

統計解析特論 講義メモ 4 判別分析

学習データ： $(\boldsymbol{x}_1, y_1), \dots, (\boldsymbol{x}_n, y_n)$.

- 2値判別： $y \in \{+1, -1\}$
 - 迷惑メールの判別, デジカメの顔検出, 特定の疾患の診断.
- 多値判別： $y \in \mathcal{Y} = \{1, 2, \dots, G\}$
 - 文字認識, 自然言語処理.

目的

学習データと同じ分布にしたがう新たな入力 \boldsymbol{x} に対して,
ラベル y を予測する.

予測の方法

- 学習データから

仮説 $h : \mathcal{X} \rightarrow \{+1, -1\}$ を推定.

仮説：判別器 (**classifier**) ともいう.

- x のラベルを $h(x)$ で予測.

— 入力 x のラベル y を予測する手順 —

1. データ $(x_1, y_1), \dots, (x_n, y_n)$ に対して
できるだけ $h(x_i) = y_i$ となるような仮説を学習 (推定).
2. 新たな入力 x のラベルを $h(x) \in \{+1, -1\}$ で予測.

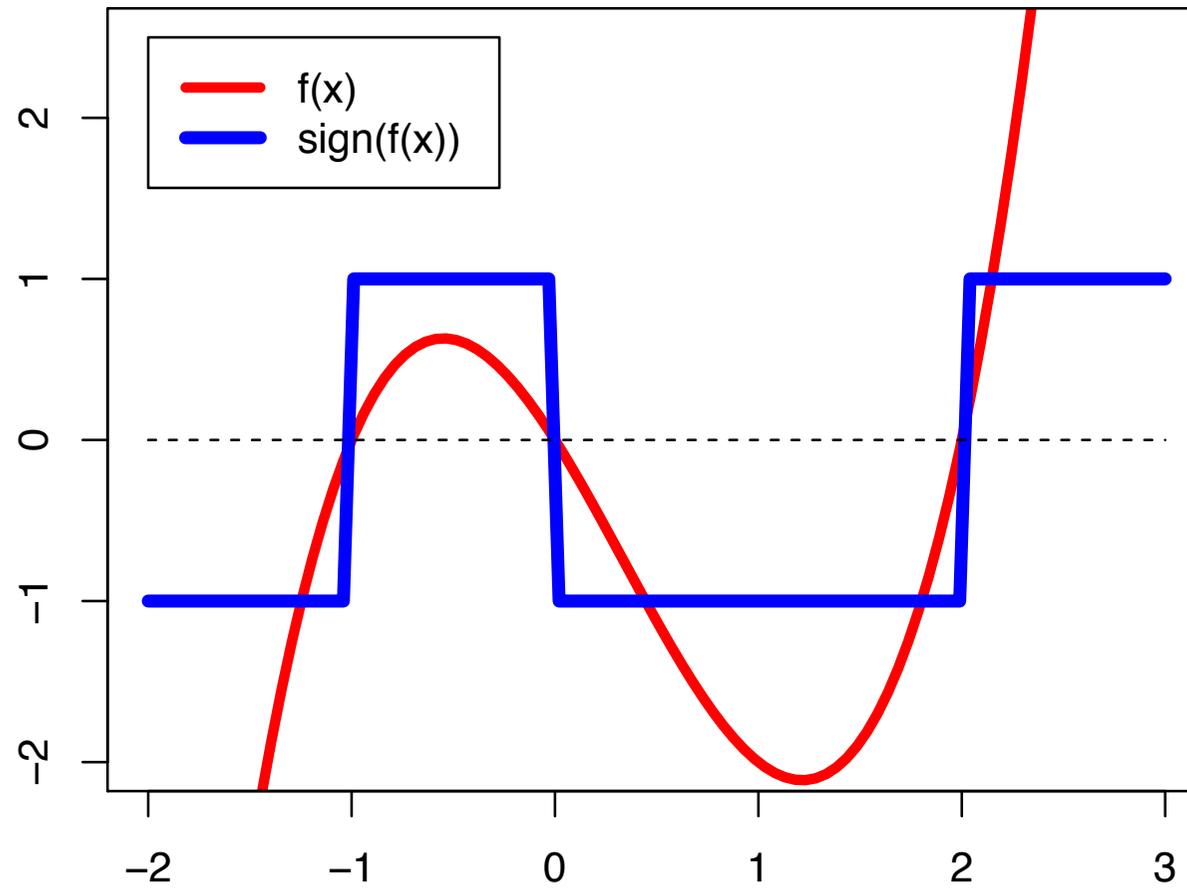
判別器のモデリング

- 判別関数 $f : \mathcal{X} \rightarrow \mathbb{R}$
- 判別関数 $f(\boldsymbol{x})$ から仮説 $h(\boldsymbol{x})$ を構成

$$h(\boldsymbol{x}) = \text{sign}(f(\boldsymbol{x}))$$

- 符号関数 : $\text{sign}(z) = +1 (z > 0), -1 (z < 0), 0 (z = 0)$
 $h(\boldsymbol{x}) = 0$ のとき : 「判別不能」, 「 ± 1 のどちらかに適当に割りふる」 など.

