

SVMの使い方

東京大学大学院新領域創成科学研究科
情報生命科学専攻
加藤 毅

従来の2クラス識別器

予測対象の
特徴ベクトル 入力 → 2クラス
識別器 → 出力 Yes?
No?

従来の2クラス識別器

左目の幅
右目の幅
目間距離
⋮
口の幅
顎の高さ

入力 → 2クラス
識別器 → 出力 Yes?
No?

この人物は加藤毅か?

従来の2クラス識別器

遺伝子1の発現量
遺伝子2の発現量
⋮
遺伝子Nの発現量

入力 → 2クラス
識別器 → 出力 Yes?
No?

マイクロアレイ
癌の種類はAMLか?

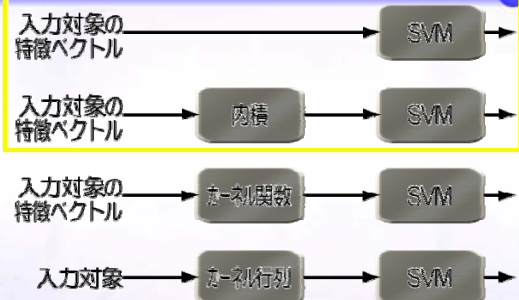
従来の2クラス識別器

4文字前はA
4文字前はT
4文字前はG
4文字前はC
3文字前はA
⋮
4文字後はC


入力 → 2クラス
識別器 → 出力 Yes?
No?

ここはspraysaitoか?

SVMの使い方



線形識別器



スコア関数

$$g(x; w, b) = \langle w, x \rangle + b$$


パラメータ
 $w \in \mathbb{R}^d, b \in \mathbb{R}$

特徴ベクトル
 $x \in \mathbb{R}^d$

If スコア > 0 , x は **+** だろう

If スコア < 0 , x は **-** だろう

SVMの学習方法の概要



分類済みの学習用例题集合
 $(x_1, y_1), \dots, (x_n, y_n)$


を収集 $x_i \in \mathbb{R}^d, y_i \in \{+1, -1\}$

マージンが最大になる
分離面を見付ける

SVMソフトウェア

- SVM-light
<http://svmlight.joachims.org/>
- LIBSVM
<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>
- kemba-svm.exe
<http://www.cb.k.u-tokyo.ac.jp/asailab/kato/kemba-svm1-ts/>

SVM学習の定式化




$$\min 1/(\text{マージン})^2$$

subj. to

- +** の例题は境界面より上
- の例题は境界面より下

$$\text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

SVM学習の定式化



$$\min \frac{1}{2} \|w\|^2$$


subj. to

$$\begin{cases} \text{+} \langle w, x_i \rangle + b \geq +1 \\ \text{-} \langle w, x_i \rangle + b \leq -1 \end{cases}$$

$$\Leftrightarrow y_i (\langle w, x_i \rangle + b) \geq +1$$

$$\text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

SVM学習の定式化



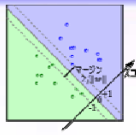
$$\min \frac{1}{2} \|w\|^2 \quad \text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

$$\text{subj. to } 1 - y_i (\langle w, x_i \rangle + b) \leq 0$$

$$\Leftrightarrow \min_{w, b} \max_{\alpha \geq 0} L(w, b, \alpha)$$

定理 最適化問題 $\min_x f(x) \text{ wrt } x \in \mathbb{R}^d \text{ subj. to } g_i(x) \leq 0 \quad i=1, \dots, n$
 の解 = $\min_{\alpha \geq 0} \max_{w, b} L(w, b, \alpha)$ の解 (\bar{w}, \bar{b})
 ば、ラグランジュ関数 $L(w, b, \alpha) = f(w, b) + \sum_{i=1}^n \alpha_i g_i(w, b)$

SVM学習の定式化



$$\min \frac{1}{2} \|w\|^2 \quad \text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

$$\text{subj. to } 1 - y_i (\langle w, x_i \rangle + b) \leq 0$$

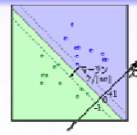
$$\Leftrightarrow \min_{w, b} \max_{\alpha \geq 0} L(w, b, \alpha)$$

