

MOVE!

Um Sistema de Recomendação de Músicas para uma Atividade Física.

Rodrigo B. Silva, Flavia C. Bernardini

¹Laboratório de Inovação no Desenvolvimento de Sistemas — LabIDeS
Instituto de Ciência e Tecnologia – Universidade Federal Fluminense (UFF)
Rio das Ostras – RJ – Brazil

{rodrigossilva, fcbernardini}@id.uff.br

Abstract. *Nowadays, it is quite common for people to assemble your playlists for different types of contexts in their daily tasks. This work aims to present an application on Android platform to recommend songs, according to the user's speed, via mobile device. The purpose of this application is to motivate people to engage in physical activity.*

Resumo. *Nos dias de hoje, é bastante comum as pessoas montarem suas listas de músicas para diversos tipos de contextos em seu dia-a-dia. Este trabalho tem como objetivo apresentar um aplicativo em plataforma Android para recomendar músicas, de acordo com a velocidade do usuário, através de um dispositivo móvel. O propósito do aplicativo é motivar pessoas a realizar atividades físicas.*

1. Introdução

A prática de atividade física faz bem ao corpo e à mente. Com ela podemos listar diversos tipos de benefícios que ajudam a lidar com o nosso dia-a-dia, tais como: emagrecer com saúde, diminuir o estresse, melhorar a auto estima, e muitas outras. A atividade física não está restrita a nenhuma idade, podendo assim estar presente desde nossos primeiros anos de vida até a terceira idade. Não existe uma atividade física que se sustente se não houver prazer e satisfação. Com isso é necessária uma motivação que leve as pessoas a realizá-las, que as ajudem a atingir o objetivo e, assim, melhorar a sua saúde. A motivação é uma força interior que se modifica a cada momento durante toda a vida, e direciona e intensifica os objetivos de um indivíduo [Cabral 2014].

Uma das muitas motivações que as pessoas possuem é a realização da atividade física acompanhada por música. A música adequada dá ritmo ao movimento, amplitude e leveza ao corpo. As vibrações musicais provocam vibrações corporais. A música tonifica, exalta, alivia. A música faz com que o participante esqueça um pouco o corpo e as suas fraquezas, com que se purifique pela beleza um gesto em particular, participando ao máximo da atividade [Pavlovic 1987].

A atividade física acompanhada por música ocorre com muita frequência, seja em situação prática individual, por meio da utilização de fones de ouvidos; seja em situação em grupo, com música ambiente. Em ambas situações, os movimentos executados pelos praticantes podem estar sincronizados com a música, ou esta funcionar

simplesmente como fundo musical. Não se pode negar, entretanto, que muitos a consideram como uma forma de prevenção contra monotonia existente na atividade física sistematizada [Miranda and Godeli 2002].

É comum as pessoas montarem suas listas de músicas para diversos tipos de contextos em seu dia-a-dia, sejam eles festas, reunião de amigos e até mesmo para relaxar, estudar, dentre outros. Ao frequentar uma academia, as pessoas costumam seguir o ritmo da música em execução com a ajuda do professor que prepara as músicas para aquela aula. As pessoas que frequentam a aula se sentem felizes e motivadas, independentemente se gostam do gênero musical ou do artista. Também é comum observar nas academias que as músicas são selecionadas durante a aula, pois toda vez que uma música termina, o professor sai da sua posição e executa uma outra música manualmente em seu dispositivo móvel, perdendo assim tempo da aula e o foco dos alunos. Assim, automatizar essa montagem de listas de músicas para serem executadas de acordo com uma atividade física pode ser interessante.

O objetivo deste trabalho é propor um aplicativo na plataforma Android para geração de uma lista de músicas recomendadas, utilizando aprendizado de máquina supervisionado, de acordo com a atividade física que o usuário está realizando.

2. Trabalhos Relacionados

Ringo [Maes and Shardanand 1995] é um sistema desenvolvido para recomendação personalizada de música. O trabalho explora similaridades entre os gostos de diferentes usuários para recomendar itens, baseado no fato de que os gostos das pessoas apresentam tendências gerais e padrões entre gostos, e entre grupos de pessoas. As pessoas descrevem suas preferências musicais, avaliando algumas canções. Tais avaliações constituem o perfil dos indivíduos. O sistema usa então esses perfis para gerar recomendações para usuários individuais. Para o seu funcionamento, primeiramente usuários similares são identificados. A partir dessa identificação e comparação de perfis, o sistema pode prever o quanto o usuário gostaria de um álbum/artista que ainda não foi avaliado pelo mesmo.

