

Método para definir o número de clusters

Além do método do cotovelo e do método matemático, ainda existe mais uma forma de determinar o número ideal de cluster: o método da silhueta.

Você pode ler [esse texto no Medium \(https://medium.com/@jyotiyadav99111/selecting-optimal-number-of-clusters-in-kmeans-algorithm-silhouette-score-c0d9ebb11308\)](https://medium.com/@jyotiyadav99111/selecting-optimal-number-of-clusters-in-kmeans-algorithm-silhouette-score-c0d9ebb11308) falando sobre o método. Como o texto está em inglês, segue a tradução do parágrafo que diz respeito ao assunto:

Coefficiente de silhueta: Essa é uma medida melhor para decidir o número de clusters a serem formulados a partir dos dados. É calculado para cada instância e a fórmula é assim:

$$S = \frac{(x - y)}{\max(x, y)}$$

onde y é a distância média intra cluster: distância média para as outras instâncias no mesmo cluster.

E x representa a distância média mais próxima do cluster, ou seja, a distância média às instâncias do próximo cluster mais próximo.

O coeficiente varia entre -1 e 1. Um valor próximo a 1 implica que a instância está próxima ao cluster e faz parte do cluster correto. Por outro lado, um valor próximo de -1 significa que o valor está atribuído ao cluster errado.

Sendo assim, considerando o gráfico abaixo de coeficiente de silhueta, o número de cluster deveria ser 5, onde ocorre o maior valor.

