

サポートベクターマシン

Support Vector Machine

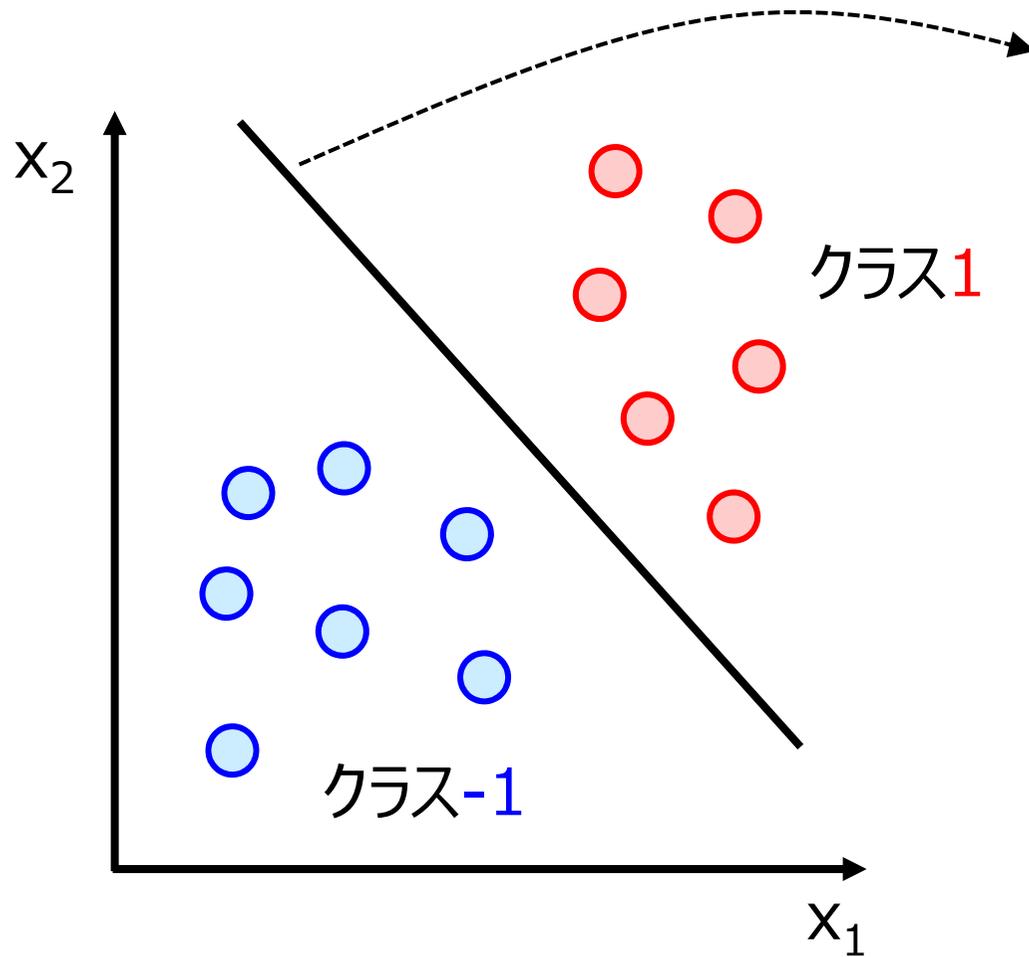
SVM

明治大学 理工学部 応用化学科
データ化学工学研究室 金子 弘昌

サポートベクターマシン (SVM) とは？

- ✓ 線形判別関数によるクラス分類
- ✓ 2つのクラス (1のクラス・-1のクラス) のどちらに属するか決定
- ✓ 予測能力の高いモデルを作成可能
- ✓ カーネルトリックにより非線形の判別モデルに