判別関数と仮説のプロット



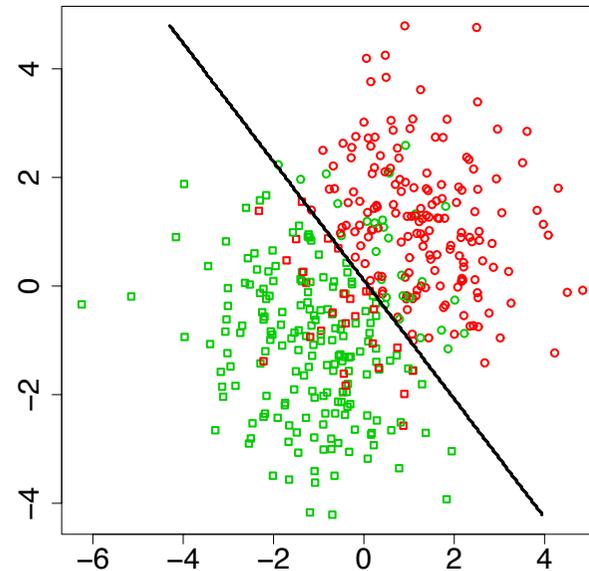
線形判別器

基底関数 $\phi : \mathcal{X} \rightarrow \mathbb{R}^d$ を定める. $\phi(x) = (\phi_1(x), \dots, \phi_d(x))$.

判別関数の集合 $\mathcal{F} = \{ f(x) = \phi(x)^T w + b \mid b \in \mathbb{R}, w \in \mathbb{R}^d \}$

線形判別器の集合 $\mathcal{H} = \{ \text{sign}(f(x)) \mid f(x) \in \mathcal{F} \}$

データから, 適切なパラメータ
 w, b を推定する



0-1 損失

データ (x, y) を判別器 $h \in \mathcal{H}$ で学習

- $h(x) = y \Rightarrow$ 正しい : **loss** = 0
- $h(x) \neq y \Rightarrow$ 間違い : **loss** = 1

定義関数を使って表現 :

$$\mathbf{0-1 損失} : \mathbf{1}[h(x) \neq y], \quad \mathbf{1}[A] = \begin{cases} 1, & A \text{ が真,} \\ 0, & A \text{ が偽.} \end{cases}$$

補足：非対称損失を用いることもある。
データ (x, y) に対して

- $h(x) = y \Rightarrow$ 正しい：損失 0
- $h(x) = 1 \ \& \ y = 0 \Rightarrow$: 損失 1
- $h(x) = 0 \ \& \ y = 1 \Rightarrow$: 損失 10

例：健康なら $y = 0$, 病気なら $y = 1$.

講義内容は、非対称損失に一般化可能.

学習誤差・予測誤差

仮説 $h : \mathcal{X} \rightarrow \{+1, -1\}$ の予測誤差と学習誤差.

- **学習誤差** : 学習データ $(x_1, y_1), \dots, (x_n, y_n)$ に対して

$$\hat{e}(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}[h(x_i) \neq y_i]$$

- **予測誤差** : 分布 $(x, y) \sim P$ に対して

$$e(h) = \Pr(h(x) \neq y) = E[\mathbf{1}[h(x) \neq y]]$$

[確率密度 $p(x, y)$ から定まる]