Em outro domínio relacionado à recomendação de músicas, muitas vezes a maneira em que uma pessoa dirige está diretamente ligada ao tipo de música que está tocando. Uma música mais suave pode fazer um usuário dirigir mais tranquilamente, e vice-versa. O aplicativo da Volkswagen [Tudo Celular 2014], ao invés de recomendar uma música existente, produz uma música em tempo real, baseando-se na forma como o usuário está dirigindo. O aplicativo funciona coletando informações de um *smartphone* ligado ao carro, usando a velocidade, RPM, aceleração, e informações do GPS.

Runners Rhythm [Runners Rhythm 2014] permite ao usuário selecionar e executar uma música nas batidas por minuto (BPM) desejadas para correr ou caminhar. Uma vez que o ritmo for selecionado, ele pode ser ajustado ao ritmo do usuário. No menu de opções é possível ajustar o número de músicas selecionadas por consulta. Também pode ser ajustado o nível máximo ou mínimo de BPM das músicas, o que permite que mais ou menos variabilidade em BPMs quando as músicas são selecionadas durante a atividade.

O sistema apresentado neste trabalho possui como principal diferencial em relação a esses trabalhos apresentados por utilizar aprendizado de máquina para recomendar músicas para os movimentos.

3. Sistemas de Recomendação

Os Sistemas de Recomendação auxiliam no aumento da capacidade e eficácia do processo de indicação de um ou mais itens dentre diversas alternativas, já bastante conhecido na relação social entre os seres humanos. Em um sistema típico, as pessoas fornecem recomendações como entradas que o sistema agrega, e direciona para os indivíduos considerados potenciais interessados neste tipo de recomendação. Um dos grandes desafios desse tipo de sistema é realizar a combinação adequada entre as expectativas dos usuários em relação aos produtos, serviços e pessoas a serem recomendados. Em outras palavras, definir e descobrir esse relacionamento de interesses é o grande problema a ser atacado [Resnick and Varian 1997].

As técnicas de recomendação, em geral, dependem das contribuições dos indivíduos na avaliação da informação. O princípio dos sistemas de recomendação se baseia em “o que é relevante para mim, também pode ser relevante para alguém com interesse similar”. Várias técnicas têm surgido visando à identificação de padrões de comportamento (consumo, pesquisa e outros) e utilização de tais padrões na personalização do relacionamento com os usuários, sendo algumas delas: Filtragem Baseada em Conteúdo, Filtragem Colaborativa, Filtragem Híbrida e Filtragem Baseada em Conhecimento [Cazella et al. 2010].

A Filtragem Baseada em Conteúdo tem como objetivo básico utilizar as descrições dos conteúdos dos itens, e comparar com os interesses dos usuários, verificando se o item é ou não relevante para cada um. Essa técnica realiza uma seleção baseada na análise de conteúdo de itens e no perfil do usuário [Herlocker 2000]. As informações sobre o perfil do usuário, onde contém suas preferências e necessidades, podem ser obtidas pelo próprio usuário, como uma consulta realizada por ele, coletadas através do conteúdo dos itens que o usuário consome, ou através de um cadastro de informações [Cazella et al. 2010]. Segundo [Adomavicius and Tuzhilin 2005], a abordagem baseada em conteúdo tem algumas limitações, como por exemplo a extração e análise de conteúdo multimídia (vídeo e som), que é muita mais complexa do que a extração e análise de documentos textuais.

A Filtragem Colaborativa se diferencia da filtragem baseada em conteúdo por não exigir a compreensão ou reconhecimento do conteúdo dos itens. Essa abordagem foi desenvolvida para atender as limitações da filtragem baseada em conteúdo [Herlocker 2000]. Na Filtragem Colaborativa, a essência está na troca de experiências entre as pessoas que possuem interesses comuns. Nesses sistemas, os itens são filtrados baseados nas avaliações feitas pelos usuários. Um usuário de um sistema colaborativo deve, portanto, pontuar cada item experimentado, indicando o quanto esse item casa com sua necessidade de informação. Essas pontuações são coletadas para grupos de pessoas, permitindo que cada usuário se beneficie das pontuações (experiências) apresentadas por outros usuários na comunidade. A filtragem colaborativa pode apresentar algumas limitações, como por exemplo: quando um novo item aparece no banco de dados não existe maneira deste ser recomendado para o usuário até que mais informações sejam obtidas através de outros usuários.

