

(83342) パターン認識特論

張 潮

zhang@u-fukui.ac.jp

0776-27-8477

本日の内容

- 第1回 パターン認識のための線形代数
- 第2回 パターン認識のための確率論
- 第3回 凸最適化の概念
- 第4回 線形回帰とLMSアルゴリズム
- 第5回 分類とロジスティック回帰
- 第6回 一般化線形モデル
- 第7回 ガウシアン判別分析と単純ベイズ分類器
- 第8回 サポートベクターマシン(1)
- 第9回 サポートベクターマシン(2)
- 第10回 正則化とモデル選択
- 第11回 k平均法
- 第12回 混合ガウスモデルとEMアルゴリズム
- 第13回 因子分析
- 第14回 主成分分析
- 第15回 未定

前回

- 学習データの幾何マージンを最大化することでよい超平面(決定境界)を見つけることができる
- マージンの最大化を凸最適化問題としてみなすことができる

$$\begin{aligned} \min_{\gamma, w, b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & y^{(i)}(w^T x^{(i)} + b) \geq 1, \quad i = 1, \dots, m \end{aligned}$$

- 二次計画法で解けるが、全データを使うことになる(非効率的！)
- 一部のデータのみを使用し、最大なマージンを探す
 - 相対問題を利用する

前回

- カルーシュ・クーン・タッカー条件
 - Karush-Kuhn-Tucker (KKT) conditions

SVMの場合

$$\frac{\partial}{\partial w_i} \mathcal{L}(w^*, \alpha^*, \beta^*) = 0, \quad i = 1, \dots, n$$

~~$$\frac{\partial}{\partial \beta_i} \mathcal{L}(w^*, \alpha^*, \beta^*) = 0, \quad i = 1, \dots, l$$~~

$$\alpha_i^* g_i(w^*) = 0, \quad i = 1, \dots, k$$

$$g_i(w^*) \leq 0, \quad i = 1, \dots, k$$

$$\alpha^* \geq 0, \quad i = 1, \dots, k$$

$$\begin{aligned} \min_{\gamma, w, b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & y^{(i)}(w^T x^{(i)} + b) \geq 1, \quad i = 1, \dots, m \end{aligned}$$

$$g_i(w) = -y^{(i)}(w^T x^{(i)} + b) + 1 \leq 0.$$

- KKT条件に満たす w^*, α^*, β^* は主問題と相対問題の解である

ラグランジュ相対性を利用した 最適解の求め方

- w を求めたい

$$\mathcal{L}(w, \alpha, \beta) = f(w) + \sum_{i=1}^k \alpha_i g_i(w) + \sum_{i=1}^l \beta_i h_i(w).$$

$\alpha_i = 0$ の項は、最適解 w に影響しない

$$\frac{\partial}{\partial w_i} \mathcal{L}(w^*, \alpha^*, \beta^*) = 0, \quad i = 1, \dots, n$$

~~$$\frac{\partial}{\partial \beta_i} \mathcal{L}(w^*, \alpha^*, \beta^*) = 0, \quad i = 1, \dots, l$$~~

$$\alpha_i^* g_i(w^*) = 0, \quad i = 1, \dots, k$$

$$g_i(w^*) \leq 0, \quad i = 1, \dots, k$$


$$\alpha^* \geq 0, \quad i = 1, \dots, k$$

>0 なら $g_i(w)=0$

$$g_i(w) = -y^{(i)}(w^T x^{(i)} + b) + 1 \leq 0.$$

ラグランジュ相対性を利用した 最適解の求め方

$$g_i(w) = -y^{(i)}(w^T x^{(i)} + b) + 1 \leq 0.$$



$$y^{(i)} = 1, w^T x^{(i)} + b = 1$$

$$y^{(i)} = -1, w^T x^{(i)} + b = -1$$

サポートベクトル！！

ラグランジュ相対性を利用した最適解の求め方

- g_i を代入すると

$$\mathcal{L}(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i [y^{(i)}(w^T x^{(i)} + b) - 1].$$

- w と b における微分=0で L を最小化

$$\nabla_w \mathcal{L}(w, b, \alpha) = w - \sum_{i=1}^m \alpha_i y^{(i)} x^{(i)} = 0$$

$$w = \sum_{i=1}^m \alpha_i y^{(i)} x^{(i)}.$$

$$\frac{\partial}{\partial b} \mathcal{L}(w, b, \alpha) = \sum_{i=1}^m \alpha_i y^{(i)} = 0.$$

