



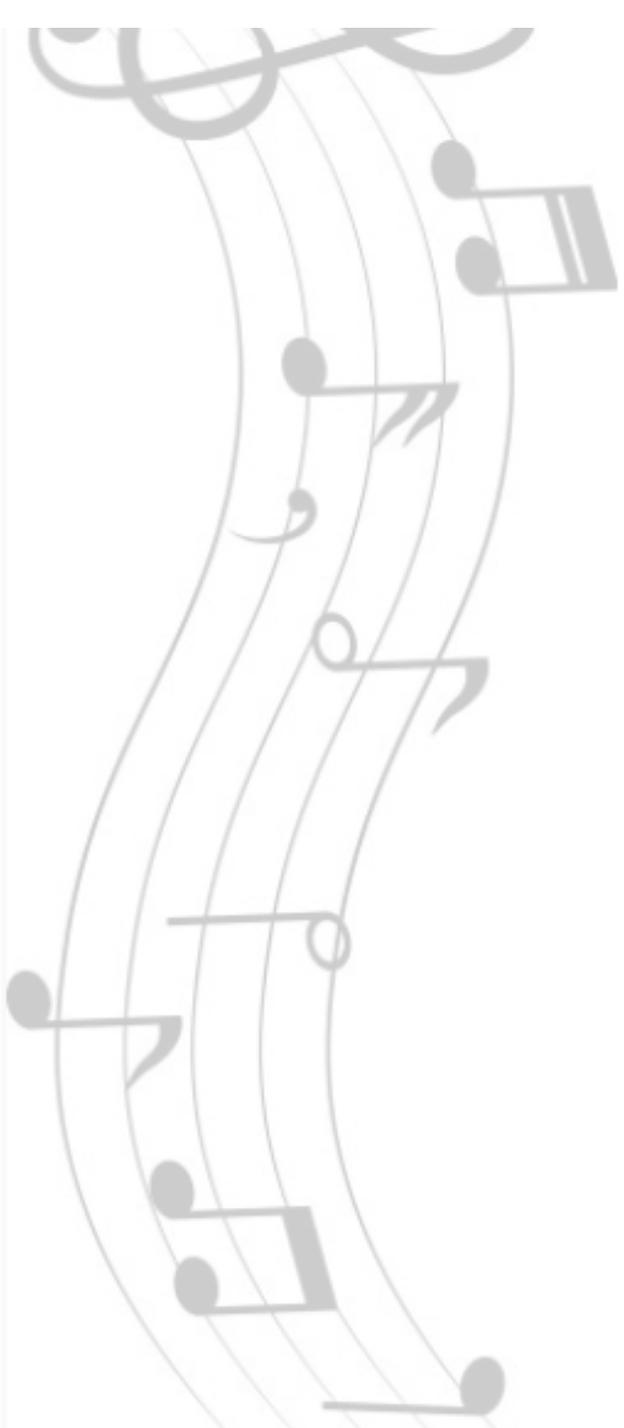
Universidade Federal do Paraná
Programa de Pós-graduação em Bioinformática

**“Padrões de Emoções Musicais segundo o Modelo de
Russell”**

*Uma análise de trechos de músicas em serviços de
streaming (Spotify)*

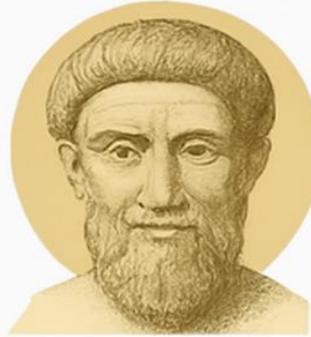
Aluna: Margarete Klamas Marzani

Orientador: Razer Anthom Nizer Rojas Montaña

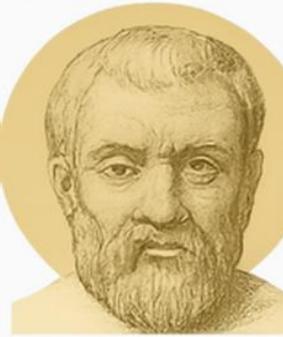


Música → emoções

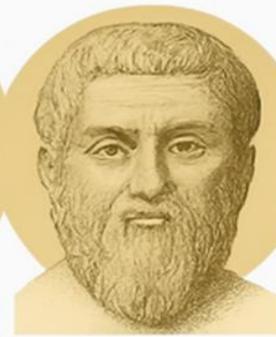
Filósofos



PITÁGORAS
(SEC. VI A.C.)



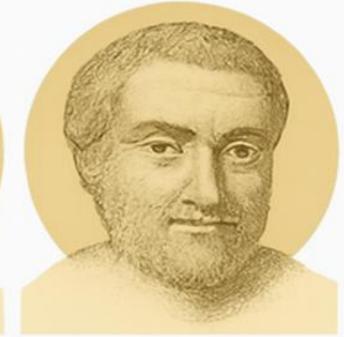
SÓCRATES
(470-399 A.C.)



PLATÃO
(385-332 A.)



ARISTÓTELES
(384-322 C.)



ARISTÓXENO
(sec. IV A.C.)



DESCARTES
1596-1650



LEIBNIZ
1646-1716



**JOHANN
MATTHESON**
1681-1764

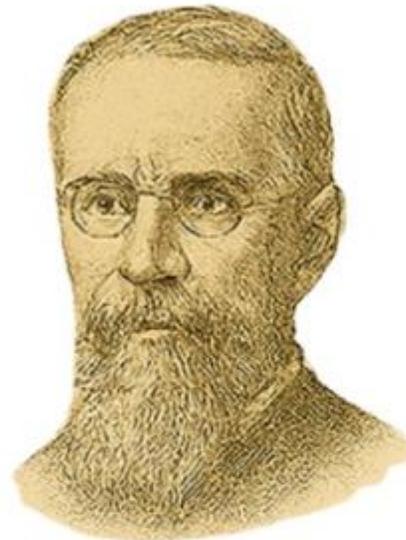


**EDUARD
HANSLICK**
1825-1904

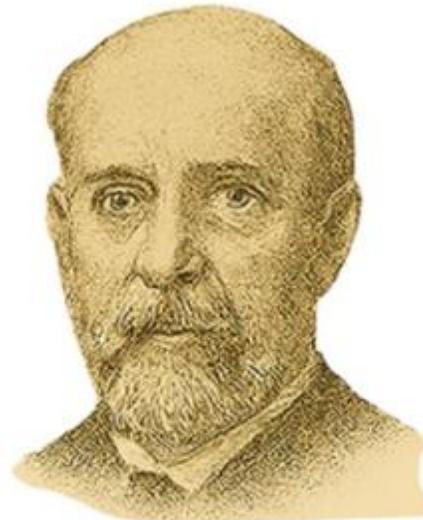
Psicólogos



HELMHOLTZ
(1821-1894)



WUNDT
(1853-1929)



