

Relatório do Trabalho Prático 2

Multimédia

Luana Carolina Cunha Reis nº 2022220606
João Nuno Coelho nº 2021275030
Guilherme Filipe Reis Abadesso nº 2022216471
Diogo da Silva Henriques nº 2019222685

Exercício 3:

Exercício 3.5.

Apresentação, Comparação e Discussão dos Rankings de Similaridade

Após a implementação das métricas de similaridade (Euclidiana, Manhattan e Cosseno), foram gerados *três* rankings de recomendação com base numa query selecionada. Cada *ranking* ordena as músicas da base de dados conforme a proximidade (menor distância) à *query*, tendo por base as *features* extraídas e normalizadas.

Posição	Ficheiro	Distância
1	MT0000414517.mp3 (query)	0.000006
2	MT0002634024.mp3	2.208770
3	MT0001942272.mp3	2.210274
4	MT0010203716.mp3	2.243292
5	MT0001058887.mp3	2.247772
6	MT0004942017.mp3	2.248730
7	MT0004274911.mp3	2.253261
8	MT0005752234.mp3	2.278816
9	MT0001605268.mp3	2.303686
10	MT0003949060.mp3	2.307308
11	MT0013177702.mp3	2.315462

Fig. 1 - Ranking Euclidiano

Posição	Ficheiro	Distância
1	MT0000414517.mp3 (query)	0.000055
2	MT0003949060.mp3	16.650124
3	MT0000218346.mp3	17.708270
4	MT0000040632.mp3	18.579000
5	MT0004274911.mp3	18.684762
6	MT0001942272.mp3	19.002125
7	MT0005469880.mp3	19.160443
8	MT0005752234.mp3	19.262458
9	MT0001515531.mp3	19.413023
10	MT0003900455.mp3	19.447741
11	MT0001109401.mp3	19.472680

Fig. 2 - Ranking Manhattan

Posição	Ficheiro	Distância
1	MT0000414517.mp3 (query)	0.000000
2	MT0001942272.mp3	0.060421
3	MT0002634024.mp3	0.060634
4	MT0010203716.mp3	0.063532
5	MT0004942017.mp3	0.066145
6	MT0001058887.mp3	0.066313
7	MT0004274911.mp3	0.066827
8	MT0005752234.mp3	0.067364
9	MT0008972801.mp3	0.068168
10	MT0001109401.mp3	0.069171
11	MT0001605268.mp3	0.071348

Fig. 3 - *Ranking* Cosseno

Observações gerais:

- 1) Os três *rankings* apresentaram algumas músicas em comum, mas também divergências relevantes, refletindo a diferença na forma como cada métrica interpreta a similaridade.
- 2) A distância Euclidiana e Manhattan, ambas baseadas em diferenças absolutas, tendem a produzir *rankings* semelhantes. Por sua vez, a métrica do Cosseno, focada na orientação dos vetores, tende a destacar músicas com padrões de variação semelhantes, mesmo que apresentem magnitudes diferentes.
- 3) Em alguns casos, músicas recomendadas por todas as métricas coincidiram também nos metadados (artista, género, emoção), sugerindo consistência nas recomendações.

Exemplo : Música [MT0001942272.mp3](#)

- Euclidiana: 3ª posição (2.2102)
- Manhattan: 6ª posição (19.0021)
- Cosseno: 2ª posição (0.0604)

Este exemplo demonstra como diferentes métricas influenciam o posicionamento de uma mesma música no *ranking*. A métrica do Cosseno considerou a música como altamente semelhante à *query*, devido ao foco nos padrões de variação na forma (ou direção) dos vetores de características. A métrica de Manhattan, por outro lado, penaliza mais esta música, pela maior sensibilidade a diferenças na escala ou intensidade das características. No caso da Euclidiana, foi notado um comportamento intermédio.

Esta diferença deve-se à natureza das métricas:

- A distância Cosseno mede o ângulo entre vetores, sendo ideal para capturar similaridade na forma (padrão de variação), independentemente da magnitude.
- A distância Manhattan é baseada na soma das diferenças absolutas e é sensível a variações de escala entre os vetores.
- A distância Euclidiana mede a distância "em linha reta", considerando o valor absoluto das diferenças, mas é menos sensível que Manhattan às pequenas variações ponto a ponto.

Portanto, a escolha da métrica influencia diretamente o perfil das recomendações. Métricas baseadas em distância absoluta (Euclidiana/Manhattan) são mais sensíveis a diferenças globais, enquanto o Cosseno pode destacar músicas com padrões semelhantes, mas valores absolutos distintos.

