

言語処理のための機械学習入門

1.5 パラメータ推定法

河野 和平

パラメータ推定法

- 言語処理研究
 - 言語データの性質から確率分布の種類を仮定
 - パラメータの値をデータから決定
- パラメータ推定問題
 - 与えられたデータがある種類の確率分布から生成されたと仮定する。
 - パラメータの値は分からない。

尤度

- 独立に同一の確率分布に従うデータ (i.i.d.)
 - 確率変数 X のサンプルデータ $D = \{x^{(1)}, \dots, x^{(N)}\}$
 - 生成確率(尤度)

$$P(D) = \prod_{x^{(i)} \in D} p(x^{(i)})$$

$$\begin{aligned} \log P(D) &= \log \prod_{x^{(i)} \in D} p(x^{(i)}) \\ &= \sum_{x^{(i)} \in D} \log p(x^{(i)}) \\ &= \sum_x n_x \log p(x) \end{aligned}$$

最尤推定

i.i.d.であるデータ $D = \{x^{(1)}, \dots, x^{(N)}\}$ が与えられたとき、対数尤度が最も高くなるようにパラメータを決定する。

ポアソン分布 (パラメータ μ)

$$\log P(D) = \sum_{x^{(i)} \in D} \log \frac{\mu^{x^{(i)}}}{x^{(i)}!} e^{-\mu}$$

最尤推定

ポアソン分布 (パラメータ μ)

$$\begin{aligned}\log P(D) &= \sum_{x^{(i)} \in D} \log \frac{\mu^{x^{(i)}}}{x^{(i)}!} e^{-\mu} \\ &= \sum_{x^{(i)} \in D} \log \frac{\mu^{x^{(i)}}}{x^{(i)}!} + \log e^{-\mu}\end{aligned}$$

$$\frac{\partial \log P(D)}{\partial \mu} = \sum_{x^{(i)} \in D} \left(x^{(i)} \frac{1}{\mu} - 1 \right)$$

$$\sum_{x^{(i)} \in D} x^{(i)} \frac{1}{\mu} = \sum_{x^{(i)} \in D} 1 = |D|$$

$$\mu = \frac{\sum_{x^{(i)} \in D} x^{(i)}}{|D|}$$

最大事後確率推定

パラメータがどんな値をとりやすいか事前に分かっていると仮定する。

パラメータ θ の確率分布 $P(\theta)$ 事前確率分布

データ D が与えられたときの
パラメータ θ の確率分布 $P(\theta|D)$ 事後確率分布

事後確率 $P(\theta|D)$ が最大になるように
パラメータを決定

最大事後確率推定

- 事後確率の最大化

$$\begin{aligned}\arg \max_{\theta} P(\theta|D) &= \arg \max_{\theta} \frac{P(\theta) \cdot P(D|\theta)}{P(D)} \\ &= \arg \max_{\theta} P(\theta) \cdot P(D|\theta)\end{aligned}$$

を最大化するようなパラメータ θ を求める。

簡単のため、対数をとって計算する。

$$\begin{aligned}&\log P(\theta) \cdot P(D|\theta) \\ &= \log P(\theta) + \log P(D|\theta) \\ &= \log P(\theta) + \sum_{x^{(i)} \in D} \log P(x^{(i)}|\theta)\end{aligned}$$