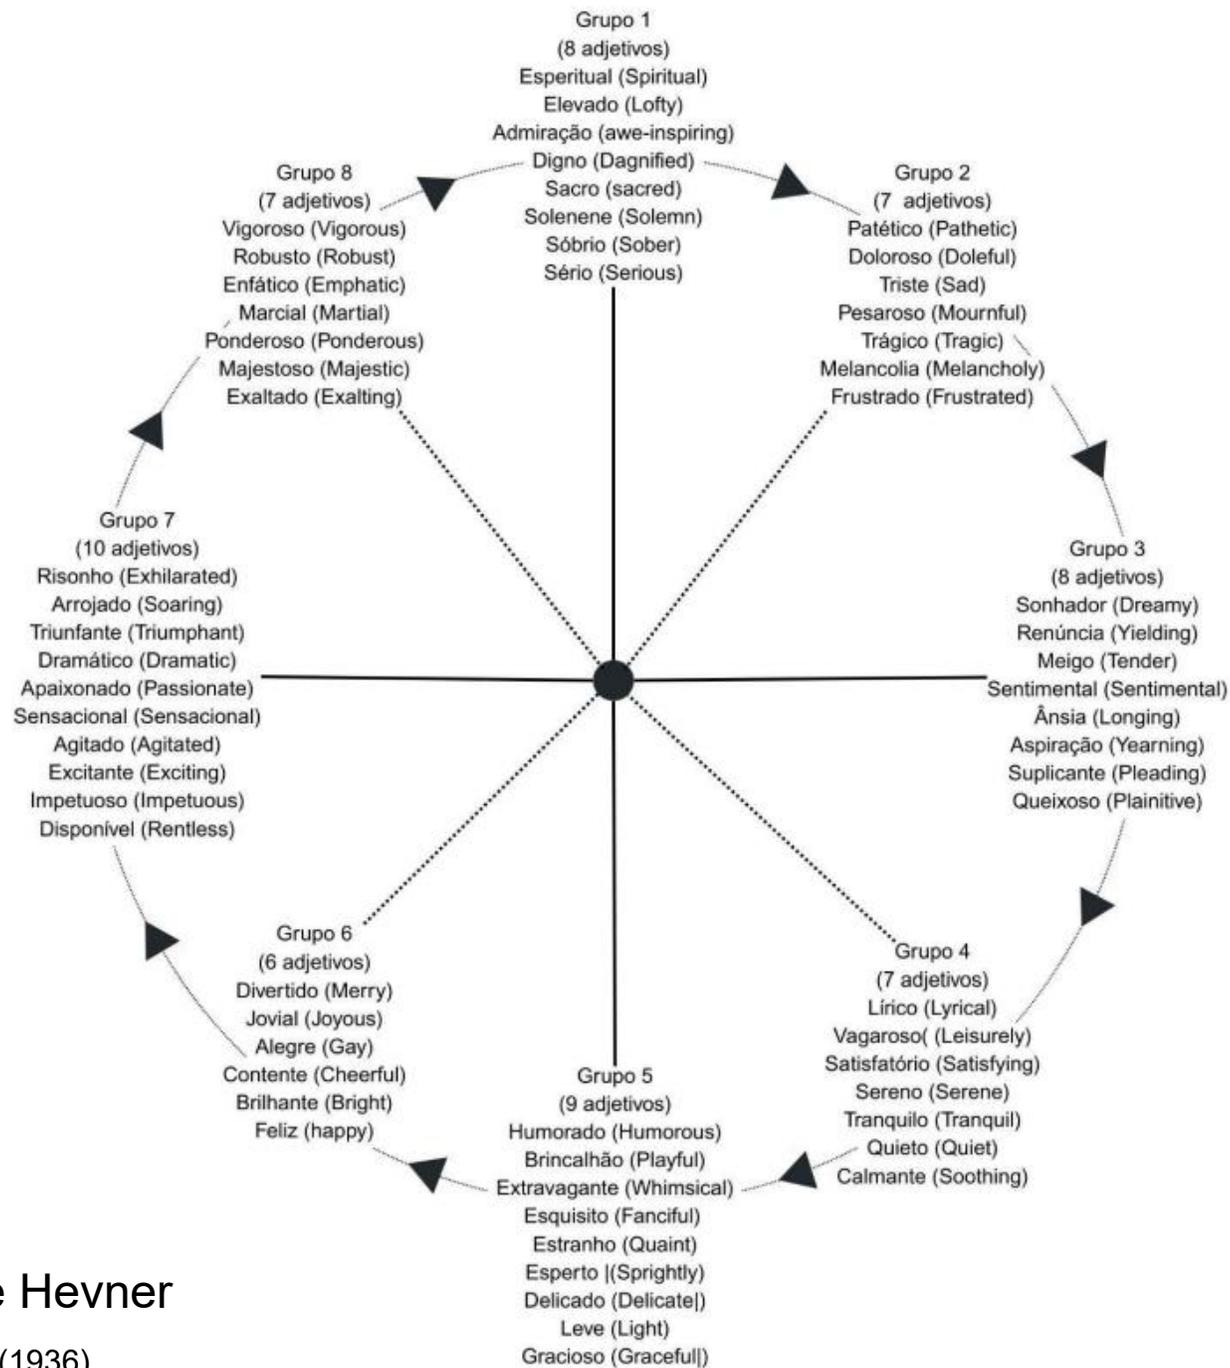
STUMPF
(1848-1956)



SEASHORE
(1856-1949)



HEVNER
(1895-1979)



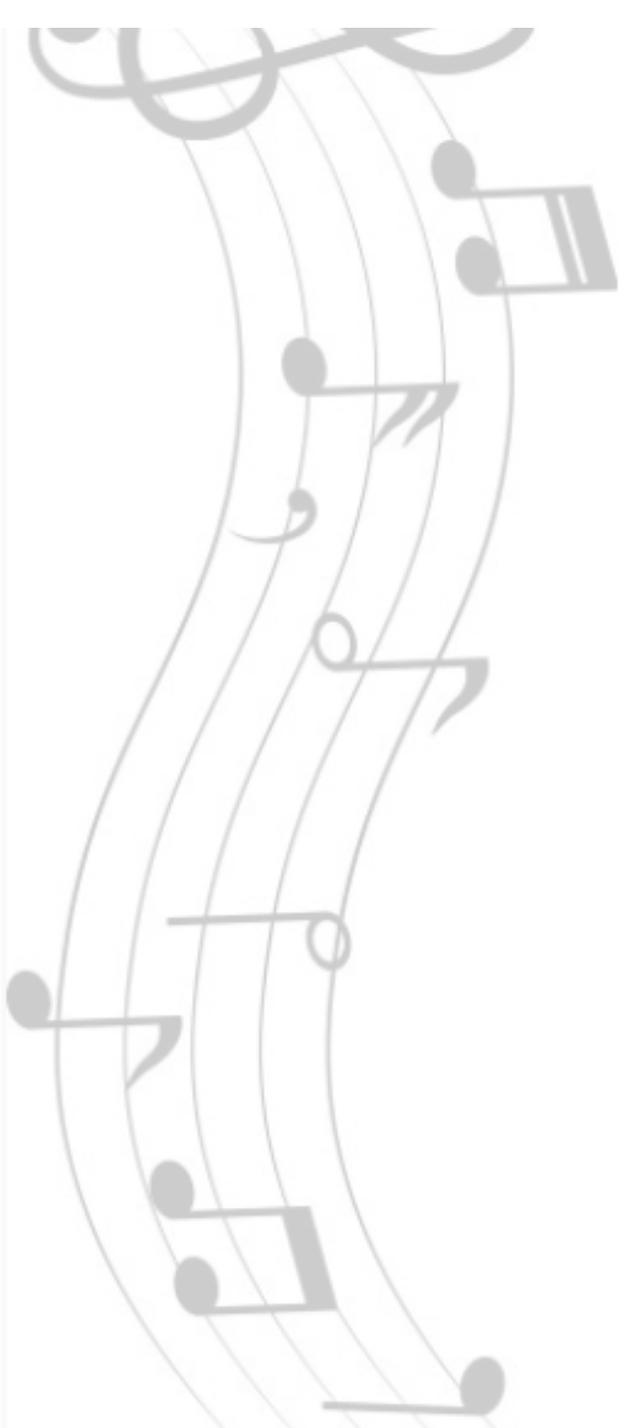
Círculo de Adjetivos de Hevner

Fonte: Adaptado de Hevner (1936)

Circumplexo do Afeto de Russell



Fonte: Adaptado de Russell (1980).

