

演習 カーネル法

瀬戸 道生 (防衛大学校・数学教育室)

自己紹介など

15年前：横浜

神奈川大で助手として働く。
同じ建物にいた轟木君と出会う。

自己紹介など

15年前：横浜

神奈川大で助手として働く。
同じ建物にいた轟木君と出会う。

2007年～2015年：島根

島根大学で働く。第二の修行時代。

自己紹介など

15年前：横浜

神奈川大で助手として働く。
同じ建物にいた轟木君と出会う。

2007年～2015年：島根

島根大学で働く。第二の修行時代。

3年前：インド

Ball 師匠「数学の学生の就職対策に再生核の理論はもってこい」
カーネル法の数学的仕組みに詳しいことに気づく。

自己紹介など

15年前：横浜

神奈川大で助手として働く。
同じ建物にいた轟木君と出会う。

2007年～2015年：島根

島根大学で働く。第二の修行時代。

3年前：インド

Ball 師匠「数学の学生の就職対策に再生核の理論はもってこい」
カーネル法の数学的仕組みに詳しいことに気づく。

ここ数年：横須賀

機械学習について勉強中。しかし、応用は素人（通信空手黒帯のような状態）。

今回のお話

この話の内容

- 第1部 カーネル法とは何か？
- 第2部 カーネル法の理論と応用
- 第3部 サポートベクトルマシン入門

注意

学部2、3年生に講義するつもりで話します。

第一部 カーネル法とは何か？

Wikipedia によると

“カーネル関数₁ を使って、
計算複雑度の増大を抑えつつ内積にもとづく解析手法を
高次元特徴空間へ拡張₂ するアプローチを、
一般に カーネルトリック₃ と呼ぶ。”

まず，下線部 2 から解説します．

期末試験の問題

問題

次の積分の値を求めよ．

$$I = \int_{-\infty}^{\infty} e^{-x^2} dx$$

期末試験の問題

問題

次の積分の値を求めよ.

$$I = \int_{-\infty}^{\infty} e^{-x^2} dx$$

解答

$$\begin{aligned} I^2 &= \left(\int_{-\infty}^{\infty} e^{-x^2} dx \right) \left(\int_{-\infty}^{\infty} e^{-y^2} dy \right) \\ &= \int_{\mathbb{R}^2} e^{-(x^2+y^2)} dx dy \\ &= \int_{\mathbb{R}^2} e^{-r^2} r dr d\theta \\ &= \int_0^{2\pi} d\theta \int_0^{\infty} e^{-r^2} r dr = 2\pi [-e^{-r^2}/2]_0^{\infty} = \pi. \end{aligned}$$

$$\therefore I = \sqrt{\pi}.$$

下線部 2 について

「高次元特徴空間へ拡張するアプローチを、・・・」



数学全体での基本的かつ重要なアイデア

- 高次元化することで，問題が簡単になることがある．
- 上空移行の原理（岡 潔）
- ジェットコースターの話（広中 平祐）
- $\int_{-\infty}^{\infty} \frac{1}{x^4 + 1} dx$ も $x \rightarrow z$ と変換することで求められる．

カーネル関数とは何か？

線型代数を思い出すと

$A = (a_{ij})$: $n \times n$ 対称行列 (すなわち $(a_{ji}) = (a_{ij})$)

$$A \geq 0 \stackrel{\text{def}}{\Leftrightarrow} \sum_{i,j=1}^n a_{ij} c_i c_j \geq 0 \quad (\forall (c_1, \dots, c_n) \in \mathbb{R}^n).$$

- $A \geq 0 \Leftrightarrow \langle Ac, c \rangle_{\mathbb{R}^n} \geq 0 \quad (\forall c \in \mathbb{R}^n) \Leftrightarrow A$ の固有値が非負 .

カーネル関数とは何か？

設定

Ω : 集合 (データはこの中の点)

$K(x, y)$: $\Omega \times \Omega$ 上の関数

カーネル関数とは何か？

設定

Ω : 集合 (データはこの中の点)

$K(x, y)$: $\Omega \times \Omega$ 上の関数

カーネル関数

$K(x, y)$ が次の 1 と 2 をみたすとき, $K(x, y)$ をカーネル関数と呼ぶ.