仮説の学習

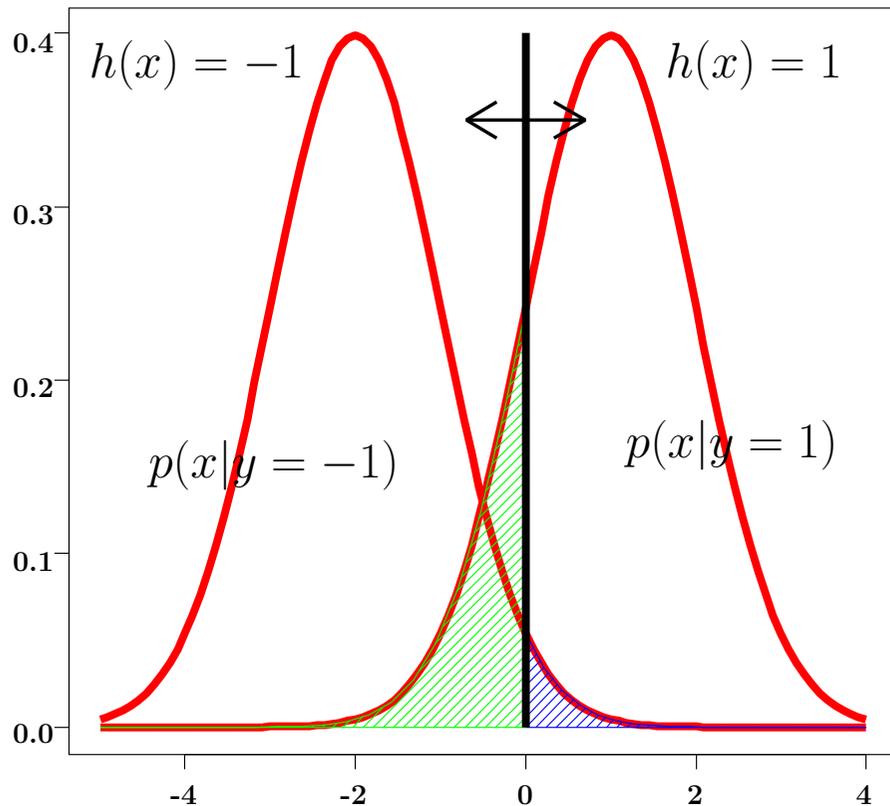
- $h(x)$ の予測精度が高い $\iff e(h)$ が小さい
 $e(h)$ を小さくする仮説 h を選びたい.
- 確率分布 P は未知なので $e(h)$ の値は分からない
- 案：代わりに $\hat{e}(h)$ を小さくする h を選ぶ

根拠：各 h に対して $\hat{e}(h) \xrightarrow{p} e(h)$, $n \rightarrow \infty$, (大数の法則)

$\implies [e(h) \text{ を最小にする } h] \simeq [\hat{e}(h) \text{ を最小にする } h]$

例：予測誤差の計算

$x \in \mathbb{R}, y \in \{1, -1\}, p(x, y) = p(x|y)p(y)$ とする



$$\begin{aligned} e(h) &= \Pr(h(X) = -1, Y = +1) \\ &\quad + \Pr(h(X) = +1, Y = -1) \\ &= \Pr(h(X) = -1 | Y = 1) \Pr(Y = 1) \\ &\quad + \Pr(h(X) = 1 | Y = -1) \Pr(Y = -1) \\ &= \text{[■の面積]} \times \Pr(Y = 1) \\ &\quad + \text{[■の面積]} \times \Pr(Y = -1) \end{aligned}$$

例 1. 線形判別器 $h(x) = \text{sign}(w^T \phi(x_i) + b)$ に対して

$$\hat{e}(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}[\text{sign}(w^T \phi(x_i) + b) \neq y_i] \rightarrow \min_{w,b}$$

- $\hat{e}(h)$ の最小化は数值的に困難
- 計算しやすい他の方法が提案されている (代替損失の理論)

講義の予定：

1. 分布 P のもとで最適な仮説：ベイズルール, ベイズ誤差.
2. 学習誤差最小による学習法の予測誤差
3. 補足：代替損失による学習

ベイズ規則, ベイズ誤差

- ベイズルール (**Bayes rule**) : 予測誤差を最小にする仮説

$$e(h_0) = \inf_{h:\text{任意の仮説}} e(h) \quad \longrightarrow \quad h_0 \text{ はベイズルール}$$

- $e(h_0)$ をベイズ誤差 (**Bayes error**) という : 予測精度の下限
- 学習の目標 : 学習データからベイズルール h_0 を推定.

Theorem 1.

2値判別 ($y \in \{\pm 1\}$) でデータの分布を $p(x, y) = \Pr(Y = y|x)p(x)$ とする.

$$\text{ベイズルール } h_0(x) = \begin{cases} +1, & \Pr(Y = +1|x) \geq \Pr(Y = -1|x), \\ -1, & \Pr(Y = -1|x) > \Pr(Y = +1|x). \end{cases}$$

$$\text{ベイズ誤差 } e(h_0) = \int \min_y \{p(x, y)\} dx$$

出現しやすいラベルを予測ラベルとするのが最適.

$$\text{note: } \Pr(Y = +1|x) \geq \Pr(Y = -1|x)$$

$$\iff p(x, +1) \geq p(x, -1)$$

補足： $\Pr(Y = y|x)p(x)$, $x \in \mathbb{R}^d$, $y \in \{+1, -1\}$ について.

$$p(x, y) = p(x|Y = y)\Pr(Y = y) = \Pr(Y = y|x)p(x)$$

Y に関する確率を表すときは \Pr と書く.

