas em humor (e.g.: músicas para fins de namoro, músicas para dias chuvosos, etc), que transitam entre estilos de forma gradual, ou que usam outros critérios mais sutis para relacionar músicas de forma mais inusitada [7]. Tem-se assim um grande nicho explorável de pessoas que buscam aplicações que os provejam ferramental para a realização de tais atividades.

Uma outra faceta da criação de playlists refere-se à automatização deste processo. Muitos softwares são capazes de montar playlists de forma automática, comumente baseando-se em modelos geradores que usam descritores musicais que sirvam de base para a criação, como andamento ou timbre, ou que sejam treinados sobre corpora de playlists criadas por pessoas. Este tipo de abordagem está associada à área de recomendação musical [11][25], sendo amplamente usada por aplicações especializadas em tal tarefa, como é o caso do Last.fm³, Deezer⁴, Spotify⁵, etc. Estas usam informações dos hábitos musicais de seus usuários para sugeri-los playlists que os agradem em certo contexto. Por exemplo, em diversas situações é agradável que as playlists sejam compostas por músicas que sejam familiares mas ao mesmo tempo novas para os ouvintes, como músicas nunca ouvidas mas de estilos bem conhecidos [25].

Com a popularização destes serviços dependentes de geração automática de playlists também veio a necessidade de conhecer o quão eficientemente esta atividade está sendo realizada, tanto do ponto de vista computacional como do ponto de vista do usuário. Do ponto

¹<http://8tracks.com/>

²<http://www.artofthemix.org/>

³<http://www.last.fm/>

⁴<http://www.deezer.com/>

⁵<https://www.spotify.com/>

de vista computacional, é importante desenvolver modelos e técnicas cada vez mais precisas e computacionalmente eficientes. Do ponto de vista do usuário consumidor, deve-se avaliar como estas pessoas interagem com estes sistemas e como estas avaliam os itens gerados a fim de os fornecer serviços cada vez melhores, mais especializados e personalizados. Neste trabalho não nos preocuparemos com o aspecto da complexidade computacional e manteremos nosso foco na qualidade percebida dos itens gerados por tais modelos geradores.

É um consenso da área de recomendação musical que de fato ainda não sabemos como avaliar de maneira satisfatória a qualidade de playlists produzidas por modelos geradores. Esta avaliação é comumente feita usando-se modelos matemáticos que comparam playlists geradas a conjuntos de playlists feitas por humanos ou é feita diretamente por pessoas, sejam especialistas ou usuários comuns. Entretanto, os dois tipos de avaliação possuem limitações bem conhecidas. As formas matemáticas possuem limitações dos próprios métodos, que exigem certas propriedades dos modelos sendo avaliados. Além disso, a comparação com conjuntos de teste não suficientemente grandes pode resultar em avaliações imprecisas. Já a avaliação por pessoas costuma ser muito custosa e consumir muito tempo, tornando-as inviáveis para a ampla utilização.

Neste trabalho nós consultamos DJs, os equivalentes humanos aos modelos geradores de playlists, por meio de *in-depth interviews* em relação às estratégias que estes usam para criar suas playlists para discotecagem e suas opiniões acerca de que adjetivos caracterizam boas playlists. Dentro da entrevista também realizamos sessões *think-aloud* onde playlists automaticamente geradas por 3 geradores diferentes os foram apresentadas para que eles as apreciassem e fizessem comentários acerca delas, sendo incentivados a julgá-las usando as mesmas estratégias e adjetivos que eles levantaram no primeiro momento de entrevista, além de discutirem o que torna estas playlists mais próximas ou distantes de parecerem com playlists geradas por seres humanos.

Com estes dados coletados, pretendíamos identificar as percepções destes entrevistados sobre playlists geradas automaticamente, focando na expectativa que estes possuem acerca de playlists automáticas em contraste com playlists humanas, em que estratégias usadas por eles para criação de playlists próprias eles conseguem identificar como presentes ou ausentes nas playlists amostradas e se e como eles conseguem diferenciar os diferentes geradores responsáveis pela geração das playlists apresentadas. Nosso intuito é o de, a partir do melhor

entendimento destes aspectos, ser capazes de fazer sugestões sobre que aspectos são considerados mais importantes por estes especialistas, para que isto possa servir de norte para pessoas que criam e que avaliam modelos geradores de playlists em seus trabalhos futuros.

Analizamos os dados coletados usando a metodologia originária das ciências sociais conhecida como *grounded theory*. A principal vantagem desta metodologia é nos permitir derivar teorias a partir dos dados qualitativos obtidos, mantendo um certo rigor científico mas sem excluir o aspecto investigativo e criativo que é característico dos estudos típicos das ciências humanas.

Descobrimos que em geral nossos entrevistados costumam buscar playlists, tanto automáticas como criadas por humanos, como forma de encontrar novidades musicais. Entretanto, relatam sentir limitações nas playlists automáticas em relação à novidades mais surpreendentes, o que remete ao problema do *cold start*. Playlists automáticas ainda são vistas como meio aleatórias e, no geral, não conseguem expressar temáticas que amarrem as músicas, característica que é vista como humana pelas entrevistados. Similaridade entre as músicas, presença de surpresas não bruscas, ordenação das músicas e agrupamentos foram as características para a criação de playlists mais observadas (em presença ou ausência) nas playlists amostradas. Por fim, os entrevistados foram capazes de diferenciar os três geradores usados para gerar as playlists, caracterizando-os de formas distintas. O modelo baseado apenas no treinamento com *corpora* de playlists, TribeFlow, é visto como mais humano, enquanto o modelo que usa características das músicas como adicional no treinamento, Hipergrafos, é capaz de gerar mais surpresas agradáveis para os entrevistados. O terceiro modelo, aleatório, é visto como muito desorganizado e sem sentido pela maioria dos participantes. Tais resultados indicam um possível caminho para trabalhos futuros, seja por fornecer possíveis enfoques para métricas de avaliação, seja para a escolha de técnicas a serem usadas no desenvolvimento de novos modelos geradores.

1.2 Justificativa

A indústria fonográfica no final do século XIX mudou completamente a forma como se consumia música, finalmente eliminando a necessidade do artista presente durante as execuções de obras musicais.

Na sequência dessa revolução, vem a consolidação do rádio, a invenção da televisão e

a atualização dos conceitos de comunicação de massa. Esses meios tornaram-se os grandes propagadores de produtos culturais de massa, caracterizados pela grande eficiência em termos de distribuição de programação generalista desenvolvida pelas grandes gravadoras, mas com a consequência negativa marginalizar segmentos culturais mais específicos, de ignorar os nichos [8][22][30].

Outro marco importante para entendermos a forma como consumimos músicas na atualidade foi a revolução das tecnologias digitais, que tornou os meios de produção acessíveis, contribuindo assim para o notável aumento no volume de produções musicais, bem como nas emanações populares de nichos e popularização de estilos menos conhecidos [18][16].

A popularização do acesso à internet, por sua vez, vem dando espaços de escoamento para esse grande volume de produções fonográficas que, além de eliminar a hegemonia da mídia física e das grandes gravadoras, tem tornando o acesso cada vez menos restrito ao público.[14]

Tamanhas modificações nos modos de consumo e produção produziram efeitos adversos. Diante do massivo volume de músicas disponíveis a qualquer momento, dos mais variados estilos e qualidades, torna-se uma tarefa cada vez mais complexa para os consumidores selecionar música, tanto para o simples ato de escolher algo já conhecido para ouvir como para descobrir novos grupos, artistas ou estilos. O que acarreta, por sua vez, na dificuldade para o produtor de conteúdo musical que, diante de um público já saturado de informações, não consegue direcionar sua produção para o público alvo.

Surgido como solução para o problema de direcionamento de conteúdo para usuários específicos, os sistemas de recomendação musical tornam-se parte importante da experiência do consumo de música nos moldes atuais, inclusive tornando-se padrão a presença destes em players de música e serviços de *streaming*. Como é o caso do Spotify, que produz semanalmente uma playlist personalizada para cada um de seus usuários com base em seus hábitos na semana anterior [27]. Desta forma, os usuários têm acesso à recomendações personalizadas baseadas em seus hábitos de consumo.

Apesar dos notórios resultados já alcançados com os sistemas de recomendação musical, tal campo ainda é muito recente e precisa de atenção. Considerando a razoável quantidade de vertentes de sistemas de recomendação musical existentes e as que ainda virão a existir, ser capaz de avaliá-los de forma satisfatória é essencial para que possamos aperfeiçoá-los.

Atualmente três tipos de avaliação são mais comumente utilizadas: coesão semântica (i.e.: homogeneidade das músicas), opinião humana e comparação com playlists feitas por humanos. Entretanto, todas estas abordagens possuem graves limitações, que discutiremos em mais detalhes na fundamentação teórica. O que nos deixa sem uma forma adequada de abordar tal problema.

DJs, pessoas que, por profissão ou por hobby, planejam programações musicais e as executam para um certo público alvo, podem ser vistos como os equivalentes humanos dos geradores automáticos de playlists. É possível que o entendimento do processo mental realizado por estes profissionais durante seu processo criativo de preparação e execução de repertório nos dê um entendimento importante sobre que aspectos levarmos em conta tanto para o desenvolvimento de novos modelos geradores como para o desenvolvimento de novas formas de avaliação.

Achamos então que, a partir dos conhecimentos, opiniões e impressões coletadas desde especialistas, tanto sobre seus próprios processos criativos como sobre playlists automáticas amostradas, seremos capazes de derivar informações valiosas que possam contribuir para o direcionamento e, conseqüentemente, o desenvolvimento da área de recuperação de informação musical.

1.3 Objetivos

Temos por consequência das limitações citadas na seção anterior, o seguinte objetivo geral de pesquisa:

- Explorar as percepções de usuários criadores de playlists acerca de playlists geradas automaticamente.

Temos também os seguintes objetivos específicos:

- Explorar as diferentes expectativas que DJs possuem para playlists geradas por humanos e playlists geradas por modelos geradores.
- Explorar as características relacionadas à criação de playlists que DJs são capazes de identificar, em presença ou falta, nas amostras de playlists geradas por modelos geradores.

- Entender se e como DJs percebem diferenças entre os modelos geradores usados para gerar as playlists.

2 Fundamentação Teórica

Existem na literatura atual uma grande diversidade de estudos que visam desenvolver modelos de geração automática de playlists e validá-los de modo a mostrar sua eficiência, muito comumente, confrontando-os com modelos anteriores. Existem também estudos com o foco mais direcionado às formas de validação em si, procurando formas menos custosas, acuradas e padronizadas para a execução de tal tarefa. Nesta seção listamos de forma não exaustiva alguns estudos que foram importantes para a definição de nossa pesquisa.

Em sua pesquisa, Logan [21] usa uma medida de similaridade desenvolvida previamente por ela e apresenta um gerador que cria playlist a partir das músicas mais próximas de uma dada música semente. Essa proximidade é determinada a partir de similaridades de áudio, classificação de gênero musical e relevância das músicas que é obtida a partir de um algoritmo de *automatic relevance feedback* cujos pesos resultantes são usados para ajustar a playlist final. Pauws, Verhaegh et al [29] apresentam um algoritmo capaz de gerar playlists de acordo com as preferências de um dado usuário. Tal algoritmo usa um procedimento de busca local baseado em *simulated annealing* para atacar o problema. Para fins de performance eles aplicam três heurísticas chamadas redução de domínio de canção, votação parcial de restrições e estrutura de vizinhança em dois níveis, conseguindo resultados melhores que modelos anteriores baseados em satisfação de restrições. Correa, Levada et al [6] por sua vez procuram determinar a relação entre gêneros musicais e suas emoções expressadas pela captura da presença de padrões rítmicos, usando então uma árvore de extensão mínima para determinar suas playlists. Moore, Chen et al [24] por sua vez, apresentam um modelo probabilístico capaz de incorporar músicas e tags sociais em um único espaço. Com essa técnica eles são capazes de gerar playlists, resolver o problema de *cold start* inferindo tags para músicas que não estavam no conjunto de treino, além de facilitar *queries* em linguagem natural mesmo que boa parte das músicas não possuam tags.

Uma abordagem com um intuito um pouco diferente, mas ainda dentro da área de recomendação musical, que merece ser mencionada é o modelo de Smaaberg, Shabib et al [31] para recomendação de concertos para grupos de pessoas. A abordagem proposta leva em conta dados geográficos das pessoas, dados temporais (i.e.: não recomendar um concerto que já aconteceu), além do gosto dos membros do grupo recebendo recomendações em um

dados momento. Eles implementam três técnicas para enfrentar o problema: uma baseada em filtragem colaborativa, uma em algoritmo de fatorização de matrizes e uma combinação das duas técnicas anteriores. Mostram que o filtro colaborativo e a técnica híbrida conseguem melhores resultados. Também realizam uma avaliação de usabilidade com usuários que se mostraram satisfeitos com as recomendações.