ラグランジュ相対性を利用した最適解の求め方

- 微分=0の解を代入することで最小化

$$w = \sum_{i=1}^m \alpha_i y^{(i)} x^{(i)}.$$

$$\frac{\partial}{\partial b} \mathcal{L}(w, b, \alpha) = \sum_{i=1}^m \alpha_i y^{(i)} = 0.$$

↓ 代入

↓ 制限

$$\mathcal{L}(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i [y^{(i)} (w^T x^{(i)} + b) - 1].$$

$$\mathcal{L}(w, b, \alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y^{(i)} y^{(j)} \alpha_i \alpha_j (x^{(i)})^T x^{(j)} - b \sum_{i=1}^m \alpha_i y^{(i)}.$$

ラグランジュ相対性を利用した最適解の求め方

- max min で相対問題を作る

$$\begin{aligned} \max_{\alpha} \quad & W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y^{(i)} y^{(j)} \alpha_i \alpha_j \langle x^{(i)}, x^{(j)} \rangle. \\ \text{s.t.} \quad & \alpha_i \geq 0, \quad i = 1, \dots, m \\ & \sum_{i=1}^m \alpha_i y^{(i)} = 0, \end{aligned}$$

α が解ける(解き方については後で紹介する) $\rightarrow w$ が分かる $\rightarrow b$ が分かる

$$b^* = - \frac{\max_{i:y^{(i)}=-1} w^{*T} x^{(i)} + \min_{i:y^{(i)}=1} w^{*T} x^{(i)}}{2}.$$

SVMでの予測

- 最適化されたパラメータで新しいテストデータを予測




- 入力: x
- 下記の式が >0 なら $y=1$ と予測する
- 下記の式が <0 なら $y=-1$ と予測する

=0の項を無視できる

$$\begin{aligned}
 w^T x + b &= \left(\sum_{i=1}^m \alpha_i y^{(i)} x^{(i)} \right)^T x + b \\
 &= \sum_{i=1}^m \alpha_i y^{(i)} \langle x^{(i)}, x \rangle + b.
 \end{aligned}$$


線形分離不可能なデータに対応できない☹

②カーネル関数 (kernel function)



②カーネル関数 (kernel function)

- 属性とは？ 特徴量とは？



- 属性ではなく、特徴量で学習することもできる

②カーネル関数 (kernel function)

$$\begin{aligned}
 w^T x + b &= \left(\sum_{i=1}^m \alpha_i y^{(i)} x^{(i)} \right)^T x + b \\
 &= \sum_{i=1}^m \alpha_i y^{(i)} \langle x^{(i)}, x \rangle + b.
 \end{aligned}$$

$$\langle x, z \rangle \rightarrow \langle \phi(x), \phi(z) \rangle$$

属性の代わりに、特徴量を使う

$$K(x, z) = \phi(x)^T \phi(z).$$

カーネル: 特徴量ベクトルの内積

②カーネル関数 (kernel function)

- $K(x, z) = (x^T z)^2.$
- $K(x, z) = \phi(x)^T \phi(z).$ の形で書くことが可能

■この場合の特徴量マッピング関数 ϕ は？

$$\begin{aligned}
 K(x, z) &= \left(\sum_{i=1}^n x_i z_i \right) \left(\sum_{j=1}^n x_j z_j \right) \\
 &= \sum_{i=1}^n \sum_{j=1}^n x_i x_j z_i z_j \\
 &= \sum_{i,j=1}^n (x_i x_j) (z_i z_j)
 \end{aligned}$$

 $n=3$ の場合

$$\phi(x) = \begin{bmatrix} x_1 x_1 \\ x_1 x_2 \\ x_1 x_3 \\ x_2 x_1 \\ x_2 x_2 \\ x_2 x_3 \\ x_3 x_1 \\ x_3 x_2 \\ x_3 x_3 \end{bmatrix}.$$

②カーネル関数 (kernel function)

