

Pattern Recognition (Advanced)
パターン認識特論 その2

Kyoto University, ACCMS
京都大学 学術情報メディアセンター

Mori Shinsuke
森 信介

<http://www.ar.media.kyoto-u.ac.jp/members/mori/>

regularization 正則化

- linear programming classifier
● 線形計画識別器

let regularization term be L_1 norm $\|\mathbf{w}\|_1 = \sum_{i=1}^{d'} |w_i|$ にする
正則化項を L_1 ノルム $\|\mathbf{w}\|_1 = \sum_{i=1}^{d'} |w_i|$ にする

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

sparse solution parameters near 0 become 0
スパースな解 (0に近い w_i を0に押し切る)

- various variations
● 様々なヴァリエーション

- first term loss function
第1項: 損失関数
- second term regularization term
第2項: 正則化項

sequential minimal optimization 逐次最小最適化アルゴリズム (SMO algorithm) その1

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

only two variable parameters

1. 変化させるパラメータを2つに限定

without loss of generality we choose
一般性を失わずに α_1, α_2 と仮定

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

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

2. α_2^{new} is considered as the variable を 変数 と みなす

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

sequential minimal optimization 逐次最小最適化アルゴリズム (SMO algorithm) その2

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

- from the box constraints
- 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

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

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

sequential minimal optimization 逐次最小最適化アルゴリズム (SMO algorithm) その3

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

notations for simplicity

- 簡略化のための表記法

difference between the class and the output of the discriminant function

1. (ある途中段階での) 識別関数の出力とクラスの差

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

second-order derivative along with the diagonal line

2. 対角直線に沿う目的関数の2次導関数 ($-\kappa$)

$$\begin{aligned} \kappa &= K(\mathbf{x}_1, \mathbf{x}_1) + K(\mathbf{x}_2, \mathbf{x}_2) - 2K(\mathbf{x}_1, \mathbf{x}_2) \\ &= \|\boldsymbol{\phi}(\mathbf{x}_1) - \boldsymbol{\phi}(\mathbf{x}_2)\|^2 \end{aligned}$$

sequential minimal optimization 逐次最小最適化アルゴリズム (SMO algorithm) その4

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

- the analytic solution in the two variable case
● 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

$$\alpha_2^{\text{tmp}} = \alpha_2^{\text{old}} + \frac{y_2(E_1 - E_2)}{\kappa} \quad \leftarrow \begin{array}{l} \text{to be checked} \\ \text{要確認} \end{array}$$

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

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

3. ^{finally} 最後に $\alpha_1^{\text{new}} = \alpha_1^{\text{old}} + (\alpha_2^{\text{old}} - \alpha_2^{\text{new}})y_1y_2$

sequential minimal optimization

逐次最小最適化アルゴリズム (SMO algorithm) その5

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

- select two parameters
- 変化させるパラメータ α_1, α_2 (に対応する点 $\mathbf{x}_i, \mathbf{x}_j$ (の添字)) の選択
 - search for points which do not satisfy KKT condition
 - 1. KKT (Karush-Kuhn-Tucker) 条件を満たさない点を探す
 - let one to be α_1 if found
 - 見つければそれを α_1 とする
 - select \mathbf{x}_2 which maximizes $|E_1 - E_2|$
 - 2. $|E_1 - E_2|$ が最大化となる \mathbf{x}_2 を選択
 - checking the sign
 - (a) 符合チェック
 - (b) ^{full search} 全探索

sequential minimal optimization

逐次最小最適化アルゴリズム (SMO algorithm) その6

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

- select variable parameters
1. 変化させるパラメータ α_1, α_2 の選択
- renew
2. α_1, α_2 の更新
- check the stop condition
3. 停止条件のチェック

maximum entropy method 最大エントロピー法

- distorted trihedron
いびつな3面体

probability of each surface

各面の出る確率を $p = (p_1, p_2, p_3)$ とする

condition
条件:

1. $p_1 + p_2 + p_3 = 1$

2. $p_3 = 2p_1$

what probabilities are reasonable

- 各面の出る確率をいくらとするのが妥当か?

maximum entropy method 最大エントロピー法 (ME)

- maximum entropy principle
最大エントロピー原理
select the model of the maximum entropy
エントロピーが最大となるモデルを選択

