

# 言語処理のための機械学習入門

4.4. カーネル法

4.5. 対数線形モデル

4.6. 素性選択

永田 純平

# カーネル法

$$\max. -\frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y^{(i)} y^{(j)} x^{(i)} \cdot x^{(j)} + \sum_i \alpha_i$$

$$s. t. \sum_i \alpha_i y^{(i)} = 0$$

$$\alpha_i \geq 0; \forall_i$$

$$f(x) = \sum_i \alpha_i y^{(i)} x^{(i)} \cdot x - b$$

訓練データ  $D = \{d^{(1)}, d^{(2)}, \dots, d^{(|D|)}\}$  は常に内積の形である

# カーネル関数

事例の対を引数として高次元の内積を与える関数  
引数である事例間の類似度をあらわす

$$\max. -\frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y^{(i)} y^{(j)} K(d^{(i)}, d^{(j)}) + \sum_i \alpha_i$$

$$s. t. \sum_i \alpha_i y^{(i)} = 0$$

$$\alpha_i \geq 0; \forall_i$$

$$f(d) = \sum_i \alpha_i y^{(i)} K(d^{(i)}, d) - b$$

- 木構造カーネル
- 文字列カーネル

- 多項式カーネル

$$K_{poly}(x^{(i)}, x^{(j)}) = (x^{(i)} x^{(j)} + r)^d$$

- RBFカーネル

$$K_{RBF}(x^{(i)}, x^{(j)}) = \exp(-s|x^{(i)} - x^{(j)}|^2)$$

# 対数線形モデル

- 確率的な分類器で、事例があるラベルをもつ確率を得る。

$$P(y|d) = \frac{1}{Z_{d,w}} \exp(w \cdot \phi(d, y))$$

$$\text{※ } Z_{d,w} = \sum_y \exp(w \cdot \phi(d, y))$$

$$y^* = \arg \max \frac{1}{Z_{d,w}} \exp(w \cdot \phi(d, y))$$

$$y^* = \arg \max w \cdot \phi(d, y)$$

※対数線形モデルでは

$P(d), P(d|y), P(d, y)$ は計算できない。

# 対数線形モデルの学習

$$L(w) = \sum_{(d^{(i)}, y^{(i)}) \in D} \log P(y^{(i)} | d^{(i)}) - \frac{C}{2} |w|^2$$

上記の目的関数を最大化するが、この問題は解析的には求めることができない。

$$w^{new} = w^{old} + \epsilon \nabla_w L(w^{old})$$

$$\nabla_w L(w_t) = \sum_{(d^{(i)}, y^{(i)}) \in D} (\phi(d^{(i)}, y^{(i)}) - \sum_y P(y | d^{(i)}) \phi(d^{(i)}, y)) - Cw$$

# 素性選択

- ラベル付き訓練データと素性集合が与えられたときに自動的に有効な素性を選択する。
- 素性選択することで、分類の精度の向上やよりコンパクトなモデルにすることができる

# 自己相互情報量

$$PMI(w, c) = \log \frac{P(X_w = 1, C = c)}{P(X_w = 1) \times P(C = c)}$$

素性選択するためにクラスに依存しない指標が必要である

$$I_{average}(w) = \sum_c P(c) PMI(w, c)$$

$$I_{max}(w) = \max_c P(c) PMI(w, c)$$

# 情報利得

- 「ある素性が出現したか否か」という情報がエントロピーを減少させるかを素性の有効性とする

$$H(C) = - \sum_c P(c) \log P(c)$$

$$IG(w)$$

$$= H(C) - (P(X_w = 1)H(C|X_w = 1) + (P(X_w = 0)H(C|X_w = 0)))$$