A Filtragem Híbrida busca combinar os pontos fortes da filtragem colaborativa e da filtragem baseada em conteúdo, visando criar um sistema que possa melhor atender as necessidades do usuário [Herlocker 2000]. Essa abordagem é constituída das seguintes vantagens: descoberta de novos relacionamentos entre usuários; recomendação de itens

diretamente relacionados ao histórico; bons resultados para usuários incomuns; e precisão independente do número de usuários.

Por fim, na Filtragem Baseada em Conhecimento, o conhecimento resultante da aplicação do processo de Descoberta de Conhecimento de Base de Dados, ou KDD (do inglês *Knowledge Discovery from Databases*) é utilizado. Segundo [Zaiane 2000], KDD é definido como um processo de extração não trivial de informações potencialmente úteis, as quais não são previamente conhecidas e encontram-se implícitas em grandes coleções de dados. Quando se trabalha com sistemas de recomendação, o KDD se torna um recurso importante para a descoberta de relações entre itens, entre usuários e entre itens e usuários. Através de análises de arquivos de *log*, por exemplo, pode-se obter conhecimentos aprofundados a respeito dos usuários que se conectaram a um website. Este conhecimento pode ser utilizado para a personalização da oferta de produtos, na estruturação de sites de acordo com o perfil de cada internauta e personalização do conteúdo das páginas. Neste trabalho, usamos a técnica de Filtragem Baseada em Conhecimento.

4. Aprendizado de Máquina

Aprendizado de Máquina é uma parte da Inteligência Artificial responsável pelo desenvolvimento de teorias computacionais focadas na criação do conhecimento artificial. Softwares desenvolvidos com esta tecnologia possuem a característica de tomarem decisões com base no conhecimento prévio acumulado através da interação com o ambiente. [Facelli et al. 2011].

Algoritmos de aprendizado têm sido amplamente utilizados em diversas tarefas, que podem ser organizadas de acordo com diferentes critérios. Em uma tarefa de previsão, a meta é encontrar uma função (também chamada de modelo ou hipótese) a partir dos dados de treinamento que possa ser utilizada para prever um rótulo ou valor que caracterize um novo exemplo, com base nos valores de seus atributos de entrada. Para isso, cada objeto do conjunto de treinamento deve possuir atributos de entrada e saída. Os algoritmos ou métodos de Aprendizado de Máquina utilizados nessa tarefa induzem modelos preditivos. Esses algoritmos seguem o paradigma de aprendizado supervisionado. O termo supervisionado vem da presença de um “supervisor externo”, que fornece a saída (rótulo) desejada para cada exemplo (conjunto de valores para os atributos de entrada).

No aprendizado supervisionado, o objetivo é induzir um conceito utilizando os exemplos previamente rotulados, denominado conjunto de exemplos de treinamento, realizando generalizações, tal que o conceito (hipótese) induzido é capaz de prever a classe (rótulo) de futuros exemplos. Nesse caso, o conceito induzido é visto como um classificador [Facelli et al. 2011]. Há vários paradigmas para indução do classificador, e um deles é o simbólico, que envolve os algoritmos de indução de árvores de decisão e de regras. Um algoritmo em aprendizado supervisionado de indução de árvores de decisão é o algoritmo J48, uma implementação em Java na ferramenta Weka do algoritmo C4.5 [Witten and Frank 2005]. O modelo de árvore de decisão é construído a partir do processamento dos dados de treino, e o modelo é utilizado para classificar dados ainda não classificados. O J48 gera árvores de decisão, em que cada nó da árvore avalia a existência ou significância de cada atributo individual. As árvores de decisão são construídas do nó raiz para os nós folha, através da escolha do atributo mais apropriado para cada situação. Uma vez escolhido o atributo, os dados de treino são divididos em sub-grupos, correspon-

dendo aos diferentes valores dos atributos, e o processo é repetido para cada sub-grupo até que uma grande parte dos exemplos em cada nó pertençam a uma única classe.

5. Metodologia de Desenvolvimento do Sistema MOVE!

O aplicativo proposto neste trabalho tem como principal objetivo recomendar músicas para uma atividade física. Primeiramente, as músicas da lista do usuário são classificadas por classificador musical. O classificador musical tem como principal objetivo prever, para uma determinada atividade física, qual música é mais adequada. Dada uma música, o classificador recebe dados referentes aos atributos fornecidos pela API da Echo Nest da música, e então a música é classificada para uma atividade física. Para a construção do classificador, foi utilizado o algoritmo de aprendizado J48.

