

Um sistema de recomendação de músicas brasileiras

Maiara B. Monteiro¹, Natan R. Machado¹, Paulo A. L. Nogueira¹,
Thales A. Campos¹, Fernando W. Cruz¹, Edilson Ferneda¹

¹Universidade Católica de Brasília
SGAN 916, Módulo B 71.790-160 Brasília DF

maiara_bsb@hotmail.com, natanucb@gmail.com, pbao.nog@gmail.com,
thales_acampos@hotmail.com, fwcruz@ucb.br, eferneda@pos.ucb.br

Resumo. Este artigo propõe uma base de metadados de músicas brasileiras e um sistema de recomendação musical associado. A base de metadados é fruto de uma revisão do modelo de dados do MusicBrainz e permite a identificação de tracks por meio de um índice de fingerprint. A recomendação musical proposta é precedida pela extração de características das músicas e auxiliada por um classificador de músicas por similaridade de gênero. Na versão corrente, o sistema consegue promover recomendações com um nível de acerto na ordem de 70 a 80 por cento.

Abstract. This article proposes a database of metadata of Brazilian music and a associated musical recommendation system. The basis of metadata is the result of a review of the MusicBrainz's data model and allows the identification of tracks by an index fingerprint. The musical recommendation proposed is preceded by the extraction of music characteristics and assisted by a binder of music by similarity of gender. In the current version, the system can promote recommendations with a level of accuracy in the order of 70 to 80 percent.

1. Introdução

Constata-se, atualmente, uma mútua influência entre o aumento de buscas por músicas na Internet e a melhoria significativa das ferramentas de seleção, armazenamento, indexação e recuperação musical e da infra-estrutura de conexão. O vertiginoso crescimento nas vendas de música pela Internet vem gerando grandes mudanças na forma de disseminação e comercialização de músicas (Cruz, 2008). Isso tem feito com que cada vez mais artistas optem por ofertar diretamente na Web suas produções musicais, competindo em igualdade de condições com as grandes produtoras. Esse novo modelo de negócios favorece investimentos em estratégias de recomendação musical (Byrd, 2006) baseadas no comportamento do usuário, procurando prever seu gosto e suas vontades (Celma & Lamere, 2007).

Entre as diversas iniciativas para recomendação musical estão o Musicoverly (www.musicoverly.com), o Pandora (www.pandora.com) o One Lhama (www.onellama.com) e o last.fm (www.last.fm), que o fazem por meio de técnicas tais como (i) anotação das características do áudio e comparação de similaridades, (ii) levantamento de perfil comportamental do usuário e (iii) suas relações sociais. Em alguns desses sistemas, a eficácia dessas técnicas é testada disponibilizando-se gratuitamente músicas para o público, a fim de que opinem se um determinado conjunto de músicas que estão sendo tocadas

possui algum nível de similaridade. Na prática, esses portais submetem o público a uma avaliação de resultados de classificação automáticos, ao mesmo tempo em que fornecem opções de compra das músicas ouvidas.

As alternativas citadas, apesar de também incluírem músicas brasileiras, têm um forte viés comercial e nem sempre atendem satisfatoriamente as demandas por produções musicais de caráter regional. Este trabalho descreve uma proposta de arquitetura de base de metadados de músicas brasileiras e uma estratégia de recomendação associada.

2. A base de metadados Estação Verde-Amarela (EVA)

A base de metadados sobre músicas brasileiras EVA é fruto de uma revisão do modelo de dados do MusicBrainz (musicbrainz.org), acervo de metadados disponibilizado na Internet, cujas tabelas contemplam informações sobre autores, títulos, entre outras. A base de metadados proposta é *opensource* e aproveita do MusicBrainz: (i) a modelagem de dados com as devidas alterações, (ii) o esquema de interfaceamento com os clientes, (iii) o mecanismo de moderação para controlar a validação dos metadados inseridos e (iv) o modelo ontológico subjacente. Ela diferencia-se do MusicBrainz por uma nova interface Web de manutenção dos metadados e pela remoção de tabelas desnecessárias à abordagem que está sendo adotada, em particular as que fazem uso do TRM, uma solução de *fingerprint* utilizada nas versões iniciais do MusicBrainz. No entanto, a maior modificação conceitual no projeto é relativa ao esquema de indexação e uso de *fingerprint*: apesar de ser uma base de metadados *opensource*, as informações do MusicBrainz são indexadas pelo PUID, um índice proprietário controlado pela MusicIP (www.musicip.com), o que limita o seu uso.

