

正則化

- 線形計画識別器

正則化項を l_1 ノルム $\|w\|_1 = \sum_{i=1}^d |w_i|$ にする

$$\min_{w,b} \frac{1}{n} \sum_{i=1}^n c(f(x_i), y_i) + \lambda \|w\|_1$$

スパースな解 (0に近い w_i を0に押し切る)

- 様々なヴァリエーション

- 第1項: 損失関数
- 第2項: 正則化項

25

逐次最小最適化アルゴリズム (SMO algorithm) その1

$$\max W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0$$

1. 変化させるパラメータを2つに限定

一般性を失わずに α_1, α_2 と仮定

変更前 $(\alpha_1^{\text{old}}, \alpha_2^{\text{old}}) \Rightarrow$ 変更後 $(\alpha_1^{\text{new}}, \alpha_2^{\text{new}})$

$$\alpha_1^{\text{new}} y_1 + \alpha_2^{\text{new}} y_2 = \text{定数} = \alpha_1^{\text{old}} y_1 + \alpha_2^{\text{old}} y_2 \quad \left(\because \sum_{i=1}^n \alpha_i y_i = 0 \right)$$

2. α_2^{new} を変数とみなす

$$\alpha_1^{\text{new}} = \alpha_1^{\text{old}} + (\alpha_2^{\text{old}} - \alpha_2^{\text{new}}) y_1 y_2$$

26

逐次最小最適化アルゴリズム (SMO algorithm) その2

$$\max W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0$$

- ボックス制約 $0 \leq \alpha_i \leq C$ から

$$U \leq \alpha_2^{\text{new}} \leq V$$

1. $y_1 \neq y_2$ の場合

$$U = \max(0, \alpha_2^{\text{old}} - \alpha_1^{\text{old}})$$

$$V = \min(C, C - \alpha_1^{\text{old}} + \alpha_2^{\text{old}})$$

2. $y_1 = y_2$ の場合

$$U = \max(0, \alpha_1^{\text{old}} + \alpha_2^{\text{old}} - C)$$

$$V = \min(C, \alpha_1^{\text{old}} + \alpha_2^{\text{old}})$$

27

逐次最小最適化アルゴリズム (SMO algorithm) その3

$$\max W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0$$

- 簡略化のための表記法

1. (ある途中段階での) 識別関数の出力とクラスの差

$$E_i = f(x_i) - y_i = \left(\sum_{j=1}^n \alpha_j y_j K(x_j, x_i) + b \right) - y_i \quad i = 1, 2$$

2. 目的関数の2次導関数

$$\begin{aligned} \kappa &= K(x_1, x_1) + K(x_2, x_2) - 2K(x_1, x_2) \\ &= \|\phi(x_a) - \phi(x_b)\|^2 \end{aligned}$$

28

逐次最小最適化アルゴリズム (SMO algorithm) その4

$$\max W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0$$

- 変化するパラメータが2の場合の解

1. $\frac{\partial W}{\partial \alpha_2} = 0$ から

$$\alpha_2^{\text{tmp}} = \alpha_2^{\text{old}} + \frac{y_2(E_1 - E_2)}{\kappa} \quad \leftarrow \text{要確認}$$

2. $U \leq \alpha_2^{\text{new}} \leq V$ なので

$$\alpha_2^{\text{new}} = \begin{cases} V & \text{if } \alpha_2^{\text{tmp}} > V \\ \alpha_2^{\text{tmp}} & \text{if } U \leq \alpha_2^{\text{tmp}} \leq V \\ U & \text{if } \alpha_2^{\text{tmp}} < U \end{cases} \quad V < \alpha_2^{\text{tmp}}$$

3. 最後に $\alpha_1^{\text{new}} = \alpha_1^{\text{old}} + (\alpha_2^{\text{old}} - \alpha_2^{\text{new}}) y_1 y_2$

29

逐次最小最適化アルゴリズム (SMO algorithm) その5

$$\max W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0$$

- 変化させるパラメータ α_1, α_2 (に対応する点 x_i, x_j (の添字)) の選択

1. KKT(Karush-Kuhn-Tucker) 条件を満たさない点を探す
見つければそれを α_1 とする

2. $|E_1 - E_2|$ が最大化となる x_2 を選択

- (a) 符合チェック
- (b) 全探索

30

逐次最小最適化アルゴリズム (SMO algorithm) その6

$$\max_{\alpha} W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad \text{s.t.} \quad 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0$$

1. 変化させるパラメータ α_1, α_2 の選択
2. α_1, α_2 の更新
3. 停止条件のチェック

31

最大エントロピー法 (Maximum Entropy Method)

- いびつな3面体

各面の出る確率を $p = (p_1, p_2, p_3)$ とする

条件:

1. $p_1 + p_2 + p_3 = 1$
2. $p_3 = 2p_1$

- 各面の出る確率をいくらとするのが妥当か?

