

Learning Machine

Nils, J. Nilsson

C. 2

2.2 discriminant function

$$f(x) = w_1 x_1 + \dots + w_d x_d + w_{d+1}$$

2.3 minimum distance classifiers

$$|x - p_i|^2 = x \cdot x - 2x \cdot p_i + p_i \cdot p_i$$

$$f_i(x) = x \cdot p_i - \frac{1}{2} p_i \cdot p_i$$

$$p_{ij} = w_{ij}, \quad w_{i,d+1} = -\frac{1}{2} p_i \cdot p_i$$

2.4 the decision surface of linear machine

$$f_i(x) - f_j(x) = 0$$

the decision regions of a linear machine are always convex.

2.5 linear classifications of patterns

a finite set \mathcal{X} of distinct patterns $\{X_1, X_2, \dots, X_N\}$

$\mathcal{X} \rightarrow$ subsets $\mathcal{X}_1, \mathcal{X}_2, \dots, \mathcal{X}_R$

$$f_i(x) > f_j(x) \text{ for all } X \text{ in } \mathcal{X}_i$$

$$j = 1 \dots R, \quad j \neq i \text{ for all } i = 1 \dots R$$

\Downarrow a classification of \mathcal{X} is linear
subsets $\mathcal{X}_1, \dots, \mathcal{X}_R$ are linearly separable

2.6 TLU the threshold logic unit



$$g(x) = w_1 x_1 + \dots + w_d x_d + w_{d+1}$$

$$\begin{cases} x \cdot w = -w_{d+1} \\ x \cdot \pi = P \cdot \pi \end{cases}$$

$$\pi = \frac{P \cdot w}{|w|} \quad \pi \cdot P = -\frac{w_{d+1}}{|w|} = -\Delta_w$$

hyperplane $x \cdot \pi + \Delta_w = 0$

2.7 Piecewise linear discriminant functions

R finite point sets P_1, \dots, P_R

$$P_i \mapsto P_i^{(1)}, \dots, P_i^{(L_i)}$$

$$d(x, P_i) = \min_{j=1, \dots, L_i} |x - P_i^{(j)}|$$

$$g_i(x) = \max \left\{ P_i^{(j)} \cdot x - \frac{1}{2} P_i^{(j)} \cdot P_i^{(j)} \right\} = \max \{ g_i^{(j)}(x) \}$$

$\hookrightarrow \tau$

subsidary discriminant function $\in \mathbb{R}$

$$g_i^{(j)}(x) = w_{i,1}^{(j)} x_1 + \dots + w_{i,d}^{(j)} x_d + w_{i,d+1}^{(j)}$$

$\exists \tau$

$$P_i^{(j)} (P_{i,1}^{(j)}, \dots, P_{i,d}^{(j)}) \in \mathbb{R}^d$$

$$w_{i,k}^{(j)} = P_{i,k}^{(j)} \quad \left. \begin{array}{l} j=1, \dots, R \\ j=1, \dots, L_i \end{array} \right\}$$

$$k=1, \dots, d$$

$$w_{i,d+1}^{(j)} = -\frac{1}{2} P_i^{(j)} \cdot P_i^{(j)}$$

minimum distance classifier or discriminant function
 $\in \tau$ piecewise linear discriminant function

2.8 quadric discriminant functions

$$f_i(x) = \sum_{j=1}^d w_{jj} x_j^2 + \sum_{j=1}^{d-1} \sum_{k=j+1}^d w_{jk} x_j x_k + \sum_{j=1}^d w_{0j} x_j + w_{d+1}$$

