

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 ρ 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

$$g_1(x) - g_2(x) = w^t x$$

$$g(x) = w^t x > 0 \quad x \in A_1$$

$$g(x) = w^t x < 0 \quad x \in A_2$$

- 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
- $w' = w + \rho x$ （A1をA2と誤るとき）
- $w' = w - \rho x$ （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 \mathbf{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)



$$\begin{pmatrix} g_1(\mathbf{x}_1) = 1 \\ g_2(\mathbf{x}_1) = 0 \\ g_3(\mathbf{x}_1) = 0 \end{pmatrix}$$

これを指定

→ \mathbf{u}_1

カテゴリ数だけの要素がある
(例は3カテゴリ)

練習4

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

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

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

まず wx の項に関して
 入れ替えを考える

回答

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

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

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

(k2)

回答

次に全体で考えてみよう

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

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

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

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

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

この式の2乗のもとも意味は
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 $\|Xw-b\|$ という形にします

本当かどうか試してみましょう

識別関数があつてる場合(a1)と間違つてる場合(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

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

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

→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

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

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
 ρ だけ更新する → 凸関数なら極に収束