A Echo Nest ¹ é a maior empresa de inteligência de música da indústria, fornecendo aos desenvolvedores a compreensão mais profunda do conteúdo de música. Tal conteúdo musical pode ser acessado através da API disponível gratuitamente para o desenvolvimento de aplicativos relacionados a música. A Echo Nest apresenta alguns atributos sonoros utilizados em aplicativos desenvolvidos com a API. Um atributo sonoro é uma qualidade subjetiva estimada em uma faixa de música. Ele é modelado através da aprendizagem e é dado como um único número de ponto flutuante que varia no intervalo fechado $[0, 1]$. A Echo Nest deriva os atributos de uma música das faixas de áudio que a compõem. As canções podem ser classificadas por qualquer um desses eixos, ou os atributos podem ser usados como filtros para a construção de listas de reprodução personalizadas.

O conjunto de dados utilizado na construção do classificador foi criado a partir de 390 arquivos em MP3 de diversas músicas de diversos gêneros, estilos e épocas de lançamento. Boa parte das músicas selecionadas para serem analisadas tiveram origem de uma pesquisa de opinião feita através de uma rede social, em que as pessoas recomendavam músicas para algumas atividades.

Os arquivos foram divididos igualmente para três atividades, que foram utilizadas como classes. As atividades escolhidas foram: CORRER, PEDALAR e CAMINHAR. Para a análise de cada música, foi utilizada a biblioteca jEN, para o acesso à API da ECHO NEST, com o objetivo de coletar informações referentes a cada uma. As informações extraídas para atributos de entrada são: *Danceability*, *Energy*, *Speechiness*, *Liveness*, *Loudness*. Coletamos essas informações de um conjunto de exemplos referentes a 130 músicas para três classes diferentes — CORRER, PEDALAR e CAMINHAR — o que totalizou 390 músicas. O conjunto de dados foi utilizado como entrada para a Ferramenta WEKA, para ser construído o classificador.

5.1. Avaliação do algoritmo de aprendizado

Para a classificação das músicas foi utilizado o algoritmo de indução de árvore de decisão J48 no Weka. Foram utilizados os seguintes atributos, extraídos das músicas pela API da EchoNest: *Danceability*, *Energy*, *Speechiness*, *Liveness* e *Loudness*. O uso de uma árvore de decisão foi devido ao fato de ser uma estrutura simples para ser utilizada em um dispositivo móvel, o qual geralmente possui menos recursos tecnológicos que um

¹Informações disponíveis em <http://www.echonest.com/>

computador. A estimativa de erro foi executada em validação cruzada de 10 partições, obtendo-se uma baixa acurácia de 38,72%. Para contornar esse problema, foi utilizado o método estatístico de amostragem com reposição, com a aplicação no Weka, do filtro supervisionado *Resample*, para balanceamento das classes. O classificador foi induzido novamente com o algoritmo J48 no Weka, em validação cruzada de 10 partições, obtendo-se uma melhor acurácia de 67,45%. A descoberta do conhecimento pela árvore de decisão gerada pelo algoritmo J48 pode ser feita pela visualização de padrões relevantes através de regras de decisão. A árvore de decisão gerada foi implementada no protótipo construído. Na Figura 1 é ilustrado o método para construção do classificador.

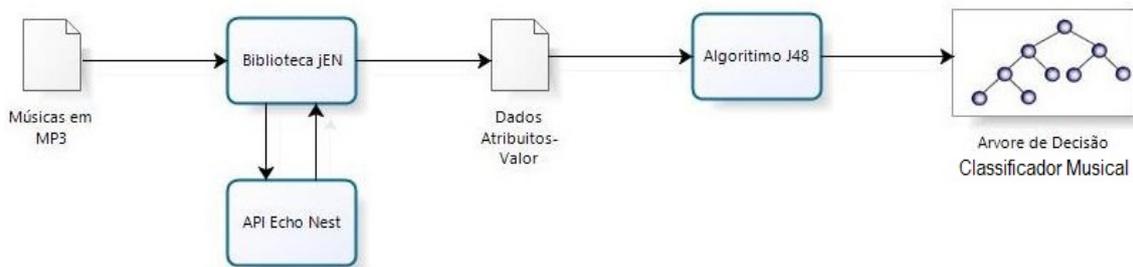


Figura 1. Construção do Classificador

Na Figura 2 é apresentada o processo de classificação de uma música. A música em formato MP3 é dada como entrada para a biblioteca jEN, que fará a análise desta música e extrair seus dados musicais referentes a *Danceability*, *Energy*, *Speechiness*, *Liveness*, *Loudness* sendo assim passando para a próxima etapa que é o classificador musical onde uma atividade física será atribuída para a música e por final teremos a música classificada. Podemos notar a tarefa de classificação é simples, no intuito de acelerar esse processo, devido as limitações de um dispositivo móvel em termos de hardware e software serem bastantes limitados.