$$A = [a_{jk}]$$

$$a_{jj} = w_{jj} \quad j=1 \dots d$$

$$a_{jk} = \frac{1}{2} w_{jk} \quad j, k=1 \dots d, j \neq k$$

$$B = \begin{pmatrix} b_1 \\ \vdots \\ b_d \end{pmatrix}$$

$$b_j = w_{0j} \quad j=1 \dots d$$

$$C = w_{d+1}$$

$$f(x) = x^t A x + x^t B + C$$

↑ quadratic form

all the eigenvalues of $A > 0 \rightarrow$ quadratic form ≥ 0

A and quadratic form is positive definite

the eigenvalues of $A > 0$ or $= 0$

A and quadratic form is positive semidefinite

2.9 quadric decision surfaces

$$R_i \cap R_j \cap \dots \cap R_k = \emptyset$$

$$x^t [A^{(i)} - A^{(j)}] x + x^t [B^{(i)} - B^{(j)}] + [C^{(i)} - C^{(j)}] = 0$$

$$x^t A x + x^t B + C = 0$$

A is positive definite \rightarrow hyperellipsoid

The axes are in the direction of the eigenvalues of A

A is an identity matrix \rightarrow hypersphere

A is positive semidefinite \rightarrow hyperellipsoidal cylinder

上記以外の A のとき

\rightarrow hyperhyperboloid

2.10 Implementation of quadratic discriminant function

$$g_i(x) = \sum_{j=1}^d w_{ij} x_j^2 + \sum_{j=1}^{d-1} \sum_{k=j+1}^d w_{jk} x_j x_k + \sum_{j=1}^d w_j x_j + w_{d+1}$$

$$g(x) = w_1 f_1 + \dots + w_M f_M + w_{M+1}$$

$$\underline{F = F(x) = F(f_1, f_2, \dots, f_M)}$$

$$x = x(x_1, x_2, \dots, x_d)$$

* のすべての二次識別関数は F の線形識別関数に対応させる

2.11. Φ functions

この式は weights $w_1, w_2, \dots, w_M, w_{M+1}$ に関して linear
 $\therefore \Phi$ function

$f_i(x)$ は weights に関して 独立

線形独立, 実, 一価関数

$$* \xrightarrow[\text{手簿}]{F(x)} \underline{F} \quad (M\text{-次元空間})$$

Φ -space

互関数空間 ... 119 - 二分類機 = Φ -machine

"
 Φ processor + linear machine

piecewise linear machine = Φ machine

2.12 the utility of Φ functions for classifying patterns.

one measure of the effectiveness

the total number of dichotomies of N patterns

2.13. the number of linear dichotomies of N -points of d -dimensional

$L(N, d)$ for N d -dimensional patterns
the number of linear dichotomies

general position

$N > d$ no subset of $d+1$ points lies on a $(d-1)$ -dimensional hyperplane

$N \leq d$ no $(N-2)$ -dimensional hyperplane contains the set of N points

$$L(N, d) = L(N-1, d) + L_{X_N}(N-1, d)$$

$$L_{X_N}(N-1, d) = L(N-1, d-1)$$

$$\therefore L(N, d) = L(N-1, d) + L(N-1, d-1).$$

$$\text{iff } L(1, d) = 2. \quad L(N, 1) = 2^N$$

$$\therefore L(N, d) = 2 \sum_{i=0}^d \binom{N-1}{i} \quad \text{for } N > d$$
$$= 2^N \quad \text{for } N \leq d$$

2.14 the effects of constraints

a set X of N points

a set Z of K points $K < d$

$L_Z(N, d)$ = the number of linear dichotomies of X achievable by a hyperplane constrained to contain all the points of Z .

$$L_Z(N, d) = L(N, d - K).$$

2.15 the number of Φ function dichotomies

Φ function family $f(x) = w_1 f_1(x) + \dots + w_m f_m(x) + w_{m+1}$

$f(x) = 0$ による N 点集合 X の分割法 “ Φ = 分法”

109-space $r = M + 1$ 以上の Φ の $r = 1$ に相当し $f(x) = 0$ は \dots とす

“ Φ - 一般位置”

$$\underline{\Phi(N, d) = L(N, M)}$$

$$1. \Phi(x) = |x - w|^2 - a^2 = x \cdot x - 2x \cdot w + w \cdot w - a^2$$

$$M = d + 1$$

(a hypersphere decision surface)

