

Recomendação baseada em similaridade de genero

Transcrição

Vamos dar uma olhada em uma outra possibilidade de recomendação, agora levando em consideração os filmes que o usuário assistiu. Me utilizando como exemplo, anotei alguns filmes que eu "assisti": 1 , 21 , 19 , 10 , 11 , 7 e 2 .

Criaremos um array com esses filmes, atribuindo-o a uma variável `eu_assisti`, e vamos filtrá-los no nosso dataset com `filmes.loc[eu_assisti]`. Os filmes serão listados nessa mesma ordem: Toy Story, Get Shorty, Ace Ventura, GoldenEye, The American President, Sabrina e Jumanji.

Agora, podemos criar um sistema de recomendação ignorando as informações colaborativas que nos foram passadas, e nos baseando somente nas informações que temos sobre o usuário: você sabe que eu assisti esses filmes e sabe os gêneros desses filmes.

Por exemplo, imagine que o último filme que eu assisti foi o Jumanji original, que é dos gêneros Aventura, Infantil e Fantasia. Vamos copiar esses três gêneros e, com `filmes.query("generos=='Aventure|Children|Fantasy'")`, buscaremos no nosso dataframe outros filmes cujos gêneros sejam exatamente esses três.

Como retorno, teremos diversos filmes desse conjunto de gêneros. Agora que os filtramos, vamos ordená-los, por exemplo, pelas notas médias. Porém, teremos diversos filmes cujo total de votos é muito baixo, já que estamos trabalhando com todo o dataset filmes. Será que devemos trabalhar com filmes que têm um total de votos baixo? Eu acho que não.

Portanto, basearemos nossa `query()` nos `filmes_com_mais_de_50_votos`, atribuindo o seu retorno a uma variável `aventura_infantil_e_fantasia`. Em seguida, vamos ordená-los da maior média para a menor e exibir os 10 primeiros.

Na nossa lista de recomendações para alguém que viu Jumanji, temos Harry Potter e a Pedra Filosofal, A História sem Fim (que faz parte da minha infância), Crônicas de Nárnia, A Bússola Dourada, o próprio Jumanji e A Chave Mágica (um filme que desconheço).

Nesse momento, é interessante removermos o Jumanji da lista, afinal eu já o assisti. Portanto, antes do `sort_values()`, faremos um `drop()`, passando como parâmetro a variável `eu_assisti`. Porém, nosso código deixará de funcionar, pois nem todos os filmes contidos no array `eu_assisti` estão presentes em `aventura_infantil_e_fantasia`.

A função `drop()` do Pandas possui um parâmetro extra, chamado `errors`, que por padrão retorna um erro quando ela não encontra um elemento. Vamos setar esse parâmetro como `errors='ignore'`. Dessa vez, conseguiremos remover o Jumanji da lista com sucesso, obtendo 5 filmes que, com base no nosso conjunto de dados, seriam recomendados para quem acabou de assistir ao Jumanji - independentemente de sabermos se a pessoa gostou ou não de Jumanji.

Repare que nessa abordagem não utilizamos, pelo menos inicialmente, o `total_de_votos` ou a `nota_media`. Porém, quando filtramos os elementos para tentarmos atribuir mais qualidade à recomendação, nós voltamos a utilizar esses critérios: primeiro para remover os filmes de nicho, e depois para estabelecer alguma preferência na recomendação.

Fizemos isso nos baseando em um conceito de similaridade, que definimos como sendo filmes que possuem exatamente os mesmos gêneros.