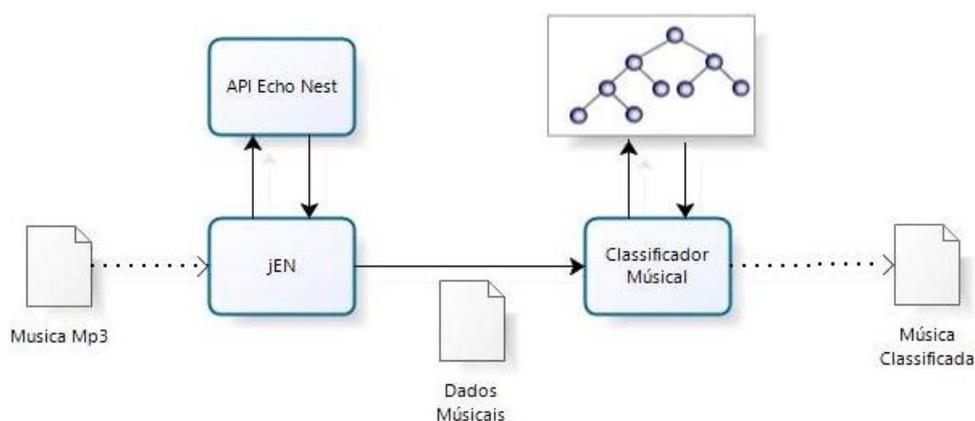


Figura 2. Processo de Classificação

5.2. Componentes do Sistema Move

Na Figura 3 é apresentado o diagrama de componentes do sistema MOVE!. O componente do sistema MOVE! utiliza internamente a plataforma Android. Esse componente se

comunica com o componente da API da Echo Nest, no qual são extraídas as características das músicas na Internet. O componente GPS tem como principal função fornecer a velocidade do usuário, utilizada para identificar o movimento do usuário — ANDAR (de 0 Km/h a 7 Km/h), CORRER (de 7,1 km/h a 14 Km/h), PEDALAR (a partir de 14,1 Km/h). O componente de banco de dados SQLite tem como objetivo armazenar os dados sobre as músicas do aplicativo. Os componentes Musica.java e Playlist.java são as principais classes do aplicativo. Deve ser observado que na classe Musica.java está implementado o método para classificação musical.