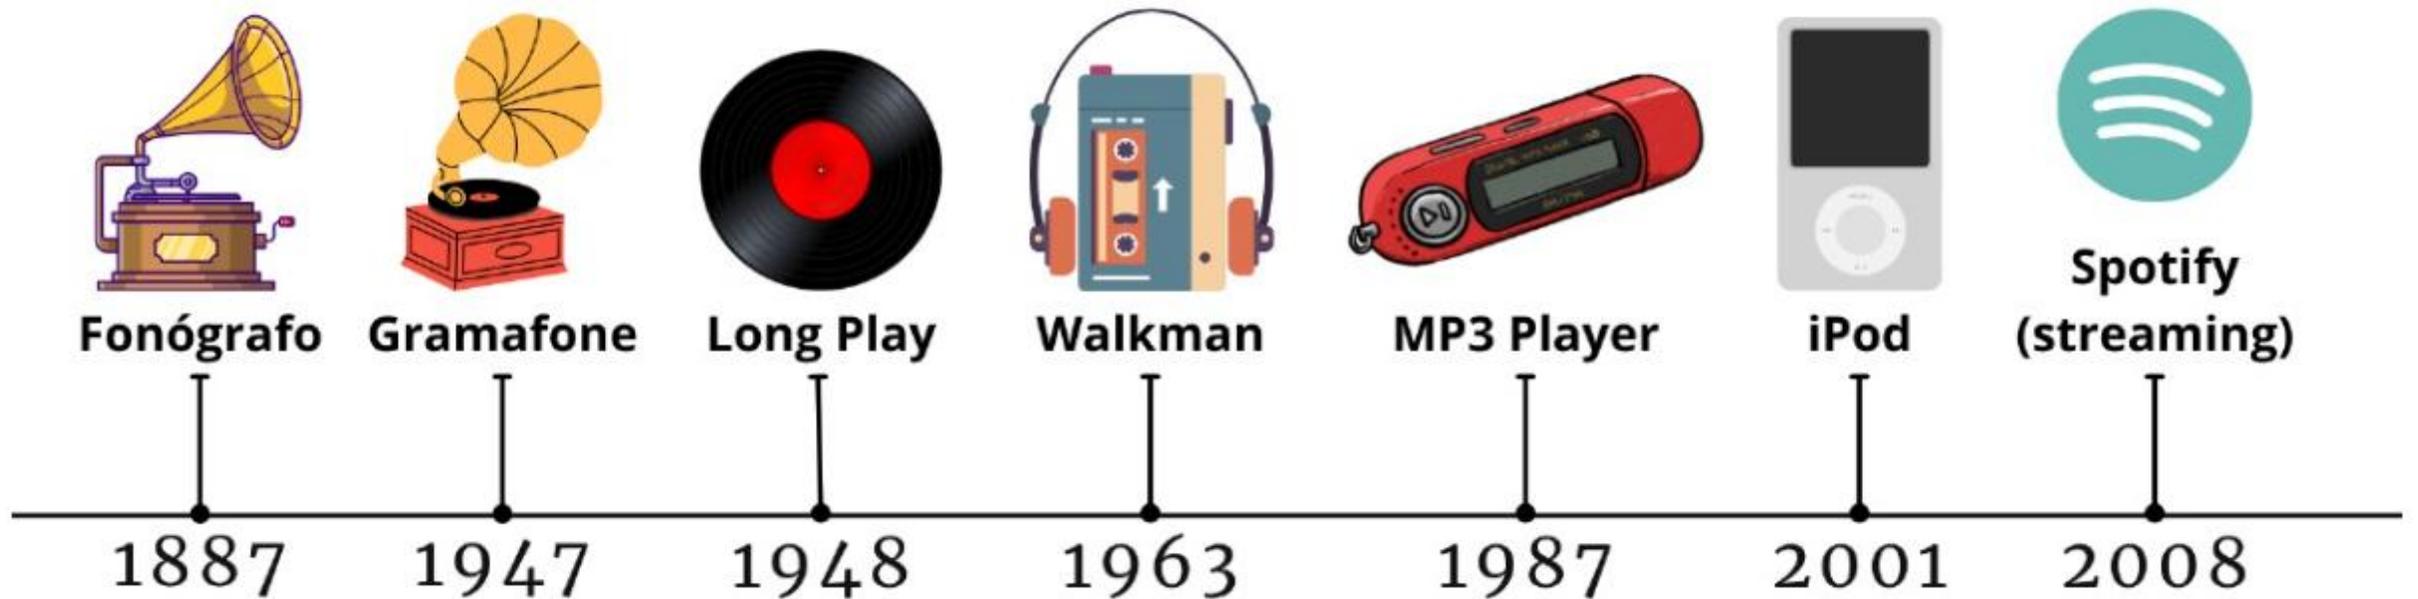


Música →

características

{ ritmo
melodia
harmonia
timbre
letra

EVOLUÇÃO DA FORMA DE OUVIR MÚSICA





Objetivo geral

Avaliar e comparar diferentes algoritmos de aprendizado de máquina aplicados ao reconhecimento de emoções musicais, utilizando os atributos disponibilizados pela API do Spotify e o modelo de emoções de Russell.

Objetivos Específicos

- **Pré-processar** a base de dados de músicas anotadas em quadrantes emocionais (modelo de Russell).
- **Treinar e avaliar** diferentes algoritmos de classificação supervisionada (árvores de decisão, SVM, KNN, Random Forest, Gradient Boosting, XGBoost).
- **Comparar o desempenho** dos classificadores utilizando métricas de acurácia, precisão, recall e F1-score.
- **Avaliar estatisticamente** os resultados obtidos, aplicando testes comparativos (Friedman e Nemenyi) para verificar diferenças significativas entre os classificadores.
- **Confrontar os resultados** obtidos com trabalhos do estado da arte, destacando vantagens e limitações dos atributos do Spotify API para a tarefa de Music Emotion Recognition.



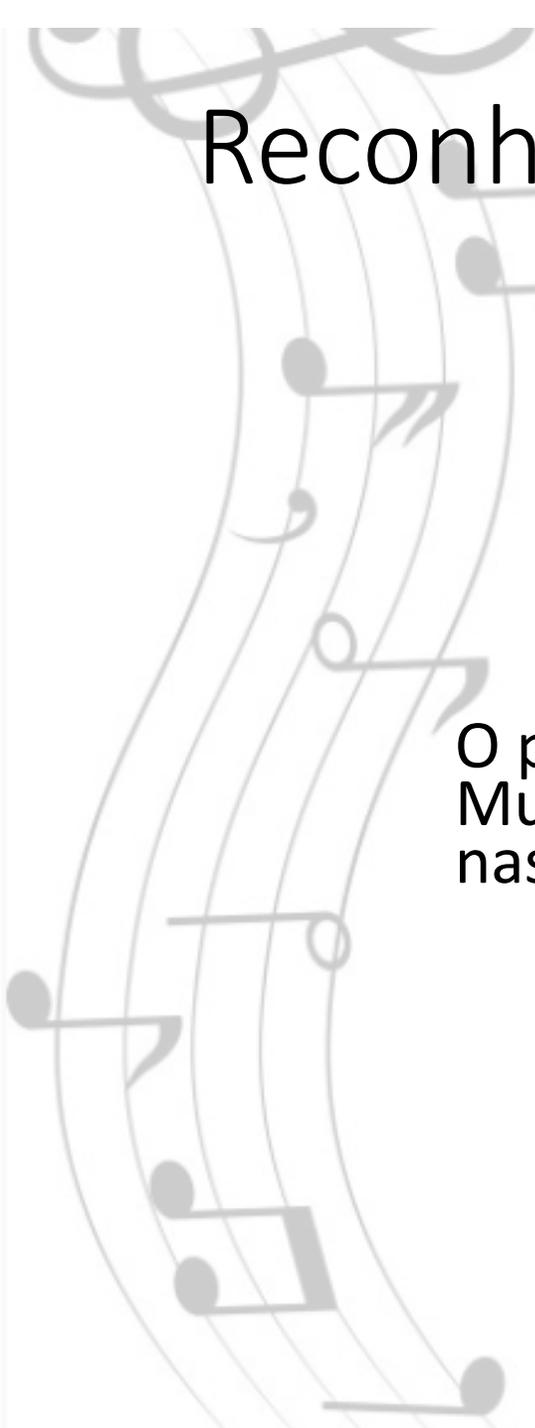
Music Information Retrieval (MIR)

- É uma área interdisciplinar que desenvolve métodos para **extrair, organizar e interpretar informações musicais diretamente de arquivos de áudio digitais.**

- Classificação por gênero;
- Identificação de instrumentos;
- Extração de ritmo, melodia e harmonia;
- Reconhecimento de emoções musicais (MER);
- Sistemas de recomendação musical.

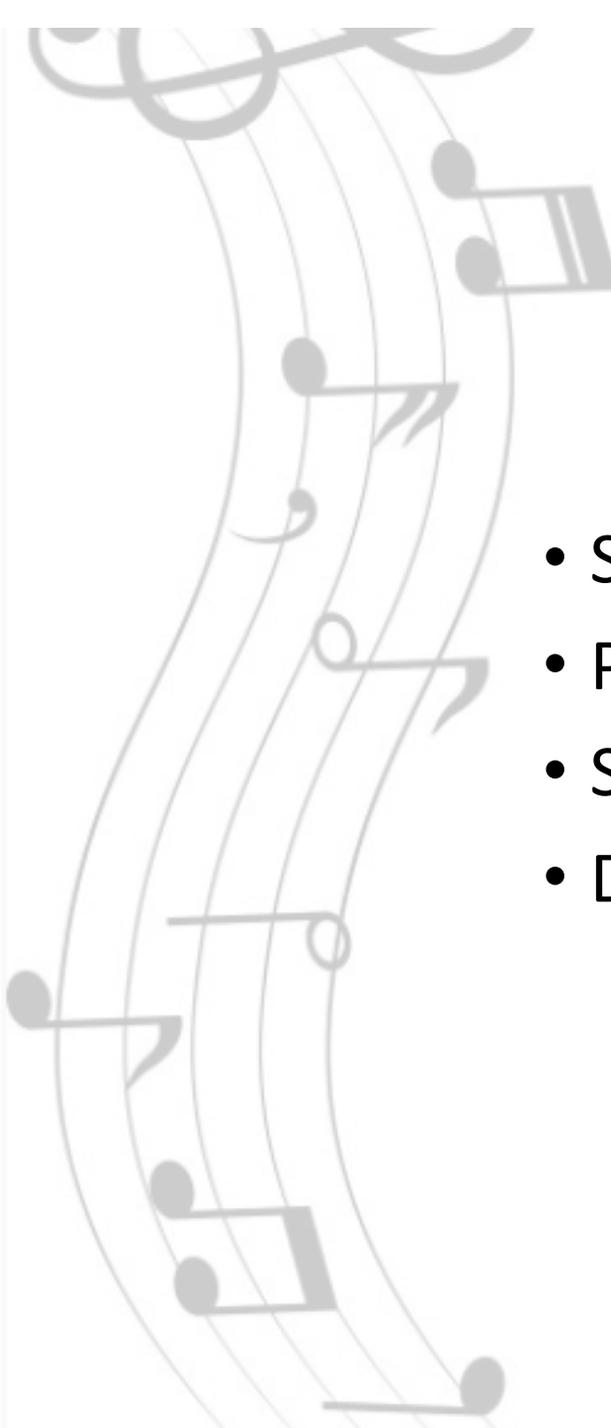
Frameworks e ferramentas importantes em MIR incluem:

- *MARSYAS*
- MIRtoolbox
- *PsySound3*
- jMIR
- *Essentia*
- LibROSA
- EmoMV-A, EmoMV-B e EmoMV-C
- TROMPA-MER
- *EMMA – Emotion-to-Music Mapping Atlas*
- SiTunes



Reconhecimento de Emoções Musicais (*Music Emotion Recognition – MER*)

O principal objetivo das pesquisas em Reconhecimento de Emoções Musicais é treinar algoritmos capazes de classificar músicas com base nas emoções que expressam ou evocam.