線形判別関数

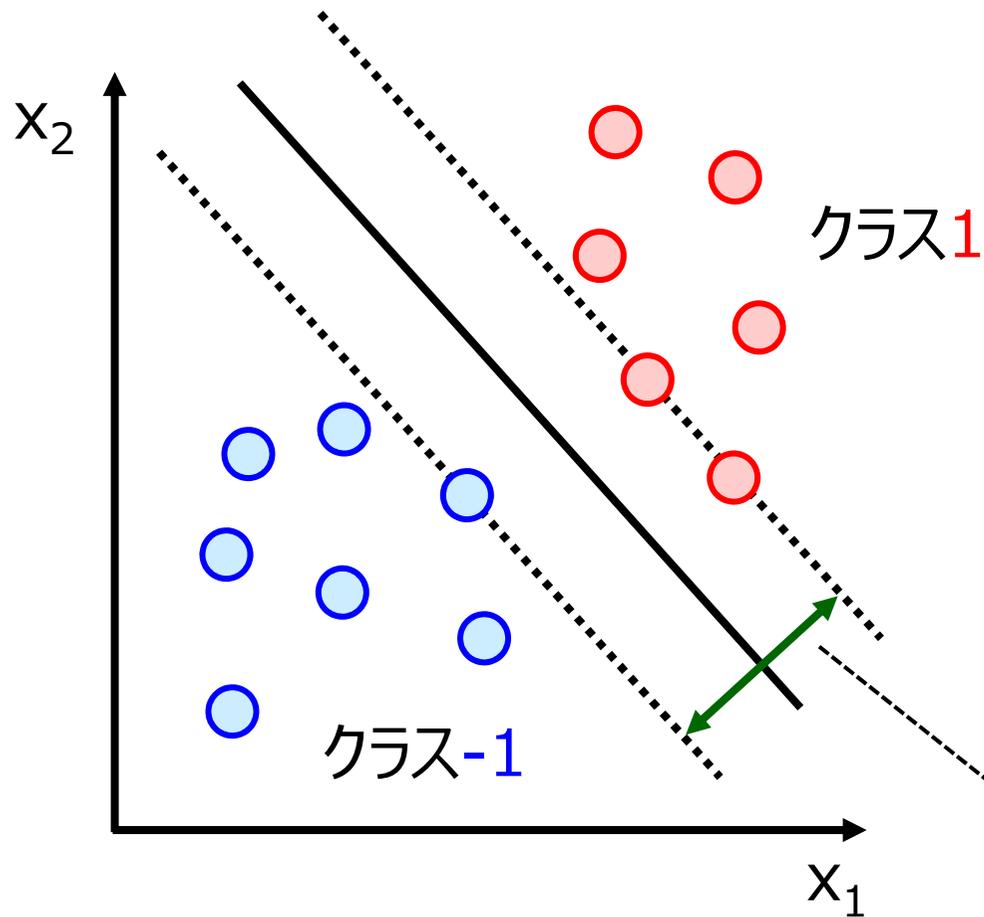


線形判別関数：

$$f(x_1, x_2) = w_1 x_1 + w_2 x_2 + b$$
$$= \mathbf{xw} + b$$

$$\mathbf{x} = [x_1 \quad x_2], \quad \mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}$$