1. $K(y, x) = K(x, y)$ (対称性)
2. $\forall n \in \mathbb{N}, \forall w_1, \dots, w_n \in \Omega, \forall c_1, \dots, c_n \in \mathbb{R}$ に対し,

$$\sum_{i,j=1}^n K(w_i, w_j) c_i c_j \geq 0 \quad (\text{正定値性})$$

例 1

$f(x)$: Ω 上の一変数関数

$$K(x, y) = f(x)f(y)$$

はカーネル関数 .

なぜならば ,

1. $K(y, x) = f(y)f(x) = f(x)f(y) = K(x, y)$

2.

$$\sum_{i,j=1}^n K(w_i, w_j) c_i c_j = \sum_{i,j=1}^n f(w_i) f(w_j) c_i c_j = \left(\sum_{j=1}^n c_j f(w_j) \right)^2 \geq 0.$$

例 2

$\Phi: \Omega \rightarrow \mathbb{R}^n$ (写像)

$$K(x, y) = \langle \Phi(x), \Phi(y) \rangle_{\mathbb{R}^n}$$

はカーネル関数 .

なぜならば ,

1. $K(y, x) = \langle \Phi(y), \Phi(x) \rangle_{\mathbb{R}^n} = \langle \Phi(x), \Phi(y) \rangle_{\mathbb{R}^n} = K(x, y)$

2.

$$\begin{aligned} \sum_{i,j=1}^n K(w_i, w_j) c_i c_j &= \sum_{i,j=1}^n \langle \Phi(w_i), \Phi(w_j) \rangle_{\mathbb{R}^n} c_i c_j \\ &= \left\langle \sum_{i=1}^n c_i \Phi(w_i), \sum_{j=1}^n c_j \Phi(w_j) \right\rangle_{\mathbb{R}^n} \geq 0. \end{aligned}$$

統計学への応用

設定

$\{x_1, \dots, x_n\} (\subset \Omega)$: データの集合 (有限個)

現場からの要望

$\{x_1, \dots, x_n\}$ を適切な基準で二つに分割したい (例: 健康診断)

統計学への応用

設定

$\{x_1, \dots, x_n\} (\subset \Omega)$: データの集合 (有限個)

現場からの要望

$\{x_1, \dots, x_n\}$ を適切な基準で二つに分割したい (例: 健康診断)

数学的には

空間内に分布している点を (超) 平面で分割できるか?

統計学への応用

設定

$\{x_1, \dots, x_n\} (\subset \Omega)$: データの集合 (有限個)

現場からの要望

$\{x_1, \dots, x_n\}$ を適切な基準で二つに分割したい (例: 健康診断)

数学的には

空間内に分布している点を (超) 平面で分割できるか?

この問題の難しい点

データの分布が (超) 平面と相性が良いとは限らない.

統計学への応用

設定

$\{x_1, \dots, x_n\} (\subset \Omega)$: データの集合 (有限個)

現場からの要望

$\{x_1, \dots, x_n\}$ を適切な基準で二つに分割したい (例: 健康診断)

数学的には

空間内に分布している点を (超) 平面で分割できるか?

この問題の難しい点

データの分布が (超) 平面と相性が良いとは限らない.

カーネルトリック

データ x_j を $k_{x_j} = K(\cdot, x_j)$ に変換せよ. $\Phi: x_j \mapsto k_{x_j}$ (特徴写像)

カーネルトリックの数学的背景

$K: \Omega$ 上のカーネル関数 ($k_x := K(\cdot, x)$),

定理 (Moore-Aronszajn)

K には次をみたすヒルベルト空間 \mathcal{H}_K がただ一つ対応する .

1. \mathcal{H}_K は Ω 上の関数からなるヒルベルト空間 .
2. $f(x) = \langle f, k_x \rangle_{\mathcal{H}_K}$ ($f \in \mathcal{H}_K, x \in \Omega$).

カーネルトリックの数学的背景

K : Ω 上のカーネル関数 ($k_x := K(\cdot, x)$),

定理 (Moore-Aronszajn)

K には次をみたすヒルベルト空間 \mathcal{H}_K がただ一つ対応する .

1. \mathcal{H}_K は Ω 上の関数からなるヒルベルト空間 .
2. $f(x) = \langle f, k_x \rangle_{\mathcal{H}_K}$ ($f \in \mathcal{H}_K, x \in \Omega$).

用語の整理

- \mathcal{H}_K は再生核ヒルベルト空間とよばれる .
- K はカーネル関数 , $k_x = K(\cdot, x)$ は再生核 .
- カーネル関数と再生核の関係 : $K(x, y) = \langle k_y, k_x \rangle_{\mathcal{H}_K}$.