Problemas

- Seleção musical representativa
- Pré-processamento: conversão/padronização.
- Segmentação de trechos consistentes
- Desafios: qualidade, acesso restrito, falta de padronização.



Materiais e Métodos

Base de Dados
(Pandas et al., 2021 -> 704 músicas)

Atributos Utilizados
12 features

Padronização
(StandartScaler)

Seleção de Atributos (ReliefF)

Split treino/teste (80/20, stratify,
random_state=1234)

Modelagem (SVM, RF, kNN, Boosting)

Validação (GridSearchCV)

Avaliação (Accuracy, Precision, Recall, F1,
Matriz de Confusão)

Comparação estatística (Friedman +
Nemenyi)

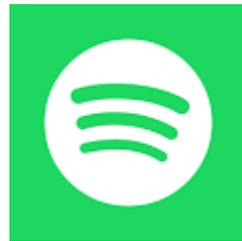
Recursos

Energy
(0.0 a 1.0)

Valence
(0.0 a 1.0)

Acousticness
(0.0 a 1.0)

Danceability
(0.0 a 1.0)



Spotify

Instrumentalness
(0.0 a 1.0)

Key
(-1 a -11)

Time_signature
(3 a 7)

Tempo

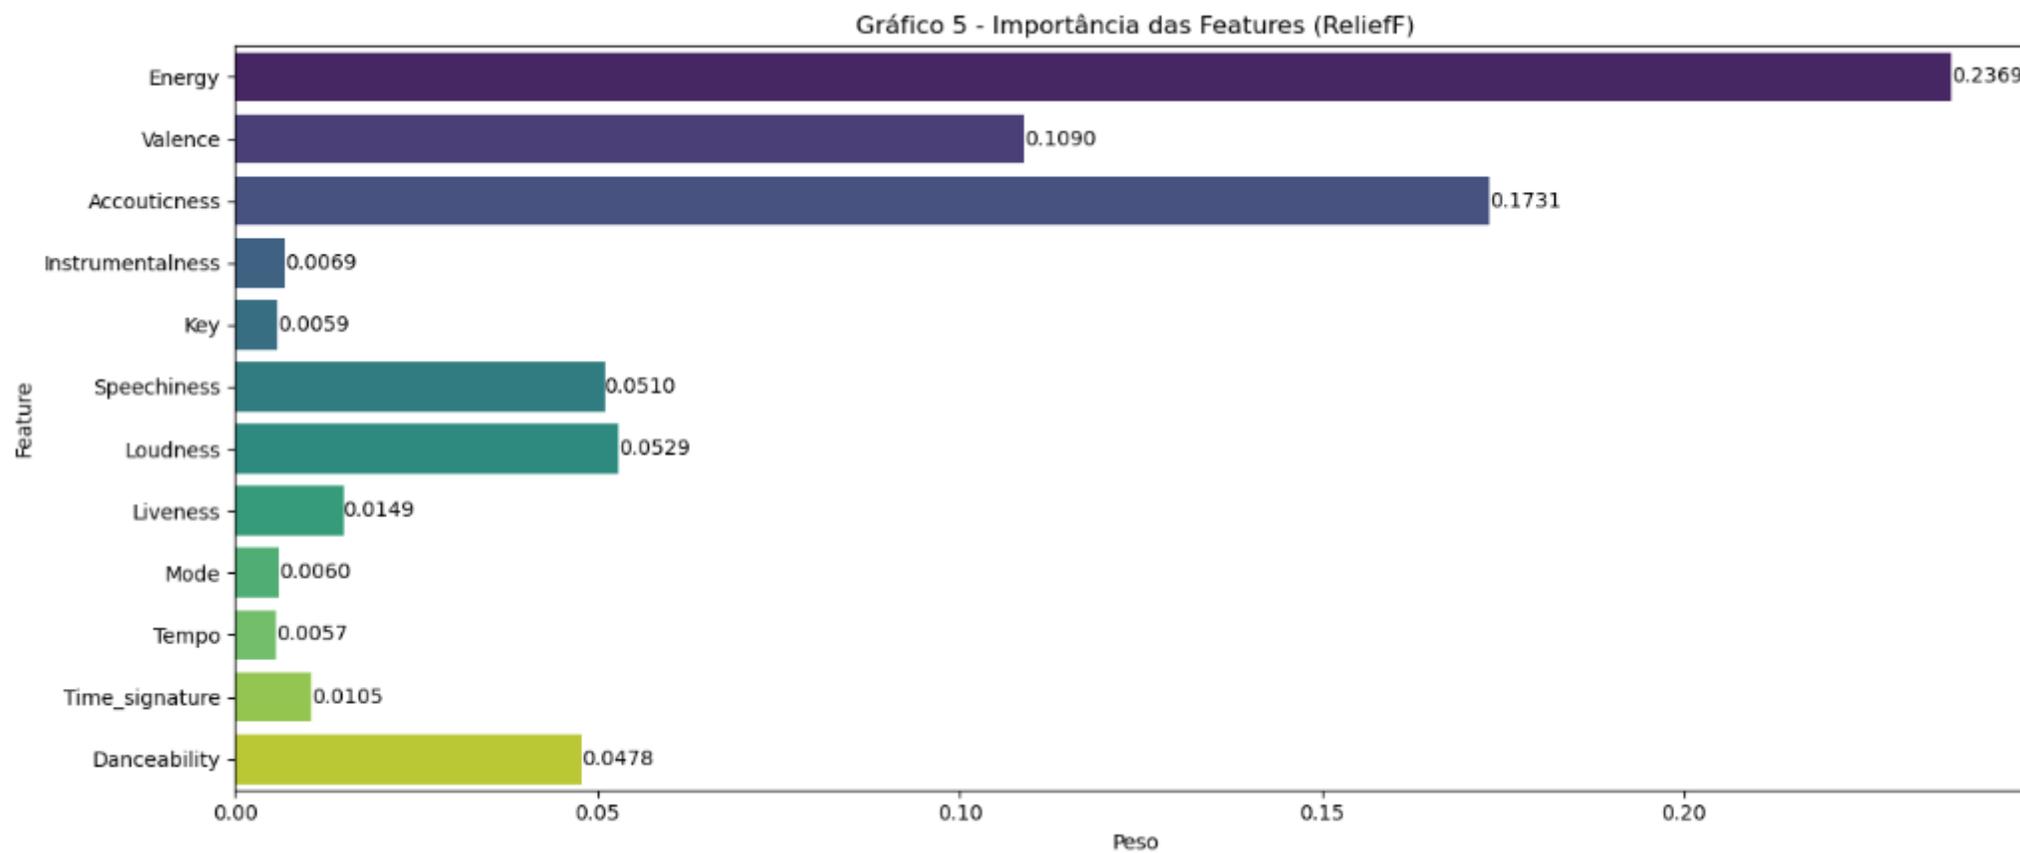
Speechiness
(0.0 a 1.0)

Mode
(0.0 a 1.0)

Liveness
(0.0 a 1.0)

Loudness
(-60 a 0)