2. $\Phi(x)$: r 次多項式

$$M = \sum_{i=1}^r \binom{d+i-1}{i} = \binom{d+r}{r} - 1$$

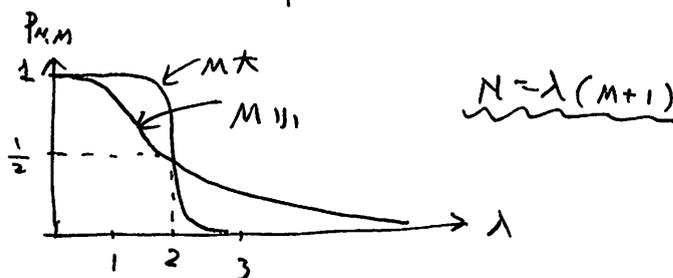
$$r = 2 \text{ or } 3 \quad M = \frac{d(d+3)}{2}$$

(the general quadric surface)

2.6 machine capacity

$P_{N,M}$: N patterns の可能な二分法の数 2^N の;
 任意に 1 通り入る "2 進数", 与えられた Φ machine へ
 与えられた N 通り入る "2 進数" へ Φ machine へ
 与えられた N 通り入る "2 進数" へ Φ machine へ probability

$$P_{N,M} = \frac{L(N,M)}{2^N} = \begin{cases} 2^{1-N} \sum_{i=0}^M \binom{N-1}{i} & N > M \\ = 1 & N < M \end{cases}$$



" $M+1$ " threshold effect

Capacity C of a Φ machine = $2(M+1)$.

~~Φ machine implemented on pattern space~~
 Φ machine
 Decision boundary in pattern space
 implemented by Φ machine

	Capacity
Hyperplane	$2(d+1)$
Hypersphere	$2(d+2)$
General quadric surface	$(d+1)(d+2)$
r th order polynomial surface	$2 \binom{d+r}{r}$

3.4 a special loss function

$$\lambda(i|j) = 1 - \delta_{ij} \quad : \text{symmetrical loss function}$$

$$\underbrace{L(x|i)}_{\text{minimum}} = P(x) - \underbrace{P(x|i) P(i)}_{\text{maximum}}$$

全ての i での事前生起確率 $P(i) = \frac{1}{R}$ とし
 $P(x|i)$ を maximum にする i を選ぶのが...
 maximum likelihood decision
 最大決定

$$\lambda(i|j) = 1 - \delta_{ij} \text{ のときは}$$

$$\text{識別関数は } g_i(x) = P(x|i) P(i)$$

$$\text{or } g_i(x) = \log(x|i) + \log P(i)$$

3.5 An example.

d の 2 値成分を持つ n 次元データを分類 $x_i = 0 \text{ or } 1$

$$R = 2$$

• $\lambda(i|j)$: symmetrical loss function とすると

$$\text{識別関数 } g(x) = g_1(x) - g_2(x) = \log \left[\frac{P(x|1)}{P(x|2)} \right] + \log \left[\frac{P(1)}{1-P(1)} \right]$$

• この d 次元データ x の各成分は互いに独立になると

$$P(x|i) = P(x_1|i) \cdots P(x_d|i)$$

また $P(x_i=1|1) \triangleq p_i$
 $P(x_i=1|2) \triangleq \beta_i$) と表すと

$$\begin{aligned}
 g(x) &= \sum_{i=1}^d \log \left[\frac{P(x_i|1)}{P(x_i|2)} \right] + \log \left[\frac{P(1)}{1-P(1)} \right] = \sum_{i=1}^d x_i \log \left[\frac{p_i(1-\beta_i)}{\beta_i(1-p_i)} \right] \\
 &\quad + \sum \log \left(\frac{1-p_i}{1-\beta_i} \right) + \log \left[\frac{P(1)}{1-P(1)} \right]
 \end{aligned}$$