SVMの基本的な考え方



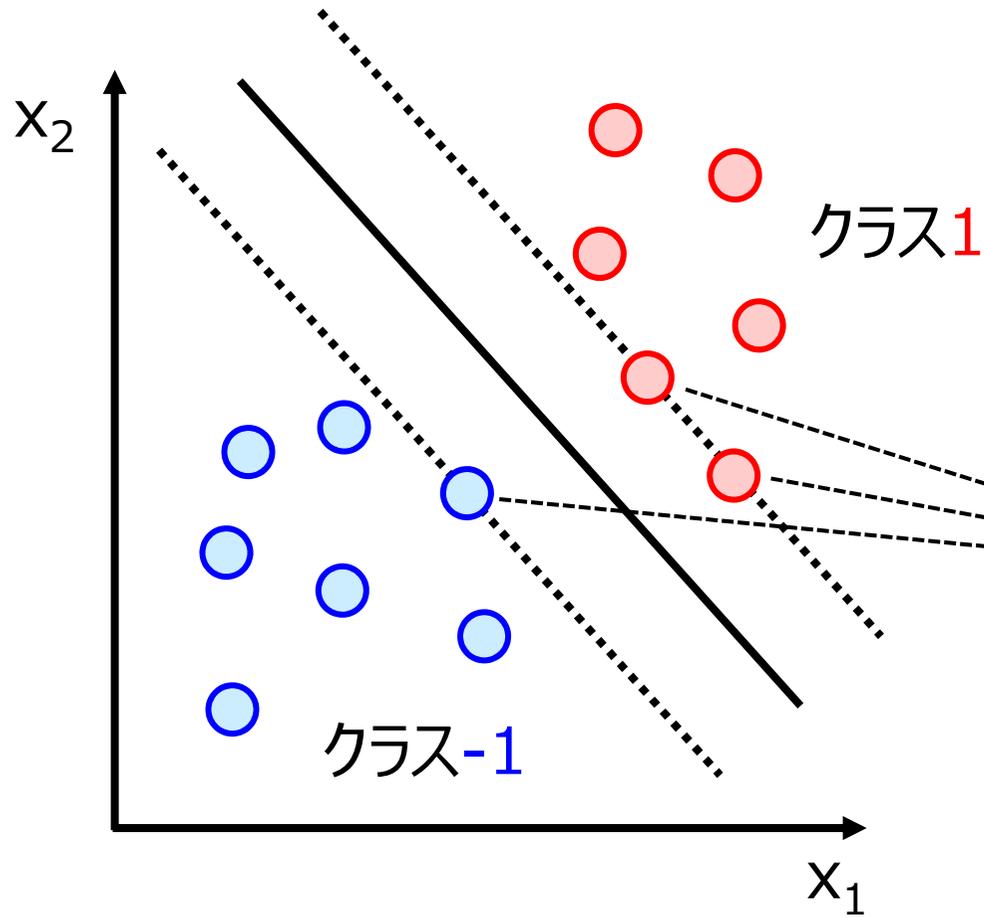
マージンを最大化するように
判別関数を決める！

$$\begin{aligned} f(x_1, x_2) &= w_1 x_1 + w_2 x_2 + b \\ &= \mathbf{xw} + b \end{aligned}$$

$$\text{マージン} = \frac{2}{\|\mathbf{w}\|} = \frac{2}{\sqrt{w_1^2 + w_2^2}}$$

(点と直線との距離で計算)

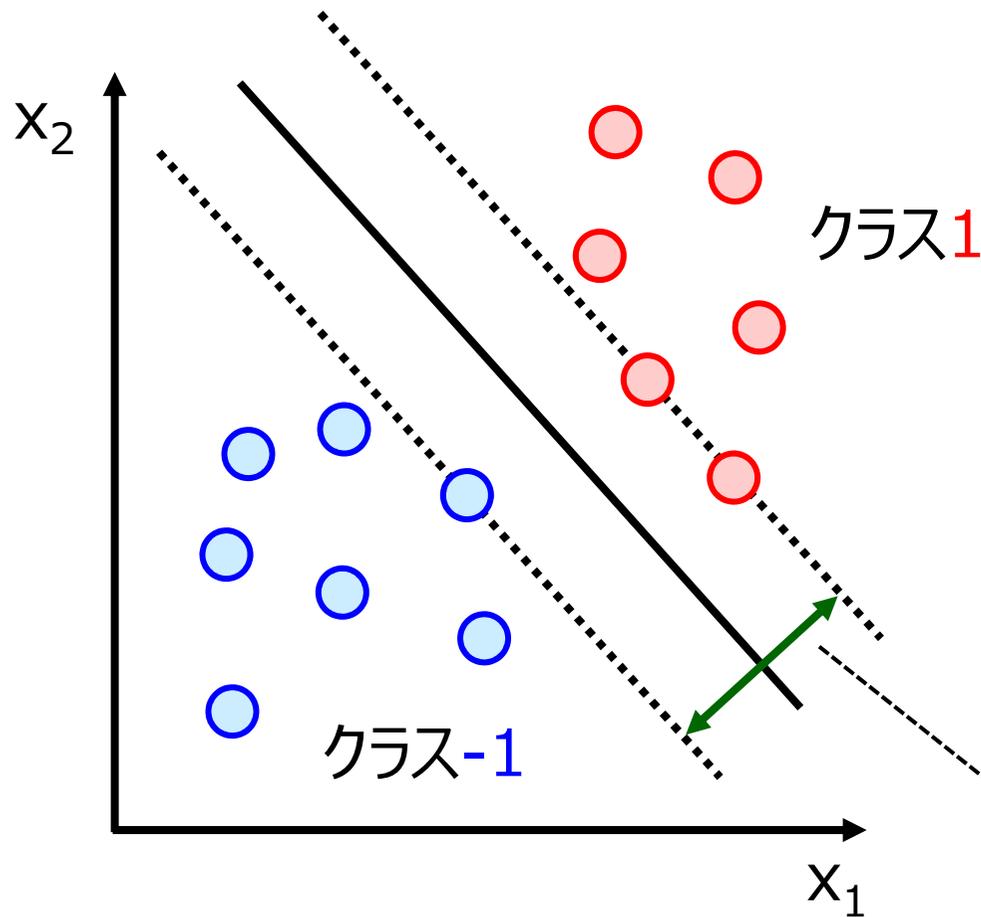
サポートベクター



サポートベクター

- ...他のクラスのサンプルと最も近いところにいるサンプル
 $f(\mathbf{x}) = 1$ (クラス1)
 $f(\mathbf{x}) = -1$ (クラス-1)