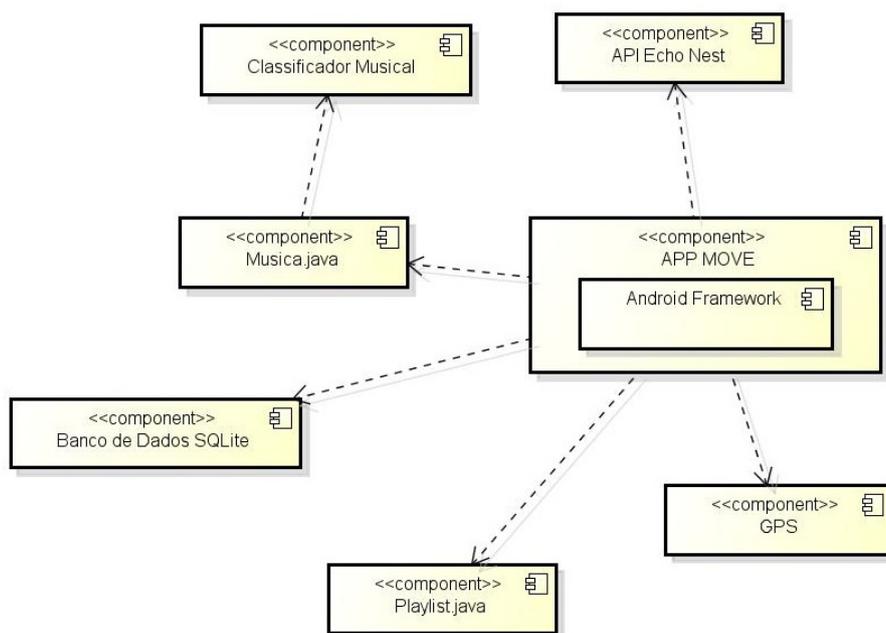


Figura 3. Diagrama de Componentes

6. Conclusão

Neste trabalho, apresentamos um sistema de recomendação de músicas de acordo com a atividade do usuário. O protótipo foi implementado utilizando a API da Echo Nest e a Plataforma Android, que por sua vez utiliza a linguagem Java. Para o aplicativo recomendar músicas, foi utilizado um método que utiliza uma árvore de decisão, induzida utilizando o algoritmo J48, implementado na ferramenta WEKA. Para induzir o classificador, foram utilizadas recomendações oferecidas por usuários de uma rede social. A taxa de erro obtida com o classificador induzido foi considerada promissora, pois o usuário do aplicativo pode ter, durante sua atividade, a melhor lista musical sugerida baseada em sugestões de outros usuários, e que contém apenas suas músicas favoritas. Porém, como a API necessita de uma conexão com a Internet, a música pode ter seu tempo de análise aumentado caso essa mesma conexão seja lenta. Pelo resultado da análise do conjunto de músicas feita para a indução da árvore de decisão, fica claro que é de extrema importância a pesquisa de nossos atributos para aprimorar ainda mais a classificação da atividade para a qual a música se encaixa.

Observamos, com o desenvolvimento deste trabalho, que dados musicais são um grande desafio. Pela pesquisa em redes sociais, ficou claro que as preferências dos

usuários são bastante heterogêneas. Ao contrário do esperado, observamos que músicas com batidas energéticas e pesadas podem ser recomendadas para atividades físicas tranquilas, e o inverso também é possível. Neste trabalho, pudemos observar que pode ser mais interessante explorar construção de um classificador para cada indivíduo, ao invés de construir um único classificador para todos os usuários, devido a essa característica intrínseca de cada usuário. Ainda, observamos também que definir o movimento de cada usuário também é um desafio que deve ser explorado, já que o movimento ANDAR de uma pessoa pode ser equivalente ao movimento CORRER de outra. Por fim, experimentos com usuários também necessitam ser realizados com nosso protótipo.

Referências

- Adomavicius, G. and Tuzhilin, A. (2005). *Toward the Next Generation Of Recommender Systems: A Survey of the State-of-the Art and Possible Extensions*. IEEE Transactions on Knowledge and Data Engineering.
- Cabral, G. (2014). Motivação. Disponível em <http://www.brasilecola.com/psicologia/motivacao-psicologica>. Acessado em 23 de maio de 2014].
- Cazella, S. C., Nunes, M. A. S. N., and Reategui, E. B. (2010). *A Ciência da Opinião: Estado da arte em Sistemas de Recomendação*. XXX Congresso da SBC: Computação Verde – Desafios Científicos e Tecnológicos.
- Facelli, K., Lorena, A. C., Gama, J., and Carvalho, A. (2011). *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina*. LTC.
- Herlocker, J. L. (2000). *Understanding and Improving Automated Collaborative Filtering Systems*. Tese de Doutorado em Ciência da Computação, University of Minnesota.
- Maes, P. M. and Shardanand, U. (1995). Social information filtering: algorithms for automating “word of mouth”. In *Proc. SIGCHI Conference on Human Factors in Computing Systems*.
- Miranda, M. L. J. and Godeli, M. R. C. S. (2002). *Avaliação de Idosos sobre o papel e a influência da música na atividade física*. Dissertação de Mestrado — USP.
- Pavlovic, B. (1987). *Ginástica aeróbica – Uma nova cultura física*. Rio de Janeiro: Sprint.
- Resnick, P. and Varian, H. R. (1997). *Recommender Systems*. Comm. of the ACM.
- Runners Rhythm (2014). Runners rhythm. Disponível em <http://www.runnersrhythm.com/index.html>. Acessado em 21 de Julho de 2014.
- Tudo Celular (2014). App da volkswagen cria música baseada em como você dirige. Disponível em <http://www.tudocelular.com/curiosidade/noticias/n31414/appcarro-volkswagen-musica-trilha-sonora.html>. Acessado em 21 de Julho de 2014.
- Witten, I. H. and Frank, E. (2005). *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, 2nd edition.
- Zaiane, O. R. (2000). *Web Mining: Concepts, Practices and Research*. Simpósio Brasileiro de Banco de Dados.