Outro trabalho que destacamos é o método proposto por McFee e Lanckriet [23]. Esses autores atacam o problema da geração de playlists usando um algoritmo baseado em modelo probabilístico que é treinado sobre corpora diversos (e.g.: músicas de rock, músicas depressivas, etc), chamados por eles de dialetos. No modelo proposto, níveis de similaridade entre as músicas são calculados para diversos descritores, tais como o ano de gravação da música e medidas espectrais de timbre. A partir daí, uma representação em hipergrafo é gerada: músicas são nós, e todas as músicas que têm o mesmo valor de um descritor (e.g.: gravada nos anos 70) são ligadas por uma aresta no hipergrafo, e as arestas têm pesos aprendidos a partir do corpus de treinamento (ver Figura 1). Playlists são geradas a partir de caminhadas aleatórias (*random walks*) no hipergrafo. Como a seleção de uma música depende apenas da selecionada anteriormente e dos pesos das arestas, este modelo é um processo de Markov de primeira ordem. Para avaliar a qualidade dos resultados gerados por seu modelo, McFee usa a medida de *average log-likelihood* onde compara-se playlists geradas pelo modelo quando treinado usando dialetos contra playlists geradas treinando-se o modelo com o conjunto inteiro de playlists. McFee mostra melhores valores de *log-likelihood* quando o modelo é treinado usando dialetos. Usamos este modelo para gerar playlists para o nosso experimento e o discutiremos mais nas seções seguintes.

Outro método de geração automática de playlists que queremos destacar é o TribeFlow, desenvolvido por Figueiredo, Ribeiro et al [12]. Este modelo não foi concebido, entretanto, com a exata tarefa de geração de playlists em mente, mas sim de ser um preditor de futuros comportamentos de um indivíduo dado um conjunto de ações anteriores suas dentro de um contexto, chamada trajetória do usuário. TribeFlow recebe um conjunto de trajetórias de usuários e é capaz de inferir um conjunto de ambientes latentes (i.e.: grafos ponderados item-item e suas escalas de tempo) que melhor descrevem as trajetórias dos usuários através de curtas caminhadas aleatórias sobre esses ambientes (ver Figura 2). Uma vez que essa relação é inferida, o modelo é capaz de, dado um histórico de usuário e uma trajetória




Figura 1: Modelo de Hipergrafos: hiper-arestas derivadas dos descritores (neste exemplo: época, estilo musical e *features* de áudio) e músicas como vértices.

atual, performar previsões acuradas do próximo item a ser visitado. Exemplos de histórico de usuário podem ser uma lista de últimas músicas ouvidas por uma pessoa ou um conjunto de playlists criadas por geradores humanos. Para validação seus autores usam duas métricas: a *mean reciprocal rank* e, mais uma vez, a *log-likelihood*, que são comparadas com os valores obtidos para outros 7 modelos preditores da literatura. O TribeFlow obtém melhores resultados em todos os conjuntos de dados testados para ambas as medidas, além de obter tais medidas em tempos muito menores que os modelos de comparação. Vale salientar que alguns dos outros modelos não foram capazes de calcular as métricas em tempo hábil e a comparação teve de ser feita com subconjuntos reduzidos dos dados de teste. Este modelo também foi usado para gerar playlists para nosso experimento e também será retomado mais adiante.

Pauws e Eggen [28] desenvolvem uma aplicação que gera playlists de jazz que se encaixem em um determinado contexto de uso (e.g.: uma festa, um jantar formal, etc). Tal modelo usa um método de agrupamento dinâmico no qual canções são agrupadas baseando-se em similaridade de atributos de metadados (e.g.: título, ano, músicos participantes, notação rítmica, etc). Além disso, um algoritmo indutivo é usado para descobrir os atributos mais importantes para um dado contexto de uso a partir de *feedback* do usuário. A eficiência do modelo é mostrada pela realização de avaliações feitas por pessoas recrutadas para testar a aplicação, onde estas são expostas a playlists geradas pelo modelo desenvolvido e a playlists geradas de forma aleatória dentro de um software que funciona como ambiente de testes. Ao

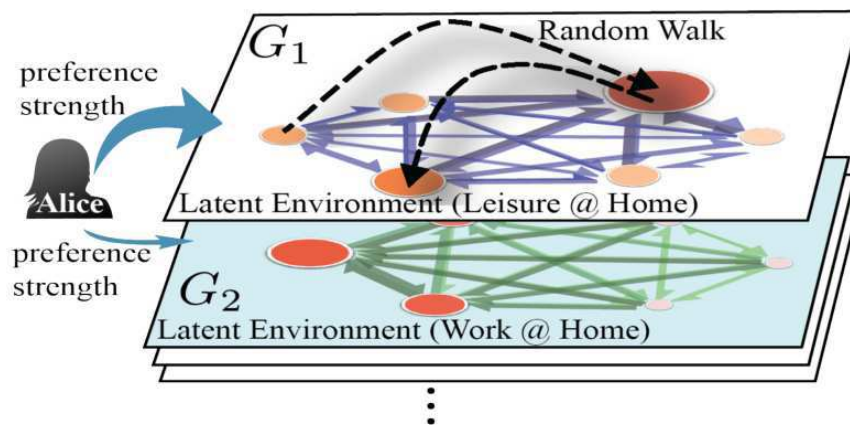


Figura 2: TribeFlow: Alice escolhe aleatoriamente um ambiente latente de acordo com suas preferências, navega um pouco e aleatoriamente salta para outro ambiente.

Além disso, os usuários também respondem a uma pergunta sobre a utilidade percebida por eles de geradores automáticos de playlists.

Em relação às formas já citadas de avaliação de qualidade de playlists geradas automaticamente, mais especificamente *average log-likelihood* e *average hit-hate*, Bonnin e Jan-nach [4][5] fazem uma revisão das vertentes existentes no desenvolvimento de geradores de playlists e propõem um algoritmo base para que seja utilizado em futuras comparações de eficiência por possíveis pesquisadores da área. Eles também discutem estratégias de design de avaliação da literatura e apresentam experimentos que usam estas duas métricas avaliativas baseadas em comparações com playlists feitas por criadores humanos. A primeira métrica é a contagem média de acertos (*average hit-rate*) onde um acerto é quando, dada uma playlist de teste e uma música dessa playlist, o modelo gerador tenta acertar a próxima música da playlist e acerta (ver Figura 3). A segunda métrica é a *average log-likelihood* que é uma medida determinada computando-se a probabilidade, dado um conjunto de testes de playlists, de se observar cada próxima faixa de acordo com um histórico de playlists e um modelo aprendido sobre um conjunto de treinamento. O mais interessante para nós deste estudo é que ele trás discussões acerca das limitações destas métricas que ele utiliza. Os autores destacam a importância de conjuntos de testes grandes para o caso da *average hit-rate*, que pode acabar gerando um grande número de falsos negativos caso este conjunto não seja amplo o suficiente. Em relação à *average log-likelihood* é destacada a necessidade da

métrica de que os modelos avaliados não tenham nenhuma transição com probabilidade 0, o que pode afetar o resultado de alguns modelos que tenham que ser ajustados aos requisitos da métrica avaliativa. Além disso, destaque-se a falta de significado da *log-likelihood* como valor isolado. É um valor que serve apenas para comparação, mas que não diz nada sobre o modelo avaliado por si só. Os autores também discorrem brevemente sobre a dificuldade de se realizar avaliações por humanos e por isto decidem não aplicar este tipo de avaliação em seu estudo.

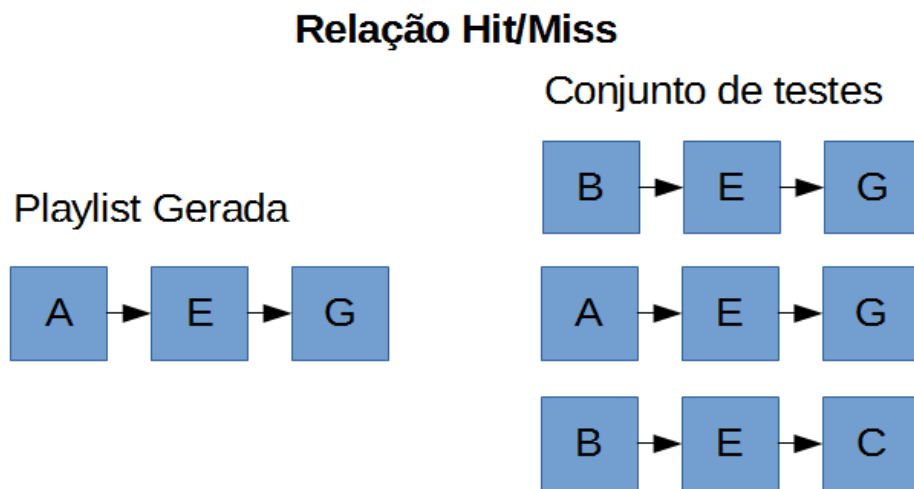


Figura 3: *Hit-Rate*: transições iguais às do conjunto de testes são consideradas *hits*, diferentes são consideradas *misses*.

Em um estudo mais recente, dados da *Audio Music Similarity and Retrieval* (AMS), que é uma das tarefas de avaliação conduzidas na *Music Information Retrieval eXchange* (MIREX) e que usa avaliadores humanos como *ground truth* de similaridade entre músicas, são usados por Lee [19] no intuito explorá-los para gerar playlists ou recomendações para usuários. *In-depth interviews* foram conduzidas com usuários onde estes são apresentados a playlists tiradas de um subgrupo dos resultados do AMS 2010, é pedido deles que as avaliem com uma nota e que discorra os motivos para gostar ou não gostar das playlists. Depois disso os usuários discorrem sobre o que considerariam uma playlist ideal e que características esta teria ou não. O estudo mostra que similaridade é apenas um dos muitos fatores que influenciam como pessoas se sentem sobre playlists e fatores como variedade, preferência pessoal, mistura de familiaridade e novidade, etc. também afetam fortemente a percepção dos usuários. Estes fatores levantados foram importantes para o nosso estudo e serão retomados mais

a frente.

3 Definições

Para melhor compreensão de termos e conceitos expressos neste trabalho, achamos por bem de defini-los isoladamente a fim de evitar possíveis conflitos de informações, objetivos e confusões com outros usos cotidianos dos termos.

3.1 Definição de gosto

Gosto é uma forma complexa e particular de aproximação e identificação com conteúdos materiais ou psíquicos que tem a ver com vários fatores como histórico do indivíduo, condições sociais, mentais e biológicas, diferindo de valor, que pode ser criteriosamente julgado, medido e quantificado. A isso se deve a comum alegação de que é descabida a crítica qualitativa ao gosto.

"O gosto é, então a faculdade de julgar a priori a comunicabilidade de sentimentos que se ligam a dada representação [...] Se pudéssemos supor que a mera comunicabilidade geral de um sentimento traz consigo, em si mesma, um interesse para nós [...] deveríamos ser capazes de explicar porque o sentimento, no juízo do gosto, vem a ser imputado em cada um, por assim dizer como um dever.

Immanuel Kant - Crítica do Juízo [17].

Trazemos esta definição aqui para lembrar que neste trabalho estaremos lidando com impressões subjetivas de pessoas com seus gostos e contextos particulares. Isto, entretanto, não deve ser visto de forma negativa, dada toda a subjetividade normalmente associada ao gosto musical e outras formas de apreciação artística.

Por outro lado, uma das vantagens de usarmos DJs como entrevistados é que estes também são capazes de ir além de seus próprios gostos pessoais, visto que é parte da profissão ser capaz de entender o gosto dos públicos para os quais eles discotecam, nos dando uma dimensão a mais de análise.

3.2 Definição de playlist

Neste trabalho uma playlist pode ser definida como qualquer grupo de músicas, tipicamente ordenadas, que foi criado no intuito de que estas sejam ouvidas em sequência, ainda que aleatória. Tal termo foi utilizado neste contexto pela primeira vez durante o período inicial

de popularização das rádios como meio de comunicação [11]. O uso de sequências de peças musicais como forma de expressar uma determinada ideia, sentido ou sentimento, entretanto, ocorre antes da existência da música gravada, como por exemplo a execução de obras eruditas formadas por mais de uma música [11]. Com a popularização dos computadores pessoais, o termo foi adotado por programas organizadores e tocadores de música. Em sistemas deste tipo, playlists são sequências de músicas para serem executadas tipicamente de forma sequencial sem que seja necessário o usuário ter que selecionar individualmente as músicas enquanto elas vão sendo executadas.