マージンの最大化



線形判別関数：

$$f(x_1, x_2) = w_1 x_1 + w_2 x_2 + b$$

$$= \mathbf{xw} + b$$

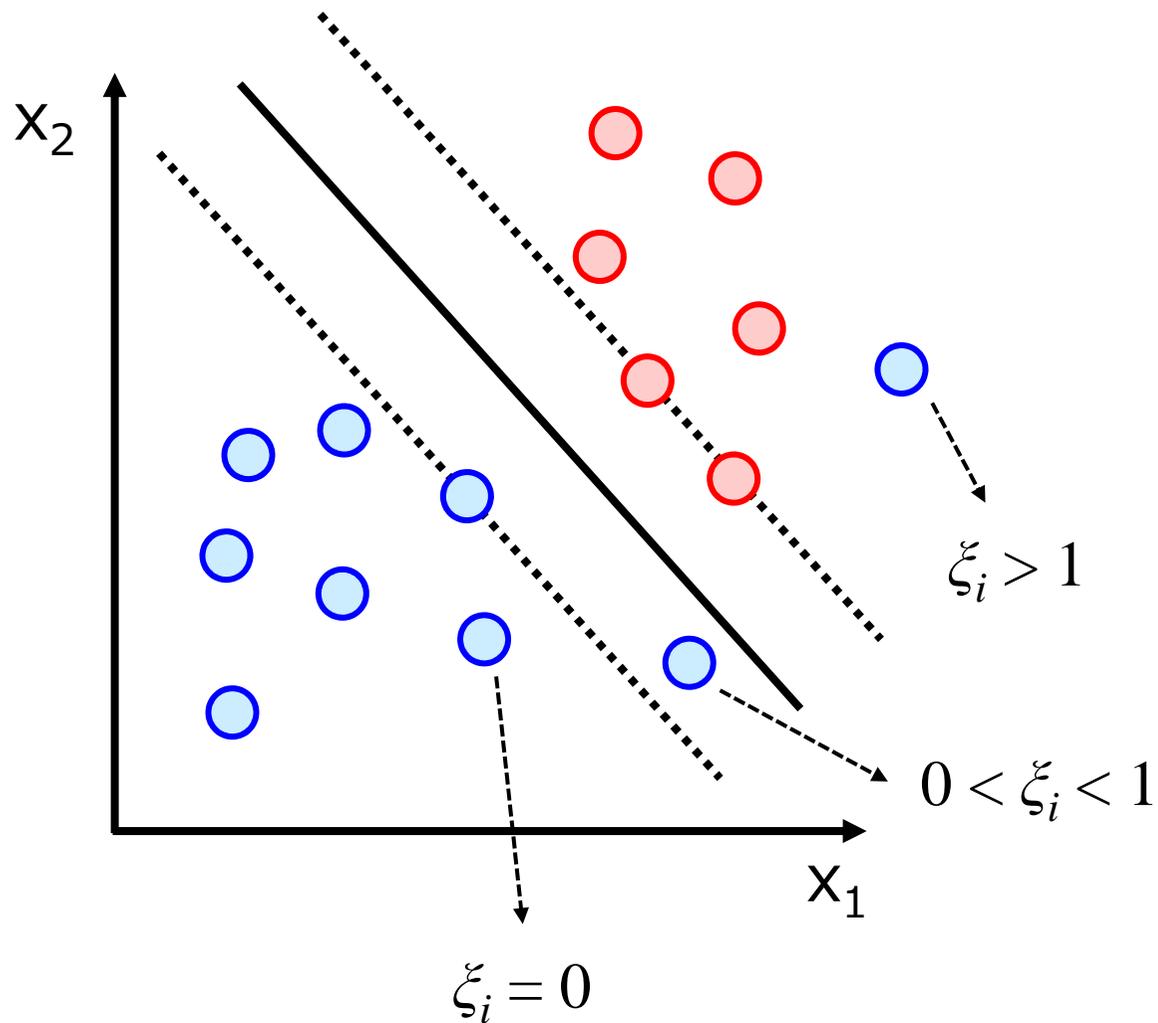
$\frac{2}{\|\mathbf{w}\|}$ の最大化

➡ $\frac{1}{2}\|\mathbf{w}\|$ の最小化

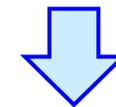
マージン $= \frac{2}{\|\mathbf{w}\|} = \frac{2}{\sqrt{w_1^2 + w_2^2}}$