No MusicBrainz (Figura 1a), a base de metadados é acessada da seguinte maneira: (1) o cliente gera o *acoustic fingerprint* e o utiliza como parâmetro de busca no MusicDNS (www.musicip.com/dns/index.jsp), que (2) retorna o PUID associado ao *fingerprint*; (3) o cliente acessa o MusicBrainz, informando o PUID como parâmetro de busca; (4) o MusicBrainz retorna os metadados bibliográficos associados ao *fingerprint* em questão. A geração de *fingerprint* baseia-se no algoritmo OFA (MusicIP, 2006).

Este projeto investiga algumas alternativas para a geração do *fingerprint* segundo as recomendações de Cano (2004). Dentre as opções consideradas até agora estão o próprio OFA e o libFooID (www.foosic.org), aplicadas a um único formato musical (MP3). Além disso, prioriza-se a eliminação de uma solução proprietária para a identificação de *tracks*. Assim, o acesso à base de metadados se dá da seguinte maneira (Figura 1b): (1) o cliente MusicBrainz gera o *fingerprint* do arquivo musical, aplica um algoritmo de *hash* a este *fingerprint* e utiliza o resultado na consulta à base de *metadados*; (2) a base retorna os *metadados* bibliográficos associados ao *fingerprint* em questão.

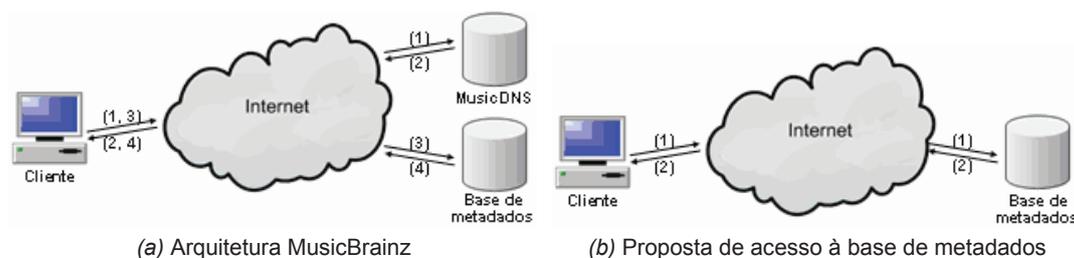


Figura 1. Formas de acesso à base de metadados musicais

3. Esquema de recomendação adotado

A arquitetura proposta é baseada no modelo cliente-servidor. Estão sendo investigadas duas estratégias de recomendação. Na primeira, o cliente dispõe de uma interface de captura de amostras de áudio que são enviadas ao servidor. No lado servidor, é feita a análise do áudio coletado e a consequente geração de um rol de informações sobre músicas similares ao áudio recebido. Nesse caso, as recomendações ficam disponíveis aos usuários, assumindo que esses estejam previamente cadastrados no sistema de recomendação (como ocorre no last.fm). A Figura 2 representa essa estratégia.



Figura 2. Estratégia de recomendação proposta

A recuperação das músicas é feita por um software “farejador”, instalado na máquina do usuário, para recuperar amostras de áudio e enviá-las ao servidor. O servidor recebe as amostras, promove a recomendação e armazena as amostras colhidas para ampliação da base de músicas. A partir do áudio recebido, são extraídas suas características pela aplicação do Marsyas (<http://marsyas.sness.net/>), uma biblioteca voltada para análise de áudio. Essas características são submetidas a um classificador neural que produz um vetor de similaridades da música em relação aos estilos para os quais o classificador foi previamente treinado. Um módulo de pesquisa seleciona uma lista de músicas da base com as menores distâncias euclidianas em relação à música em questão. Essa lista, composta de informações recuperadas da base de metadados, é então disponibilizada para o usuário, que deverá estar previamente cadastrado para ter o direito de instalar o farejador em sua máquina e de visualizar as recomendações. Neste processo, está prevista a inclusão deste áudio na base, o que envolve o cálculo de seu índice de *fingerprint* e a geração de uma URI (*Uniform Resource Identifier*) associada.