ラグランジ関数

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle + \sum_{i=1}^{\ell} \alpha_i (1 - y_i (\langle w, x_i \rangle + b))$$

$$\frac{\partial L}{\partial w} = 0, \quad \frac{\partial L}{\partial b} = 0 \quad \text{yields} \quad w = \sum_{i=1}^{\ell} \alpha_i y_i x_i, \quad \sum_{i=1}^{\ell} \alpha_i y_i = 0$$

SVM学習の双対形式



$$\min \frac{1}{2} \|w\|^2 \quad \text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

$$\text{subj. to } 1 - y_i (\langle w, x_i \rangle + b) \leq 0$$

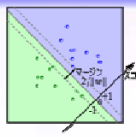
$$\Leftrightarrow \max_{\alpha \geq 0} -\frac{1}{2} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle + \sum_{i=1}^{\ell} \alpha_i$$

$$\text{subj. to } \sum_{i=1}^{\ell} \alpha_i y_i = 0$$

SVM学習に
特徴ベクトルは 不要
内積のみ 必要

$$\text{xE } w = \sum_{i=1}^{\ell} \alpha_i y_i x_i$$

バイアス b の復元



スコア関数

$$g(x | w, b) = \langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x \rangle + b$$

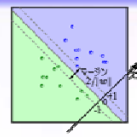
$$= \sum_{j=1}^{\ell} \alpha_j y_j \langle x_j, x \rangle + b$$

定理 最適化問題 $\min f(x)$ wrt $x \in \mathbb{R}^d$ subj. to $g_i(x) \leq 0 \quad i=1, \dots, n$
の解 = $\min_{w, \alpha} \max_{x, \omega} L(x, \omega)$ の解 (x, ω)
ただし、ラグランジ関数 $L(x, \omega) = f(x) + \sum_{i=1}^n \alpha_i g_i(x)$

$$\frac{\partial L(x, \omega)}{\partial x} \Big|_{x=x^*} = 0, \quad \frac{\partial L(x, \omega)}{\partial \alpha_i} \Big|_{\alpha_i=\alpha_i^*} \leq 0, \quad \text{KKT 相補条件 } \alpha_i g_i(x^*) = 0, \quad \forall_i$$

$$w = \sum_{i=1}^n \alpha_i \nabla g_i(x^*)$$

バイアス b の復元



スコア関数

$$g(x | w, b) = \langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x \rangle + b$$

$$= \sum_{j=1}^{\ell} \alpha_j y_j \langle x_j, x \rangle + b$$

$\alpha_i > 0$ なる i に対し

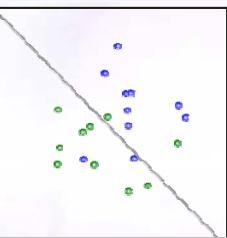
$$y_i (\langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x_i \rangle + b) - 1 = 0$$

$$\therefore b = -\sum_{j=1}^{\ell} \alpha_j y_j \langle x_j, x_i \rangle + y_i$$

SVM 識別に
特徴ベクトルは 不要
内積のみ 必要

$$\text{xE } w = \sum_{i=1}^{\ell} \alpha_i y_i x_i$$

線形分離不可能な場合



$$\min \frac{1}{2} \|w\|^2$$

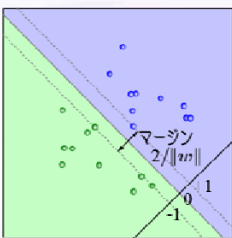
$$\text{subj. to}$$

$$\begin{cases} + \langle w, x_i \rangle + b \geq +1 \\ - \langle w, x_i \rangle + b \leq -1 \end{cases}$$

解なし

$$\text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

ソフトマージンSVM



$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} \xi_i$$

正規化定数

$$\text{subj. to}$$

$$\begin{cases} + \langle w, x_i \rangle + b \geq +1 - \xi_i \\ - \langle w, x_i \rangle + b \leq -1 + \xi_i \end{cases}$$


マージン $2/\|w\|$

$$\text{wrt } w \in \mathbb{R}^d, b \in \mathbb{R}$$

$$\xi = [\xi_1, \dots, \xi_{\ell}]^T \in \mathbb{R}_+^{\ell}$$

全要素が非負の ℓ 次元実数ベクトル


2次元の例



線形カーネル 多項式カーネル RBFカーネル

C = 1000

2次元の例



線形カーネル 多項式カーネル RBFカーネル

C = 1

ソフトマージンSVM学習の双対形式

$$\min_w \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} \xi_i \quad \text{with } w \in \mathbb{R}^d, b \in \mathbb{R}, \xi_i \in \mathbb{R}_+$$

$$\text{subj. to } 1 - y_i \langle w, x_i \rangle + b \leq \xi_i$$

$$\Leftrightarrow \max_{\alpha} -\frac{1}{2} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle + \sum_{i=1}^{\ell} \alpha_i$$

$$\text{subj. to } \sum_{i=1}^{\ell} \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C$$