なぜ再生核ヒルベルト空間 (RKHS) を考えるのか

RKHS に期待される 2 つの機能

- 直交射影が使える .
- 代入が内積で表される .

なぜ再生核ヒルベルト空間 (RKHS) を考えるのか

RKHS に期待される 2 つの機能

- 直交射影が使える .
- 代入が内積で表される .

代入が内積で表される数学は良い数学

$$\int_{\Omega} f(x)g(x) dx \text{ (連続)} \longrightarrow \sum_i a_i b_i \text{ (離散)}$$

$$f(\lambda) = \frac{1}{2\pi i} \int_C \frac{f(z)}{z - \lambda} dz \quad (\text{コーシーの積分公式}),$$

$$f(a) = \int_{-\infty}^{\infty} f(x)\delta(x - a) dx \quad (\text{ディラックのデルタ関数}).$$

第一部のまとめ

カーネル法（カーネルトリック）とは

- 非線型なデータを「直交射影」プラス「代入が内積（積分）で表される仕組み」で扱う方法である。
- 特徴写像 $\Phi : x \mapsto k_x$ にデータの非線形性が組み込まれている（従って、問題は特徴写像の選び方（モデルの選択）である）。

常微分方程式 $\xrightarrow{\text{ラプラス変換}}$ 代数方程式

非線形なデータの問題 $\xrightarrow{\text{カーネルトリック}}$ 線形代数の問題

第二部 カーネル法の理論と応用

定理 (Aronszajn)

K_1, K_2 が Ω 上のカーネル関数ならば $K_1 + K_2, K_1 K_2$ も Ω 上のカーネル関数であり, $\mathcal{H}_{K_1+K_2}, \mathcal{H}_{K_1 K_2}$ を $\mathcal{H}_{K_1}, \mathcal{H}_{K_2}$ から構成できる.

第二部 カーネル法の理論と応用

定理 (Aronszajn)

K_1, K_2 が Ω 上のカーネル関数ならば $K_1 + K_2, K_1 K_2$ も Ω 上のカーネル関数であり, $\mathcal{H}_{K_1+K_2}, \mathcal{H}_{K_1 K_2}$ を $\mathcal{H}_{K_1}, \mathcal{H}_{K_2}$ から構成できる.

補足

カーネル関数の構成法 (= RKHS の構成法) はたくさんある.

第二部 カーネル法の理論と応用

定理 (Aronszajn)

K_1, K_2 が Ω 上のカーネル関数ならば $K_1 + K_2, K_1 K_2$ も Ω 上のカーネル関数であり, $\mathcal{H}_{K_1+K_2}, \mathcal{H}_{K_1 K_2}$ を $\mathcal{H}_{K_1}, \mathcal{H}_{K_2}$ から構成できる.

補足

カーネル関数の構成法 (= RKHS の構成法) はたくさんある.

カーネル法の言葉で言えば

新しい特徴写像 (モデル) を次々に構成できる.

例: K がカーネル関数ならば e^K もカーネル関数 (\rightarrow ガウスカーネル).

第二部 カーネル法の理論と応用

定理 (Aronszajn)

K_1, K_2 が Ω 上のカーネル関数ならば $K_1 + K_2, K_1 K_2$ も Ω 上のカーネル関数であり, $\mathcal{H}_{K_1+K_2}, \mathcal{H}_{K_1 K_2}$ を $\mathcal{H}_{K_1}, \mathcal{H}_{K_2}$ から構成できる.

補足

カーネル関数の構成法 (= RKHS の構成法) はたくさんある.

カーネル法という言葉で言えば

新しい特徴写像 (モデル) を次々に構成できる.

例: K がカーネル関数ならば e^K もカーネル関数 (\rightarrow ガウスカーネル).

フォン ノイマン流の量子力学に詳しい方へ

RKHS は「ヒルベルト空間」と「自己共役作用素」の組

リプレゼンター定理 1

問題 1

$\{x_1, \dots, x_n\} \subset \Omega$, $\{\lambda_1, \dots, \lambda_n\} \subset \mathbb{R}$ に対し,

$$J(f) = \sum_{j=1}^n |f(x_j) - \lambda_j|^2$$

を最小化する $f \in \mathcal{H}_K$ を見つけよ.