3.3 Definição de DJ

DJ, abreviatura de Disk Jockey, é o artista que toca músicas previamente gravadas, podendo ser mixadas na hora ou não, para um determinado público. Também advindo do período inicial da popularização das rádios, o termo foi utilizado pela primeira vez em 1935 para descrever o anunciante de rádio estadunidense Martin Block, que ficou famoso pelo seu programa *Bake Believe Ballroom* onde ele tentava passar a sensação de que ele estava transmitindo ao vivo de um salão de dança onde bandas estavam performando. Hoje o termo é usado de forma ampla para as atividades realizadas pelo DJ, que vão além da programação e podem incluir (re)mixagem, sampling, produção e até performances ao vivo com bandas usando mesas de som e outros eletrônicos como instrumentos musicais. Existe também uma faceta de capital social associada ao DJ, que é responsável por fazer a leitura do ambiente e de seu público, sendo assim capaz de realizar escolhas musicais que agradem tal contexto. Ainda falando deste lado social, principalmente em cenas musicais mais undergrounds (e.g.: cena gótica, EBM, hip-hop, etc), DJ são comumente citados como propagadores e geradores de tendências [1].

No caso específico do nosso estudo, nos limitamos a uma definição mais ortodoxa do termo, sendo o DJ o responsável por criar uma programação musical para um determinado público, ambiente e evento.

3.4 Definição de gerador automático de playlists e de modelo gerador

Em uma visão mais alto nível, um gerador automático de playlists é um software que possui por função, dada uma coleção de faixas musicais, uma base de dados de conhecimentos e algumas características desejadas para as playlists, criar uma sequência de músicas que atenda tais características desejadas. Essa definição abrange uma vasta gama de aplicativos e cenários de aplicação, cada um com seu conjunto de características desejadas particular. Podemos pegar como exemplo o Spotify que é capaz de gerar playlists compostas por recomendações personalizadas para o usuário baseadas em seus hábitos de escuta, tendo como característica desejada a geração de playlists que possuem itens que sejam desconhecidos para o usuário porém similares a itens já consumidos por ele. Temos também o RunMusic⁶, criado por estudantes da UFCG, que escolhe músicas baseadas no ritmo de corrida do seu usuário, onde o resultado desejado é uma playlist composta de músicas quem tenham andamento rítmico similar ao ritmo dos movimentos do exercício sendo performado pelo usuário. Outro exemplo mais simples é o Desescute⁷, que basicamente escolhe músicas aleatoriamente de sua base de dados que contém faixas descritas subjetivamente como “músicas grudentas” [5].

Sob um olhar baixo nível, gerador automático de playlists pode se referir simplesmente aos modelos matemáticos e computacionais por trás das aplicações supracitadas, sem levar necessariamente em conta como se dará a interação com usuários.

Em nosso trabalho, usamos o termo gerador automática de playlist para nos referir à óptica de alto nível, às aplicações com as quais usuários interagem. Usamos modelo gerador para nos referirmos ao baixo nível por trás de tais aplicações.

⁶<http://runmusic.me/>

⁷<http://www.desescute.com.br>

4 Metodologia e técnicas de pesquisa

4.1 Da pesquisa qualitativa

A utilização de técnicas de análise qualitativa, advindas das ciências humanas, dentro dos estudos da computação e ferramentas computacionais no geral ainda é uma atividade realizada de forma minoritária. Entretanto, quando a computação começa a sair dos seus aspectos mais teóricos e baixo nível e passa a tratar dos aspectos relacionados à forma que usuários experenciam e lidam com softwares e suas interfaces, é intuitivo se pensar que, para entender melhor essas relações, estudos com um enfoque mais humano se façam necessários. Outra vantagem de alguns técnicas de análise com enfoque mais humano é a possibilidade de se desenvolver uma teoria a partir de dados empíricos, contrastando com as análises puramente quantitativas que costumam ter teorias preestabelecidas que serão ou não confirmadas após a realização da análise dos dados.

Nossa metodologia de pesquisa segue como base a proposta por Hennink, Hutter e Bailey em seu livro *Qualitative Research Methods* [15] e nas seções que se seguem detalharemos todas as partes do processo, do design inicial às conclusões obtidas.

4.2 Ciclo de Design

O ciclo de design é o primeiro componente da pesquisa qualitativa como um todo e consiste de quatro atividades interligadas: a formulação de perguntas de pesquisa, revisão de literatura e incorporação de teoria, desenvolvimento de um framework conceitual para o estudo e a escolha de uma metodologia de estudo de campo apropriada. A revisão de literatura e incorporação de teoria já foram abordadas anteriormente, então nos focaremos aqui em descrever os itens restantes.

4.2.1 Da formulação de perguntas de pesquisa qualitativas

Do objetivo de pesquisa geral já mencionado anteriormente derivamos a seguinte pergunta de pesquisa:

- Quais são as percepções de DJs acerca de playlists geradas por geradores automáticos?

E dos objetivos específicos derivamos outras três perguntas secundárias:

- Quais são as diferentes expectativas para playlists geradas automaticamente e por humanos?
- Quais são as características relacionadas à criação de playlists que os DJs conseguem identificar nas amostras de playlists automaticamente geradas?
- Se e como os DJs percebem as diferenças entre os modelos usados para gerar as playlists?

4.2.2 Do desenvolvimento do modelo teórico

Tendo em mãos todo o material recolhido como forma de revisão bibliográfica, focamos nos estudos acerca de avaliação de playlists por humanos e nos estudos sobre a cultura de DJs. O estudo de Lee [19] em especial trás a importância de características além de similaridade entre as músicas que são percebidas como boas em uma playlist. Ele também lista algumas destas características elencadas pelos usuários entrevistados, como variedade, metadados, preferência pessoal, familiaridade, mistura de músicas familiares e novas, mais músicas do artista *seed*, etc. Sobre a cultura de DJs, Attias, Gavana e Rietveld [1] trazem mais características desejáveis em playlists, mas dessa vez vindas de criadores humanos especializados, reforçando a importância da mistura de músicas conhecidas com novidades, o equilíbrio entre o gosto pessoal do DJ e o que se entende como gosto da pista, etc. O entendimento de programação de repertório e das formas de pensar de alguns DJs também expostas por eles foram importantes para a concepção de nosso modelo teórico.

Outro ponto que também é relevante mencionar neste contexto de pesquisa é o fato de os pesquisadores também terem experiência como DJs. Um deles há alguns anos e o outro há alguns meses. Estas experiências pessoais também foram importantes para o desenvolvimento do modelo teórico que guiou o estudo daqui pra frente.

Nosso modelo teórico parte da premissa de que os DJs, conhecendo formas eficientes de criar playlists para seu público, são capazes de usar estratégias iguais ou similares para discorrerem sobre as playlists geradas pelos modelos geradores que estamos usando, podendo dar uma opinião especializada caracterizando, avaliando e julgando de forma geral as playlists que a eles foram apresentadas.

Tendo em mente todos os pontos citados acima temos nosso modelo teórico (*framework* conceitual):

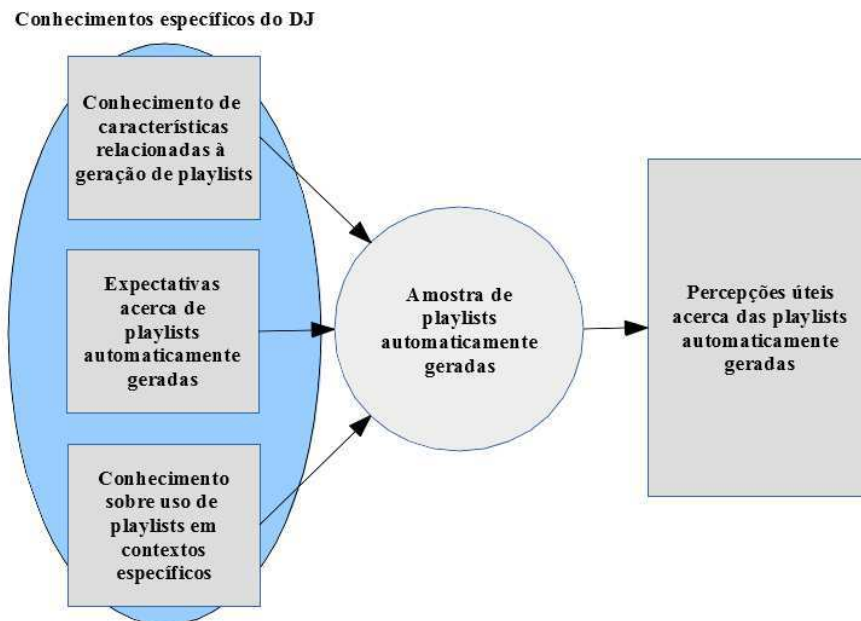


Figura 4: Modelo teórico inicial (*framework* conceitual)

4.2.3 Da escolha da metodologia de campo

Por causa de seu foco em experiências pessoais e individuais sobre um tópico específico, *in-depth interviews* foi o método escolhido para coleta de dados.

4.3 Ciclo Etnográfico

O ciclo etnográfico é o segundo componente da pesquisa qualitativa. Aqui descrevemos as principais tarefas relacionadas à coleta de dados, incluindo o design da ferramenta de pesquisa, recrutamento de participantes, a coleta de dados em si e a realização de inferências indutivas. Discorreremos nessa seção acerca dos três primeiros tópicos. As inferências serão tratadas futuramente junto com o ciclo de análise para fins de organização, evitando repetições.

4.3.1 Do recrutamento de participantes

O recrutamento de participantes consiste em duas etapas: definição da população de estudo, seguida da identificação de estratégias para recrutamento.

Definição da população de estudo:

Nos estágios iniciais da pesquisa havíamos decidido estudar DJs apenas de Campina Grande e regiões próximas por fins de facilidade de *networking*, entretanto, no decorrer da pesquisa, fomos capazes de expandir nossa rede de contatos para DJs de outros estados do país e decidimos ampliar nosso escopo para DJs de todo o Brasil.

Nos focamos também na cena musical alternativa, recrutando DJs que têm o costume de tocar em lugares entendidos como frequentados por públicos alternativos em uma definição bem vaga do termo mas incluindo o público LGBT, consumidores de música indie e de culturas underground (e.g.: góticos). Esse foco entretanto, não foi aplicado ao estilo musical preferido de cada DJ. Não fizemos nenhuma delimitação em relação ao estilo de música mais comumente executado da população de estudo.

A primeira motivação para a escolha dos DJs desta cena foi pela conveniência dos próprios pesquisadores que estão inseridos neste meio, o que facilitou o acesso, contato, recrutamento e comunicação de forma geral com os possíveis entrevistados. A segunda diz respeito a diversidade musical que costuma fazer parte dos *sets* musicais destes DJs. Ao contrário dos DJs de boates, DJs da cena alternativa costumam não se prender a técnicas ou estéticas específicas, tocando uma grande diversidade de estilos musicais, o que faz que suas playlists estejam bem mais próximas das playlists ouvidas por pessoas comuns no dia a dia.

Também não fizemos nenhuma delimitação em termos técnicos dos DJs, em relação ao equipamento usado, nem de software nem de hardware. Entretanto, os DJs entrevistados deveriam estar ativos e ter tocado ao menos em algumas festas que não envolvessem apenas amigos destes.

Resumindo nossa população de estudo:

- DJs da cena alternativa brasileira
- Qualquer idade
- Qualquer nível de aparelhamento

- Atualmente ativos
- Tenham performado em pelo menos algumas festas para um público que não envolvesse apenas amigos

Estratégias para recrutamento:

Devido à experiência dos pesquisadores dentro do ciclo de discotecagem da região, o método de recrutamento escolhido foi o *informal network* (rede informal), que consiste em recrutar membros da rede informal que costuma se formar entre pessoas que têm uma determinada característica ou praticam uma determinada atividade em comum. Sendo parte desta rede, foi intuitivo para os pesquisadores começar o recrutamento por conhecidos que participam do mesmo ambiente social e profissional e a partir destes ir atingindo pessoas mais distantes.

Ao fim do recrutamento, possíveis entrevistados de vários estados do país haviam sido contactados, mas a maioria se encontrava dentro da Paraíba.

4.3.2 Do design da ferramenta de pesquisa

Um guia de entrevista foi elaborado levando em conta as perguntas que queríamos responder, informações colhidas da literatura, o modelo teórico e as metodologias propostas pelos autores nos quais baseamos nosso formato de pesquisa qualitativa. O guia de entrevista pode ser encontrado nos apêndices. O guia foi dividido em três etapas padrão:

Perguntas de abertura:

O intuito dessas perguntas é o de criar uma conexão com os entrevistados. Entram aqui perguntas mais abertas sobre as experiências iniciais como DJ dos entrevistados, por exemplo. Esta etapa também serve para conhecer um pouco dos critérios para a criação das playlists dos próprios participantes, avaliação das playlists deles e em geral e para conhecer o envolvimento técnico com a profissão destes por meio de perguntas sobre software e hardware utilizados por eles.

Conhecer os critérios de criação de boas playlists dos entrevistados é de extrema importância para nós dado que na etapa seguinte estes terão que discorrer sobre as playlists

que os mostraremos e estes critérios servirão como base para o diálogo que se seguirá.