(点と直線との距離で計算)

きれいに分離できないときは？



スラック変数 ξ を導入！



サンプルごとの ξ_i の和

$$\sum_{i=1}^n \xi_i$$

を最小化

n : モデル構築用
サンプル数

2つの項を一緒に最小化

✓ $\|\mathbf{w}\| / 2$ の最小化 → 計算の都合上、 $\|\mathbf{w}\|^2 / 2$ の最小化

✓ ξ_i の和の最小化

➡ $\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i$ の最小化

ただし、 $\xi_i \geq 0$, $y^{(i)} f(\mathbf{x}^{(i)}) \geq 1 - \xi_i$

C : 2つの項のバランスを決める係数

$\mathbf{x}^{(i)}$: i 番目のサンプルの説明変数

$y^{(i)}$: i 番目のサンプルの値 (1 もしくは -1)

重み \mathbf{w} を求める

✓ Lagrangeの未定乗数法

- ラグランジュ乗数 α_i, β_i ($i=1, 2, \dots, n$) を導入

$$G = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i \{y^{(i)} f(\mathbf{x}^{(i)}) - 1 + \xi_i\} - \sum_{i=1}^n \beta_i \xi_i$$

\mathbf{w} 、 b 、 ξ_i に関して G を最小化し、 α_i 、 β_i に関して G を最大化



\mathbf{w} 、 b 、 ξ_i に関して G が極小



G を \mathbf{w} 、 b 、 ξ_i それぞれで偏微分して0とする

偏微分して0

G を \mathbf{w} で偏微分して0

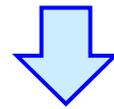
$$\mathbf{w} = \sum_{i=1}^n \alpha_i y^{(i)} \mathbf{x}^{(i)T}$$

G を b で偏微分して0

$$\sum_{i=1}^n \alpha_i y^{(i)} = 0$$

G を ξ_i で偏微分して0

$$\alpha_i + \beta_i = C \quad (i = 1, 2, \dots, n)$$



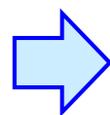
これらを使って
 G を変形すると...

$$G = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y^{(i)} y^{(j)} \mathbf{x}^{(i)} \mathbf{x}^{(j)T}$$

$$G = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y^{(i)} y^{(j)} \mathbf{x}^{(i)} \mathbf{x}^{(j)T}$$

制約 $0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y^{(i)} = 0$ のもとで、

G を α_i に対して最大化する二次計画問題を解くと α_i が求まる



\mathbf{w} が求まる

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y^{(i)} \mathbf{x}^{(i)T}$$

線形判別関数を求める

$$f(\mathbf{x}) = \mathbf{x}\mathbf{w} + b$$

$$= \mathbf{x} \sum_{i=1}^n \alpha_i y^{(i)} \mathbf{x}^{(i)\top} + b = \sum_{i=1}^n \alpha_i y^{(i)} \mathbf{x}\mathbf{x}^{(i)\top} + b$$

$$b = \frac{1}{n_S} \sum_{i \in S} \left(y^{(i)} - \sum_{j \in S} \alpha_j y^{(j)} \mathbf{x}^{(i)} \mathbf{x}^{(j)\top} \right)$$

