


- パターン認識: 「パターンをそれが属すべきカテゴリに対応づける操作」
 - パターン: 「空間的または時間的に観測可能な事象であって, 観測された対象どうしが同一であるか(または似ているか) 否かを判定できるような性質を備えているもの」
 - カテゴリ(またはクラス): 「パターン認識の結果, 同等とみなされるパターンの集合概念」
- パターン認識の過程
 - 観測: 入力パターンを認識系の内部に取り込む操作
 - 前処理: 後段の処理をしやすいするための予備的処理
 - 特徴抽出: カテゴリの選択に役立つようなパターン特有の性質を担うごく少数の特徴量(数値, 記号)の組(特徴パラメータ)を取り出す.
 - 決定: 抽出された特徴パラメータの値を用いて, 入力パターンが所属するとみなされるカテゴリをきめる.
- パターン空間
 - パターンベクトル: パターンを表す n 個の数値の組
$$\boldsymbol{x} = (x_1, x_2, \dots, x_n)$$
 - パターン空間: パターンベクトルのつくる空間. もともとよく似ていたパターンはパターン空間の中でも近くにある.
- 特徴空間
 - 特徴ベクトル: パターンに関する本質的な情報を含む少数個の数値の組. 位相を崩さずに次元数を極力減らす.

特徴ベクトルと特徴空間の例



5 × 5 メッシュによる 2 値パターン

- パターン

$$\boldsymbol{x} = (x_1, x_2, \dots, x_{25})$$

- 特徴量


$$\begin{cases} x_j = 1 & (\text{黒: 文字部分}) \\ x_j = 0 & (\text{白: 背景部分}) \end{cases} \quad (1 \leq j \leq 25)$$

- パターンの組み合わせ: $2^{25} = 33554432$ 通り

- 出力カテゴリ: 0 から 9 までの数字

$$\Omega = \{\omega_1, \omega_2, \dots, \omega_{10}\} \quad (c = 10)$$

決定則の例




入力パターン

- 全数記憶方式: 33554432通りのすべてのパターンの参照テーブルをつくる。
 - もっとも簡単な識別法
 - 記憶容量, テーブル作成作業が膨大
- 最近傍決定則: 入力パターンともっとも距離の近いプロトタイプの種類を選ぶ。

$$\min_{p=1, \dots, n} \{D(\mathbf{x}, \mathbf{x}_p)\} = D(\mathbf{x}, \mathbf{x}_k) \Rightarrow \mathbf{x} \in \omega_k$$

- 特徴空間の分割法 (3 と 8 は似ている)
- プロトタイプの選び方 (6 と回転した 9 の識別)



領域分割とプロトタイプ

重みベクトル

- 2分識別器 (正のクラスと負のクラスを識別):

$$f : X \subset R^n \rightarrow R \quad \text{s.t.} \quad \begin{cases} \text{if } \mathbf{x} \in P : f(\mathbf{x}) \geq 0 \\ \text{otherwise} : f(\mathbf{x}) < 0 \end{cases}$$


ただし $P \subset X$ は正のクラス

- 線形識別器

$$f(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b = \sum_{i=1}^n w_i x_i + b$$

ただし $(\mathbf{w}, b) \in (R^n, R)$ はパラメータ

- 線形識別可能性: 線形識別器でカテゴリズ可能かどうか
- 識別面: R^n における R^{n-1} 超平面
 - パラメータ数: $n + 1$
 - n 次元は R^n における平面の法線ベクトル w の次元
 - 1 次元は平面の原点からの距離 b



パーセプトロン

- F. Rosenblatt: The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological Review*, 65: 386-408, 1959 1960.
- M. L. Minsky and S. A. Papert: Perceptrons, MIT Press, 1969. Expanded Edition 1990.