Perguntas chave:

Após feita a conexão e ter um conhecimento básico dos entrevistados, passamos para as perguntas chave, a partir das quais procuramos entender de forma mais direta as opiniões e expectativas dos participantes sobre playlists criadas por outras, por geradores automáticos e como essas visões se relacionam.

É também nesta seção que ocorre o momento de apresentá-los às playlists amostradas dos modelos geradores usados (disponíveis no Anexo B). Os entrevistados são convidados a olhar as playlists geradas, recebem uma explicação geral sobre o contexto em que elas foram geradas e são informados em como eles devem proceder.

Em relação ao contexto de geração, os DJs são informados que todas as playlists foram geradas automaticamente por máquinas e que são playlists de pop-rock e rock. Não é informado aos entrevistados que modelo gerador foi responsável por cada playlist gerada. Em seguida é dito que eles devem ouvir as playlists e as músicas de cada uma em ordem, mas podendo voltar para músicas anteriores caso achem necessário, não sendo obrigatório que eles escutem as músicas por completo mas que escutem ao menos 30 segundos de cada uma e a transição entre uma faixa e outra. Eles são orientados a opinar livremente a medida que elas vão escutando o material levando em conta os aspectos levantados no momento anterior da entrevista em relação a suas próprias definições de boa construção de playlists. O que acontece neste momento foi uma sessão *think-aloud*. Também os é informado que ao final mais algumas perguntas simples e de opinião serão feitas acerca do material escutado.

Ao término da etapa de apreciação das playlists, caso o entrevistador sinta a necessidade, perguntas sobre a identificação de características negativas e positivas das playlists são feitas de forma mais direta e os entrevistados são questionados sobre as playlists que mais parecem ter sido criadas por seres humanos.

Perguntas de encerramento:

Por fim temos as perguntas de encerramento. Sua função principal é quebrar de forma não brusca o vínculo com os entrevistados. Além disso, são feitas umas perguntas mais gerais sobre geradores de playlists, sua utilidade como ferramenta de auxílio para DJs, ferramentas

associadas a esses geradores que os participantes gostariam de ter e sobre a possibilidade de uso geradores como DJs em festas. O intuito com essas perguntas é também tentar abordar algum aspecto da conversa que o entrevistador tenha detectado como pouco explorado nas seções anteriores e, no geral, quando a entrevista ocorre de forma mais fluida parte dessas perguntas já estão respondidas e esta seção é encurtada.

4.3.3 Das entrevistas realizadas

Entramos em contato com um total de 16 DJs (sendo 4 destes de fora da Paraíba). As entrevistas foram realizadas por ordem de disponibilidade dos possíveis entrevistados. Infelizmente não foi possível entrevistar todos devido a limitações de tempo para a conclusão da pesquisa e a dificuldade de marcar horários com alguns dos possíveis entrevistados em decorrer das férias e dos eventos de fim de ano.

Foram realizadas um total de 6 entrevistas, número abaixo do esperado pelos pesquisadores que pretendiam realizar ao menos 10. Neste tipo de pesquisa, o número de entrevistas realizadas é determinado pelo princípio da saturação da informação, onde para-se de entrevistar novos participantes a medida que a informação fornecida por eles começa a se repetir. No nosso caso, devido ao número de entrevistas abaixo do esperado, nem todas as questões que desejávamos abordar nas entrevistas foram saturadas. Deste modo, as análises que se seguem foram realizadas levando em consideração apenas o que conseguimos saturar dentro do grupo de entrevistados. Abordaremos um pouco os dados não saturados na seção de trabalhos futuros.

Dos 6 entrevistados 5 eram do sexo masculino. Em se tratando de localização, 4 paraibanos vivendo em Campina Grande, 1 paraibano vivendo em João Pessoa e 1 goiano de Goiânia. O DJ menos experiente possuía 6 meses de experiência, o mais experiente X anos. 5 dos 6 DJs possuíam mais de um ano de atividade. O DJ mais experiente era o único que tinha a atividade como profissão principal, enquanto os outros 5 levavam a atividade como hobby e/ou forma de renda complementar.

Em relação aos estilos musicais mais tocados por cada um deles: apenas 2 dos 6 entrevistados tinham o hábito de discotecar seguindo algum foco estético. Estes 2 DJs costumam tocar mais música indie e alternativa, apesar de não se limitarem só a isto. Os outros 4 costumam construir playlists para serem tocadas em eventos mais ecléticos que vão do pop

estadunidense, passando pelo funk brasileiro até chegar em estilos mais diversos como aberturas de desenhos animados.

As entrevistas foram realizadas pessoalmente ou via internet, dependendo da comodidade e da localização de cada participante.

Duas entrevistas foram realizadas pessoalmente, uma na casa do entrevistado e outra na casa do entrevistador, a pedido dos próprios entrevistados. As entrevistas presenciais foram gravadas usando-se o gravador padrão de um smartphone Android. Quatro entrevistas foram realizadas online usando o Skype ou Google Hangouts, dependendo da preferência dos entrevistados. O aplicativo web Zencastr⁸ foi utilizado para fazer a gravação do áudio das entrevistas.

Nossa estimativa inicial para a duração das entrevistas era de aproximadamente 1 hora. A primeira entrevista teve duração de 31 minutos, a segunda de 1 hora e 15 minutos, a terceira e quarta de 51 minutos, a quinta de 1 hora e 6 minutos e a sexta de 1 hora e 13 minutos. Em média, as entrevistas tiveram aproximadamente 58 minutos de duração.

4.3.4 Playlists utilizadas

Uma das partes mais importantes da entrevista é o momento onde os entrevistados são apresentados às playlists e pedidos para opinar acerca delas seguindo o formato *think-aloud*. Esta seção fala sobre os modelos usados para a geração e dos conjuntos de dados que foram utilizados para alimentá-los.

Dos modelos usados e escolha das playlists:

Um total de 5 playlists com 5 músicas cada foram apresentados aos entrevistados. Uma delas foi gerada aleatoriamente da lista de músicas disponíveis para fins de controle e possível comparação. As outras quatro foram geradas por dois modelos geradores diferentes. Duas para cada modelo. A quantidade de faixas em cada playlist foi escolhida levando em conta o que é tipicamente usado na literatura [2] e o tempo gasto para não cansar demais os entrevistados.

O primeiro modelo foi desenvolvido por McFee e Lankriet [23] e foi escolhido por ser estado da arte em termos de geradores probabilísticos e que usam características das músicas

⁸<https://zencastr.com/>

(e.g.: similaridades acústicas, época, *tags*, etc) como parâmetros de treinamento, apresentado originalmente no ISMIR do ano 2012. O segundo modelo é de autoria de Figueiredo, Ribeiro et al [12] e também é um modelo probabilístico estado da arte. Um de seus diferenciais é que ele não é especializado em recomendação musical e é, na verdade, um preditor de trajetórias de usuários para fins genéricos, seja recomendação musical, seja de produtos em uma loja, por exemplo. Para o treinamento deste modelo são necessários apenas usuários e os dados de comportamento prévio destes (e.g.: músicas ouvidas, itens visitados em uma loja, etc), que são usados para treinamento. No nosso caso específico, playlists são consideradas usuários e as músicas que as compõem são consideradas seus itens visitados. Outro fator que devemos ressaltar é que a proximidade com um dos desenvolvedores, Fábio Figueiredo, que nos permitiu ter um acesso mais aprofundado ao modelo também nos serviu de motivação para seu uso.

O modelo de McFee promete resultados melhores para playlists de um único estilo de música, chamado por ele de dialetos. Devido à forma de treinamento do modelo de Figueiredo também espera-se dele resultados mais especializados quando usados conjuntos de dados mais focados em comparação com conjuntos de dados mais generalistas (i.e.: playlists de um único estilo musical em comparação com playlists de vários estilos musicais misturados). Com o intuito de obter as melhores amostras possíveis e evitar confusão com os entrevistados, optamos por escolher então um único estilo musical para as playlists geradas pelos modelos que, como previamente mencionado, foi o pop rock/rock.

Para fazer a escolha deste estilo nós realizamos uma consulta com colegas de trabalho e amigos. Nós geramos 10 playlists de cada dialeto (i.e.: estilo musical) usando o modelo gerador de McFee e pedimos para estas pessoas identificarem quais dialetos apresentavam menos *outliers* (i.e.: playlists contendo músicas de gêneros muito diferentes do proposto). Escolhemos o estilo que foi votado como o mais coerente para as pessoas consultadas.

Após a escolha do estilo também geramos 10 playlists deste mesmo estilo com o TribeFlow. De cada um dos conjuntos de playlists gerados, pegamos a primeira e quinta playlist para usarmos no nosso experimento. A escolha destas posições foi feita de forma aleatória para reduzir o viés da amostra.

Dos conjuntos de dados utilizados:

O Million Song Dataset⁹ [3] é uma coleção de *features* de áudio e metadados para um milhão de músicas populares contemporâneas abertamente disponível. Suas informações foram usadas para duas tarefas específicas: a primeira é usar tais *features* no modelo de McFee, que as usa para realizar agrupamentos de músicas relacionados a parte da sua otimização interna. A segunda é servir de *pool* para escolha de músicas na hora de gerar playlists para ambos os modelos e para a amostra aleatória. No entanto, as faixas que não apareceram em nenhuma das playlists de do Art of The Mix não foram consideradas, reduzindo o total de músicas possíveis para 97.411.

O Art of The Mix é um banco de playlists extraídas diariamente do iTunes da Apple. Tais playlists podem ser previsualizadas e compradas do site. Ele também funciona como uma comunidade para discussões e compartilhamento de *reviews*, *mixes* e *mix tapes*. Um *snapshot* desta base de dados foi utilizada para treinamento de ambos os modelos e para testes e validação do modelo de McFee. Foram usadas um total de 209.485 playlists que foram coletadas em 2010 pelo próprio McFee, inspirado no trabalho de Ellis et al [10] que usava um *snapshot* da mesma base de dados em 2002.

Da forma de exposição das playlists ao entrevistados:

Como já dito anteriormente, as entrevistas foram realizadas tanto presencialmente como de forma remota através da internet e as playlists foram apresentadas de forma particular porém similar para cada um destes casos.

Para as entrevistas presenciais o computador do entrevistador foi utilizado. As playlists foram organizadas e apresentadas no software reprodutor e organizador de playlists Foo-bar 2000¹⁰, e *headphones* foram fornecidos para uso dos entrevistados. As playlists eram mostradas uma de cada vez e todas as músicas que a compunham eram visíveis, o que era importante para dar uma melhor noção da playlist como um todo para os entrevistados, além de permitir que eles pudessem voltar a músicas anteriores com facilidade caso achassem necessário. Instruções básicas do uso do software eram passadas para que o controle do fluxo de execução ficasse a cargo dos entrevistados.

No caso das entrevistas realizadas online, instruções foram dadas para que as condições

⁹<http://labrosa.ee.columbia.edu/millionsong/>

¹⁰<https://www.foobar2000.org/>

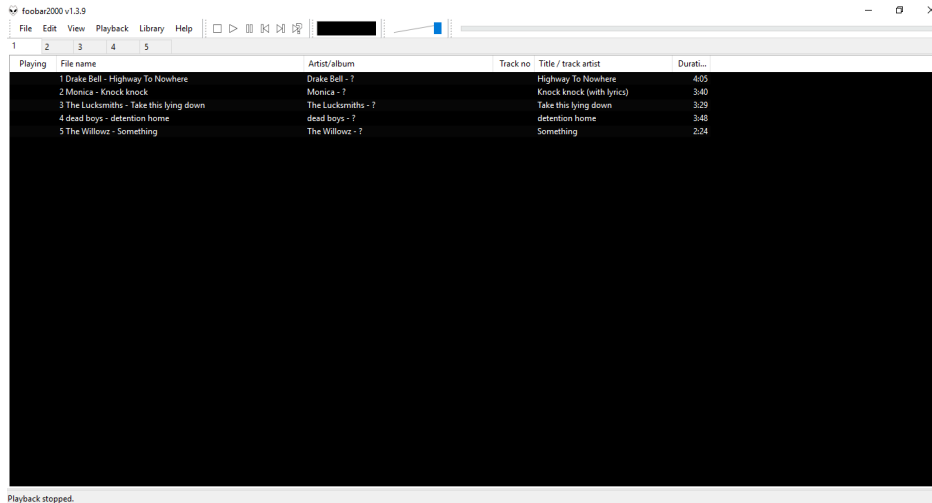


Figura 5: Interface do Foobar 2000, player utilizado nas entrevistas presenciais.