- $\Phi(x)$ と $\Phi(z)$ が似ていれば $K(x, z)$ が小さくなる
 - 直交した場合は0になる

$$K(x, z) = \phi(x)^T \phi(z).$$

- カーネルをガウシアンカーネルにしたら Φ はどうなる？

$$K(x, z) = \exp\left(-\frac{\|x - z\|^2}{2\sigma^2}\right).$$

$\Phi(x)$ が無限次元になる

②カーネル関数 (kernel function)

- 任意のカーネルが有効というわけではない
 - 対応しているマッピング関数が存在しない場合も
 - マッピング関数の存在を判定する必要がある



- カーネル行列で判定を行う

$$K_{ij} = K(x^{(i)}, x^{(j)})$$

$$K_{ij} = K(x^{(i)}, x^{(j)}) = \phi(x^{(i)})^T \phi(x^{(j)}) = \phi(x^{(j)})^T \phi(x^{(i)}) = K(x^{(j)}, x^{(i)}) = K_{ji}$$

対称行列である

②カーネル関数 (kernel function)

- カーネル行列の二次形式を見てみよう

$$\begin{aligned}
 z^T K z &= \sum_i \sum_j z_i K_{ij} z_j \\
 &= \sum_i \sum_j z_i \phi(x^{(i)})^T \phi(x^{(j)}) z_j \\
 &= \sum_i \sum_j z_i \sum_k \phi_k(x^{(i)}) \phi_k(x^{(j)}) z_j \\
 &= \sum_k \sum_i \sum_j z_i \phi_k(x^{(i)}) \phi_k(x^{(j)}) z_j \\
 &= \sum_k \left(\sum_i z_i \phi_k(x^{(i)}) \right)^2 \\
 &\geq 0.
 \end{aligned}$$

カーネル行列が対称半正定値行列なら、
 カーネルの特徴マッピング関数 ϕ が存在し、
 カーネルが有効である。
 (実は、必要条件だけではなく、必要十分条件である)

半正定値行列である(1回目授業の24ページ)

②カーネル関数 (kernel function)

● Mercerの定理

Theorem (Mercer). Let $K : \mathbb{R}^n \times \mathbb{R}^n \mapsto \mathbb{R}$ be given. Then for K to be a valid (Mercer) kernel, it is necessary and sufficient that for any $\{x^{(1)}, \dots, x^{(m)}\}$, ($m < \infty$), the corresponding kernel matrix is symmetric positive semi-definite.

- Mercer, J. (1909), "Functions of positive and negative type and their connection with the theory of integral equations", *Philosophical Transactions of the Royal Society A*, 209 (441–458): 415–446, doi:10.1098/rsta.1909.0016

②カーネル関数 (kernel function)

- カーネルという考え方は、SVM以外でもある
- 属性ベクトルの内積をカーネルベクトルの内積で書き換えるだけで、高次元や線形分離不可のデータに対応できるようになる



カーネルトリック (kernel trick)

カーネルを取り入れたSVM の例

- 手書き数字の認識

- 16ピクセル×16ピクセル

- 多項式カーネルorガウシアンカーネルが有効




正則化と外れ値への対応

●外れ値


- 関数マージン=1の点のみ使われているため

$$y^{(i)}(w^T x^{(i)} + b) = 1$$



正則化と外れ値への対応

$$y^{(i)}(w^T x^{(i)} + b) \leq 1 \text{ 使う}$$



$$y^{(i)}(w^T x^{(i)} + b) \geq 1 \text{ 使わない}$$

$$y^{(i)}(w^T x^{(i)} + b) = 1 \text{ 使う}$$

外れ値をペナルティとして考える

正則化と外れ値への対応

- 条件を緩める
- ペナルティ項を追加

$$\begin{aligned} \min_{\gamma, w, b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & y^{(i)}(w^T x^{(i)} + b) \geq 1, \quad i = 1, \dots, m \end{aligned}$$

$$\begin{aligned} \min_{\gamma, w, b} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i \\ \text{s.t.} \quad & y^{(i)}(w^T x^{(i)} + b) \geq 1 - \xi_i, \quad i = 1, \dots, m \\ & \xi_i \geq 0, \quad i = 1, \dots, m. \end{aligned}$$

正則化と外れ値への対応

- 正則化項を追加した後のKKT条件の一部

追加前の変わらない

$$\alpha_i = 0 \Rightarrow y^{(i)}(w^T x^{(i)} + b) \geq 1$$

$$\alpha_i = C \Rightarrow y^{(i)}(w^T x^{(i)} + b) \leq 1$$

$$0 < \alpha_i < C \Rightarrow y^{(i)}(w^T x^{(i)} + b) = 1.$$

④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)