ソフトマージンSVMに
特徴ベクトルは 不要
内積のみ 必要

ソフトマージンSVMのスコア関数

スコア関数

$$g(x|w, b) = \langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x \rangle + b$$

$$= \sum_{j=1}^{\ell} \alpha_j y_j \langle x_j, x \rangle + b$$

KKT 相補条件 $\alpha_i (y_i (\langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x_i \rangle + b) - 1 + \xi_i) = 0$

の解 = $\min_{\alpha} \max_{\xi} L(\alpha, \xi)$ $\delta_i \xi_i = 0$ $\delta_i \geq 0$

$\alpha_i + \delta_i = C$ $L(\alpha, \alpha) = f(x) + \sum_{i=1}^{\ell} \alpha_i g_i(x)$

$\frac{\partial L(\alpha, \alpha)}{\partial \alpha_i} = 0, \quad \frac{\partial L(\alpha, \alpha)}{\partial \alpha_i} \leq 0, \quad \text{KKT 相補条件 } \alpha_i \omega_i = 0, \forall i$

ソフトマージンSVMのスコア関数

スコア関数

$$g(x|w, b) = \langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x \rangle + b$$


$$= \sum_{j=1}^{\ell} \alpha_j y_j \langle x_j, x \rangle + b$$

$0 < \alpha_i < C$ なる i に対し $y_i (\langle \sum_{j=1}^{\ell} \alpha_j y_j x_j, x_i \rangle + b) - 1 = 0$


$$\therefore b = -\sum_{j=1}^{\ell} \alpha_j y_j \langle x_j, x_i \rangle + y_i$$

ソフトマージンSVMに
特徴ベクトルは 不要
内積のみ 必要

SVMの使い方



SVM学習のカーネル表現



$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} \xi_i \quad \text{var } w \in \mathbb{R}^d, b \in \mathbb{R}, \xi_i \in \mathbb{R}_+^d$$

$$\text{subj. to } 1 - y_i (w \cdot x_i + b) \leq \xi_i$$

$$\Leftrightarrow \max_{\alpha} -\frac{1}{2} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} \alpha_i \alpha_j y_i y_j k(x_i, x_j) + \sum_{i=1}^{\ell} \alpha_i$$

$$\text{subj. to } \sum_{i=1}^{\ell} \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C$$

ソフトマージンSVMに
特徴ベクトルは不要
カーネル値のみ必要

カーネル関数 $k(x, x') = \phi(x)^\top \phi(x')$, $\phi(x) = x$

主要なカーネル


関数 k : 入力空間 \times 入力空間 \rightarrow 実数 が

$$k(x, z) = \phi(x)^\top \phi(z)$$

なる写像関数 ϕ : 入力空間 \rightarrow 内積空間 が存在
するとき, **カーネル関数** と呼ぶ

	入力空間	定義式
線形カーネル	特徴ベクトル	$k(x, x') = x^\top x'$ $\phi(x) = x$
多項式カーネル	特徴ベクトル	$k(x, x') = (x^\top x' + c)^p$
RBFカーネル	特徴ベクトル	$k(x, x') = \exp\left(-\frac{\ x - x'\ ^2}{2\sigma^2}\right)$


2次元の例



線形カーネル 多項式カーネル RBFカーネル

C=1000

2次元の例



線形カーネル 多項式カーネル RBFカーネル

C=1

多項式カーネルはカーネル?

多項式カーネル 特徴ベクトル $k(x, x') = (x^\top x' + c)^p$

$$\begin{aligned} (x^\top x')^2 &= x^\top x' (x')^\top x \\ &= \text{tr}(x x^\top x' (x')^\top) \\ &= \text{vec}(x x^\top)^\top \text{vec}(x' (x')^\top) \end{aligned}$$

2次の多項式カーネルは
特徴量の情報を
取り込める

$$\phi(x) = \text{vec}(x x^\top)$$

$$= \text{vec} \begin{pmatrix} x_1 x_1 & \cdots & x_1 x_d \\ \vdots & \ddots & \vdots \\ x_d x_1 & \cdots & x_d x_d \end{pmatrix}$$

多項式カーネルはカーネル?