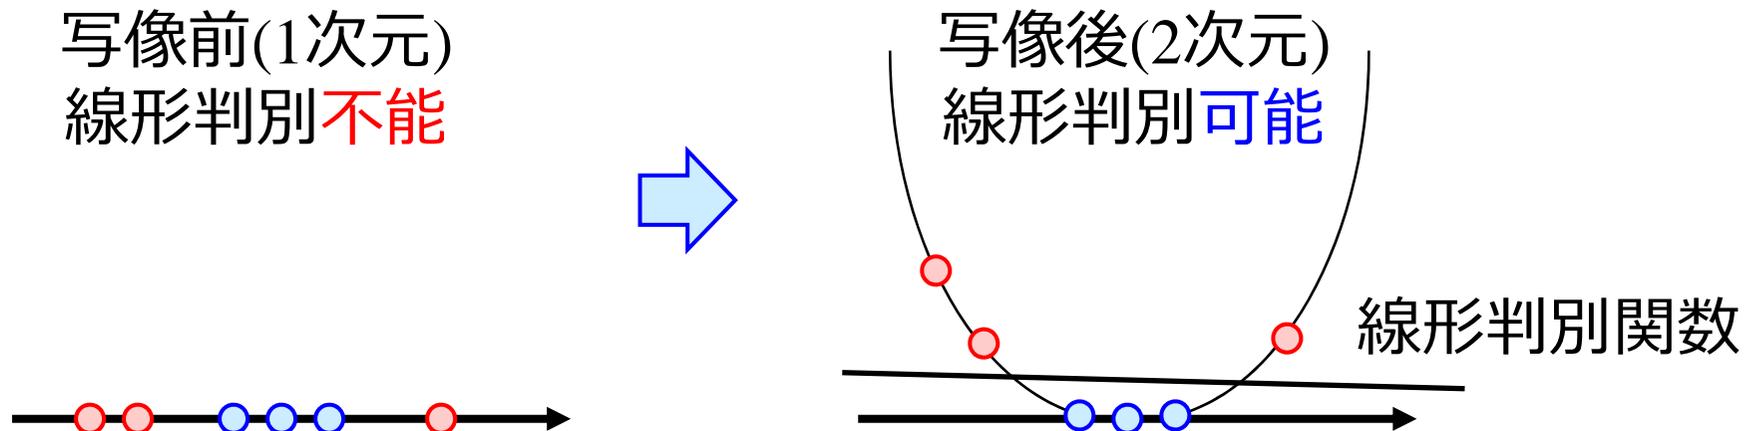
S : サポートベクター ($\alpha_i \neq 0$ のサンプル) の集合

n_S : サポートベクターの個数

線形判別関数は判別能力に限界

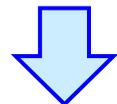
- ➡
- ✓ 元の空間より高次元に写像
 - ✓ 高次元空間上で線形判別関数を構築

高次元空間への写像の例： $x \rightarrow (x, x^2)$



カーネルトリック

線形判別関数 (元の空間) : $f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y^{(i)} \mathbf{x} \mathbf{x}^{(i)\top} + b$

 高次元空間への写像 : $\mathbf{x} \rightarrow \phi(\mathbf{x})$

非線形判別関数 (高次元空間) : $f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y^{(i)} \underbrace{\phi(\mathbf{x}) \phi(\mathbf{x}^{(i)})^\top}_{\text{-----}} + b$

$\phi(\mathbf{x})$ を求める必要はなく、内積 $\phi(\mathbf{x}) \phi(\mathbf{x}^{(i)})^\top$ が分かればOK!



高次元空間への写像 $\phi(\mathbf{x})$ ではなく、内積を指定 (カーネル関数 K)

$$K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \phi(\mathbf{x}^{(i)}) \phi(\mathbf{x}^{(j)})^\top$$

カーネル関数の例

✓ 線形カーネル

$$K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \mathbf{x}^{(i)\top} \mathbf{x}^{(j)}$$

✓ ガウシアンカーネル (使われることが多い)

$$K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \exp\left(-\frac{\|\mathbf{x}^{(i)} - \mathbf{x}^{(j)}\|^2}{2\sigma^2}\right) = \exp\left(-\gamma\|\mathbf{x}^{(i)} - \mathbf{x}^{(j)}\|^2\right)$$

✓ 多項式カーネル

$$K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \left(1 + \lambda \mathbf{x}^{(i)\top} \mathbf{x}^{(j)}\right)^d$$

最終的なSVMを作る前に最適化するパラメータ¹⁵

- ✓ ガウシアンカーネルを使用したSVMのとき、最初に C と γ とを適切に設定する必要がある

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \exp\left(-\gamma \|\mathbf{x}^{(i)} - \mathbf{x}^{(j)}\|^2\right)$$



グリッドサーチ + クロスバリデーション による C および γ の最適化

グリッドサーチ + クロスバリデーション

✓ C と γ の候補を設定し、すべての組合せ (グリッド, 下図の ●) で
クロスバリデーションを行う

✓ C と γ の候補の例

- $C : 2^{-5}, 2^{-4}, \dots, 2^9, 2^{10}$
- $\gamma : 2^{-10}, 2^{-9}, \dots, 2^4, 2^5$

✓ 例) クロスバリデーション後の
正解率が最も高い
 $C \cdot \gamma$ の組を選択

- 正解率については[こちら](#)

