

# パターン認識と学習

岡山大学大学院

講師 竹内孔一

## 本日の内容

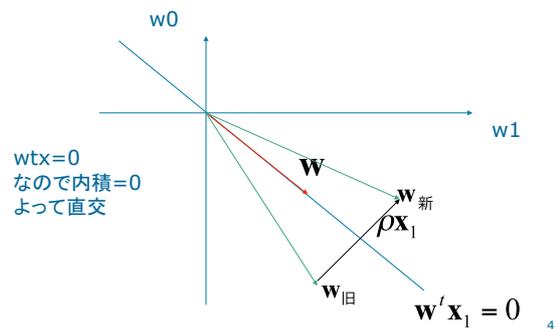
- 学習
  - Perceptron
  - Widrow-hoff learning-rule
    - 平均二乗誤差を最小

## パーセプトロン

- 特徴
  - 簡易な手続きで表現
  - 線形分離可能ならば必ず解を見つける
  - 2値分類
  - 収束する理由(その1)
    - 誤ったときに正しい方向に $p$ だけ進める

<http://neuron.eng.wayne.edu/>  
学習モデルのいろいろ

## 直交について



## 学習規則

- 識別関数  $g1(x)-g2(x)=w^t x$ 
  - $g(x) = w^t x > 0 \quad x \in A1$
  - $g(x) = w^t x < 0 \quad x \in A2$
- 学習規則 (線形分離可能な場合のみ)
  - wの初期値を決める
    - 学習パターンを1つ選ぶ
    - $w' = w + px$  (A1をA2と誤るとき)
    - $w' = w - px$  (A2をA1と誤るとき)
    - 全パターンに対して繰り返す
    - 誤りがなくなるまで上記を繰り返す

## 例題

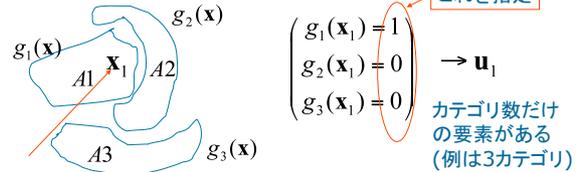
- $w=(2,-6)$ は  $x_1$ に対して誤るので $p=1$ として修正した図を書け

## Widrow-hoffの学習規則

- 何をするもの?
  - 識別関数を学習させる
- アイデア
  - 学習データ $x_p$ に対して教師信号 $u_p$ を用意
  - 誤差を最小にする
- 得られるもの
  - 重回帰分析
  - widrow-hoff学習規則(パーセプトロンも含む)

## 教師信号と正解の違い

- 従来の正解(学習パターン) ( $x_1, A_1$ )
  - ベクトルと正解のセット
- 教師信号  $u_p$ 
  - 各学習パターンについて識別関数でどう出力されたいか指定する(より強い指定)



## 練習4

- 次の誤差を求めなさい  
 識別関数  $g(x_p)$  の値が  $g(x_p) = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$   
 であるとき教師信号は  $u_p = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$  であるとする

## 2つの解法

- 解析的手法
  - 誤差最小 → 誤差の式(2乗)を微分=0
  - 直接解が求まる  
(欠点) 式は求まっても実際計算が無理
    - 大次元行列計算
- 数値解析による手法
  - 最急降下法
  - 逐次更新によって最小値を求める

## 練習5

- 式(A)が(B)に変換できることを確認せよ

$$\frac{1}{2} \sum_{p=1}^N \sum_{i=1}^C (\mathbf{w}'_i \mathbf{x}_p - u_{ip})^2 \quad (A)$$

$$\frac{1}{2} \sum_{i=1}^C \|\mathbf{X} \mathbf{w}_i - \mathbf{u}_{ip}\|^2 \quad (B)$$

まず  $\mathbf{w} \mathbf{x}$  の項に関して **回答**

入れ替えを考える

$$\sum_{p=1}^n \mathbf{w}'_i \mathbf{x}_p = (w_{i0} \quad \dots \quad w_{id}) \begin{pmatrix} x_0 \\ \vdots \\ x_d \end{pmatrix}_{p=1} + \dots + \begin{pmatrix} x_0 \\ \vdots \\ x_d \end{pmatrix}_{p=n}$$

$$= (x_0 \quad \dots \quad x_d)_{p=1} \begin{pmatrix} w_{i0} \\ \vdots \\ w_{id} \end{pmatrix} + \dots + (x_0 \quad \dots \quad x_d)_{p=n} \begin{pmatrix} w_{i0} \\ \vdots \\ w_{id} \end{pmatrix} \quad (k1)$$

$$(K1) \text{は} \begin{pmatrix} (x_0 & \dots & x_d)_{p=1} \\ \vdots \\ (x_0 & \dots & x_d)_{p=n} \end{pmatrix} \begin{pmatrix} w_{i0} \\ \vdots \\ w_{id} \end{pmatrix} = \mathbf{X} \mathbf{w}_i \text{ の各要素を足し算したもので表せられる} \quad (k2)$$

## 回答

次に全体で考えてみよう

$$\sum_{p=1}^n (\mathbf{w}'_i \mathbf{x}_p - u_{ip})^2 = (\mathbf{w}'_i \mathbf{x}_1 - u_{i1})^2 + \dots + (\mathbf{w}'_i \mathbf{x}_n - u_{in})^2$$