Resultados



Resultados

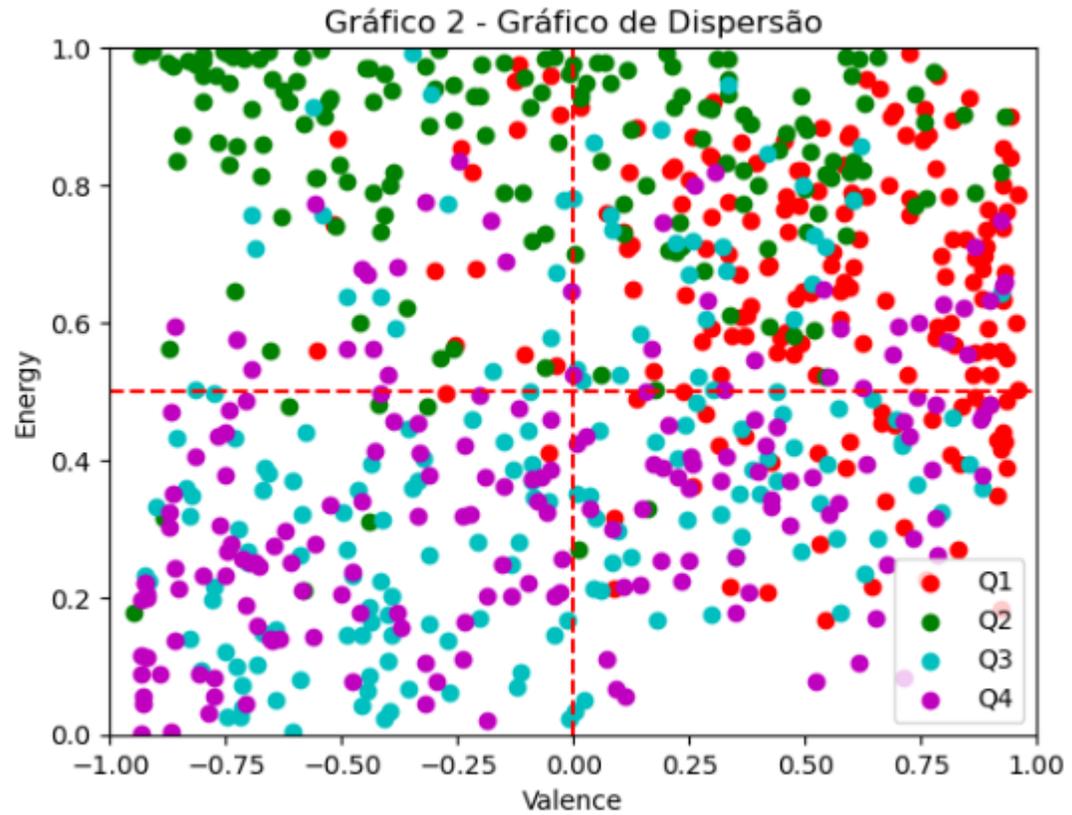


Gráfico 3 -Correlações entre variáveis

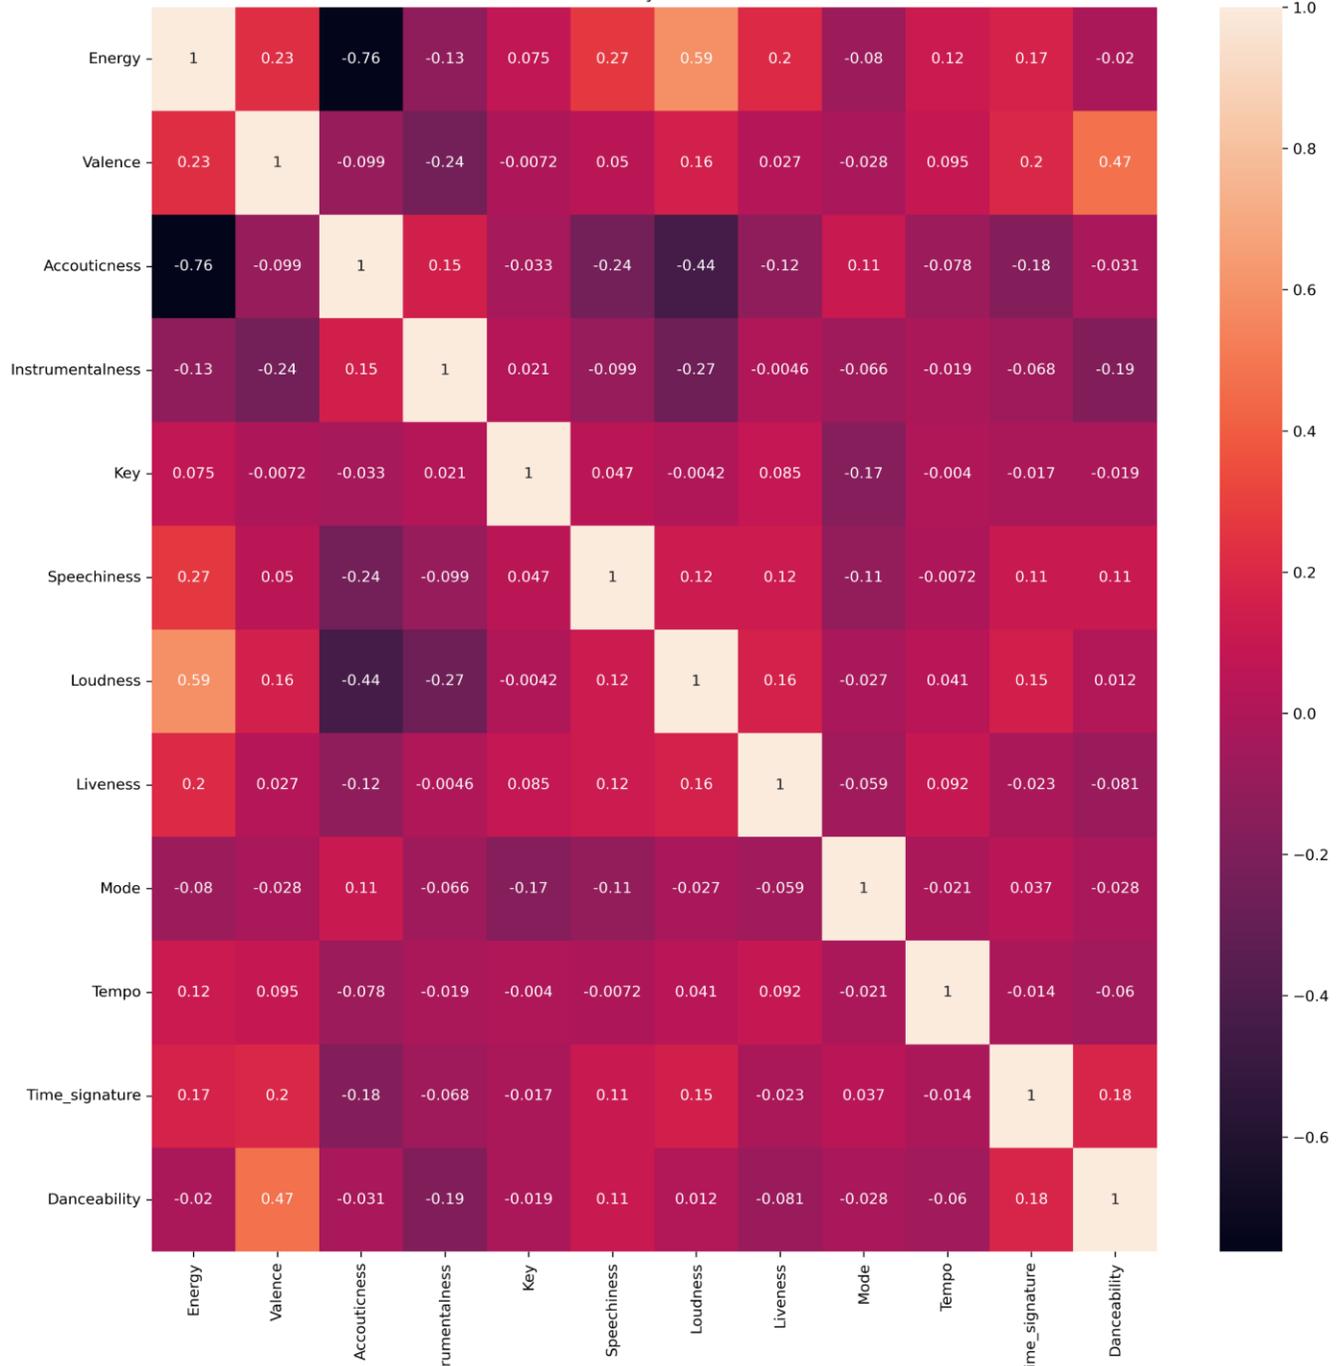
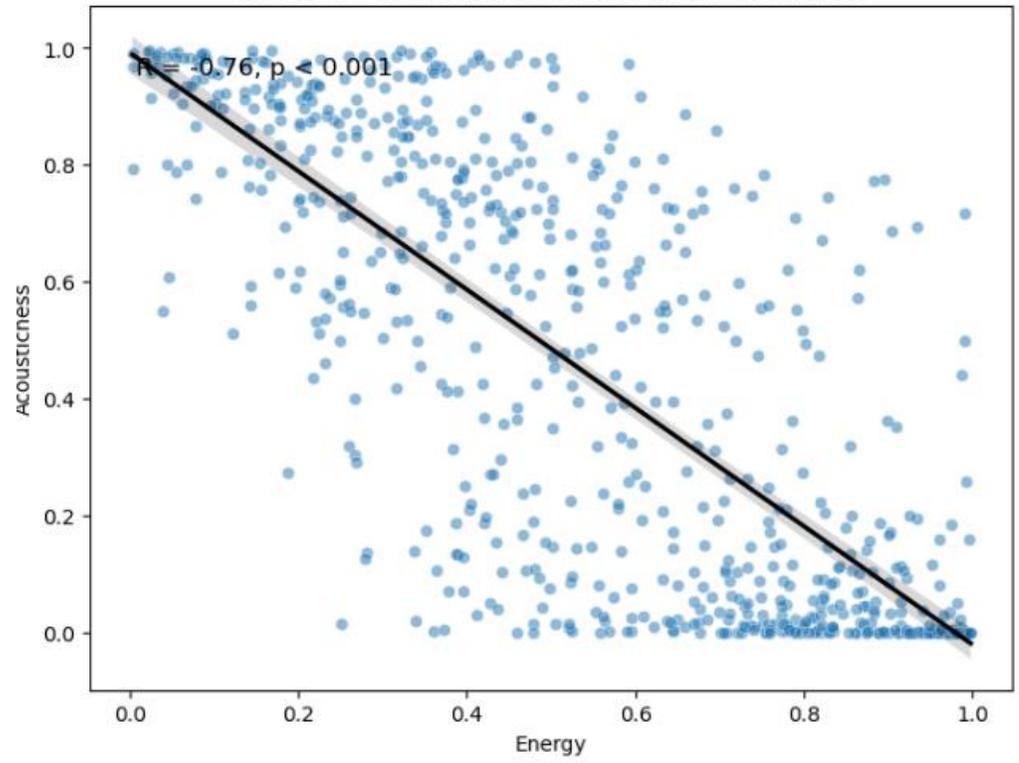