- in the distorted trihedron case
いびつな3面体の例では

- obj. func.
目的関数

$$\max_p H \quad \text{where} \quad H = \sum_{i=1}^3 -p_i \log p_i$$

- s.t.
制約条件

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

maximum entropy method 最大エントロピー法 (MaxEnt)

- from the constraints
● 制約条件から

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


- obj. func
● 目的関数

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

- from the graph
● グラフから (数値計算)

$$\hat{p} = \operatorname{argmax}_{\mathbf{p}} H = (0.218, 0.346, 0.436)$$

$$\hat{H} = \max_{\mathbf{p}} H = 1.5310$$



constraint expression with feature functions

素性関数を用いた制約表現 (その1)

training examples

- 学習データ

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

feature functions

- 素性関数

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

empirical distribution

- 経験的確率分布

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

constraint expression with feature functions

素性関数を用いた制約表現 (その2)

expectation value of f_i based on the empirical distribution

- 経験的確率分布による素性 f_i の期待値

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

- (推定すべき) モデル $P(x,y)$ による素性 ϕ_i の期待値

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

these must be equal

- 両者は一致しているべき

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

maximum entropy method 最大エントロピー法

- ^{obj. func.} 目的関数 (^{maximize} 最大化)

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

- ^{constraint} 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

Lagrange multiplier method ラグランジュの未定乗数法

introduce Lagrange multipliers

- ラグランジュ乗数 $w_i (\geq 0)$ を導入

$$L(P, \mathbf{w})$$

$$= H(P) + \sum_{i=1}^n w_i (E_P[\phi_i] - E_{\tilde{P}}[\phi_i])$$

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

partial derivative is

- 偏微分が 0 (必要条件)

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

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

constant C is decided by the other constraints

- 定数 C は残りの制約から決定

parametric form 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)
formation in a parametric form

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

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

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

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

- search algorithm
解探索アルゴリズム

GIS (Generalized Iterative Scaling),

BFGS (Broyden-Fletcher-Goldfarb-Shanno)

conditional maximum entropy model 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 ^{we need} 必要 ^{for discrimination}

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

- ^{obj. func.} 目的関数

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

- ^{s.t.} 制約

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

this refers to only x in the training data
↑ 訓練データに出現する x のみが対象

パラメトリック形式の解

- solution depending on x x に依存する解

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

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

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

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

parameter estimation パラメータ推定

probability distribution

- 確率分布

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

minimize the following

- 以下を最小化

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

the frequency of x is considered because of a sum over i
 i に対する合計なので x の頻度が考慮される

ME as a classifier

識別器としてのME

estimate the label y with the highest prob. for an input x

- 入力 x に対する確率最大のラベル y の推定
 - prob. distribution
 - 確率分布

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

- 識別 (y は多値)
 - classification (can be n -ary)

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

regularization MEの正則化

- avoid over training by a regularization term
● 正則化項を加えて過学習を防ぐ

- L_2 ノルム

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

assume a Gaussian dist.
事前分布にガウス分布 $\exp(-w_i^2/2\sigma^2)$ を仮定 as the prior

- L_1 ノルム

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

assume a Laplacian dist.
事前分布にラプラス分布 $\exp(-\sigma|w_i|)$ を仮定 as the prior

loss function comp.

損失関数の比較 (SVM, ME, etc.)

- ^{loss func.}損失関数 + ^{regularization term}正則化項

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

$f(\mathbf{x})$ ^{includes} は \mathbf{w} 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. ^{square loss}2乗誤差 ($y \in \{-1, 1\}$)

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


graph of the loss functions
損失関数のグラフ

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

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

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

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



report 課題

- 7月23日 (金曜) ^{friday deadline} 〆 切
- 手書き ^{hand written}
- 複数枚の場合は綴じて提出 ^{staple together multiple pages}

1. if ^{you attended} 講義参加者

- ソフトマージンの場合の α に対する目的関数の導出 ^{derive the objective function in the soft margin case}
- SMOにおける $U \leq \alpha_2^{\text{new}} \leq V$ の導出 ^{derive in SMO}

Else ^{make your own questions of equal or greater difficulty and answer them} それぞれについて同等かそれ以上難しい課題とその回答
^{must be different from all questions in this or previous years for full credit}
(今年分も含め既出との重複は減点)

2. アンケート ^{questionnaire}

- (a) 興味を持ったトピック ^{what interested you}
- (b) もっと詳しく掘下げて欲しいトピック ^{what you want to learn more about}
- (c) 新たに扱って欲しいトピック ^{other topics you want to learn}