3.6 the bivariate normal probability-density function
the expectation operator $E[\]$

$$E[x_1] = m_1, \quad E[x_2] = m_2 \quad : \text{mean value}$$

$$E[x_1^2] - E^2[x_1] = \sigma_{11}, \quad E[x_2^2] - E^2[x_2] = \sigma_{22} \quad : \text{variance}$$

$$z_1 = \frac{x_1 - m_1}{\sqrt{\sigma_{11}}} \quad z_2 = \frac{x_2 - m_2}{\sqrt{\sigma_{22}}}$$

$$E[z_1] = 0 \quad E[z_2] = 0 \quad E[z_1^2] - E^2[z_1] = 1$$

2変数正規密度関数

$$p(z_1, z_2) = \frac{1}{2\pi\sqrt{1-\sigma_{12}^2}} \exp\left\{-\frac{1}{2} \frac{z_1^2 - 2\sigma_{12}z_1z_2 + z_2^2}{1-\sigma_{12}^2}\right\}$$

$$\sigma_{12} = E[z_1z_2] \quad : \text{covariance or correlation}$$

z_1, z_2 平面

等確率密度を示す等高線は円

仮定 2次元空間の2変数正規分布から選択できるとする

: 2変数正規空間

\therefore 空間 \rightarrow 点 \therefore は (m_1, m_2) を中心とする円状集積

$$x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}, \quad M = \begin{pmatrix} m_1 \\ m_2 \end{pmatrix}, \quad \Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{bmatrix} \quad : \text{covariance matrix}$$

$$p(x) = \frac{1}{2\pi|\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(x-M)^T \Sigma^{-1}(x-M)\right\}$$

3.9 some special cases involving identical covariance matrix

例 $\Sigma_1 = \Sigma_2 = \Sigma$: $\Sigma_1 = \Sigma_2$ 一定

$\Sigma_1 = \Sigma_2$ の項を略すと

3.8 の discriminant function は

$$g_i(x) = x^t \Sigma^{-1} M_i + \log P_i - \frac{1}{2} M_i^t \Sigma^{-1} M_i$$

(線形判別関数となる)

例 $R=2$

$$g(x) = x^t \Sigma^{-1} (M_1 - M_2) - \frac{1}{2} M_1^t \Sigma^{-1} M_1 + \frac{1}{2} M_2^t \Sigma^{-1} M_2 + \log \frac{P_1}{P_2}$$

$g(x) = 0$ は $\Sigma^{-1} M_1$ と $\Sigma^{-1} M_2$ の垂直二等分線

例 $\Sigma = I$ (単位行列) and $P_i = \frac{1}{R}$

$$g_i(x) = x \cdot M_i - \frac{1}{2} M_i \cdot M_i$$

(2 章の点に関する最小二乗判別法と同じ)

3.10 training with normal pattern sets

正規分布に対する最適分類機械の存在 = 線形機械の存在は分布の形だけで決まる。

例 R の category に属する例 n 個 = n 次元集合が与えられる

sample statistics

x_1, x_2, \dots, x_n

$$\langle x \rangle_i = \frac{1}{N_i} \sum_{x \in \mathcal{X}_i} x \quad ; \text{ sample mean}$$

$$\langle \Sigma \rangle_i = \frac{1}{N_i} \sum_{x \in \mathcal{X}_i} (x - \langle x \rangle_i)(x - \langle x \rangle_i)^t \quad ; \text{ sample covariance matrix}$$

この M_i, Σ_i の推定値 \rightarrow 判別関数 : 10 次元訓練法

$Q_i = \xi_i$ の pattern 行列となる matrix

$$\langle \Sigma \rangle_i = \frac{1}{N_i} Q_i Q_i^t$$

注意 以上は Σ_i は正則として

Σ_i が nonsingular $\rightarrow N_i \geq d$ かつ $\langle \Sigma \rangle_i$ も singular