- 入力空間: $X \subset R^n$

- 出力カテゴリ: $Y = -1, 1$

- トレーニングデータ: $S = ((\mathbf{x}_1, y_1), \dots, (\mathbf{x}_\ell, y_\ell)) \subset (X \times Y)^\ell$

- パーセプトロン:

Given linearly separable training set S and learning rate $\eta > 0$

$\mathbf{w}_0 = \mathbf{0}; b_0 = 0; k = 0$

$R = \max_{1 \leq i \leq \ell} \|\mathbf{x}_i\|$

do

 for $i = 1$ to ℓ

 if $y_i(\langle \mathbf{w}_k, \mathbf{x}_i \rangle + b_k) \leq 0$ then

$\mathbf{w}_{k+1} = \mathbf{w}_k + \eta y_i \mathbf{x}_i$

$b_{k+1} = b_k + \eta y_i R^2$

$k = k + 1$

 end if

 end for

until no mistakes made within the for loop


return $k, (\mathbf{w}_k, b_k)$ where k is the number of mistakes

マージン

- 超平面 (w, b) に関するトレーニングデータ (x_i, y_i) のマージン

$$\gamma_i = y_i(\langle w, x_i \rangle + b)$$

- $\gamma_i > 0$ ならば (x_i, y_i) に関して正しい識別



- 超平面 (w, b) に関するトレーニングセット S のマージン: トレーニングデータに関するマージンの最小値
- トレーニングセット S のマージン: すべての超平面 (w, b) に関するトレーニングセット S のマージンの最小値

収束定理

- 定理: (Novikoff) Let S be a non-trivial training set, and let

$$R = \max_{1 \leq i \leq \ell} \|\mathbf{x}_i\|.$$

Suppose that there exists a vector \mathbf{w}_{opt} such that $\|\mathbf{w}_{opt}\| = 1$ and

$$y_i(\langle \mathbf{w}_{opt}, \mathbf{x}_i \rangle + b_{opt}) \geq \gamma$$

for $1 \leq i \leq \ell$. Then the number of mistakes made by the on-line perceptron algorithm on S is at most

$$\left(\frac{2R}{\gamma}\right)^2.$$

- 間違いの回数に上限 \implies 有限回の繰り返しで収束
- 線形識別可能性を仮定
- 線形識別可能でなければ修正を繰り返し収束しない
- 線形識別可能性の判断には使えない
- 途中で打ち切った場合, そのときの重みが最適かどうかわからない

- カテゴリ: $\omega_1, \dots, \omega_c$
- 学習パターン: $\mathcal{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$
- 教師ベクトル: $\mathbf{b}_1, \dots, \mathbf{b}_n$

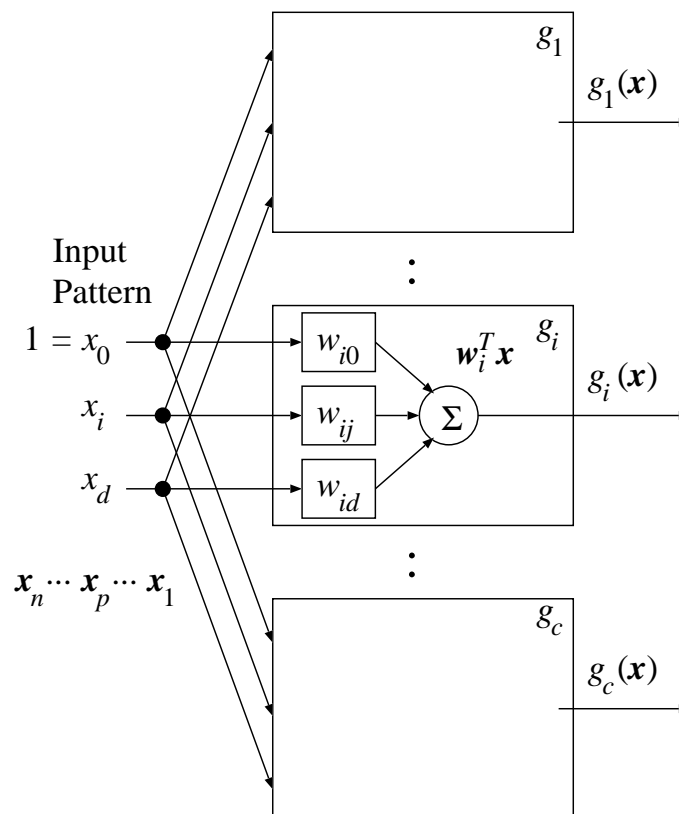
$$\mathbf{b}_p = [b_{1p}, \dots, b_{cp}]^T$$