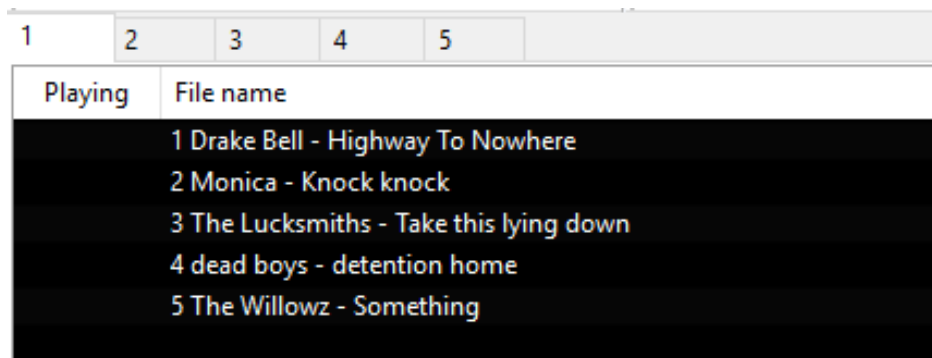


Figura 6: Interface do Foobar 2000, detalhe da exibição de playlists.

das entrevistas presenciais fossem simuladas. Pediu-se que os entrevistados usassem o software de sua preferência desde que pudessem ver a playlist como um todo e que tivessem controle do fluxo das músicas durante a execução destas. Também foi pedido que eles usassem *headphones* para minimizar interferências sonoras externas.

4.4 Ciclo Analítico

O ciclo analítico é a terceira parte da pesquisa qualitativa. É composto pelas atividades centrais de análise de dados: desenvolvimento de códigos, descrição e comparação, categorização e conceitualização, e finalmente o desenvolvimento da teoria.

Nossa análise é baseada em *grounded theory* [13], um popular método de coleção e análise de dados nas ciências sociais que combina o rigor metódico das ciências exatas e ele-

mentos “criativos” e de descoberta. Algumas das atividades analíticas desenvolvidas neste tipo de processo incluem: preparar transcrições das entrevistas, desenvolver códigos, definir códigos, codificar os dados transcritos, descrever, comparar e categorizar os dados, conceitualizar e desenvolver a teoria. Essas atividades não são necessariamente desenvolvidas nessa ordem e na nossa pesquisa essas atividades foram realizadas de forma cíclica, mas esta seção seguirá o ordem para fins de melhor entendimento.

4.4.1 Do tratamento de dados

Os dados eram inicialmente arquivos de áudio e o primeiro passo deste processo é transcrevê-los para texto. As entrevistas realizadas presencialmente apresentaram maior dificuldade de transcrição já que o gravador capta todos os sons como uma única faixa e, por esse tipo de entrevista se assemelhar muito a uma conversa mais informal, é comum ter momentos onde as duas pessoas falam algo ao mesmo tempo, dificultando o entendimento posterior. Já as entrevistas por internet usaram o aplicativo web Zencast que é grava separadamente o áudio de cada participante, apesar de existir opção para mixar os dois. Esta separação evita os problemas de sobreposição de áudio e entender os participantes vira uma tarefa bem mais simples.

Para a transcrição propriamente dita foi usado outro aplicativo web. Uma licença gratuita do Transcribe¹¹ nos foi dada por seus desenvolvedores. A aplicação fornece uma interface para digitação junto com um tocador de áudio, além de possuir uma série de atalhos no teclado com funções como pausar, acelerar, desacelerar, rebobinar e adiantar a entrevista que está sendo ouvida. Em comparação com a entrevista piloto que foi transcrita sem o auxílio dele, este aplicativo nos garantiu uma economia de algumas horas para cada transcrição.

4.4.2 Do desenvolvimento de códigos

Houveram duas etapas de desenvolvimento de códigos para análise das entrevistas: uma anterior à leitura das transcrições e outra após. A primeira é chamada de etapa dedutiva, onde códigos são derivados do framework conceitual criado, do próprio guia de entrevista, da literatura e da experiência profissional e/ou pessoal dos próprios pesquisadores. A segunda é

¹¹<https://transcribe.wreally.com/>

chamada de etapa indutiva e os códigos foram derivados da leitura em si das entrevistas, na grande maioria dos casos observando-se temas recorrentes no discurso dos entrevistados.

Estão listados a seguir os códigos usados nessa pesquisa separados por dedutivos ou indutivos.

Códigos dedutivos:

Do framework conceitual:

- Expectativas sobre playlists: usado para etiquetar de forma geral as diferentes expectativas que os entrevistados possuem acerca de playlists, sejam geradas automaticamente ou por humanos. Por exemplo: *“Se for uma playlist pra ser pesada ela tem que ser pesada. Uma quebra no meio, e ainda mais assim, ainda mais quando ela quebra no meio e depois ela volta a ser pesada e volta pra o leve, fica... Eu acho estranho. Eu acho muito estranho na verdade”*
- Características relacionadas à criação de playlists: usado para etiquetar as características relacionadas à criação de playlists que os entrevistados vão detectando ao longo da entrevista. Por exemplo: *“Aí você toca uma coisa mais farofa mesmo. Muito pop mesmo, porque se não fica sendo pra mim e eu tenho que pensar na vibe da galera também.”*
- Diferenças percebidas entre as playlists: usado para etiquetar as diferenças percebidas e mencionadas entre as diversas playlists apresentadas no intuito de tentar descobrir se os entrevistados são capazes de diferenciar os diferentes modelos usados. Por exemplo: *“eu acho que cada uma tem um ponto que tem falta sobre essas questões. Ou sobre linearidade, aliás ou sobre coerência, ou sobre fluxo ou sobre ordenação.”*

Do guia de entrevistas (disponível no Anexo A):

- Boa playlist: usado para etiquetar passagens onde o entrevistado identifica características consideradas por ele as de uma boa playlist. Por exemplo: *“que o começo e o fim não, não dê uma quebrada muito intensa entre a discotecagem de antes e a discotecagem que vai vir depois.”*

- **Motivação para ouvir playlists:** usado para etiquetar os motivos levantados por um entrevistado para ouvir playlists. Por exemplo: *“A minha forma de ouvir música nova é vendo playlist das pessoas.”*
- **Motivações para usar geradores automáticos:** usado para etiquetar menções a motivos de um entrevistado para usar um gerador automático em particular. Por exemplo: entrevistado falando sobre a rádio do Last.fm *“que eu já tava um pouco cansado de ouvir as coisas de sempre, então eu tava procurando outra coisas.”*
- **Características de geradores automáticos usados:** usado para etiquetar as menções a características que um entrevistado identifica acerca de um gerador automático mencionado por ele. Por exemplo: *“Um dos defeitos que eu vejo nesse Smarter Playlists¹² é porque é limitado a biblioteca do Spotify, né?”*
- **Característica positiva:** etiqueta a menção a uma característica de uma playlist das amostradas vista como positiva dentro do contexto. Por exemplo: *“Assim, a 1, 2 e 4 casam”*
- **Característica negativa:** etiqueta a menção a uma característica de uma playlist das amostradas vista como negativa dentro do contexto. Por exemplo: *“eu achei que essa terceira quebrou bem o clima. Ela... Não me agradou, essa transição não me agradou não.”*
- **Humanidade:** usada para as citações de características entendidas como humanas de uma playlist. Por exemplo: *“Não entendi bem como o gerador interpretou isso. Acho que uma pessoa por exemplo não faria isso.”*
- **Sugestões para geradores automáticos:** usado para as características que os entrevistados citam como ausentes mas desejáveis em geradores automáticos. Por exemplo: *“Então eu acho que se um programa fizesse isso, tivesse essa noção de fazer a escala, ou saber a notação, o tom da música, né? Na verdade. Isso que era a palavra que eu tava buscando. Saber o tom da música pra que ele pudesse fazer essa transição e as vezes o BPM também... Nem que não precisa ser o BPM igualzinho, “ah, 128*

¹²<http://smarterplaylists.playlistmachinery.com/>

tem que casar com 128... "Não, 128 casar com 130, com 126 ou 124. Algo que tivesse relativamente próximo, acho que seria interessante pra uma playlist automática."

- Limitações de geradores automáticos: usado em características identificadas pelo entrevistado como faltando ou vistas como impossíveis de serem alcançadas em geradores automáticos no geral. Por exemplo: *"não, nunca vi em nenhum gerador automático algo parecido. Eles geralmente ficam no mesmo... É aquele negócio que te falei, é uma coisa que eu odeio nesses geradores automáticos é colocar as mesmas músicas de sempre, nunca tem algo diferente, entendeu?"*

Da literatura:

- Egoísmo: usado para marcar a motivação de muitos DJs quando montando suas playlists para execução em festas [1]. Por exemplo: *"A gente saia pras festas mas geralmente a gente não gostava das músicas. eu e meu pessoal. aí a gente começou a preferir ficar em casa e a gente fazia nossas próprias festas e a gente fazia as playlists da gente também."*

Códigos indutivos:

- Relação hit-novidade: etiqueta a noção de que uma boa playlist deve incluir um balanceamento entre músicas já conhecidas e não conhecidas pelo público. Por exemplo: *"Assim, tipo, eu coloco músicas hits, aqueles hinos, eu coloco os hinos. Eu coloco um estilo seguido pra atizar a galera. Aí depois eu joga o que eu acho que a galera não vai conhecer. Porque aí já dá o tempo da galera dar uma descansada, pensar mais no que tá ouvindo. Uma coisa assim."*
- Ordenação: referente às percepções dos entrevistados sobre a ordem das músicas integrantes de uma playlist. Por exemplo: *"Talvez se Cat Stevens que é a terceira viesse em segundo ficaria melhor."*
- Contexto: menção do entrevistado sobre questões de contexto (i.e.: onde a playlist vai ser executada, seja lugar, humor, clima, etc). Por exemplo: *"Talvez se fosse uma playlist pra chuva ou depressiva até cairia..."*

5 Análise de dados

Neste capítulo mostramos a análise dos dados propriamente dita. Inicialmente, abordamos os dados com o fim de responder nossas 3 perguntas de pesquisa secundárias e em seguida, a partir dos conceitos e das teorias inferidos destas, discutiremos um pouco mais as teorias que deduzimos e suas implicações ao se observar o escopo mais amplo da pergunta principal.

Nas subseções que se seguem, abordaremos cada pergunta separadamente e em seguida discutiremos os conceitos por nós derivados de forma conectada e como essas conexões são relevantes dentro do conceito maior da pergunta principal. É importante explicitar que as duas primeiras perguntas foram feitas de forma direta aos entrevistados durante a entrevista (o guia de entrevista pode ser encontrado no Anexo A), mas afirmações feitas durante o momento de apreciação das playlists também foram usadas. A última pergunta, por outro lado, depende totalmente do que foi dito neste momento de escuta das playlists geradas pelos modelos geradores de estudo.

5.1 Quais são as diferentes expectativas para playlists geradas automaticamente ou por humanos?

Com esta pergunta nós queremos entender melhor quais as expectativas e motivações dos nossos entrevistados no que diz respeito ao seu consumo de playlists que não foram geradas por eles mesmos. Queremos entender o que estas pessoas buscam quando decidem que querem escutar uma playlist, se buscam experiências diferentes ao ouvir uma playlist gerada automaticamente de quando buscam playlists feitas por outras pessoas, o que há de comum e de diferente nestas expectativas, etc. Nos parágrafos seguintes descreveremos algumas expectativas que fomos capazes de saturar dentro do nosso conjunto de entrevista. Cada observação que fizermos também serão seguidas de alguns exemplos retirados das conversas que tivemos com os DJs entrevistados.