Gráfico 6 - Correlação entre Energy e Acousticness



Quadrante	Modelo de Russell (teoria)	Achados empíricos (Spotify API) Obs*	Interpretação
Q1 – Excitado, Feliz	Alta energia, valência positiva.	Energy moderada (0,649), Valence positiva (0,521), Acousticness (0,301)	Alegria pode ser expressa tanto em músicas acústicas quanto eletrônicas.
Q2 – Relaxado, Positivo	Baixa energia, valência positiva, predominância acústica	Energy alta (0,829), Valence ligeiramente negativa (-0,094), Acousticness = 0,167.	Músicas “relaxantes” aparecem majoritariamente eletrônicas.
Q3 – Triste, Sonolento	Baixa energia, valência negativa.	Energy baixa (0,378), Valence negativa (-0,107), Acousticness 0.716	Tristeza pode ser expressa tanto em baladas acústicas quanto em produções digitais.
Q4 – Nervoso, Estressado	Alta energia, valência negativa, predominância eletrônica	Energy baixa (0,352), Valence negativa (-0,102), Acousticness 0.66	Emoções de estresse aparecem em gêneros diversos, sem vínculo exclusivo com eletrônica

Obs.: Valores médios estipulados com base nos 704 áudios.

Modelo	Acurácia	Melhor Precision	Melhor Recall	Melhor F1-score
Gradient Boosting	62.4%	Q2 (0.76)	Q1 (0.83)	Q1 (0.75)
SVM	61.7%	Q2 (0.73)	Q1 (0.86)	Q1 (0.74)
XGBoost	60.3%	Q2 (0.77)	Q1 (0.78)	Q2 (0.77)
Random Forest	59.6%	Q2 (0.79)	Q1 (0.83)	Q2 (0.78)
Decision Tree	55.3%	Q2 (0.86)	Q1 (0.64)	Q2 (0.68)
KNN	52.5%	Q2 (0.68)	Q1 (0.78)	Q2 (0.61)

Modelo	Melhores parâmetros	Acurácia	Melhor Precision	Melhor Recall	Melhor F1-score	Pior Recall
KNN	metric=manhattan, n_neighbors=9, weights=uniform	60,99%	Q2 (0,73)	Q1 (0,81)	Q2 (0,72)	Q3 (0,38)
SVM (SVC)	C=1, kernel=linear	58,16%	Q2 (0,72)	Q2 (0,82)	Q2 (0,77)	Q3 (0,38)
Decision Tree	criterion=entropy, max_depth=20, min_samples_split=10	57,49%	Q2 (0,91)	Q2 (0,85)	Q2 (0,88)	Q4 (0,30)
Random Forest	criterion=gini, max_depth=None, n_estimators=200	63,12%	Q2 (0,76)	Q2 (0,85)	Q2 (0,81)	Q3 (0,41)
Gradient Boosting	learning_rate=0,05, max_depth=3, min_samples_split=5, n_estimators=100	63,83%	Q2 (0,80)	Q2 (0,82)	Q2 (0,81)	Q3 (0,53)
XGBoost	colsample_bytree=0,8, learning_rate=0,05, max_depth=3, n_estimators=100, subsample=1,0	60,99%	Q2 (0,81)	Q2 (0,85)	Q2 (0,83)	Q4 (0,41)

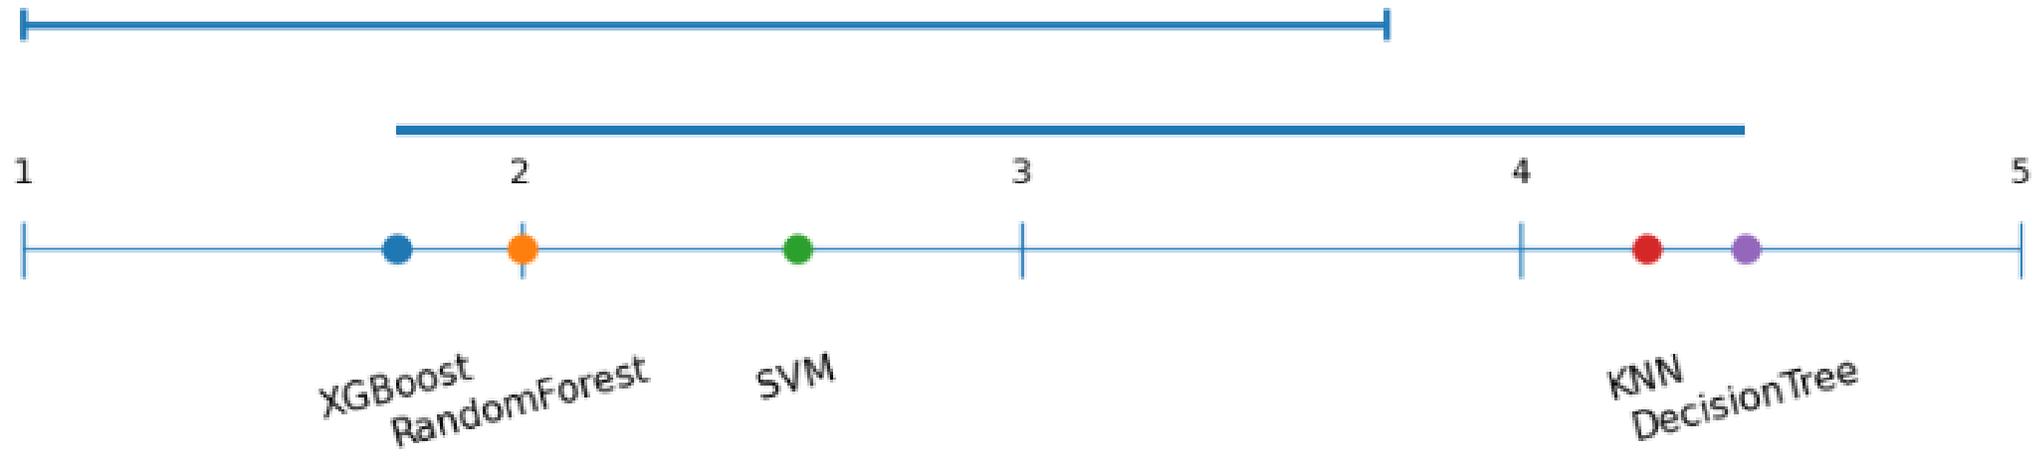
Comparação estatística entre modelos (Friedman + Nemenyi)

Modelo	Rank médio	Posição
XGBoost	1.75	Melhor
RandomForest	2.00	Muito bom
SVM	2.55	Médio
KNN	4.25	Fraco
DecisionTree	4.45	Mais fraco

Friedman $\chi^2=25.9798$, $p\text{-value}=0.000032$

Nenhum par com diferença significativa (Nemenyi, $\alpha=0.05$).

Diagrama de Diferença Crítica — Acurácia (10-fold)
CD = 2.73



Estudo / Fonte	Atributos utilizados	Modelo(s)	Desempenho médio
Este trabalho	12 atributos do Spotify API (Energy, Valence, Danceability, Acousticness etc.)	XGBoost, Random Forest	Acurácia ≈ 63%
Panda et al. (2021)	12 atributos do Spotify API	SVM	F1 ≈ 58,5%
Panda et al. (2021)	100 atributos especializados (estado da arte)	SVM	F1 ≈ 74,7%
Panda et al. (2020)	Novos atributos de alto nível (vibrato, glissando, textura, dinâmica etc.) + tradicionais	SVM	F1 ≈ 76,4%
Yang et al. (2008)	Atributos acústicos + ReliefF	Regressão contínua	Melhor para Arousal; valence mais difícil de modelar

Conclusões

- Os resultados (máx. $\approx 63,8\%$) confirmam a **viabilidade dos atributos do Spotify** para reconhecimento de emoções musicais, mas também suas **limitações**, já que ficam **10 a 13 pontos abaixo** dos atributos especializados do estado da arte.
- O **Gradient Boosting** se destacou como o melhor, superando Random Forest e XGBoost. Os resultados são consistentes com Panda et al. (2021), que também reportaram desempenho moderado para o Spotify.
- Outros trabalhos (Panda 2020, Panda 2021) mostram que o uso de **atributos de alto nível, mais próximos da percepção musical humana**, eleva o desempenho para $\approx 75\%$, reforçando que avanços futuros em MER exigem descritores além dos fornecidos pelo Spotify.