- 出力ベクトル: $\mathbf{g}(\mathbf{x}_p) = [g_1(\mathbf{x}_p), \dots, g_c(\mathbf{x}_p)]^T$

- 線形識別関数

$$g_i(\mathbf{x}_p) = w_{i0} + \sum_{j=1}^d w_{ij} x_{pj} = \mathbf{w}_i^T \mathbf{x}_p$$

$$\mathbf{w}_i = [w_{i0}, w_{i1}, \dots, w_{id}]^T, \quad \mathbf{x} = [1, x_{p1}, \dots, x_{pd}]^T$$



評価関数

- 誤差: $\boldsymbol{\varepsilon}_p = [\varepsilon_{1p}, \dots, \varepsilon_{cp}]^T = \mathbf{g}(\mathbf{x}_p) - \mathbf{b}_p$


$$\varepsilon_{ip} = g_i(\mathbf{x}_p) - b_{ip}$$

- パターン \mathbf{x}_p に対する評価関数: J_p

$$J_p(\mathbf{w}_1, \dots, \mathbf{w}_c) = \frac{1}{2} \|\boldsymbol{\varepsilon}_p\|^2 = \frac{1}{2} \sum_{i=1}^c \varepsilon_{ip}^2 = \frac{1}{2} \sum_{i=1}^c (\mathbf{w}_i^T \mathbf{x}_p - b_{ip})^2$$

- 全パターンに対する評価関数: J

$$J(\mathbf{w}_1, \dots, \mathbf{w}_c) = \sum_{p=1}^n J_p(\mathbf{w}_1, \dots, \mathbf{w}_c) = \frac{1}{2} \sum_{p=1}^n \sum_{i=1}^c (\mathbf{w}_i^T \mathbf{x}_p - b_{ip})^2$$



最適重み

- 最適重み: 評価関数 J を最小にする w_i ($i = 1, \dots, c$)

$$\frac{\partial J}{\partial w_i} = 0 \quad (i = 1, \dots, c)$$

- 全パターンに対する評価関数: J

$$J(w_1, \dots, w_c) = \frac{1}{2} \sum_{p=1}^n \sum_{i=1}^c (w_i^T x_p - b_{ip})^2$$

- 最適重み w_i は次式をみたす

$$\begin{aligned} 0 &= \frac{\partial J}{\partial w_i} = \sum_{p=1}^n (w_i^T x_p - b_{ip}) x_p = [x_1, \dots, x_n] \begin{bmatrix} w_i^T x_1 - b_{i1} \\ \vdots \\ w_i^T x_n - b_{in} \end{bmatrix} \\ &= [x_1, \dots, x_n] \left(\begin{bmatrix} x_1^T \\ \vdots \\ x_n^T \end{bmatrix} w_i - \begin{bmatrix} b_{i1} \\ \vdots \\ b_{in} \end{bmatrix} \right) = X^T (X w_i - \bar{b}_i) \end{aligned}$$

ただし (X はパターン行列と呼ばれる)

$$X = [x_1, \dots, x_n]^T, \quad \bar{b}_i = [b_{i1}, \dots, b_{in}]^T$$

[注意:] \bar{b}_i は教師ベクトル b_p とは以下の関係がある .

$$[b_1, \dots, b_n] = \begin{bmatrix} b_{11} & \cdots & b_{1n} \\ \vdots & \cdots & \vdots \\ b_{c1} & \cdots & b_{cn} \end{bmatrix} = \begin{bmatrix} \bar{b}_1^T \\ \vdots \\ \bar{b}_c^T \end{bmatrix}$$