- 残りの最後の問題

$$\begin{aligned} \max_{\alpha} \quad & W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y^{(i)} y^{(j)} \alpha_i \alpha_j \langle x^{(i)}, x^{(j)} \rangle. \\ \text{s.t.} \quad & 0 \leq \alpha_i \leq C, \quad i = 1, \dots, m \\ & \sum_{i=1}^m \alpha_i y^{(i)} = 0. \end{aligned}$$

④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)


- 座標降下法

- Coordinate Descent Algorithm

$$\max_{\alpha} W(\alpha_1, \alpha_2, \dots, \alpha_m).$$

```
Loop until convergence: {  
  For  $i = 1, \dots, m$ , {  
     $\alpha_i := \arg \max_{\hat{\alpha}_i} W(\alpha_1, \dots, \alpha_{i-1}, \hat{\alpha}_i, \alpha_{i+1}, \dots, \alpha_m).$   
  }  
}
```

④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)



④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)

$$\begin{aligned} \max_{\alpha} \quad & W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y^{(i)} y^{(j)} \alpha_i \alpha_j \langle x^{(i)}, x^{(j)} \rangle. \\ \text{s.t.} \quad & 0 \leq \alpha_i \leq C, \quad i = 1, \dots, m \\ & \sum_{i=1}^m \alpha_i y^{(i)} = 0. \end{aligned}$$

$$\alpha_1 y^{(1)} = - \sum_{i=2}^m \alpha_i y^{(i)}.$$

$$\alpha_1 = -y^{(1)} \sum_{i=2}^m \alpha_i y^{(i)}.$$

α_1 は $\alpha_2 \sim \alpha_m$ で決まるため、 $\alpha_2 \sim \alpha_m$ を固定すると、 α_1 を変更することができない

④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)

- One-by-one できないなら、two-by-two でやろう

Repeat till convergence {

1. Select some pair α_i and α_j to update next (using a heuristic that tries to pick the two that will allow us to make the biggest progress towards the global maximum).
2. Reoptimize $W(\alpha)$ with respect to α_i and α_j , while holding all the other α_k 's ($k \neq i, j$) fixed.

}

④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)

- $\alpha_3 \sim \alpha_m$ を固定し、 α_1 および α_2 を最適化すると考えよう

$$\alpha_1 y^{(1)} + \alpha_2 y^{(2)} = - \sum_{i=3}^m \alpha_i y^{(i)}.$$

固定のため、定数 ζ で表す

$$\alpha_1 y^{(1)} + \alpha_2 y^{(2)} = \zeta.$$

$$\alpha_1 = (\zeta - \alpha_2 y^{(2)}) y^{(1)}.$$


代入

$$W(\alpha_1, \alpha_2, \dots, \alpha_m) = W((\zeta - \alpha_2 y^{(2)}) y^{(1)}, \alpha_2, \dots, \alpha_m).$$

α_2 に関する多項式になった
(微分=0で最適化できる)

④逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)

- α_2 に範囲制限あり



④ 逐次最小問題最適化法 (Sequential Minimal Optimization, SMO)

- 範囲からはみ出したときに”クリップ”処理を行う

$$\alpha_2^{new} = \begin{cases} H & \text{if } \alpha_2^{new,unclipped} > H \\ \alpha_2^{new,unclipped} & \text{if } L \leq \alpha_2^{new,unclipped} \leq H \\ L & \text{if } \alpha_2^{new,unclipped} < L \end{cases}$$

次回は

- 第1回 パターン認識のための線形代数
- 第2回 パターン認識のための確率論
- 第3回 凸最適化の概念
- 第4回 線形回帰とLMSアルゴリズム
- 第5回 分類とロジスティック回帰
- 第6回 一般化線形モデル
- 第7回 ガウシアン判別分析と単純ベイズ分類器
- 第8回 サポートベクターマシン(1)
- 第9回 サポートベクターマシン(2)
- 第10回 正則化とモデル選択
- 第11回 k平均法
- 第12回 混合ガウスモデルとEMアルゴリズム
- 第13回 因子分析
- 第14回 主成分分析
- 第15回 未定