Estudos futuros



Experimentar técnicas de Deep Learning



CNNs, RNNs, Transformers para extrair automaticamente representações musicais.



Ampliar e diversificar os datasets



Aumentar a variedade de gêneros e culturas musicais.

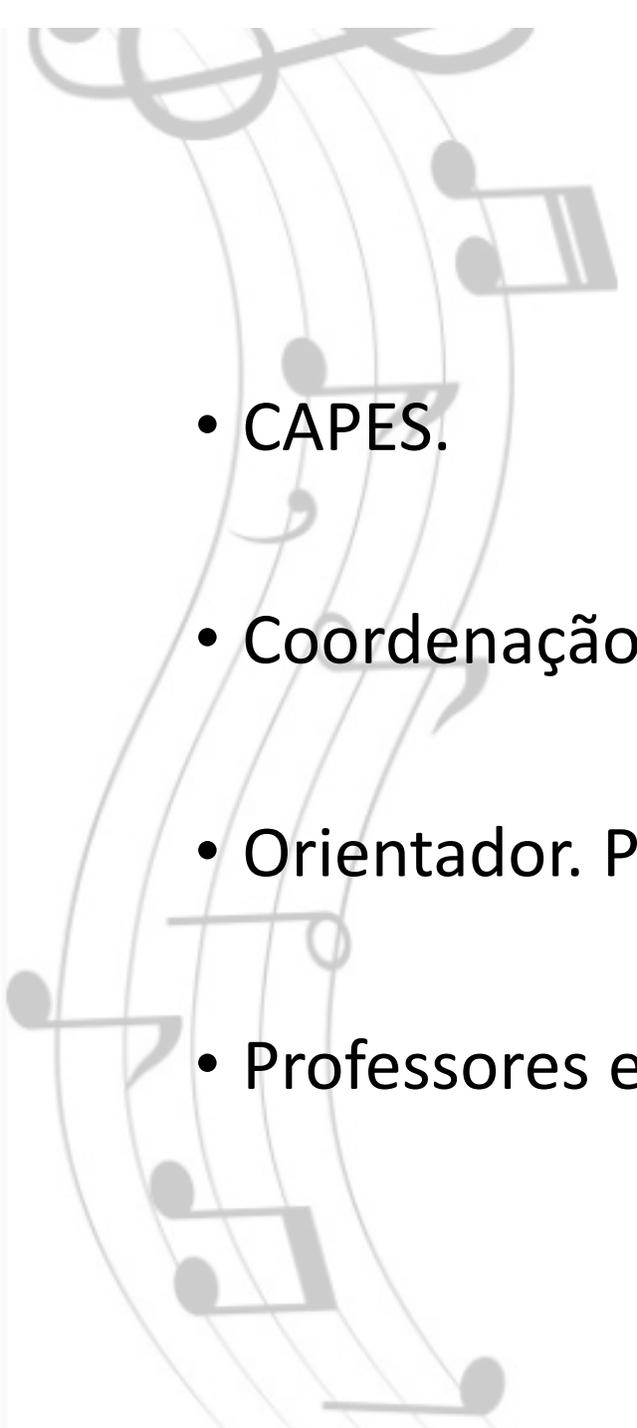


Analisar letras de músicas



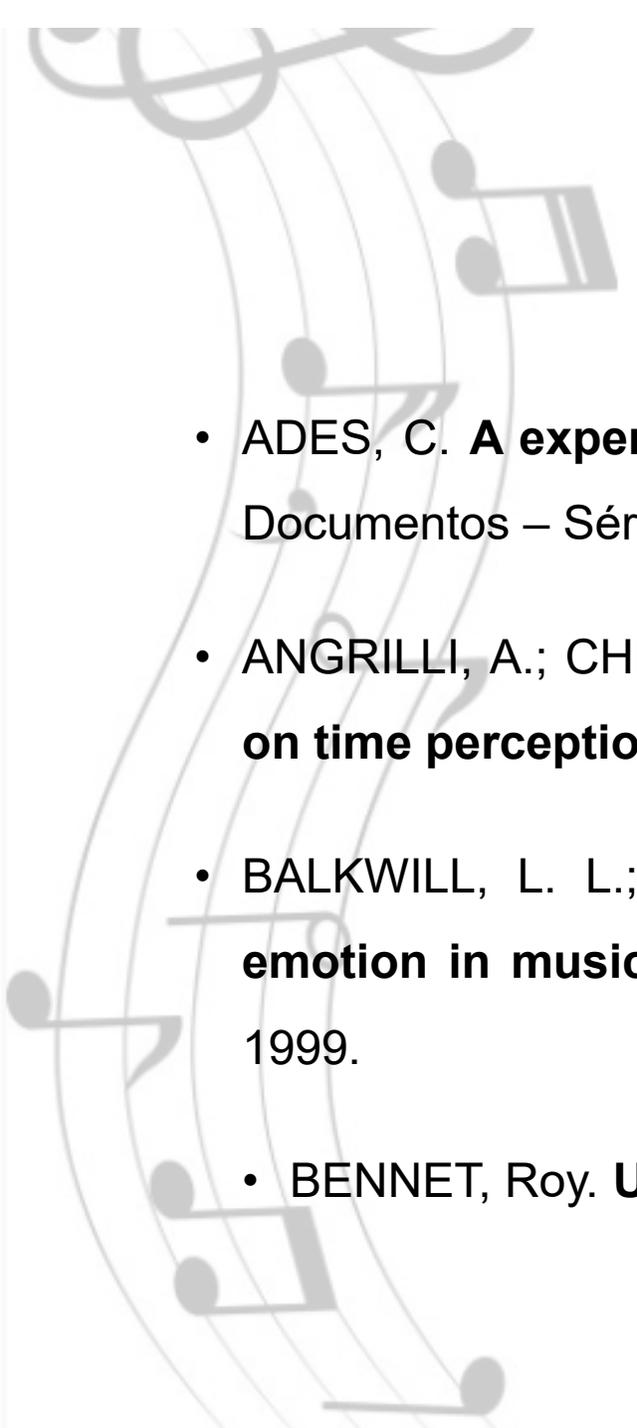
Cronograma

- 2025
- Termino da escrita -> setembro, outubro, novembro
- Defesa -> dezembro



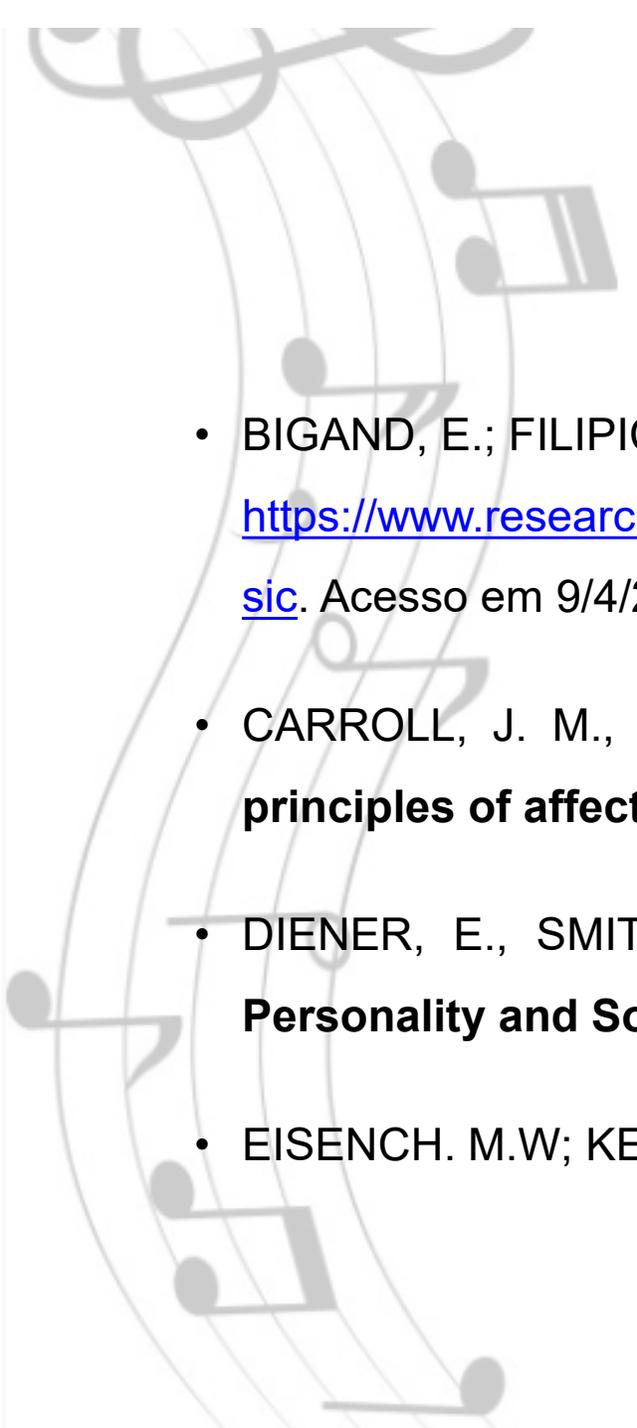
AGRADECIMENTOS

- CAPES.
- Coordenação e a secretaria do programa.
- Orientador. Prof. Razer Anthom Nizer Rojas Montaña
- Professores e colegas.