多項式カーネル 特徴ベクトル $k(x, x') = (x^\top x' + c)^p$

数学的帰納法

多項式カーネルはカーネル

$p=0$ のとき

$$\phi_0(x) = 1 \text{ とおくと } (x^\top x' + c)^0 = 1 = \phi_0(x)^\top \phi_0(x')$$

$p=k$ のとき $(x^\top x' + c)^k = \phi_k(x)^\top \phi_k(x')$ と仮定

$$(x^\top x' + c)^{k+1} = \text{tr} \left(\left(\phi_k(x) \begin{bmatrix} x^\top \\ c \end{bmatrix}^\top \right) \left(\phi_k(x') \begin{bmatrix} x'^\top \\ c \end{bmatrix} \right) \right)$$


$$\begin{aligned} \phi_{k+1}(x) = \text{vec} \left(\phi_k(x) \begin{bmatrix} x^\top \\ c \end{bmatrix}^\top \right) &= \text{vec} \left(\phi_k(x) \begin{bmatrix} x^\top \\ c \end{bmatrix} \right)^\top \text{vec} \left(\phi_k(x') \begin{bmatrix} x'^\top \\ c \end{bmatrix} \right) \\ \text{とおくと} &= \phi_{k+1}(x)^\top \phi_{k+1}(x') \end{aligned}$$

カーネル行列

定義 $A \in \mathbb{R}^{n \times n}$ を対称行列とする
 $e^T A e \geq 0 \quad \forall e \in \mathbb{R}^n$
 ならば A は **半正定値**
 $A \succeq 0 \Leftrightarrow A$ のすべての固有値が非負

定理 $K \in \mathbb{R}^{n \times n}$ を半正定値行列とする
 For $\forall x_1, \dots, x_n \in \mathcal{X}$
 $K_{ij} = \phi(x_i)^T \phi(x_j)$
 なる写像
 $\phi(x) = [\phi_1(x) \ \dots \ \phi_d(x)]^T$
 が存在
 全固有値非負 \Leftrightarrow カーネル行列

SVMの使い方



準備: 固有値分解と行列指数

固有値分解 $A = UDU^T$
 固有ベクトルの行列 U | 固有値の行列 D
 $U^T U = I_n$
 $D = \text{diag} \{D_{ii}\}_{i=1}^n$
行列指数
 $\exp(A) = U \text{diag} \{\exp D_{ii}\}_{i=1}^n U^T$
 $\lim_{s \rightarrow \infty} \left(I + \frac{1}{s} A\right)^s = \lim_{s \rightarrow \infty} U \left(I + \frac{1}{s} D\right)^s U^T$
 $= U \left(\lim_{s \rightarrow \infty} \left(I + \frac{1}{s} D\right)^s\right) U^T = U \left(\text{diag} \left\{ \lim_{s \rightarrow \infty} \left(1 + \frac{1}{s} D_{ii}\right)^s \right\}_{i=1}^n\right) U^T$
 $= U \left(\text{diag} \{\exp D_{ii}\}_{i=1}^n\right) U^T = \exp(A)$

拡散カーネル $\exp(-\beta L)$ の解釈

$x(0) \sim \mathcal{N}(0, I_n)$
 毎時刻割合 α 隣接ノードに送る
 $z_i(t) = z_i(t-1) + \alpha \sum_{j \sim i} (z_j(t-1) - z_i(t-1))$
行列表現
 $z(t) = (I_n - \alpha L) z(t-1) = T(t) z(0)$
オペレータ
 $T(t) = (I_n - \alpha L)^t$
 1 ステップ Δt に変更
 $T(t) = \left(I_n - \frac{\alpha}{1/\Delta t} L\right)^{t/\Delta t}$
時刻 t の共分散行列
 $\text{Cov}(z(t)) = T(2t)$ ($\Delta t \rightarrow 0$ とすると)
 $= \left(\lim_{1/\Delta t \rightarrow \infty} \left(I_n - \frac{1}{1/\Delta t} \alpha L\right)^{1/\Delta t}\right)^{2t}$
 $= \left(\exp(-\alpha L)\right)^{2t} = \exp(-\beta L)$
 ($\beta = 2\alpha t$ とおくと)