- 最適重み

$$w_i = (X^T X)^{-1} X^T \bar{b}_i$$

- 最急降下法 (パターンが提示されるたびに修正を行う)

$$\mathbf{w}'_i = \mathbf{w}_i - \rho \frac{\partial J_p}{\partial \mathbf{w}_i} \quad (i = 1, \dots, c)$$

$$J_p(\mathbf{w}_1, \dots, \mathbf{w}_c) = \frac{1}{2} \sum_{i=1}^c (\mathbf{w}_i^T \mathbf{x}_p - b_{ip})^2$$

ここで $\varepsilon_{ip} = \mathbf{w}_i^T \mathbf{x}_p - b_{ip}$ に注意すると

$$\frac{\partial J_p}{\partial \mathbf{w}_i} = \frac{\partial J_p}{\partial \varepsilon_{ip}} \frac{\partial \varepsilon_{ip}}{\partial \mathbf{w}_i} = \varepsilon_{ip} \mathbf{x}_p$$

であるから

$$\mathbf{w}'_i = \mathbf{w}_i - \rho \varepsilon_{ip} \mathbf{x}_p = \mathbf{w}_i - \rho (\mathbf{w}_i^T \mathbf{x}_p - b_{ip}) \mathbf{x}_p \quad (i = 1, \dots, c)$$

を得る . これを Widrow-Hoff の学習則という .

パーセプトロン(再)

- 学習: \mathcal{X}_i に属するすべての \boldsymbol{x} に対して

$$g_i(\boldsymbol{x}) > g_j(\boldsymbol{x}) \quad (j = 1, \dots, c, j \neq i)$$

が成り立つように重み w_i を決定すること .

- 学習アルゴリズム

1. 重みベクトル w_i の初期値を適当に設定する .
2. \mathcal{X}_i のなかから学習パターンをひとつ選ぶ .
3. 識別関数

$$g_i(\boldsymbol{x}) = \boldsymbol{w}_i^T \boldsymbol{x}$$

によって識別を行い, 誤識別を生じた場合 (w_i に属するパターンを w_j と誤ったとする) のみ次式により重みベクトルを修正する .

$$\boldsymbol{w}'_i = \boldsymbol{w}_i + \rho \boldsymbol{x}$$

$$\boldsymbol{w}'_j = \boldsymbol{w}_j - \rho \boldsymbol{x}$$

4. 上の処理, 2, 3 を \mathcal{X}_i の全パターンに対して繰り返す .
5. \mathcal{X}_i の全パターンを正しく識別できたら終了, 誤りがあるときには 2 に戻る .

誤差評価とパーセプトロン

- 教師信号

$$b_{ip} = \begin{cases} 1 & (\mathbf{x}_p \in \omega_i) \\ 0 & (\mathbf{x}_p \notin \omega_i) \end{cases} \quad (i = 1, \dots, c)$$

- 出力にしきい値関数 T_i を施す

$$T_i(u) = \begin{cases} 1 & (u > 0) \\ 0 & (u \leq 0) \end{cases} \quad (i = 1, \dots, c)$$

- Widrow-Hoff 学習規則 (パターン $\mathbf{x}_p \in \omega_i$ を ω_j と誤認識したとき)

$$\begin{cases} \mathbf{w}'_i = \mathbf{w}_i + \rho(g_i(\mathbf{x}_p) - b_{ip})\mathbf{x}_p = \mathbf{w}_i + \rho\mathbf{x}_p \\ \mathbf{w}'_j = \mathbf{w}_j + \rho(g_j(\mathbf{x}_p) - b_{jp})\mathbf{x}_p = \mathbf{w}_j - \rho\mathbf{x}_p \end{cases}$$

- パーセプトロンは Widrow-Hoff 学習規則の一種 !?