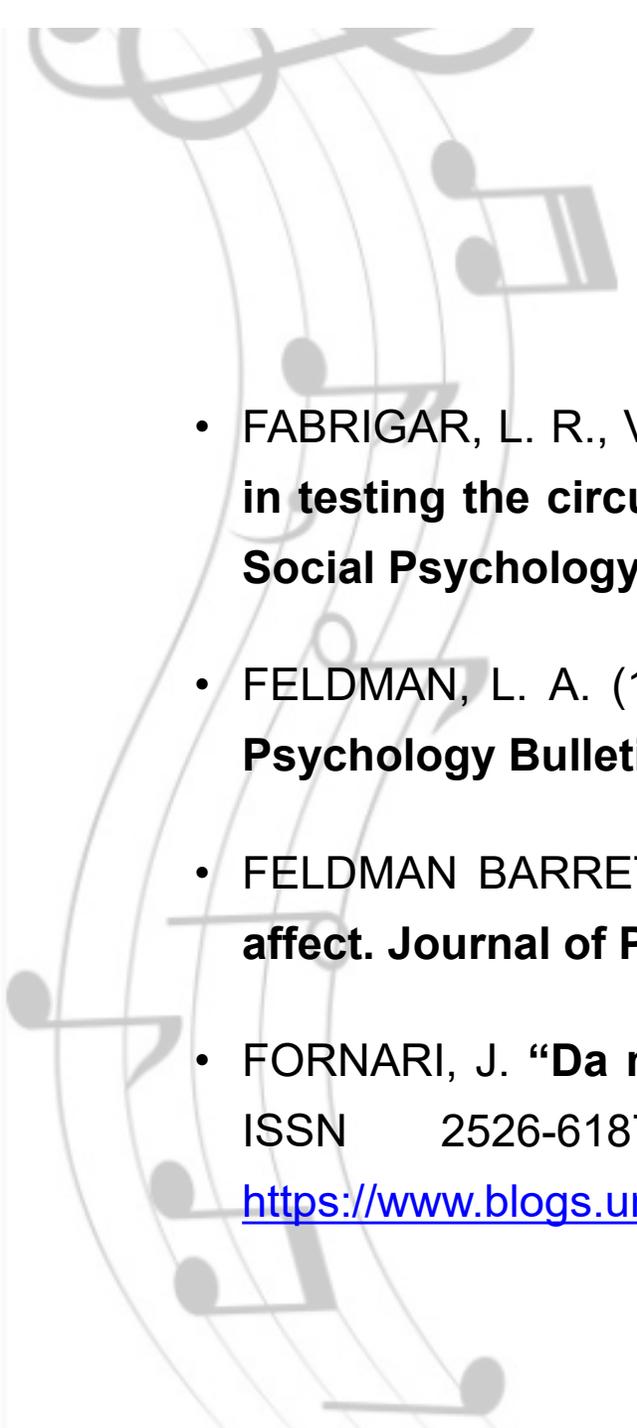
Referências Bibliográficas

- ADES, C. **A experiência psicológica da duração**. São Paulo: IEA/USP, 1991, p. 6-14, (Coleção Documentos – Série Teoria Política).
- ANGRILLI, A.; CHERUBINI, P.; PAVESE, A; MANFREDINI, S. **The influence of affective factors on time perception**. *Perception and Psychophysics*, v. 59, n. 6, p. 972-982, 1997.
- BALKWILL, L. L.; THOMPSON, W. F. **A cross-cultural investigation of the perception of emotion in music: psychophysical and cultural cues**. *Music Perception* v. 17, n. 1, p. 43-64, 1999.
- BENNET, Roy. **Uma breve história da música**. Rio de Janeiro: Zahar, 2007



Referências Bibliográficas

- BIGAND, E.; FILIPIC S.; LALITE, O. The time **course of emotional response to music**. Disponível em: https://www.researchgate.net/publication/7181577_The_Time_Course_of_Emotional_Responses_to_Music. Acesso em 9/4/2023.
- CARROLL, J. M., YIK, M. S. M., RUSSELL, J. A., & Barrett, L. F. (1999). **On the psychometric principles of affect**. *Review of General Psychology*.
- DIENER, E., SMITH, H., & FUJITA, F. (1995). **The personality structure of affect**. *Journal of Personality and Social Psychology*, 69, 130-141.
- EISENCH. M.W; KEANE, M.T. **Manual de psicologia cognitiva**. 7ª ed. Porto Alegre: Artmed, 2017.



Referências Bibliográficas

- FABRIGAR, L. R., VISSER, P. S., & BROWNE, M. W. (1997). **Conceptual and methodological issues in testing the circumplex structure of data in personality and social psychology.** *Personality and Social Psychology Review*, 1, 184-203.
- FELDMAN, L. A. (1995). **Variations in the circumplex structure of mood.** *Personality and Social Psychology Bulletin*, 21, 806-817.
- FELDMAN BARRETT, L., & Russell, J. A. (1998). **Independence and bipolarity in the structure of affect.** *Journal of Personality and Social Psychology*, 74, 967-984.
- FORNARI, J. **“Da música à musicologia”**. Blogs de Ciência da Universidade Estadual de Campinas. ISSN 2526-6187. Data da publicação: 2 de janeiro de 2019. Link: <https://www.blogs.unicamp.br/musicologia/2019/01/02/1/>



Referências Bibliográficas

- FORNARI, J. **“Musicologia na Grécia antiga e na Idade média”**. Blogs de Ciência da Universidade Estadual de Campinas. ISSN 2526-6187. Data da publicação: 9 de janeiro de 2019. Link: <https://www.blogs.unicamp.br/musicologia/2019/01/09/2/>
- MELLO, EKS. **A Influência da Familiaridade Musical Sobre a Formação de Expectativas Melódicas: Um Estudo Transcultural** – Pós-Graduação em Música, UFPR, Curitiba, 2021
- NOGUEIRA, K.A.P. Estudo de Respostas Emocionais às Cores no Contexto de Cartazes de Cinema. Disponível em:
 - [https://www.researchgate.net/publication/326541706_Estudo_de_respostas_emocionais_as_cores_no_contexto_de_c](https://www.researchgate.net/publication/326541706_Estudo_de_respostas_emocionais_as_cores_no_contexto_de_cartazes_de_cinema)
[artazes de cinema](https://www.researchgate.net/publication/326541706_Estudo_de_respostas_emocionais_as_cores_no_contexto_de_c_artazes_de_cinema). Acesso em 29/10/2023.
- RAMOS, D.; BUENO, J.L.O. **A percepção de emoções em trechos de música ocidental erudita**. Disponível em: <https://www.scielo.br/j/pm/a/rDtwxBGDLSFm7p6j5X6nzhd/?lang=pt>. Acesso em: 08/04/2023.

Referências Bibliográficas

- RAMOS D. **Fatores emocionais durante uma escuta musical afetam a percepção temporal de músicos e não músicos.** Disponível em: <https://teses.usp.br/teses/disponiveis/59/59137/tde-08102008-013413/publico/docdan.pdf>. Acesso em 9/4/2023
- RUSSELL, J. A. (1978). **Evidence of convergent validity on the dimensions of affect.** *Journal of Personality and Social Psychology*, 36, 1152-1168.
- RUSSELL, J. A. (1980). **A circumplex model of affect.** *Journal of Personality and Social Psychology*, 39, 1161-1178.
- RUSSELL, J. A., & CARROLL, J. M. (1999). **On the bipolarity of positive and negative affect.** *Psychological Bulletin*, 125, 3-30
- SPOTIFY. **Números de usuários premium cresce 17%.** Disponível em:
 - <https://open.spotify.com/episode/5d6nvv2hiCeXp3DgYeveBS>. Acesso em: 10/10/2023.
- ZHANG, J. et al. **Bridge the semantic gap between pop music acoustic feature and emotion: build an interpretable model.** *Neurocomputing*, v. 208, p.333-341, out. 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0925231216304696>
- Acesso em: 06/10/2023.