リプレゼンター定理 1

問題 1

$\{x_1, \dots, x_n\} \subset \Omega$, $\{\lambda_1, \dots, \lambda_n\} \subset \mathbb{R}$ に対し,

$$J(f) = \sum_{j=1}^n |f(x_j) - \lambda_j|^2$$

を最小化する $f \in \mathcal{H}_K$ を見つけよ.

準備

P を $\{k_{x_1}, \dots, k_{x_n}\}$ で張られる空間への直交射影とすると,

$$Pf = \sum_{j=1}^n c_j k_{x_j}$$

と表される (ヒルベルト空間を考える御利益).

リプレゼンター定理 1

解法

$$f(x_i) = \langle f, k_{x_i} \rangle_{\mathcal{H}_K} = \langle Pf, k_{x_i} \rangle_{\mathcal{H}_K} = \left\langle \sum_{j=1}^n c_j k_{x_j}, k_{x_i} \right\rangle_{\mathcal{H}_K}$$

から

$$\begin{pmatrix} f(x_1) \\ \vdots \\ f(x_n) \end{pmatrix} = (K(x_i, x_j)) \begin{pmatrix} c_1 \\ \vdots \\ c_n \end{pmatrix}$$

が導かれる。この右辺を Kc と表せば、

$$J(f) = \sum_{j=1}^n |f(x_j) - \lambda_j|^2 = \|Kc - \lambda\|_{\mathbb{R}^n}^2.$$

(関数 f の問題がベクトル c の問題になった)

カーネル法の簡単な例

問題 2

$\{x_1, \dots, x_n\} \subset \mathbb{R}$, $\{\lambda_1, \dots, \lambda_n\} \subset \mathbb{R}$ に対し,

$$J(f) = \sum_{j=1}^n |p(x_j) - \lambda_j|^2$$

を最小化する多項式 p ($d = \deg p < n - 1$) を見つけよ.

カーネル法の簡単な例

問題 2

$\{x_1, \dots, x_n\} \subset \mathbb{R}$, $\{\lambda_1, \dots, \lambda_n\} \subset \mathbb{R}$ に対し,

$$J(f) = \sum_{j=1}^n |p(x_j) - \lambda_j|^2$$

を最小化する多項式 p ($d = \deg p < n - 1$) を見つけよ.

方針

カーネル法により問題 1 に帰着させる

(次数 d 以下の多項式全体からなる \mathcal{H}_K を見つけてくればよい).

カーネル法の簡単な例

解法

特徴写像として

$$\begin{aligned}\Phi : \{x_1, \dots, x_n\} &\rightarrow \mathcal{P} := (d \text{ 次以下の多項式全体}) \cong \mathbb{R}^{d+1} \\ x_j &\mapsto 1 + x_j x + \dots + x_j^d x^d\end{aligned}$$

を採用する .

\mathcal{P} には次のようにして再生核ヒルベルト空間の構造が入る .

$p(x) = a_0 + a_1 x + \dots + a_d x^d$ に対し ,

$$\begin{aligned}\langle p, \Phi(x_j) \rangle_{\mathcal{P}} &:= \left\langle \begin{pmatrix} a_0 \\ \vdots \\ a_d \end{pmatrix}, \begin{pmatrix} 1 \\ \vdots \\ x_j^d \end{pmatrix} \right\rangle_{\mathbb{R}^{d+1}} \\ &= a_0 + a_1 x_j + \dots + a_d x_j^d.\end{aligned}$$

リプレゼンター定理 2

- P を $\{k_{x_1}, \dots, k_{x_n}\}$ で張られる空間への直交射影とすれば,

$$(Pf)(x_i) = f(x_i) \quad (i = 1, \dots, n).$$

- $f(x_i) = 0 \quad (i = 1, \dots, n)$ となる f は P で除去できる.
- $\|f\|_{\mathcal{H}_K}^2 = \|Pf\|_{\mathcal{H}_K}^2 + \|(I - P)f\|_{\mathcal{H}_K}^2$ (三平方の定理).
- $f(x_i)$ に関する問題は $(Pf)(x_i)$ を考えればよい (問題を有限次元に落とせる).

第二部のまとめ

カーネル法勉強の目安

- 内積の計算ができて有名な定理の意味がわかれば基本は OK .
- カーネル関数のいろいろな構成法を知っておくと将来便利かも .