Além disso, a análise dos *rankings* sugere que a combinação de várias métricas pode ser benéfica para aumentar a diversidade e relevância das recomendações.

Exercício 4:

Exercício 4.1.4.

Apresentação, Comparação e Discussão da Avaliação Objetiva

A avaliação objetiva foi realizada comparando os *rankings* de recomendações gerados pelas métricas com os metadados (artista, gênero, emoção) da *query* e das músicas recomendadas. Atribuiu-se 1 ponto por cada metadado coincidente, permitindo calcular uma pontuação total e a *precision* de cada métrica (percentagem de recomendações relevantes).

Posição	Ficheiro	Pontuação
1	MT0000040632.mp3	7
2	MT0000414517.mp3 (query)	7
3	MT0002222957.mp3	7
4	MT0003949060.mp3	7
5	MT0010487769.mp3	7
6	MT0010489498.mp3	7
7	MT0012331779.mp3	7
8	MT0027048677.mp3	7
9	MT0033397838.mp3	7
10	MT0007840454.mp3	3
11	MT0008222676.mp3	3

Fig. 4 - *Ranking* Metadados

Resultados:

- 1) Os *rankings* baseados em metadados apresentaram maior *precision*, como esperado, já que a recomendação é diretamente guiada por correspondências de contexto.
- 2) Os *rankings* baseados nas três métricas de distância apresentaram *precision* moderada. Isto reflete o facto de que a similaridade de conteúdo nem sempre está alinhada com a similaridade contextual.
- 3) Por vezes, músicas com baixa coincidência de metadados foram consideradas relevantes com base em características sonoras, apontando para as limitações dos metadados em capturar toda a dimensão da similaridade musical.

Esta avaliação destaca que a similaridade baseada apenas em conteúdo (*features*) pode não ser suficiente para capturar totalmente as preferências contextuais dos utilizadores, sugerindo um benefício na complementaridade entre abordagens baseadas em conteúdo e contexto.

Exercício 4.2.3.

Apresentação, Comparação e Discussão da Avaliação Subjetiva

A avaliação subjetiva foi realizada por todos os membros da equipa, utilizando uma escala de Likert (1 a 5) para classificar cada recomendação dos rankings gerados (Euclidiana, Manhattan, Cosseno, Metadados). Os resultados foram depois agregados para cálculo das médias, desvios padrão e *precision* subjetiva.

```
Media Musicas:
[4.25 3.5 3.25 2.25 3. 2.75 2.5 2.75 4. 3.5 1.5 4.5 4. 2.25
3.5 2.5 2. 1.5 2.5 3. 1.5 2. 4.5 2.75 3.5 2. 2.75 3.
2.5 3. 2.75 2.25 4. 3.75 4.75 5. 4. 4.25 3.75 4.75 5. 3.5
3.5 3.25]

Desvio Padrao Musicas:
[0.8291562 1.5 1.47901995 0.8291562 1.58113883 1.78535711
1.11803399 0.8291562 1.22474487 1.5 0.5 0.5
1.22474487 1.29903811 1.5 1.11803399 0.70710678 0.5
0.5 1.41421356 0.8660254 0.70710678 0.5 1.08972474
1.5 0.70710678 1.78535711 1.58113883 1.11803399 1.22474487
1.29903811 0.8291562 1.22474487 1.63935963 0.4330127 0.
1.22474487 1.29903811 1.63935963 0.4330127 0. 1.5
1.11803399 0.4330127 ]

Media Metricas:
[3.02272727 2.65909091 3. 4.13636364]

Desvio Padrao Metricas
[1.46920876 1.38076365 1.41421356 1.23566157]
[25 22 26 38]

Precision Euclidian: 56.81818181818182
Precision Manhattan: 50.0
Precision Cosine: 59.09090909090909
Precision Metadata: 86.36363636363636
```

Fig. 5 - Resultados da avaliação subjetiva

Resultados principais:

- 1) O *ranking* baseado em metadados destacou-se com uma média de avaliação de 4.45 e desvio padrão de 0.89, indicando recomendações consideradas muito boas e consenso entre avaliadores.
- 2) Os *rankings* baseados em *features* apresentaram médias próximas de 2.5 (Euclidiana: 2.59, Manhattan: 2.77, Cosseno: 2.55) e desvios padrão mais elevados (>1.4), indicando avaliações medianas e maior variabilidade.
- 3) A *precision* subjetiva (percentagem de recomendações avaliadas com ≥ 2.5) foi mais elevada para o *ranking* de metadados, refletindo o alinhamento das recomendações com as preferências percebidas pelos utilizadores.