O processo de construção do classificador foi fruto de uma série de experimentos. Nos testes iniciais, as amostras eram recebidas e o vetor de características internas de cada elemento era extraído com base nas experiências relatadas por Silla, Kaestner & Koerich (2007), considerando uma base composta inicialmente de 850 músicas. Como os resultados não foram satisfatórios, adotou-se uma nova estratégia com a composição de uma base de dados acessória com 200 dos melhores representantes de alguns dos principais estilos brasileiros. Essa base serviu como referência para a construção de um classificador capaz de identificar o grau de pertinência de uma determinada música em relação ao conjunto de estilos pré-determinados. Esse classificador é uma rede neural artificial do tipo *Multilayer Perception* (MLP), construída com o apoio do sistema Weka (<http://www.cs.waikato.ac.nz/ml/weka/>). A recomendação é feita comparando-se o grau de similaridade entre as características extraídas da música com cada uma das músicas que compõem a base de recomendações. O processo de seleção das características extraídas (*ZeroCrossings*, *Rolloff*, *Centroid*, *MFCC*, ...) foi feito empiricamente, ainda

sem considerar qualquer fundamentação em técnicas de processamento de sinais.

Para melhorar o processo de recomendação, a estratégia inicial é combinada com uma segunda, baseada nas relações sociais do usuário e que usa o CoFE (<http://eecs.oregonstate.edu/iis/CoFE/>), um *framework* genérico de recomendação, para a filtragem colaborativa. Aqui, (i) o usuário atribui uma avaliação ao artista, expondo o seu grau de interesse; (ii) o sistema, com base no histórico dessas avaliações, busca por usuários com perfis semelhantes ao usuário alvo por meio do coeficiente de Pearson (Cruz, 2008), que calcula a correlação entre usuários; (iii) os usuários vizinhos são selecionados e, com base em seus perfis, é estimado o interesse do usuário alvo pelo artista.

4. Conclusões

Este trabalho apresenta uma base de metadados como suporte para um sistema de recomendação de músicas brasileiras. Na fase atual, a base de metadados é indexada por meio de uma solução de *fingerprint* que considera apenas arquivos no formato MP3, mas já está sendo investigada uma alternativa para que o sistema reconheça *tracks* em outros formatos.

As informações musicais consideradas neste trabalho são compostas por metadados bibliográficos armazenados em tabelas herdadas do MusicBrainz e pelos índices de características calculados com o auxílio de um classificador neural. Atualmente, por estar numa fase experimental, a base contém apenas 1.400 músicas, mas testes estão sendo feitos para um volume maior de informações.

Considerando a similaridade calculada a partir de informação extraída do áudio, foi possível fazer recomendações com acertos na ordem de 70 a 80% para quatro estilos musicais. A base está sendo revisada para a inclusão de novos estilos e serão consideradas, futuramente, outras estratégias de recomendação baseadas em características que envolvam o perfil do usuário e suas relações sociais. Em relação ao módulo cliente, na versão atual, o farejador interage apenas com o *player* Amarok (amarok.kde.org).

5. Referências

- Byrd, D. (2006) “Other Topics in Music Organization and Representation (Lecture Notes)”. School of Music. Indiana University. <<http://www.informatics.indiana.edu/donbyrd/INFO590Spring06/I590.html>>.
- Cano, P. (2006) “Content-Based Audio Search: from Fingerprinting to Semantic Audio Retrieval”. PhD thesis, Department of Pompeu Fabra University, Barcelona, Espanha. <<http://mtg.upf.edu/files/publications/34ac8d-PhD-Cano-Pedro-2007.pdf>>.
- Celma, O.; Lamere, P. (2007) “Music Recommendation Tutorial”. ISMIR 2007, Viena, Áustria. <<http://mtg.upf.edu/~ocelma/MusicRecommendationTutorial-ISMIR2007>>.
- Cruz, F. W. (2008) “Necessidades de Informação Musical de Usuários Leigos em Música”, Tese de Doutorado em Ciência da Informação, Universidade de Brasília.
- MusicIP (2006) “Open Fingerprint™ Architecture Whitepaper Version 1.0”. <http://www.musicdns.org/files/Open_Fingerprint_Architecture_Whitepaper_v1.pdf>.
- Silla Jr, C. N., Kaestner, C. and Koerich, A. (2007) “Automatic music genre classification using ensemble of classifiers”, Proceedings of the IEEE SMC, Montreal, Canadá.