Modelo de linguagem: *n*-gramas

Prof. Walmes Zeviani

walmes@ufpr.br

Laboratório de Estatística e Geoinformação
Departamento de Estatística
Universidade Federal do Paraná

Justificativa e objetivos

- Até agora os *tokens* (termos) foram palavras.
  - "Sérgio Moro" é representado em mais de uma dimensão.
  - "Universidade Federal do Paraná" idem.
  - Isso aumenta desnecessariamente a dimensão do espaço vetor.
- Apresentar modelos probabilisticos de linguagem.
- Construir *n*-gramas no R.

Modelos de linguagem

Usos

- Correção de ortografia:
  - *A escola fica a 10 minotos da minha casa.*
  - Pr(... a 10 minutos da ...) $>$ Pr(... a 10 minotos da ...).
- Reconhecimento de discursos:
  - Pr(homem desta cidade) $>$ Pr(homocedasticidade).

Objetivo

- Objetivo: calcular a probabilidade de uma sentença ou sequência de palavras.

$$\Pr(S) = \Pr(w_1, w_2, \ldots, w_n).$$

- Probabilidade da próxima palavra (predição de texto)

$$\Pr(w_5 | w_4, w_3, w_2, w_1).$$

- O modelo que calcula $\Pr(S)$ ou $\Pr(w_5 | \ldots)$ é chamado de modelo de linguagem (*language model*).
- O ideal: gramática.
- Mas o modelo de linguagem é útil.

Regra do produto

- Como calcular

$$\Pr(\text{o}, \text{trânsito}, \text{estava}, \text{lento}, \text{próximo})?$$

- Intuição: considerar a regra do produto de probabilidades

$$\Pr(w_4, w_3, w_2, w_1) = \Pr(w_1) \cdot \Pr(w_2|w_1) \cdot \ldots \cdot \Pr(w_4|w_1, w_2, w_3).$$

- Esquema geral

$$\Pr(w_1, \ldots, w_n) = \Pr(w_1) \cdot \prod_{i=2}^{n} \Pr(w_i|\{w_j : j < i\}).$$

Aplicando a regra do produto

- Assim

$$\begin{aligned}\Pr(\text{o, trânsito, estava, lento}) = \Pr(\text{o}) \\ \cdot \Pr(\text{trânsito}|\text{o}) \\ \cdot \Pr(\text{estava}|\text{trânsito, o}) \\ \cdot \Pr(\text{lento}|\text{estava}, \ldots, \text{o}).\end{aligned}$$

- Mas como estimar tais probabilidades?
- Solução: contar e dividir.

$$\Pr(\text{lento}|\text{estava, trânsito, o}) = \frac{\text{count}(\text{lento, estava, trânsito, o})}{\text{count}(\text{estava, trânsito, o})}$$

- Problemas:
  - Limitação de insuficiência de dados para usar essa lógica.
  - É o mesmo problema que motiviou o Nayve Bayes.

Suposição de Markov

- Usa-se a suposição simplificadora de Markov

$$\Pr(\text{lento}|\text{estava}, \text{trânsito}, \text{o}) \approx \Pr(\text{lento}|\text{estava}),$$

ou talvez

$$\Pr(\text{lento}|\text{estava}, \text{trânsito}, \text{o}) \approx \Pr(\text{lento}|\text{estava}, \text{trânsito}).$$

- Dessa forma, aproxima-se as conjuntas por produtos de poucos termos

$$\Pr(w_i|w_{i-1}, \ldots, w_1) \approx \Pr(w_i|w_{i-1}, \ldots, w_{i-k}) = \Pr(w_i|\{w_j : i-j \leq k\}).$$

n-gramas

- O modelo mais simples é o unigrama:

$$\Pr(w_1, w_2, \ldots, w_n) = \prod_{i=1}^{n} \Pr(w_i).$$

- A prob. conjunta é o produto das marginais: assume independência.
- O bi-grama usa $k = 2$:

$$\Pr(w_i | w_{i-1}, \ldots, w_1) = \Pr(w_i | w_{i-1}).$$

- A ideia pode ser expandida para tri-grama, 4-grama, etc.
- Em geral, esse é um modelo de linguagem insuficiente.
- Porém, é útil.
- A linguagem tem dependências de longa distância.
  - *A máquina de lavar que acabei de descarregar no sétimo andar não funciona*.

n-gramas com R

Usando os recursos

```r
library(tm)

# Tokenizador básico (unigram, quebra nos espaços).
x <- "O cachorro comeu o chinelo outra vez."
MC_tokenizer(x = x)
```

```
## [1] "O"        "cachorro" "comeu"    "o"        "chinelo"
## [6] "outra"    "vez"
```

```r
library(RWeka)

# Uno e bi-gramas.
NGramTokenizer(x, control = Weka_control(min = 1, max = 2))
```

```
##  [1] "O cachorro"     "cachorro comeu" "comeu o"
##  [4] "o chinelo"      "chinelo outra"  "outra vez"
##  [7] "O"              "cachorro"       "comeu"
## [10] "o"              "chinelo"        "outra"
## [13] "vez"
```

Aplicação

Importação e limpeza dos textos

```r
load("../data/evang.RData")
length(evang)
```

```
## [1] 4
```

```r
# Apenas o evangelho de Mateus.
x <- evang[[1]]
cps <- VCorpus(VectorSource(x),
               readerControl = list(language = "pt"))

# Limpeza.
cps <- tm_map(cps, FUN = content_transformer(tolower))
cps <- tm_map(cps, FUN = removePunctuation)
cps <- tm_map(cps, FUN = removeNumbers)
cps <- tm_map(cps, FUN = removeWords, words = stopwords("portuguese"))
cps <- tm_map(cps, FUN = stripWhitespace)
```