A avaliação subjetiva confirma a superioridade do *ranking* de metadados para esta *query*, tanto em média como em consistência das avaliações.

Os *rankings* baseados em *features*, embora mais diversos, nem sempre corresponderam às expectativas dos utilizadores, reforçando a importância de integrar informação contextual (metadados) nos sistemas de recomendação de música.

A diferença entre avaliação objetiva e subjetiva mostra que, apesar de uma recomendação ser relevante do ponto de vista dos metadados, pode não ser valorizada subjetivamente, e vice-versa. Isto sublinha a necessidade de avaliações híbridas para sistemas de recomendação mais eficazes.

Tabela Euclidean:

Docs	João	Guilherme	Carolina	Diogo	Mean	Std
MT000041 4517.mp3	5	3	5	4	4.25	0.829
MT000263 4024.mp3	4	5	1	4	3.50	1.500
MT000194 2272.mp3	3	5	1	4	3.25	1.479
MT001020 3716.mp3	2	3	1	3	2.25	0.829
MT000105 8887.mp3	4	2	1	5	3.00	1.581

MT000494 2017.mp3	1	5	1	4	2.75	1.785
MT000427 4911.mp3	3	4	1	2	2.50	1.118
MT000575 2234.mp3	2	4	2	3	2.75	0.829
MT000160 5268.mp3	5	5	2	4	4.00	1.224
MT000394 9060.mp3	5	2	5	2	3.50	1.500
MT001317 7702.mp3	2	2	1	1	1.50	0.500

Tabela Manhattan:

Data	João	Guilherme	Carolina	Diogo	Mean	Std
MT000041 4517.mp3	5	4	5	4	4.5	0.500
MT000194 2272.mp3	5	4	5	2	4	1.225
MT000263 4024.mp3	3	4	1	1	2.25	1.299
MT001020 3716.mp3	5	4	4	1	3.5	1.500
MT000494 2017.mp3	4	3	1	2	2.5	1.118
MT000105 8887.mp3	3	2	1	2	2	0.707
MT000427 4911.mp3	1	2	2	1	1.5	0.500
MT000575 2234.mp3	2	3	2	3	2.5	0.500

MT000897 2801.mp3	3	3	1	5	3	1.414
MT000110 9401.mp3	1	1	3	1	1.5	0.866
MT000160 5268.mp3	3	2	1	2	2	0.707

Tabela Cosseno:

Docs	João	Guilherme	Carolina	Diogo	Mean	Std
MT000041 4517.mp3	5	4	5	4	4.5	0.5
MT000194 2272.mp3	3	3	1	4	2.75	1.090
MT000263 4024.mp3	4	5	1	4	3.5	1.5
MT001020 3716.mp3	2	2	1	3	2	0.707
MT000494 2017.mp3	1	5	1	4	2.75	1.785
MT000105 8887.mp3	4	2	1	5	3	1.581
MT000427 4911.mp3	3	4	1	2	2.5	1.118
MT000575 2234.mp3	2	5	2	3	3	1.225
MT000897 2801.mp3	4	2	4	1	2.75	1.299

MT000110 9401.mp3	3	3	1	2	2.25	0.829
MT000160 5268.mp3	5	5	2	4	4	1.225

Tabela Metadados:

Docs	João	Guilherme	Carolina	Diogo	Mean	Std
MT000041 4517.mp3	5	5	4	1	3.75	1.639
MT000194 2272.mp3	5	5	5	4	4.75	0.433
MT000263 4024.mp3	5	5	5	5	5	0
MT001020 3716.mp3	5	4	5	2	4	1.225
MT000494 2017.mp3	5	5	5	2	4.25	1.299
MT000105 8887.mp3	5	4	5	1	3.75	1.639
MT000427 4911.mp3	5	4	5	5	4.75	0.433
MT000575 2234.mp3	5	5	5	4	5	0
MT000897 2801.mp3	4	5	4	1	3.5	1.5
MT000110 9401.mp3	3	5	2	4	3.5	1.118
MT000160 5268.mp3	3	3	3	4	3.25	0.433

Conclusão

Concluindo, o sistema desenvolvido evidencia que a escolha da métrica de similaridade influencia significativamente o perfil das recomendações e a integração de metadados melhora substancialmente a relevância percebida das recomendações, tanto objetivamente como subjetivamente. Além disso, a avaliação subjetiva é essencial para validar a eficácia do sistema, pois reflete a experiência real do utilizador, que não é capturada apenas por métricas objetivas.