参考文献

- [1] 赤穂昭太郎, カーネル多変量解析, 岩波書店 .
- [2] 竹内一郎, 鳥山昌幸, サポートベクトルマシン, 講談社 .
- [3] 金森敬文, 統計的学習理論, 講談社 .
- [4] 福水健次, カーネル法入門, 朝倉書店 .
- [5] C. M. ビショップ, パターン認識と機械学習, 丸善出版 .
- [6] 私の講義ノート, <https://researchmap.jp/mseto/> の資料公開 .

第三部 サポートベクトルマシン入門編

設定

$D = \{(x_1, y_1), \dots, (x_n, y_n)\} \subset \mathbb{R}^2$ (データの集合)

各データには符号 $\lambda_j \in \{-1, +1\}$ がラベル付けされている .

すなわち , D は

$$D_+ = \{(x_j, y_j) \in D : \lambda_j = +1\}, \quad D_- = \{(x_j, y_j) \in D : \lambda_j = -1\}$$

と分割される .

第三部 サポートベクトルマシン入門編

設定

$D = \{(x_1, y_1), \dots, (x_n, y_n)\} \subset \mathbb{R}^2$ (データの集合)

各データには符号 $\lambda_j \in \{-1, +1\}$ がラベル付けされている .

すなわち , D は

$$D_+ = \{(x_j, y_j) \in D : \lambda_j = +1\}, \quad D_- = \{(x_j, y_j) \in D : \lambda_j = -1\}$$

と分割される .

問題

$D_+ \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) > 0\}$, $D_- \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) < 0\}$

をみたす適切な関数 $f(x, y)$ を見つけよ .

サポートベクトルマシン入門編

問題

$D_+ \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) > 0\}$, $D_- \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) < 0\}$

をみたす適切な関数 $f(x, y)$ を見つけよ .

コメント

- 適切な関数とは簡単なものであってほしい (過学習の問題).
- D_+ と D_- の間に原点を通る直線が引けるとき , D は線形分離できるという (最も単純な場合).
- データの分布が線形分離と相性が悪いときどうする ?

サポートベクトルマシン入門編

拡張された問題

$$D_+ \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) > 0\}, \quad D_- \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) < 0\}$$

をみたす関数 $f(x, y) = a + bx + cy + dx^2 + ey^2$ を見つけよ .

サポートベクトルマシン入門編

拡張された問題

$$D_+ \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) > 0\}, \quad D_- \subset \{(x, y) \in \mathbb{R}^2 : f(x, y) < 0\}$$

をみたす関数 $f(x, y) = a + bx + cy + dx^2 + ey^2$ を見つけよ .

Step 1

写像

$$\Phi : \mathbb{R}^2 \rightarrow \mathbb{R}^5 \quad \Phi(x, y) = (1, x, y, x^2, y^2)^t$$

を特徴写像として採用し, \mathbb{R}^2 上のカーネル関数を

$$k((x, y), (z, w)) = \langle \Phi(x, y), \Phi(z, w) \rangle_{\mathbb{R}^5} \quad ((x, y), (z, w) \in \mathbb{R}^2)$$

と定める .

サポートベクトルマシン入門編

Step 2

このとき , $\mathbf{v} = (a, b, c, d, e)^t \in \mathbb{R}^5$ に対し ,

$$\langle \mathbf{v}, \Phi(x_j, y_j) \rangle_{\mathbb{R}^5} = a + bx_j + cy_j + dx_j^2 + ey_j^2.$$

よって , \mathbb{R}^5 のベクトル \mathbf{v} で

$$\Phi(D_+) \subset \{\mathbf{x} \in \mathbb{R}^5 : \langle \mathbf{v}, \mathbf{x} \rangle_{\mathbb{R}^5} > 0\}, \quad \Phi(D_-) \subset \{\mathbf{x} \in \mathbb{R}^5 : \langle \mathbf{v}, \mathbf{x} \rangle_{\mathbb{R}^5} < 0\}$$

をみたすものを見つけてくればよい .

サポートベクトルマシン入門編

Step 2

このとき, $\mathbf{v} = (a, b, c, d, e)^t \in \mathbb{R}^5$ に対し,

$$\langle \mathbf{v}, \Phi(x_j, y_j) \rangle_{\mathbb{R}^5} = a + bx_j + cy_j + dx_j^2 + ey_j^2.$$

よって, \mathbb{R}^5 のベクトル \mathbf{v} で

$$\Phi(D_+) \subset \{\mathbf{x} \in \mathbb{R}^5 : \langle \mathbf{v}, \mathbf{x} \rangle_{\mathbb{R}^5} > 0\}, \quad \Phi(D_-) \subset \{\mathbf{x} \in \mathbb{R}^5 : \langle \mathbf{v}, \mathbf{x} \rangle_{\mathbb{R}^5} < 0\}$$

をみたすものを見つけてくればよい.