DTM com *n*-gramas

```
# Cria uma função para fazer bigramas.
BigramTokenizer <- function(x) {
    RWeka::NGramTokenizer(x, RWeka::Weka_control(min = 2, max = 2))
}

dtm <- DocumentTermMatrix(cps,
                          control = list(tokenize = BigramTokenizer))

# nTerms(dtm)
# nDocs(dtm)
head(Terms(dtm))
```

```
## [1] "abaixo direção"      "abandonaram fugiram"
## [3] "abandonarão pois"    "abandonem nunca"
## [5] "abateuse sobre"      "abatidos tudo"
```

```
findFreqTerms(dtm, lowfreq = 12)
```

```
## [1] "céus é"             "chefes sacerdotes"  "então jesus"
## [4] "filho homem"        "jesus disse"        "jesus respondeu"
## [7] "líderes religiosos" "mestres lei"        "reino céus"
```

n-gramas mais frequentes

```
library(lattice)                                                    1
frq <- sort(slam::colapply_simple_triplet_matrix(dtm, FUN = sum))   2
barchart(tail(frq, n = 30), xlim = c(0, NA))                        3
```

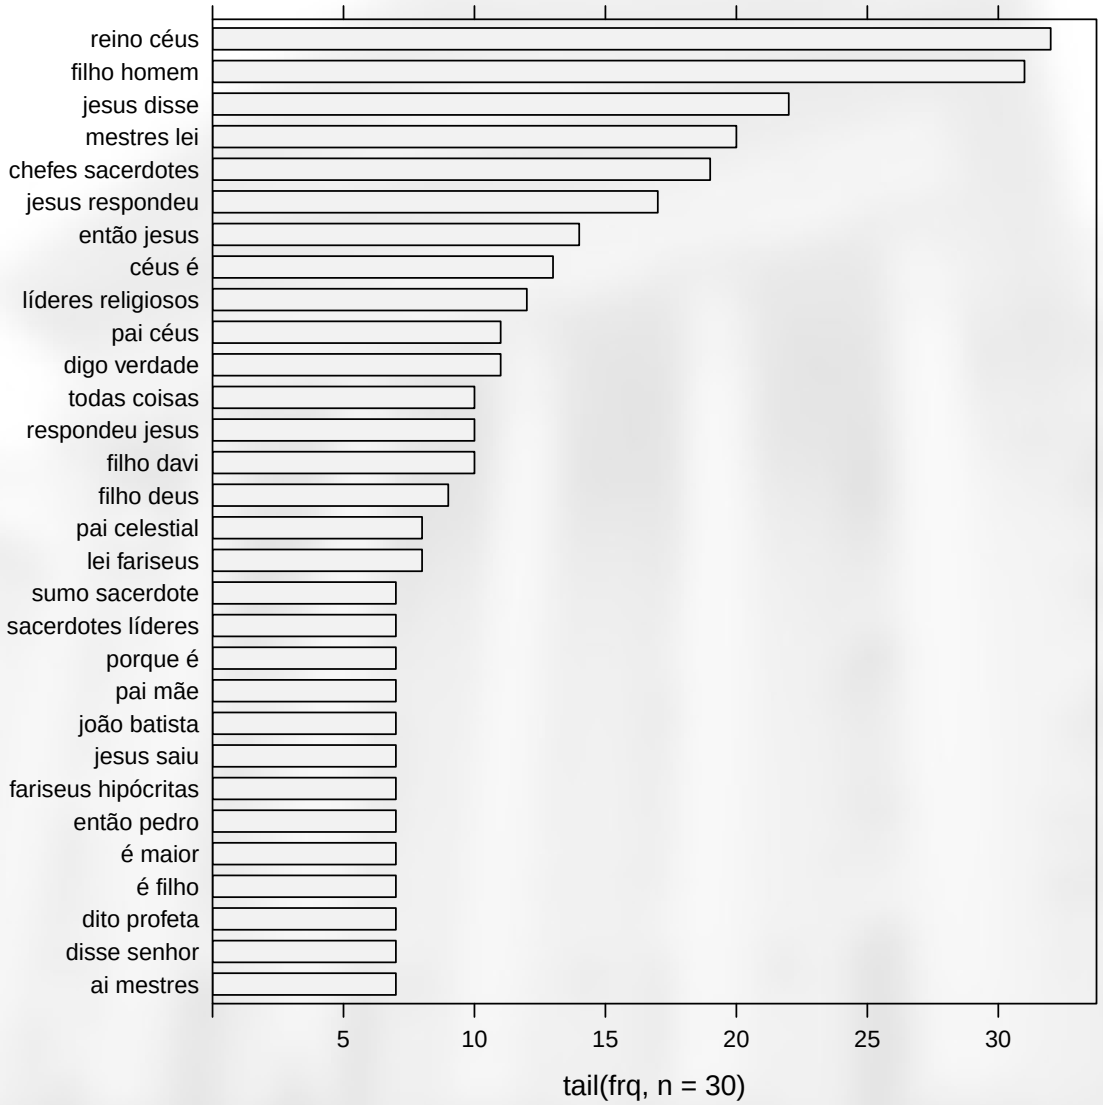
reino céus
filho homem
jesus disse
mestres lei
chefes sacerdotes
jesus respondeu
então jesus
céus é
líderes religiosos
pai céus
digo verdade
todas coisas
respondeu jesus
filho davi
filho deus
pai celestial
lei fariseus
sumo sacerdote
sacerdotes líderes
porque é
pai mãe
joão batista
jesus saiu
fariseus hipócritas
então pedro
é maior
é filho
dito profeta
disse senhor
ai mestres
5
10
15
20
25
30
tail(frq, n = 30)