

## SCC0633/5908 PROCESSAMENTO DE LINGUAGEM NATURAL LISTA DE EXERCÍCIOS 2

1. Escolha um corpus qualquer (pode ser o que foram utilizados na aula) e, usando as funções do NLTK, faça:
  - a. *Tokenize* o corpus inteiro (palavras, números e pontuações)
  - b. Verifique a quantidade de tokens do corpus
  - c. *Tokenize* o corpus apenas por suas palavras
  - d. Verifique a quantidade de palavras do corpus
  - e. Verifique a frequência de palavras no corpus
  - f. Verifique quais são as 5, 10 e 15 palavras mais frequentes do corpus
  - g. Extraia as *stopwords* do NLTK (não do corpus ainda)
  - h. Verifique a frequência dos tokens sem *stopwords* do corpus
  - i. Extraia todos os bigramas do corpus
  - j. Extraia todos os trigramas do corpus
  - k. Extraia todos os 4-gramas do corpus
  - l. Retorne as entidades nomeadas do corpus, usando os bigramas e trigramas
  - m. Escolha 3 palavras do seu corpus e faça o *stemming* delas
  - n. Separe uma sentença do seu corpus e retorne todas as classes gramaticais das palavras da sentença. Analise se o etiquetador acertou todas as classes gramaticais
  - o. Retorne as classes gramaticais de todas as palavras do seu corpus
  - p. Retorne as entidades nomeadas do seu corpus, usando a técnica de *chunking*
  
2. Utilizando um corpus de seu interesse (pode ser o que foi utilizado na aula) e utilizando o spaCy, faça:
  - a. *Tokenize* todo o corpus
  - b. *Tokenize* todo o corpus e retorne a lista com strings
  - c. *Tokenize* todo o corpus e retorne apenas as palavras
  - d. Retorne a quantidade de palavras do corpus
  - e. *Tokenize* todo o corpus e retorne apenas os números
  - f. Retorne a quantidade de números do corpus

- g. Tokenize todo o corpus e retorne apenas as pontuações
  - h. Retorne a quantidade de pontuações do corpus
  - i. Retorne a frequência de pontuação do corpus (obs: pode usar o NLTK nesse exercício!)
  - j. Tokenize todo o corpus e retorne a quantidade de espaços presentes no corpus
3. Ainda utilizando o mesmo corpus e o spaCy, faça:
- a. Analise o 1º parágrafo do corpus, lematizando todos os tokens possíveis. Verifique se foi retornado os lemas corretos
  - b. Ainda com o 1º parágrafo, retorne todas as classes gramaticais dos tokens.
  - c. Retorne todas as classes gramaticais do corpus