32

最大エントロピー法 (ME)

- 最大エントロピー原理

エントロピーが最大となるモデルを選択

- いびつな3面体の例では

- 目的関数

$$\max_{\mathbf{p}} H \quad \text{ここで} \quad H = \sum_{i=1}^3 -p_i \log p_i$$

- 制約条件

1. $p_1 + p_2 + p_3 = 1$
2. $p_3 = 2p_1$

33

最大エントロピー法 (MaxEnt)

- 制約条件から


$$p_3 = 2p_1, p_2 = 1 - 3p_1$$

- 目的関数

$$\begin{aligned} \frac{dH}{dp_1} &= \sum_{i=1}^3 \frac{\partial H}{\partial p_i} \frac{dp_i}{dp_1} \\ &= - \sum_{i=1}^3 (\log p_i + 1) \frac{dp_i}{dp_1} \end{aligned}$$

- グラフから (数値計算)

$$\begin{aligned} \hat{\mathbf{p}} &= \operatorname{argmax}_{\mathbf{p}} H = (0.218, 0.346, 0.436) \\ \hat{H} &= \max_{\mathbf{p}} H = 1.5310 \end{aligned}$$



34

素性関数を用いた制約表現 (その1)

- 学習データ

$$\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$$

- 素性関数

$$\phi_i : (x, y) \mapsto \{0, 1\}, \quad i \in \{1, 2, \dots, n\}$$

- 経験的確率分布

$$\hat{P}(x, y) = \frac{C(x, y)}{N}$$

35

素性関数を用いた制約表現 (その2)

- 経験的確率分布による素性 f_i の期待値

$$E_{\hat{P}}[\phi_i] = \sum_{x,y} \hat{P}(x, y) \phi_i(x, y)$$

- (推定すべき) モデル $P(x, y)$ による素性 ϕ_i の期待値

$$E_P[\phi_i] = \sum_{x,y} P(x, y) \phi_i(x, y)$$

- 両者は一致しているべき

$$\sum_{x,y} P(x, y) \phi_i(x, y) = \sum_{x,y} \hat{P}(x, y) \phi_i(x, y)$$

36

最大エントロピーモデル

- 目的関数 (最大化)

$$H(P) = -\sum_{x,y} P(x,y) \log P(x,y)$$

- 制約

$$\sum_{x,y} P(x,y) \phi_i(x,y) = \sum_{x,y} \tilde{P}(x,y) \phi_i(x,y) \quad \forall i \in \{1, 2, \dots, n\}$$

$$P(x,y) \geq 0 \quad \forall (x,y)$$

$$\sum_{x,y} P(x,y) = 1$$

制約を満たしつつ、 $P(x,y)$ をできるだけ散らす

37

ラグランジュの未定乗数法

- ラグランジュ乗数 $w_i (\geq 0)$ を導入

$$\begin{aligned} L(P, \mathbf{w}) &= H(P) + \sum_{i=1}^n w_i (E_P[\phi_i] - E_{\tilde{P}}[\phi_i]) \\ &= -\sum_{(x,y)} P(x,y) \log P(x,y) + \sum_{i=1}^n w_i \sum_{x,y} \{P(x,y) - \tilde{P}(x,y)\} \phi_i(x,y) \end{aligned}$$

- 偏微分が 0 (必要条件)

$$\frac{\partial L}{\partial P(x,y)} = -\log P(x,y) - 1 + \sum_{i=1}^n w_i \phi_i(x,y) = 0$$

$$\Leftrightarrow P(x,y) = C \exp\left(\sum_{i=1}^n w_i \phi_i(x,y)\right) \quad \text{十分性は省略}$$

- 定数 C は残りの制約から決定

38

パラメトリック形式

- 以下のパラメトリック形式で表せる (ラグランジュ未定乗数法)

$$P_{\mathbf{w}}(x,y) = \frac{1}{Z_{\mathbf{w}}} \exp(\langle \mathbf{w} \cdot \phi(x,y) \rangle)$$

$$Z_{\mathbf{w}} = \sum_{x,y} \exp(\langle \mathbf{w} \cdot \phi(x,y) \rangle)$$

\mathbf{w} は各素性の重み、 $\phi(x,y)$ は素性ベクトル

$$\langle \mathbf{w} \cdot \phi(x,y) \rangle = \sum_{i=1}^n w_i \phi_i(x,y)$$

- 解探索アルゴリズム

GIS (Generalized Iterative Scaling),
BFGS (Broyden-Fletcher-Goldfarb-Shanno)