Step 3

$$V = \{\mathbf{x} \in \mathbb{R}^5 : \langle \mathbf{v}, \mathbf{x} \rangle_{\mathbb{R}^5} = 0\}$$

は \mathbb{R}^5 内の原点を通る超平面である (\mathbb{R}^5 での線形分離の問題に帰着された). また, リプレゼンター定理により, $\mathbf{v} = \sum_{j=1}^n c_j \Phi(x_j, y_j)$ と仮定してよいことに注意しよう.

例題（簡単ですが）

例題 1

\mathbb{R}^3 内の D_+ と D_- が平面 $ax + by + cz + d = 0$ で分離されるとき， $\phi(D_+)$ と $\phi(D_-)$ が \mathbb{R}^4 で線形分離できるような特徴写像 ϕ を定めよ．

例題（簡単ですが）

例題 1

\mathbb{R}^3 内の D_+ と D_- が平面 $ax + by + cz + d = 0$ で分離されるとき， $\Phi(D_+)$ と $\Phi(D_-)$ が \mathbb{R}^4 で線形分離できるような特徴写像 Φ を定めよ．

略解

$$D_+ \subset \{(x, y, z)^t \in \mathbb{R}^3 : ax + by + cz + d > 0\}$$

と仮定する． D_- についても同様．特徴写像として，

$$\Phi : \mathbb{R}^3 \rightarrow \mathbb{R}^4, \quad (x, y, z)^t \mapsto (x, y, z, 1)^t$$

を採用すると， $(x, y, z)^t \in D_+$ と $v = (a, b, c, d)^t$ に対し，

$$\langle v, \Phi(x, y, z) \rangle_{\mathbb{R}^4} = ax + by + cz + d > 0$$

が成り立つ．よって，

$$\Phi(D_+) \subset \{(x, y, z, w)^t \in \mathbb{R}^4 : \langle v, (x, y, z, w)^t \rangle_{\mathbb{R}^4} > 0\}.$$

例題（簡単ですが）

例題 2

\mathbb{R}^2 内の D_+ と D_- が円 $x^2 + y^2 = 1$ で分離されるとき, $\phi(D_+)$ と $\phi(D_-)$ が \mathbb{R}^3 で線形分離できるような特徴写像 ϕ を定めよ.

例題（簡単ですが）

例題 2

\mathbb{R}^2 内の D_+ と D_- が円 $x^2 + y^2 = 1$ で分離されるとき, $\Phi(D_+)$ と $\Phi(D_-)$ が \mathbb{R}^3 で線形分離できるような特徴写像 Φ を定めよ.

略解

$$D_+ \subset \{(x, y)^t \in \mathbb{R}^2 : x^2 + y^2 > 1\}$$

と仮定しよう. D_- についても同様. 特徴写像として,

$$\Phi : \mathbb{R}^2 \rightarrow \mathbb{R}^3, \quad (x, y)^t \mapsto (x, y, x^2 + y^2 - 1)^t$$

を採用すると, $(x, y)^t \in D_+$ と $v = (0, 0, 1)^t$ に対し,

$$\langle v, \Phi(x, y) \rangle_{\mathbb{R}^3} = x^2 + y^2 - 1 > 0$$

が成り立つ. よって,

$$\Phi(D_+) \subset \{(x, y, z)^t \in \mathbb{R}^3 : \langle v, (x, y, z)^t \rangle_{\mathbb{R}^3} > 0\}.$$

サポートベクトルマシン入門編

ハードマージン法

$D = D_+ \cup D_-$ が線形分離できるとき,

$$\max_H \min_{1 \leq i \leq n} d(x_i, H) \quad (D = \{x_1, \dots, x_n\})$$

を解いて, D_+ と D_- のちょうど中間にある平面 H を選ぶ方法.

ソフトマージン法

線形分離できない場合の次善策.

- 角度と距離の問題は内積の問題である (カーネル法を使った先でも角度と距離が考えられる).
- カーネル法を使っても, リプレゼンター定理により, n 変数の2次関数の問題になる (n はデータ数).