3.11. learning the mean vector of normal patterns

仮定

共分散行列はすべて既知, 平均ベクトルのラングラム変数
仮定 pattern vector は上の仮定をみたす正規分布とする。

既知の任意の M に対する X の分布

$$P(X|M) \sim N(M, \Sigma)$$

仮定. $P(M) \sim N(\mu, K)$

$\Rightarrow X = \Sigma + M$ とする Σ : 平均 0, 共分散行列 Σ

$$\therefore P(X) \sim N(\mu, \Sigma + K)$$

Chapter 4

4.1 TLUの1-パラメータ形訓練

- 仮定 • 訓練部分集合は線形分離可能

この章での訓練法

重みの調整を繰返して行う。すなわち、hyperplaneの位置と方向を繰返して変化する。

4.2 重み空間

$\pi = (x_1, \dots, x_d, 1)$ 付加ノード = ベクトル

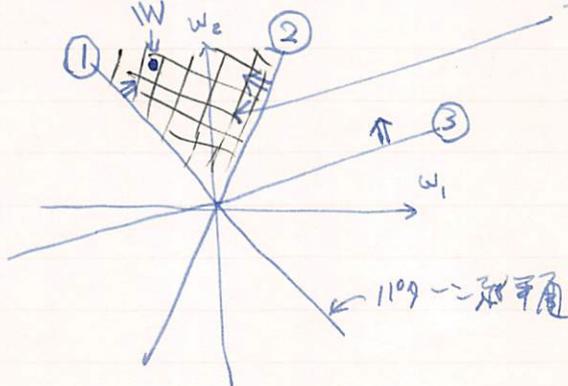
x の線形識別関数 $f(x) = \pi \cdot W$

$W \cdot \pi = 0$: ノード = 超平面

解重みベクトル W

$$\begin{cases} \pi \cdot W > 0 & y_1 \text{ に属する } \pi \\ \pi \cdot W < 0 & y_2 \text{ " } \end{cases}$$

この解重み点 W のすべてを名づける: 解地域



4.3 TLU training procedures

$$W' = W + c\pi \quad c: \text{訂正増分}$$

(注) 重み点を n 次元超平面に垂直に移動する手順に限る。
誤り訂正訓練手順

1. 固定増分法

c : positive constant

2. 絶対訂正法

$$c = \min \left\{ x; x > \frac{|W \cdot \pi|}{\pi \cdot \pi} \text{ and } x: \text{integer} \right\}$$

3. 倍数訂正法

$$c = \lambda \frac{|W \cdot \pi|}{\pi \cdot \pi}, \lambda: \text{positive}$$

1, 2. は有限回の訂正で解重みベクトルに至る: 収束性

4.4 a numerical example of error correction training

4.5 an error-correction training procedure for $R > 2$.

仮定 訓練 n 次元集合 Y は y_1, \dots, y_R に線形分離可能

識別関数 $f_i(x) = W^{(i)} \cdot x \quad i = 1, \dots, R$

i category の x について

$f_i(x) < f_j(x)$ とき

$$\begin{cases} W^{(i)'} = W^{(i)} + c\pi \\ W^{(j)'} = W^{(j)} - c\pi \end{cases}$$

4.5 applications to Φ machines

Φ machine の訓練 (→ 応用... 追加)

Chapter 5

5.1 the fundamental training theorem

Theorem 5.1

既 訓練部分集合 y_1 と y_2 が 線形分離可能

↓ S_W は、初々重みベクトル W_1 , 固定増分法、訓練列 S_{Y_1} による重みベクトル列とする。

↓ 有限 k_0 で

$$W_{k_0} = W_{k_0+1} = W_{k_0+2} = \dots$$

5.2 notation

$$y_2^* \rightarrow y_2' = \{-\pi_1^{(2)}, -\pi_2^{(2)}, \dots, -\pi_{N_2}^{(2)}\}$$