Em geral, a ideia de ter playlists como uma forma de conhecer músicas novas foi um aspecto bastante citado como a principal expectativa que os entrevistados têm ao ouvir playlists tanto humanas como playlists geradas automaticamente. Afirmações deste tipo sobre playlists automáticas foram feitas em todas as entrevistas onde os participantes disseram ter o costume de ouvir playlists geradas automaticamente (5 dos 6 entrevistados). Um dos en-

entrevistados, por exemplo, resalta a importância das playlists automáticas como uma forma fácil de alcançar novidades dado ao fato de isto ser algo crucial para sua atividade:

- *“As vezes eu gosto das automáticas porque, tipo, como eu tou ouvindo muita novidade também é bom pra chegar novidade pra mim, pra eu não ficar com aquela coisa da... desatualizado.”*

Já em relação aos entrevistados que relataram possuir o costume de ouvir playlists criadas por outras pessoas (3 dos 6), estes também teceram relatos similares acerca das playlists criadas por humanos. Um dos entrevistados descreve um pouco, por exemplo, seu uso da aplicação Mix Cloud¹³, onde DJs do mundo todo postam os *sets* de músicas que usaram durante apresentações, como uma forma de descobrir as novas tendências das pistas. No caso dele, há um maior foco no que está em alta no cenário nacional:

- *“Os djs botam os sets de apresentações. E aí eu busco alguns djs que tocam em algumas festas em São Paulo e a partir daí eu vou vendo o que é trend nessas festas que o povo...”*

Algumas citações mencionando essa similaridade de expectativas também foram feitas de forma mais direta. Por exemplo, este entrevistado relata como ele costuma usar playlists geradas automaticamente e por humanos da mesma forma quando o que ele quer encontrar músicas de um determinado estilo:

- *“eu uso da mesma forma. A minha motivação nesse caso é gerar uma playlist e eu preciso achar músicas de um determinado gênero que me agradem. A mesma função assim. Eu tento achar isso vendo o gosto pessoal de outra pessoa e tento ver isso através dessas playlists automáticas.”*

Entrando um pouco em conflito com as afirmações de expectativas similares acima, 2 dos 3 entrevistados que relataram ter o hábito de ouvir tanto playlists criadas por humanos quanto playlists criadas por geradores automáticos descreveram características particulares nas novidades que eles buscam que eles consideram que apenas playlists criadas por humanos são capazes de apresentar. Uma delas diz respeito ao que o entrevistado descreve como

¹³<https://www.mixcloud.com/>

criação de novas conexões, que é a capacidade da playlist conter relações não óbvias entre músicas, como por exemplo músicas de estilos diferentes mas que se casam de alguma forma mais subjetiva, como relatado neste comentário:

- *“acho que criar essas novas conexões automaticamente... ah! esse estilo aqui casa muito bem com esse outro...” eu nunca vi nada parecido também em nenhum gerador automático.”*

Em um relato similar, um Dj que, apesar de se dizer satisfeito com os geradores automáticos que ele usa, reforça esse aspecto das conexões inesperadas, principalmente no que diz respeito à sua profissão de DJ e a importância dessas conexões criativas na hora de discotecar:

- *“Porque DJ tem essa coisa de inspiração. E, até hoje como tou sem curso de DJ, etc, toda minha coisa é muito auto didata... Então é bom você escutar uma mixagem de uma música diferente, ou uma transição de uma música diferente pra outra.”*

O outro aspecto levantado diz respeito à descoberta de músicas novas quando os limites do catálogo de músicas de um gerador começam a ser sentidos pelo usuário. Um dos entrevistados exemplifica bem essa questão comentando sobre o Spotify e o Smarter Playlist (que também usa o catálogo do Spotify) e como ele sente que as playlists que são apresentadas a ele logo se tornam repetitivas:

- *“E as vezes ele tem um problema que é muitas músicas repetidas. Você acaba caindo no mesmo... não é dado algo novo pra você. Você fica restrito àquele mundo. E quando é humano as vezes você é surpreendido.”*

Outro aspecto levantado pelos entrevistados diz respeito à existência ou não de uma temática nas playlists escutadas (e.g.: estilo musical, época, bpm das músicas, etc). Playlists automáticas são vistas como mais aleatórias e os entrevistados esperam em geral que elas fugam de temáticas únicas, afinal *“Em geral essas playlists assim são bem variadas, né?”*, como afirma um dos entrevistados acerca de sua experiência geral com playlists automáticas. Outro entrevistado chega a relatar algumas de suas experiências com playlists automáticas como usar um *shuffle* de um *player* de música dentro de sua biblioteca musical, onde surpresas são sempre esperadas:

- *“É tipo você ligar uma playlist realmente aleatória, você pegar todas as músicas do seu computador, ligar o player e dar um random. Sem saber o que vai cair.”*

Já as playlists criadas por humanos são buscadas por suas temáticas já definidas e fluxo mais previsível. Como dois dos entrevistados relatam. Um descrevendo seu comportamento de buscar playlists humanas quando em busca de temáticas mais específicas, enquanto o outro descreve sua visão particular de que playlists mais previsíveis parecem mais humanas, ressaltando o tipo de raciocínio que ele usa ao criar playlists que ele projeta como expectativa para playlists de outras pessoas:

- *“Mas eu gosto de ouvir coisas temáticas também, tipo anos 80, anos 90... Aquela playlist da galera, tipo assim, que a galera cria, eu acho interessante. Até outros DJs também.”*
- *“Porque eu acho ela previsível assim, então acho que se uma pessoa fosse fazer pensando racionalmente ela vai ter uma ideia de construir uma playlist que seja ... Assim, pelo menos de mim, né. Construi uma playlist que seja voltada pra um tipo de público.”*

Um caso especial em relação à temática diz respeito ao gerador do Youtube que é visto como bom em termos de temática por alguns entrevistados:

- *“Do youtube particularmente, a questão do, por exemplo: se eu... se eu tou ouvindo, por exemplo, alguma coisa dos anos 90. Sei lá, um axé anos 90. Ele vai me dar uma playlist ali de axé anos 90.. ”*

Por outro lado, o mesmo gerador é criticado por ficar muito preso a *hits* (i.e.: músicas mais populares dos catálogos):

- *“não. Não sei. é porque eu acho que sempre vai remeter às coisas que tão muito popularizadas.”*

Um aspecto foi relatado como expectativa apenas para playlists humanas, sem possuir uma contrapartida automática, até pela própria forma que ele foi definido pelos entrevistados. A ideia de estilo pessoal foi relatada por pelo menos metade dos entrevistados como algo

que eles buscam em playlists humanas. Um entrevistado relata sobre o possível contexto de temática mais abstrata, assim como a possibilidade da playlist poder refletir o humor de seu criador, enquanto outro fala sobre os toques pessoais, da personalidade do criador que ele costuma esperar em playlists criadas por pessoas:

- *“Eu acho assim, a playlist por pessoa ela vai ter... vai um pouco ainda pela afinidade da pessoa. Principalmente se for tipo, a pessoa tá criando aquela playlist ali, tipo no quarto ou no dia chuvoso ou por algum status de humor, ela tá muito depressiva e "ah, vou criar uma playlist" igual a galera fica nesses grupos aí do Facebook¹⁴: "me indique músicas e etc.*
- *“principalmente pra galera que vive disso, de fazer playlist, de viver de música, tal, tem sempre uns toques que as pessoas dão pra playlists muito específicas que você pensa "não, uma máquina com certeza não colocaria essa música".”*

5.2 Quais são as características relacionadas à criação de playlist que os DJs conseguem identificar nas amostras de playlists automaticamente geradas?

Nossa intenção aqui é entender, a partir do vocabulário e das noções do que compõem uma boa playlist do próprio entrevistado, quais dessas características de boas playlists o participante consegue identificar nas playlists geradas automaticamente apresentadas a ele durante a entrevista.

Antes de listar as características identificadas pelos entrevistados é importante ressaltar que a lista de características desejáveis era levantada pelos próprios em um momento da entrevista anterior à apreciação das playlists de estudo baseados em suas próprias preferências pessoais (i.e.: “gosto”, como definido anteriormente). Em geral, a maioria das características foi mencionada por todos os participantes, com exceção de “primeiras e últimas impressões”,

Similaridade entre as músicas foi de uma maneira geral a característica mais observada por todos os entrevistados. Ela foi descrita a partir de vários parâmetros de comparação, como é o caso da época das músicas da playlist, a exemplo deste relato:

¹⁴<https://www.facebook.com/>

- *“Sim essa daqui eu achei bem convencional a playlist que é algo bem 70, 80, sei lá. (...) Quem ouve a primeira música talvez também goste de todas. É algo parecido. Eu acho que ela é uma playlist boa.”*

Coesão geral entre todas as músicas da playlist, como nestes dois relatos:

- *“Mas tá bem amarradinha. Tocaria bem de boas num cover dos Beatles lá no extensão.”*
- *“Gostei, tem uma energia boa. E dá a impressão certa sobre a playlist. Você encontra outras similares ao longo dela.”*

Assim como similaridade devido a fatores de baixo nível, como é o caso deste entrevistado que ressalta sua apreciação à similaridade de características instrumentais dentro das músicas da playlist 4 (do modelo TribeFlow) apresentada a ele:

- *“Mas eu gostei do groove. O groove do baixo dela, muito boa. Que vai casar bem com a próxima música do Duran Duran, Hungry Like The Wolf.”*

A presença de surpresas também foi mencionado pelos entrevistados, seja como presente, seja como ausente nas playlists amostradas. e é relatada tanto de forma positiva como de forma negativa dentro das playlists amostradas, dependendo da intensidade de tal surpresa. Como exemplo da presença positiva temos um participante descrevendo a primeira música da playlist aleatória e outro entrevistado relatando sua apreciação pelas mudanças de estilo da segunda playlist:

- *“Já tou gostando muito dessa. Porque a primeira música eu não conhecia e é algo que eu gosto muito, assim.”*
- *“É. Porque ela tá variada. Não tem só heavy metal, tem uma coisa mais suave, uma quebrada assim.”*

Entretanto, quebras brusca de similaridade e fluxo entre as músicas são descritas como surpresas negativas. A exemplo deste comentário simples sobre uma música que quebra muito o clima da playlist e do comentário seguinte sobre a quinta playlist que inicialmente agrada o entrevistado pela variedade, mas, ao ficar mais uniforme perto do fim, cria uma surpresa negativa para ele:

- *“Assim, da primeira pra segunda foi uma surpresa não legal assim.”*
- *“A pessoa que ouve a primeira música talvez goste da segunda, aí na terceira você acha que a playlist é bem variada. Aí na quarta e quinta música fica tudo parecido com a terceira.”*

Ainda em relação às surpresas, a total ausência destas é também descrita de uma forma negativa por 4 dos 6 entrevistados. Este entrevistado, por exemplo, critica a quarta playlist, descrita por muitos como a mais humana, por achar ela previsível demais:

- *“E até aquela que eu falei que tava bem linear talvez ela fosse linear demais até (...)”*

A forma de agrupamento ou a ordem das músicas também foi bastante discutida, principalmente nas playlists menos lineares, que em geral eram vistas como necessitadas de reordenação. Durante o momento de relatar a metodologia de criação de suas próprias playlists para discotecagem, todos os entrevistados relataram dividir seus sets em momentos, como por exemplo este entrevistado que fala da organização de seus *sets* para discotecagem:

- *“Sim. Eu geralmente penso em começar, em formar blocos. Eu nunca saio de um estilo totalmente diferente pra outro.”*

Essa preocupação com momentos distintos também se refletiu no momento de apreciação das playlists. Reordenações foram sugeridas a todas as playlists, em geral a partir da identificação de agrupamentos de músicas dentro das playlists e da tendência dos entrevistados a querer deixá-los juntos e ordenados, como nos comentários que se seguem:

- *“Essa música de Cat Stevens é bem o clima de Janes Joplin, aí tá bom, assim. Elas duas formaram um cluster, alguma coisa assim, boa. um grupo bom dentro da playlist.”*
- *“pronto, aí veio uma música de hard rock que parece mais com Black Sabbath, na minha cabeça. Então eu preferia deixar elas juntas e deixar e depois pular pra o folk tradicional. Eu gostei dessa playlist, só acho que daria pra ordenar de uma forma melhor”*
- *“No geral, tá faltando um cuidado na hora de ordenar, eu acho.”*

5.3 Se e como os DJs percebem as diferenças entre os modelos usados para gerar as playlists?

Com esta pergunta queríamos identificar se os geradores conseguiriam ser diferenciados pelos entrevistados a partir exclusivamente da forma como eles descreveriam cada uma das playlists a eles apresentadas. Não foi perguntado de nenhuma forma mais direta sobre diferenciação dos geradores.

Partindo para uma análise focada nas impressões de cada gerador em cima dos conceitos induzidos, pudemos perceber rapidamente que os usuários, através de suas diferentes formas de discorrer, foram capazes de diferenciar bem todos os geradores, inclusive o aleatório.

