

# Processamento de texto

Inteligência na Web e Big Data

---

Fabricio Olivetti de França e Thiago Ferreira Covões  
[folivetti@ufabc.edu.br](mailto:folivetti@ufabc.edu.br), [thiago.covoes@ufabc.edu.br](mailto:thiago.covoes@ufabc.edu.br)

Centro de Matemática, Computação e Cognição  
Universidade Federal do ABC



# Representação Textual

---

- Documentos de textos:
  - Não possuem representação vetorial
  - Interdependência dos atributos
  - Tamanho variável

- Se representarmos os documentos de textos como o conjunto de suas palavras:

D1 = "Estou assistindo a uma aula de Big Data, mas tudo que aprendi foi Haskell durante a aula!"

D2 = "Hoje aprendi Haskell na aula, será que o que aprendi será útil na minha vida?"

- Se representarmos os documentos de textos como o conjunto de suas palavras:

$D1 = \{\text{Estou, assistindo, a, uma, aula, de, Big, Data, mas, tudo, que, aprendi, foi, Haskell, durante, aula!}\}$

$D2 = \{\text{Hoje, aprendi, Haskell, na, aula, será, que, o, útil, minha, vida?}\}$

- Calculando a similaridade de Jaccard, temos:

$$D1 \cap D2 = \{\text{que, aprendi, Haskell}\}$$

$$D1 \cup D2 = \{\text{Estou, assistindo, a, uma, aula, de, Big, Data, mas, tudo, que, aprendi, foi, Haskell, durante, aula!, Hoje, na, aula, será, o, útil, minha, vida?}\}$$

$$J(D1, D2) = \frac{3}{24} = 0.125$$

- Essa representação é conhecida como Bag-of-Words.

## Normalização do Texto

- Pode ser interessante padronizar a forma do texto para termos serem considerados como um elemento único do conjunto independente de como é escrito.
- Por exemplo: Estou, estou, esTou, aula!, aula, aula?, útil, util.

$$D1 = \{\text{estou, assistindo, a, uma, aula, de, big, data, mas, tudo, que, aprendi, foi, haskell, durante, aula}\}$$
$$D2 = \{\text{hoje, aprendi, haskell, na, aula, sera, que, o, util, minha, vida}\}$$

$$J(D1, D2) = \frac{4}{23} = 0.17$$

## Eliminação de atributos irrelevantes

- Podemos eliminar palavras que não apresentam significado sozinhas:

$D1 = \{\text{estou, assistindo, aula, big, data, tudo, aprendi, haskell, durante, aula}\}$

$D2 = \{\text{hoje, aprendi, haskell, aula, sera, util, minha, vida}\}$

$$J(D1, D2) = \frac{4}{14} = 0.28$$



## Term-Frequency

- Se um termo aparece repetidas vezes em um documento, isso significa que ele pode ter uma importância maior do que os outros termos.
- No nosso exemplo, a repetição do termo Haskell indica um dos temas dos nossos documentos.
- A informação de frequência pode ser importante para a representação de nossos documentos. Podemos fazer então:

$$fn(t, d) = \frac{f(t, d)}{|d|},$$

- com  $f(t, d)$  sendo a frequência do termo  $t$  no documento  $d$  e  $|d|$  a quantidade de termos no documento  $d$ .

- A ideia para computar os vetores TF é primeiro representar cada documento como uma lista  $(token, 1.0)$  e, em seguida:
  - Ordenar essa lista pelo token
  - Agrupar os itens com mesmo token
  - Somar os valores em cada grupo
  - Dividir os valores pelo número de tokens

## Inverse Document Frequency

- Algumas palavras aparecem com uma frequência muito superior as demais, como: e, que, ou, etc.
- Essas palavras não costumam apresentar um significado discriminatório e, portanto, podem ter um peso menor. Para isso podemos multiplicar o TF por:

$$idf(t) = \log \frac{|D|}{|\{d \in D : t \in D\}|}$$

## Exercício

Dada as tabelas abaixo, calcule a similaridade de cosseno entre os documentos 1 e 2 com a representação tf e tf-idf:

$$s_{\cos}(\mathbf{x}, \mathbf{y}) = \frac{\mathbf{x}^T \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|}$$

|           | <b>A</b> | <b>B</b> | <b>C</b> | <b>D</b> |
|-----------|----------|----------|----------|----------|
| <b>D1</b> | 30       | 5        | 0        | 1        |
| <b>D2</b> | 60       | 0        | 4        | 10       |
| <b>D3</b> | 10       | 2        | 0        | 0        |
| <b>D4</b> | 40       | 0        | 4        | 8        |

## Exercício

| <b>tf</b> | <b>A</b> | <b>B</b> | <b>C</b> | <b>D</b> |
|-----------|----------|----------|----------|----------|
| <b>D1</b> | 0.83     | 0.14     | 0.00     | 0.03     |
| <b>D2</b> | 0.81     | 0.00     | 0.05     | 0.13     |
| <b>D3</b> | 0.83     | 0.17     | 0.00     | 0.00     |
| <b>D4</b> | 0.77     | 0.00     | 0.08     | 0.15     |

## Exercício

$$idf = [0.00, 0.69, 0.69, 0.29]$$

(base e)

| tf-idf    | A    | B     | C    | D    |
|-----------|------|-------|------|------|
| <b>D1</b> | 0.00 | 0.10  | 0.00 | 0.01 |
| <b>D2</b> | 0.00 | 0.00  | 0.04 | 0.04 |
| <b>D3</b> | 0.00 | 0.115 | 0.00 | 0.00 |
| <b>D4</b> | 0.00 | 0.00  | 0.05 | 0.04 |

$$s_{tf} = [0.97]$$

$$s_{tfidf} = [0.06]$$

# Padronizando e Normalizando os Atributos

---

- Muitos algoritmos de Aprendizado de Máquina supõem que os valores dos atributos seguem  $N(0,1)$ .
- Se um atributo não segue esse padrão, pode dominar a função-objetivo e se tornar importante demais.



- Dado uma matriz de dados  $X$ , podemos padronizar os valores de cada um de seus elementos como:

$$\hat{X}_{i,j} = \frac{X_{i,j} - \bar{X}_{i,j}}{\sigma_j}$$

- Algoritmos baseados em métodos de gradiente tendem a se beneficiar quando os atributos estão entre  $[0,1]$ .

$$\hat{X}_{i,j} = \frac{X_{i,j} - \min X_{:,j}}{\max X_{:,j} - \min X_{:,j}}$$

- Finalmente podemos normalizar cada amostra da base utilizando a normalização de vetores:

$$\hat{X}_{i,j} = \frac{X_{i,j}}{\|X_i\|_p}$$

- Esta transformação tem uma propriedade pois relacionada a similaridade do coseno com a distância euclidiana, uma vez que  $\|\mathbf{x}\| = 1$

## Exercício

Calcule o vetor padronizado, normalizado e escalonado de  
[1, 3, 2, 5, 4, 6, 3]

$$v_p = [-1.4, -0.25, -0.83, 0.91, 0.33, 1.50, -0.25]$$

$$v_n = [0.1, 0.3, 0.2, 0.5, 0.4, 0.6, 0.3]$$

$$v_e = [0, 0.4, 0.2, 0.8, 0.6, 1, 0.4]$$