この部分を行列で表そうとするとk2の (k3) 関係を利用して

$$\begin{pmatrix} (x_0 & x_d)_{p=1} \\ \vdots \\ (x_0 & x_d)_{p=n} \end{pmatrix} \begin{pmatrix} w_{i0} \\ \vdots \\ w_{id} \end{pmatrix} - \begin{pmatrix} u_{i1} \\ \vdots \\ u_{in} \end{pmatrix}$$

<=この各要素の2乗の足し算したものが上記の式(の意味)に等しいなぜかは次のスライド参照

よって上式(k3)は

$$\sum_{p=1}^n (\mathbf{w}'_i \mathbf{x}_p - u_{ip})^2 = \|\mathbf{X}\mathbf{w}_i - \mathbf{u}_i\|^2$$

となり、A式はB式に対応する

## 考察(誤差について)1/2

### 考察

$$\frac{1}{2} \sum_{p=1}^n \sum_{i=1}^C (\mathbf{w}'_i \mathbf{x}_p - u_{ip})^2$$

この式の2乗のもとと意味はノルムの2乗という意味。誤差の定義まで戻って考えてみよう

$$e_{ip} = g_i(\mathbf{x}_p) - u_{ip}$$

実はこのeはとてくせもの。e(誤差)はベクトルのノルムというのが暗に定義されているのです。つまり  $e = \|e\|$  なので先ほどの計算でも  $\|\mathbf{X}\mathbf{w} - \mathbf{b}\|$  という形にします

本当かどうか試してみましょう

識別関数がある場合(a1)と間違ってる場合(a2)の距離を実際にeで測って見ましょう

## 考察(誤差について)2/2

- 状況: 3つのクラス(A1,A2,A3)がありA2の学習データ  $x_1, x_2$  の2つについてe(誤差)を測定する

$$e_{ip} = g_i(\mathbf{x}_p) - u_{ip}$$

$g(x)$  教師

正しい識別

$$e_1 = \begin{pmatrix} 0 & 0 \\ 1 & -1 \\ 0 & 0 \end{pmatrix}$$

誤識別

$$e_2 = \begin{pmatrix} 1 & 0 \\ 0 & -1 \\ 0 & 0 \end{pmatrix}$$

eをどう計算するか?

もし各要素を単純に引き算で計算すると

$$e_1 = 0 - 0 + 1 - 1 + 0 - 0 = 0 \rightarrow \text{どっちも0となり}$$

$$e_2 = 1 - 0 + 0 - 1 + 0 - 0 = 0 \quad \text{誤りが測定できません}$$

→ノルムで計算します  $e_1 = \sqrt{0^2 + 0^2 + 0^2} = 0$  誤差が測定可能!

$$e_2 = \sqrt{(1-0)^2 + (0-1)^2 + 0^2} = \sqrt{2}$$

## 行列に関する変換(補足)p.36

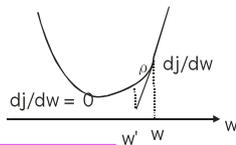
$$\begin{aligned} \sum_{p=1}^n (\mathbf{w}'_i \mathbf{x}_p) \mathbf{x}_p &= (w_{i0}, \dots, w_{id}) \begin{pmatrix} x_0 \\ \vdots \\ x_d \end{pmatrix}_{p=1} \begin{pmatrix} x_0 \\ \vdots \\ x_d \end{pmatrix}_{p=1} + \dots \\ &= (w_{i0}x_0 + \dots + w_{id}x_d)_{p=1} \begin{pmatrix} x_0 \\ \vdots \\ x_d \end{pmatrix}_{p=1} + \dots + (w_{i0}x_0 + \dots + w_{id}x_d)_{p=n} \begin{pmatrix} x_0 \\ \vdots \\ x_d \end{pmatrix}_{p=n} \\ &= \begin{pmatrix} (x_0) \\ \vdots \\ (x_d) \end{pmatrix}_{p=1} \dots \begin{pmatrix} (x_0) \\ \vdots \\ (x_d) \end{pmatrix}_{p=n} \begin{pmatrix} (w_{i0}x_0 + \dots + w_{id}x_d)_{p=1} \\ \vdots \\ (w_{i0}x_0 + \dots + w_{id}x_d)_{p=n} \end{pmatrix} \\ &= \begin{pmatrix} (x_0) \\ \vdots \\ (x_d) \end{pmatrix}_{p=1} \dots \begin{pmatrix} (x_0) \\ \vdots \\ (x_d) \end{pmatrix}_{p=n} \begin{pmatrix} (x_0 & \dots & x_d)_{p=1} \\ \vdots \\ (x_0 & \dots & x_d)_{p=n} \end{pmatrix} \begin{pmatrix} w_{i0} \\ \vdots \\ w_{id} \end{pmatrix} = \mathbf{X}' \mathbf{X} \mathbf{w}_i \end{aligned}$$

## 最急降下法

### 逐次近似

- 誤差最小値の獲得

$$\mathbf{w}' = \mathbf{w} - \rho \frac{\partial J}{\partial \mathbf{w}}$$



ある関数Jに対してwが変数であるとき、wで偏微分した傾きにrhoだけ更新する → 凸関数なら極に収束