O modelo de McFee foi em geral descrito como interessante pelos entrevistados, principalmente os mais ecléticos, por conter quebras de expectativa, o que é considerado um bom aspecto para o ambiente de discotecagem, como descreve este entrevistado:

- *“Tem aquela coisa, ela começa dançante, ela vai pra aquela coisa meio sensual as próximas duas músicas, tipo a Mônica. E depois ela volta pra uma coisa mais explosiva, começando com uma coisa mais surf rock do Dead Boys, depois vai pro The Willows. É uma sequencia boa, é uma sequencia muito boa, na verdade.”*

Entretanto, praticamente todos os entrevistados tiveram algum comentário negativo sobre a forma que essas surpresas se conectavam ou se ordenavam, mais uma vez sugerindo reordenações como nestes dois exemplos:

- *“É. Acho que devia... Tá faltando uma música intermediária, talvez, entre elas duas. E essa primeira música totalmente diferente.”*
- *“Pronto, essa última podia vir depois da terceira que estaria perfeito. Estaria melhor.”*

Em relação ao conceito de intenções (i.e.: para que funções ou ambientes essas playlists mais se encaixariam), no geral as playlists desse modelo foram descritas de forma mais vaga, focando mais em possíveis ambientes para sua execução que temáticas específicas sentidas na playlists. Por exemplo:

- *“Não, ela tá assim numa linha legal pra você escutar como som ambiente num bar. O que rolou até agora tá linear nisso.”*

O TribeFlow, por sua vez, se destacou por ser descrito como o gerador mais humano por 5 dos 6 entrevistados. Essa humanidade está diretamente relacionada às características relacionadas à criação de playlists mais facilmente identificáveis no discurso deles quando descrevendo as amostras. Um destes fatores comumente mencionados foi a época das músicas, como neste comentário que destaca que uma pessoa que goste de uma das músicas provavelmente irá gostar das outras pela similaridade:

- *“Sim essa daqui eu achei bem convencional a playlist que é algo bem 70, 80, sei lá. (...) Quem ouve a primeira música talvez também goste de todas. É algo parecido. Eu acho que ela é uma playlist boa.”*

A similaridade entre os diferentes estilos de música também foi bastante destacado, levando em consideração muitas características chave como, mais uma vez, época, estilos musicais e instrumentação, como descrito neste relato sobre a playlist 4:

- *“assim, essa pegada anos 80, começo dos 90 ali. Começa com The Cars, aquele finalzinho dos 80, começo dos 90. Muito boa. Depois vai pra Dramarama, uma coisa um pouquinho surf rock anos 80, meio punkzinho e surf rock, uma vibe muito boa. The Smithereens... mas é uma música boa. Não conhecia, esse eu não conhecia. Mas eu gostei do groove. O groove do baixo dela, muito boa. Que vai casar bem com a próxima música do Duran Duran, Hungry Like The Wolf. Foda pra caralho. E o Van Halen que fechou muito bem a playlist assim. Muito muito boa. Essa playlist ela tá salva aqui, eu vou usar ela (risos)”*

Houveram também relatos nos descrevendo as intenções percebidas destas playlists, que são em geral descritas de forma mais específica, mencionando época, como já mencionado, andamento rítmico das faixas, e descrições mais precisas de possível público alvo. Neste comentário, por exemplo, o entrevistado descreve o público alvo para o qual ele tocaria a playlist 4, assim como um possível uso fora do ambiente de festas:

- *“Mas um festa pra uma galera mais velha que tenha acima das 30 taria de boa e se fosse uma playlist pra ouvir em casa mesmo assim ela também taria de boa. Gostei muito dela.”*

Em contraponto a isso tudo descrito acima temos o único entrevistado que discordou dela como a mais humana, argumentando que uma das playlists deste modelo (a quarta) era homogênea demais. Este entrevistado já desenvolveu projetos na área de geração automática de playlists e suspeitamos que por este motivo ele tenha desenvolvido tal suspeita. Seu comentário levanta suspeitas em relação ao excesso de similaridade entre as músicas percebido por ele:

- *“humanamente falando sem fazer nenhum cálculo... mas a quarta eu acho que teria mais probabilidade de um programa dar essa playlist . As músicas se parecem mais.”*

Por último temos a playlist gerada aleatoriamente que em geral foi vista pelos entrevistados como muito difícil de identificar intenções e temáticas, chegando inclusive ao ponto de ser complicado propor uma reordenação, como descrevem estes dois entrevistados:

- *“não, eu acho que talvez uma nova ordenação, mas realmente fica muito confuso associar essas 5 músicas, pelo menos nessa ordenação. Eu não... Não me deu pra compreender. Muito louco.”*
- *“Se for temática a playlist ela já deu uma vacilada grande aqui, viu? De eletrônico pra metal... Vish! Essa daqui foi que não encaixou de jeito nenhum (risos) Já começou meio Eric Clapton aqui... Eu tou falando, máquina não sabe fazer playlist não. Apesar de ter escolhido músicas boas. Só não tão encaixando uma com a outra, né?”*

Alguns entrevistados ressaltaram pontos positivos mas em geral sobre músicas de forma isolada e focados em gosto pessoal. Como por exemplo:

- *“Porque a primeira música eu não conhecia e é algo que eu gosto muito, assim.”*

Porém, o mesmo entrevistado que não considerou as playlists do segundo modelo mais humanas, aquele que tem *background* em recomendação musical, considerou esta daqui a sua preferida. Neste exemplo de comentário temos uma descrição meio ambígua das motivações por trás de sua escolha:

- *“na verdade tirando essa quarta (música), acho que é a playlist que mais parece que um humano fez, assim. Tipo, não totalmente mas faz um pouco de sentido. Não sei.”*

Tipo, "tomar um banho aqui... vou escutar uma musiquinha... vou sei lá, fazer alguma coisa."

Mais uma vez, pelo aparente entendimento aprofundado do funcionamento de geradores, o entrevistado parece ter entendido humanidade pela dificuldade dele de identificar os tipos de metadados que seriam avaliados para se gerar a playlist, como explicitado no comentário seguinte:

- *“Eu acho que eu continuo na terceira. A terceira tem uma coisa que é... como [sic] os metadados da música não dá pra explicar.”*

5.4 Quais são as percepções de DJs acerca de playlists geradas por geradores automáticos?

Como forma de poder organizar melhor os dados coletados por nós, assim como as respostas obtidas para as perguntas de pesquisa secundárias, criamos o conceito de Percepções para podermos fazer agrupamentos das informações em nossas mãos e poder derivar as teorias para chegarmos às conclusões da nossa pesquisa. Identificamos três tipos de Percepções mais específicos que descreveremos abaixo:

- **Diferenciação dos geradores:** a capacidade dos entrevistados de diferenciar os vários geradores usados a partir de sua maneira de descrevê-los. Está bastante conectado aos códigos que adjetivam geradores como características positivas e negativas, ordenação e características relacionadas à criação de playlists.
- **Classificação de utilidade:** a forma como os entrevistados vêm os possíveis usos das diferentes playlists geradas, levando em conta suas expectativas em relação à playlists automáticas e humanas. Conectado aos mesmos códigos do conceito anterior, com a adição de contexto.
- **Humanidade:** a maneira que os entrevistados enxergam as playlists geradas em relação a quão próximas eles consideram que elas estejam de algo gerado por um criador humano, levando em conta as características relacionadas à criação de playlists identificadas por estes. Relação hit-novidade, humanidade e todos os códigos que lidam com expectativas são bem importantes para este conceito.

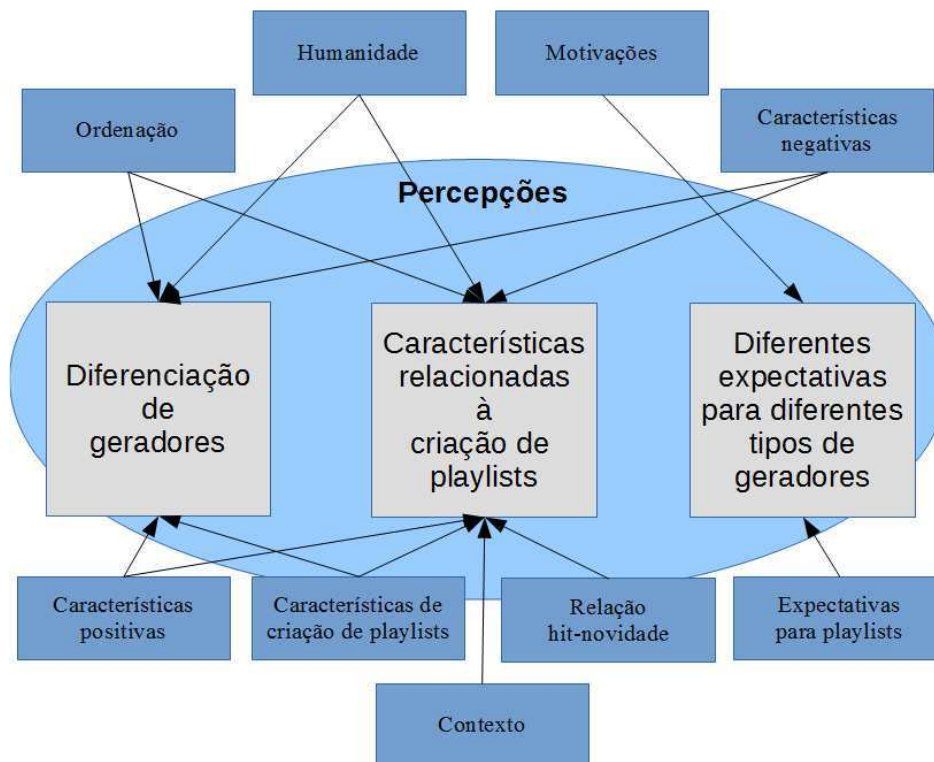


Figura 7: Diagrama de relações entre códigos e conceitos

Nosso modelo teórico vem diretamente da junção das respostas das perguntas de pesquisa secundárias, onde os conceitos *classificação de utilidade* e *humanidade* são respectivamente expansões das expectativas para playlists geradas por máquinas e por humanas e das características relacionadas à criação de playlists consideradas importantes pelos entrevistados.

Classificação de utilidade vem da ideia das expectativas dos participantes em relação à playlists de uma forma geral. Não só para apreciação própria como para fins de utilização em ambientes reais, que foi um ponto bastante levantado por todos os entrevistados. Por exemplo, este entrevistado explica que tipo de ambiente ele usaria uma determinada playlist dentre as mostradas a ele durante a entrevista, ressaltando também a importância do tipo de público:

- *Se fosse uma playlist mais festiva, um aniversário, alguma coisa, elas tariam de boa, dependendo da idade da pessoa, lógico.*

Temos aqui a ideia utilidade como o conjunto de contextos onde uma determinada playlist possa ser vista como uma boa playlist, já que nossas entrevistadas revelam que, na percepção

dos participantes, playlists são vistas mais em termos de adequação a certos contextos ao invés da dicotomia "boa x ruim".

Já humanidade vem da percepção de entrevistado de quão próxima uma playlist automática está de ser confundida com algo produzido por um ser humano. Para construir esse conceito usamos das características relacionadas à criação de playlists listadas e descritas pelos participantes tanto durante a descrição de seu processo criativo como na justificativa da pergunta do guia focada neste assunto (ver Anexo A para guia de entrevista).

6 **Discussão e conclusões**

Ao término do ciclo de análise de dados, fomos capazes de inferir as percepções dos profissionais que geram playlists sobre as playlists geradas automaticamente, bem como seus respectivos modelos geradores. Utilizamos como ferramenta de pesquisa o entendimento que esses profissionais têm sobre como criar playlists e como eles são capazes de perceber esses padrões nas playlists geradas automaticamente. Ainda que de forma não explícita, os entrevistados conseguiram caracterizar e dar contexto aos diferentes geradores, no sentido de serem capazes de descrever os possíveis usos mais apropriados para cada um dos modelos. Também foi possível entender como os participantes percebem características de humanidade nas amostras que os foram apresentadas.

Levando em conta os conceitos acima descritos, foi percebido que, para este grupo de entrevistados, playlists são percebidas como mais humanas quando os participantes conseguem identificar uma única motivação forte, uma única temática que aparentemente norteia o agrupamento e encadeamento de músicas, seja ela a época, estilo ou com a relação ao encadeamento de músicas em uma sequência que envolva características comuns entre elas, minimizando quebras bruscas de estilo. Por outro lado, também se percebe que playlists menos homogêneas não são necessariamente entendidas como playlists ruins e são muitas vezes entendidas como surpresas positivas pelos entrevistados.

Outros trabalhos já tinham sido realizados com o fim de entender as percepções de usuários acerca de playlists geradas automaticamente [19]. Neste, a importância de características como variedade, metadados, preferências pessoais, familiaridade, mistura de músicas conhecidas com novidades já eram evidenciadas pela maneira que elas afetam a percepção de qualidade de playlists para usuários. Nosso estudo reforça tais conclusões, mostrando que playlists que mais satisfazem o maior número possível destas características são vistas como mais humanas pelos DJs entrevistados. Outra relação verificada como positiva é a mescla entre músicas mais e menos famosas de uma forma menos individual e mais focada no entendimento de certos círculos sociais (i.e.: públicos alvo), em um contexto em que a relação hit versus novidades já é bem conhecida na literatura no que diz respeito à cultura dos DJs e sua importância para o ambiente de discotecagem [1].

Além disso, nossos entrevistados, devido a sua experiência com criação de playlists,

conseguem ponderar a presença e ausência de certas características das listadas acima, sendo capazes de enxergar e recomendar ambientes, públicos e contextos para os quais as playlists a eles apresentadas se encaixariam melhor. O que reforça a ideia de que, tão importante quanto ser capaz de avaliar um gerador de playlists como bom ou ruim, é entender o que se quer das playlists geradas por ele.

Playlists de um modo geral ainda são vistas pela nossa população de estudo como formas de encontrar novidades apenas. Entretanto, os participantes ainda sentem que certos tipos de novidades são apenas possíveis a partir de playlists criadas por humanos. A mencionada falta de conexões novas e imprevisíveis é um problema que já vem sendo estudado por alguns pesquisadores, como é o caso de Pachet [26] que desenvolve formas de usar modelos probabilísticos baseados em treinamento que sejam capazes de gerar resultados que possam ir além dos seus conjuntos de treinamento. O nosso trabalho reforça a importância desta linha de pesquisa. Ainda em relação a tipos de novidades apenas possíveis em playlists humanas, temos também o caso da limitação de catálogos e o problema de *cold-start*, este segundo que é bastante estudado na área de recomendação em geral, a exemplo do estudo de Eck et al [9]. Nossos entrevistados reforçam a importância prática de se minimizar o problema do *cold-start*, dado que usuários mais dedicados e exploradores [20] sentem na prática essa limitação ao ponto de se frustrarem com geradores automáticos.