39

条件付き最大エントロピーモデル

- 識別のためには $P(y|x)$ が必要

$$P(x,y) \text{ を } \tilde{P}(x)P(y|x) \text{ で置き換える}$$

- 目的関数

$$H(P) = -\sum_{x,y} \tilde{P}(x) P(y|x) \log P(y|x)$$

- 制約

$$\sum_x \tilde{P}(x) \sum_y P(y|x) \phi_i(x,y) = \sum_{x,y} \tilde{P}(x,y) \phi_i(x,y) \quad \forall i \in \{1, 2, \dots, n\}$$

↑ 訓練データに出現する x のみが対象

40

パラメトリック形式の解

- x に依存する解

$$P_{\mathbf{w}}(y|x) = \frac{1}{Z_{\mathbf{w}}(x)} \exp(\langle \mathbf{w} \cdot \phi(x,y) \rangle)$$

$$Z_{\mathbf{w}}(x) = \sum_y \exp(\langle \mathbf{w} \cdot \phi(x,y) \rangle)$$

\mathbf{w} は各素性の重み、 $\phi(x,y)$ は素性ベクトル

$$\langle \mathbf{w} \cdot \phi(x,y) \rangle = \sum_{i=1}^n w_i \phi_i(x,y)$$

41

パラメータ推定

- 確率分布

$$P(y|x; \mathbf{w}) = \frac{1}{Z_{\mathbf{w}}(x)} \exp(\langle \mathbf{w} \cdot \phi(x,y) \rangle)$$

- 以下を最小化

$$\hat{\mathbf{w}} = \underset{\mathbf{w}}{\operatorname{argmin}} \sum_{i=1}^n -\log P(y_i|x_i; \mathbf{w})$$

※ i に対する合計なので x の頻度が考慮される

42

識別器としての ME

- 入力 x に対する確率最大のラベル y の推定

- 確率分布

$$P(y|x; \mathbf{w}) = \frac{1}{Z_w(x)} \exp(\langle \mathbf{w} \cdot \phi(x, y) \rangle)$$

- 識別 (※ y は多値)

$$\begin{aligned} \hat{y} &= \underset{y}{\operatorname{argmax}} P(y|x; \mathbf{w}) \\ &= \underset{y}{\operatorname{argmax}} \log P(y|x; \mathbf{w}) \\ &= \underset{y}{\operatorname{argmax}} \log \frac{1}{Z_w(x)} \exp(\langle \mathbf{w} \cdot \phi(x, y) \rangle) \\ &= \underset{y}{\operatorname{argmax}} \langle \mathbf{w} \cdot \phi(x, y) \rangle - \log Z_w(x) \end{aligned}$$

43

ME の正則化

- 正則化項を加えて過学習を防ぐ

- l_2 ノルム

$$\min_{\mathbf{w}} \sum_{i=1}^n -\log P(y_i|x_i; \mathbf{w}) + \frac{C}{2} \|\mathbf{w}\|_2^2$$

事前分布にガウス分布 $\exp(-w_i^2/2\sigma^2)$ を仮定

- l_1 ノルム

$$\min_{\mathbf{w}} \sum_{i=1}^n -\log P(y_i|x_i; \mathbf{w}) + C \|\mathbf{w}\|_1$$

事前分布にラプラス分布 $\exp(-\sigma|w_i|)$ を仮定

44

損失関数の比較 (SVM, ME, etc.)

- 損失関数+正則化項

$$\min_{\mathbf{w}} \frac{1}{n} \sum_{i=1}^n \text{Loss}(f(\mathbf{x}_i), y_i) + CR(\mathbf{w}) \quad \text{※ } f(\mathbf{x}) \text{ は } \mathbf{w} \text{ を含む}$$

1. SVM

$$\text{HingeLoss}(f(\mathbf{x}), y) = \max(1 - yf(\mathbf{x}), 0)$$

2. ME ($y \in \{-1, 1\}$)

$$\text{LogLoss}(f(\mathbf{x}), y) = \log(1 + e^{-yf(\mathbf{x})})$$

3. AdaBoost ($y \in \{-1, 1\}$)

$$\text{ExpLoss}(f(\mathbf{x}), y) = e^{-yf(\mathbf{x})}$$

4. 2乗誤差 ($y \in \{-1, 1\}$)

$$\text{SquareLoss}(f(\mathbf{x}), y) = (1 - yf(\mathbf{x}))^2 \quad \because y^2 = 1$$

45


損失関数のグラフ

$$\text{SVM: } \max(1 - yf(\mathbf{x}), 0)$$

$$\text{AdaBoost: } e^{-yf(\mathbf{x})}$$

$$\text{ME: } \log(1 + e^{-yf(\mathbf{x})})$$

$$\text{MeanSquare: } (1 - yf(\mathbf{x}))^2$$



46

課題

- 河原先生分と綴じて提出
- 7月25日×切
- 手書き

1. アンケート (河原先生分も含む)

- 興味を持ったトピック
- もっと詳しく掘下げて欲しいトピック
- 新たに扱って欲しいトピック

47