調整された訓練集合 $y' = y_1 + y_2'$

$\pi \cdot W > 0$ 但し $\pi \in y'$ なる W の場合、 y' は "線形分離可能" である

$$S_{Y'} = \pi_1', \pi_2', \dots, \pi_{N'}'$$

$\pi_{N'}' \cdot W_{k_0} > 0$ なる $\pi_{N'}'$ を省略すると

$$S_{Y'} = \pi_1', \pi_2', \dots$$

$$S_{\hat{W}} = \hat{W}_1, \hat{W}_2, \dots$$

$S_{\hat{W}}$ = 線区 (か) $\pi_2 \dots$ かし。

$W_{k_0+1} = W_{k_0+2}$ 終了。

theorem 5.1 の proof \Rightarrow 終了のあとに proof

5.3 proof 1

$$\left\{ \begin{aligned} |W_{k+1}|^2 &\geq \frac{(\hat{W}_{k+1} \cdot W)^2}{|W|^2} \geq \frac{1}{|W|^2} \left(\sum_{j=1}^k \hat{y}_j \cdot W \right)^2 \geq \frac{(ka)^2}{|W|^2} \\ |W_{k+1}|^2 &\leq \sum_{j=1}^k |\hat{y}_j|^2 \leq kM \end{aligned} \right.$$

5.4 proof 2

W ; 重みベクトルの解地域: 各点=頂点 \Rightarrow 凸多面体
 $W' \subset W$

$$W \cdot \pi > \frac{M+b}{2} \quad ; \quad b > 0, \quad M = \max_{\pi \in Y} |\pi|^2 \quad \text{--- ①}$$

$$W \in W' \subset \mathbb{R}^2$$

$$|W - \hat{W}_j|^2 = W \cdot W - 2W \cdot W_j + W_j \cdot W_j$$

\therefore

$$d_{k+1} = |W - \hat{W}_k|^2 - |W - \hat{W}_{k+1}|^2$$

$$\rightarrow \hat{W}_{k+1} = \hat{W}_k + \hat{\pi}_k \quad \text{かつ} \quad \hat{W}_k \cdot \hat{\pi}_k \leq 0$$

$$\therefore d_{k+1} \geq 2W \cdot \hat{\pi}_k - \hat{\pi}_k \cdot \hat{\pi}_k \geq 2W \cdot \hat{\pi}_k - M \quad \text{--- ②}$$

①, ②より

$$\underline{d_{k+1} > b > 0}$$

5.5

a training theorem for R-category linear machines

y_1, y_2, \dots, y_R

o 各 $\pi \in y_i$ $i=1$ に対し $\pi \cdot W_i > \pi \cdot W_j$ ($j=1, \dots, R, j \neq i$)

\rightarrow " \downarrow

$\{y_1, y_2, \dots, y_R\}$ は linearly separable

\rightarrow " \downarrow

望み ("分類を実行する線形機械") が存在する。

o 一般化した固定増分誤り訂正訓練手順

$$S_{W_1} = W_1^{(1)}, W_2^{(1)}, \dots$$

\vdots

$$S_{W_R} = W_R^{(1)}, W_R^{(2)}, \dots$$

$$(a) \quad W_i^{(k)} \cdot \pi_k > W_j^{(k)} \cdot \pi_k \quad \pi_k \in y_i, j=1, \dots, R, j \neq i \Rightarrow W_j^{(k+1)} = W_j^{(k)}$$

$$(b) \quad W_i^{(k)} \cdot \pi_k \leq W_j^{(k)} \cdot \pi_k \quad \text{" } l, j=1, \dots, R, j \neq l+i \quad \left[\begin{array}{l} j=1, \dots, R \\ j \neq l+i \end{array} \right]$$

$$\Rightarrow W_i^{(k+1)} = W_i^{(k)} + C \pi_k$$

$$W_l^{(k+1)} = W_l^{(k)} - C \pi_k$$

$$W_j^{(k+1)} = W_j^{(k)} \quad \text{但} \quad j=1, \dots, R, \quad \begin{array}{l} j \neq l \\ j \neq l+i \end{array}$$

5.6 $R=2$ の場合の関連訓練定理.
定5.3の proof ?