Um último ponto que gostaríamos de levantar diz respeito ao futuro dos modelos geradores automáticos. Nosso estudo nos mostrou que o TribeFlow, modelo de predição de trajetória generalista, que usa apenas a ordem das músicas nas playlists como entrada, se sai bem melhor como um gerador mais humano. O que nos leva a pensar que é possível que modelos assim estejam em um caminho melhor quando o intuito do gerador é o de imitar o estilo de criação de seres humanos. Por outro lado, o modelo de HyperGrafos, apesar de ter recebido muitas críticas em relação à ordenação, no geral parece ser entendido como um modelo mais surpreendente e, até por possuir muitos parâmetros passíveis de otimização e reconfiguração, pode representar um melhor caminho para a criação de geradores que simulem a criatividade humana que os entrevistados dizem ainda falta nos geradores automáticos atuais.

7 Limitações e trabalhos futuros

Uma das limitações deste trabalho diz respeito ao número pequeno de entrevistados, mesmo que esta quantidade tenha servido de certo modo às nossas necessidades de pesquisa. Gostaríamos de ter sido capazes de ver que tipos de informações interessantes teríamos conseguido inferir caso esta pesquisa tivesse sido realizada com o dobro de participantes, por exemplo.

Uma possível atividade interessante de ser realizada seria usar estas entrevistas como base para a criação de uma entrevista semi estruturada mais curta, que possa ser feita de forma mais rápida, talvez até acíclica, para que um maior número de DJs possa ser atingido mais facilmente e assim ser possível expandir facilmente os resultados aqui obtidos.

Ainda em relação ao número de participantes, outras limitações incluem as análises de certos conceitos que, neste trabalho, foram deixadas de forma parcial. Como mencionado em seções anteriores, focamos nossas análises apenas nas informações que conseguimos saturar, mas algumas informações interessantes que surgiram nas entrevistas acabaram sendo deixadas de lado por não terem sido amplamente exploradas nas entrevistas. Fatores de familiaridade com o uso de geradores automáticos no dia a dia parecem ter alguma influência sobre como os entrevistados percebem as playlists, por exemplo, como já foi percebido em outros trabalhos da literatura [20], mas carecemos de mais informação focada nesse aspecto para verificarmos esta teoria em nossos dados.

Dois de nossos entrevistados também mencionaram que seria interessante pra eles conhecer e, talvez, manipular os parâmetros dos geradores que eles usam no dia a dia. O que remete mais uma vez a certas ideias exploradas por Pachet [26] como uma forma de gerar saídas mais diversas de modelos baseados em treinamento e talvez seja importante explorar este assunto inclusive com usuários que não sejam DJs. Outro ponto emergente que achamos interessante foi que nosso único participante que tinha conhecimento mais aprofundado da área de recomendação musical apresentou certas percepções que destoavam bastante do resto do grupo. É possível que esse fator de familiaridade com a área possa ser um bom foco de estudo para quem planeja estudar geradores com algum nível de personalização por parte dos usuários.

Referências

- [1] ATTIAS, B., GAVANAS, A., AND RIETVELD, H. *DJ Culture in the Mix: Power, Technology, and Social Change in Electronic Dance Music*. EBL ebooks online. Bloomsbury Publishing, 2013.
- [2] BARRINGTON, L., ODA, R., AND LANCKRIET, G. Smarter than genius? human evaluation of music recommender systems. . . . *Symposium on Music . . .*, Ismir (2009), 357–362.
- [3] BERTIN-MAHIEUX, T., ELLIS, D. P., WHITMAN, B., AND LAMERE, P. The million song dataset. In *Proceedings of the 12th International Conference on Music Information Retrieval (ISMIR 2011)* (2011).
- [4] BONNIN, G., AND JANNACH, D. Evaluating the quality of playlists based on hand-crafted samples. *International Society for Music Information Retrieval Conference (ISMIR)* (2013).
- [5] BONNIN, G., AND JANNACH, D. Automated Generation of Music Playlists: Survey and Experiments. *ACM Computing Surveys* 47, 2 (2014), 1–35.
- [6] CORREA, D., LEVADA, A., AND COSTA, L. A Graph-Based Method for Playlist Generation. *cmmr2012.eecs.qmul.ac.uk*, June (2012), 19–22.
- [7] CUNNINGHAM, S., BAINBRIDGE, D., AND FALCONER, A. "More of an art than a science": Supporting the creation of playlists and mixes.
- [8] DUGGER, A. Development of the mass media journalism in the united states: History timeline.
- [9] ECK, D., LAMERE, P., BERTIN-MAHIEUX, T., AND GREEN, S. Automatic generation of social tags for music recommendation. In *Advances in Neural Information Processing Systems 20*, J. C. Platt, D. Koller, Y. Singer, and S. T. Roweis, Eds. Curran Associates, Inc., 2008, pp. 385–392.

- [10] ELLIS, D. P. W., WHITMAN, B., BERENZWEIG, A., AND LAWRENCE, S. The quest for ground truth in musical artist similarity. *Proc. International Symposium on Music Information Retrieval (ISMIR 2002)* (2002), 170–177.
- [11] FIELDS, B. Contextualize your listening: the playlist as recommendation engine.
- [12] FIGUEIREDO, F., RIBEIRO, B., ALMEIDA, J., AND FALOUTSOS, C. TribeFlow : Mining & Predicting User Trajectories.
- [13] GLASER, B., AND STRAUSS, A. *The Discovery of Grounded Theory: Strategies for Qualitative Research*. Aldine, 1973.
- [14] HARING, B., AND D, C. *Beyond the Charts: MP3 and the Digital Music Revolution*. JM Northern Media LLC, 2000.
- [15] HENNINK, M., HUTTER, I., AND BAILEY, A. *Qualitative Research Methods*. SAGE Publications, 2010.
- [16] HIBBETT, R. What Is Indie Rock? *Popular Music and Society* 28, 1 (2005), 55–77.
- [17] KANT, I. *Crítica da faculdade do juízo*. Biblioteca de filosofia. Forense Universitária, 1995.
- [18] KUSEK, D., LEONHARD, G., AND LINDSAY, S. *The Future of Music: Manifesto for the Digital Music Revolution*. Berklee Press Series. Berklee Press, 2005.
- [19] LEE, J., BARE, B., AND MEEK, G. How Similar Is Too Similar?: Exploring Users’ Perceptions of Similarity in Playlist Evaluation. *ISMIR, Ismir* (2011), 109–114.
- [20] LEE, J. H., AND PRICE, R. Understanding users of commercial music services through personas: design implications. *ISMIR* (2015), 476–482.
- [21] LOGAN, B. Content-Based Playlist Generation: Exploratory Experiments. *ISMIR* (2002), 6–7.
- [22] MARE, D. Grolier multimedia encyclopedia.
- [23] MCFEE, B., AND LANCKRIET, G. Hypergraph Models of Playlist Dialects. *ISMIR* (2012).

-
- [24] MOORE, J., CHEN, S., JOACHIMS, T., AND TURNBULL, D. Learning to Embed Songs and Tags for Playlist Prediction. *ISMIR* (2012).
- [25] PACHET, F., ROY, P., AND CAZALY, D. A combinatorial approach to content-based music selection. *Multimedia Computing and ...* (1999).
- [26] PACHET, F., ROY, P., AND GHEDINI, F. Creativity through Style Manipulation: the Flow Machines project. *cs.l.sony.fr* (2008).
- [27] PASICK, A. The magic that makes spotify's discover weekly playlists so damn good, 2015.
- [28] PAUWS, S., AND EGGEN, B. PATS: Realization and user evaluation of an automatic playlist generator. *ISMIR* (2002).
- [29] PAUWS, S., VERHAEGH, W., AND VOSSEN, M. Fast Generation of Optimal Music Playlists using Local Search. *ISMIR* (2006).
- [30] RANDLE, Q. A historical overview of the effects of new mass media: Introductions in magazine publishing during the twentieth century. *First Monday* 6, 9 (2001).
- [31] SMAABERG, S. F., SHABIB, N., AND KROGSTIE, J. A user-study on context-aware group recommendation for concerts. In *CEUR Workshop Proceedings* (2014), vol. 1210.

A Guia de entrevista

Abertura:

- Você poderia me falar um pouco sobre a época em que você começou a trabalhar/atuar como DJ? (probe: motivações, desafios, impressões iniciais, segurança)
- Como é o seu planejamento de repertório ao se preparar para discotecar em uma festa? (probe: playlist fixa, improvisos, plano b, estilos favoritos)
- Ao olhar a playlist das músicas que você tocou (discotecando), você consegue ver uma lógica na sequência das músicas? Qual / quais? (probe: fluxo, conexão entre as músicas, temas em comum, conjunto, partes)
- Para você o que é uma boa playlist? (probe: continuidade, novidade, hits, atmosfera)
- Que aplicativos e programas (ou aparato em geral) você utiliza para escutar música, criar e acessar playlists? (Tocando e fora disso) (probe: uso de funcionalidades, aprendizado dos aplicativos, níveis de interesse em cada um)
- Em que outras ocasiões/situações você costuma criar playlists (além de quando vai discotecar)? (probe: diferentes ocasiões, climas (mood e weather) e humores)

Chave:

- Você costuma escutar playlists criadas por outras pessoas? Por quais razões? (probe: aplicativos, redes sociais, amizades, especialistas)
- Você usa algum gerador de playlists (e.g.: rádios do Spotify, recomendações musicais) e por quais razões você os usa? (probe: diferentes razões para usar diferentes geradores, aspectos particulares de cada um)
- Suas expectativas são diferentes para playlists geradas por pessoas e para playlists geradas por máquinas? (Probe: expectativas, comparar humano com automáticas, particularidades percebidas, diferença entre o que é considerado bom pra cada caso)
- No caso dos geradores automáticos, como vc compara os diferentes geradores? (probe: diferentes ocasiões, descobertas x itens conhecidos)

Hora do entrevistado ouvir as playlists:

- Então, agora eu vou te mostrar 5 playlists criadas por geradores automáticos. Gostaria que você as ouvisse uma de cada vez. Você pode pular músicas enquanto vai ouvindo, mas gostaria que você ouvisse pelo menos uns 30 segundos do começo de do final de cada música da playlist. E vá me contando quais suas impressões da playlist em relação aos aspectos que a gente veio conversando. (probe: expectativas, continuidade, qualidade das músicas, mood, flow, outras features já debatidas com o entrevistado, subjetividades do entrevistado, intuito aparente da playlist)
- No geral o que você achou das playlists? Quais os pontos fracos e fortes de cada? (probe: diferenças, características positivas e negativas de cada uma, “humanidade”)
- Se uma dessas playlists fosse feita por um humano qual você acha que seria? Por quê? (probe: expectativas, o que torna a playlist mais humana)

Fechamento:

- Como DJ, como geradores automáticos podem ou poderiam contribuir com seu trabalho? (Probe: grande quantidade de itens,)
- Existe algum aspecto dos geradores atuais que voce gostaria que fosse diferente? (Probe: ferramentas, personalização, limitações, serem mais útil para DJs)
- Você acha que estamos perto, se é que existe a possibilidade, de máquinas serem boas ao ponto de substituírem um DJ de verdade numa festa? Por quê? (probe: DJs famosos, outras funções do DJ além de escolher músicas)
- Agradecimentos e despedidas

B Playlists utilizadas

Playlist 1 (Hypergraph):

Drake Bell - Highway to Nowhere

Monica - Knock Knock

The Lucksmiths - Take This Lying Down

Dead Boys - Detention Home

Willowz_{the} – *Something*

Playlist 2 (TribeFlow):

Black Sabbath - Paranoid

Janis Joplin - Me And Bobby McGee

Cat Stevens - Peace Train

DAVE MATTHEWS BAND - I'll Back You Up

Monster Magnet - All Shook Out

Playlist 3 (Random):

Smooth Generation - Set It Off

Lillian Axe - Kill Me Again

Mike Griffin The Unknown Blues Band - I'm A Blues Man

Haemorrhage - Secuestrador de Cuerpos

Jim Ford - Go Through Sunday

Playlist 4 (TribeFlow):

The Cars - My Best Friend's Girl

Dramarama - Anything anything

The Smithereens - Blood And Roses

Duran Duran - Hungry Like The Wolf

Van Halen - Ain't Talkin' 'Bout Love (Album Version)

Playlist 5 (Hypergraph):

Public Enemy - Public Enemy No.1

Calexico - Nom De Plume

Over The Rhine - Bluer

Flatt Scruggs - Old Salty Dog Blues

Two Gallants - Anna's Sweater