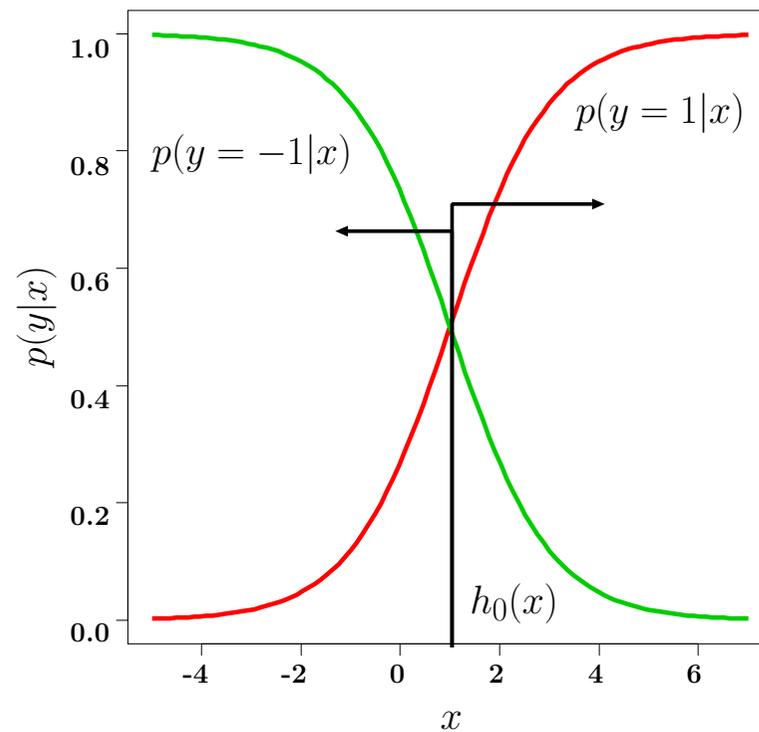
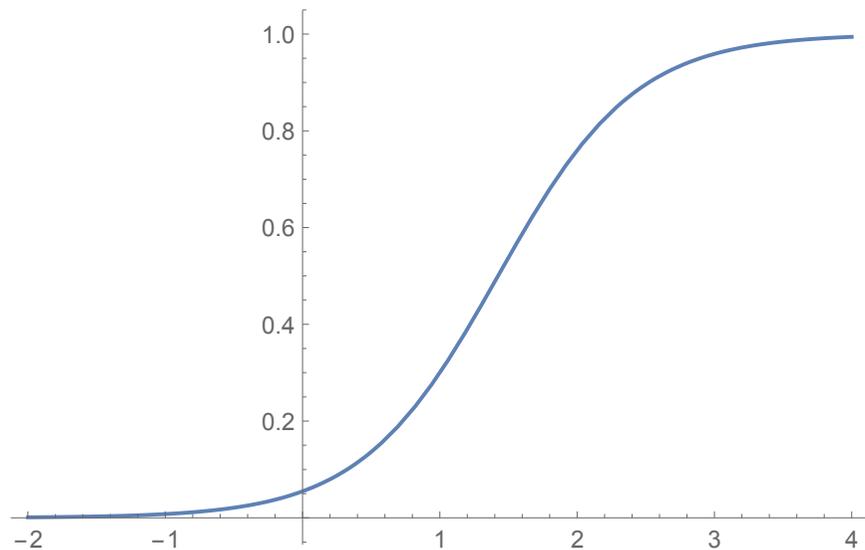
例： $x \in \mathbb{R}$, $y \in \{+1, -1\}$ とする.

$\Pr(Y = +1) = 0.3$, $p(x|Y = +1) : N(2, 1^2)$ の密度

$\Pr(Y = -1) = 0.7$, $p(x|Y = -1) : N(0, 1^2)$ の密度

$$\begin{aligned} & \Pr(Y = +1|x) \\ &= \frac{p(x|Y = +1)\Pr(Y = +1)}{\sum_{y=\pm 1} p(x|Y = y)\Pr(Y = y)} \\ &= \frac{0.3 \frac{1}{\sqrt{2\pi}} e^{-(x-2)^2/2}}{0.3 \frac{1}{\sqrt{2\pi}} e^{-(x-2)^2/2} + 0.7 \frac{1}{\sqrt{2\pi}} e^{-x^2/2}} = \frac{1}{1 + \frac{7}{3} \exp\{-2x + 2\}} \end{aligned}$$

$\Pr(Y = +1|x)$ のグラフ (x の関数としてプロット)



Theorem 1 の証明. ベイズルールへの導出.

$$\begin{aligned} e(h) &= \int \sum_{y=\pm 1} \mathbf{1}[h(x) \neq y] p(x, y) dx \\ &\geq \int \min_{y'} p(x, y') dx \\ &= \int p(x, -h_0(x)) dx \\ &= \int \sum_{y=\pm 1} \mathbf{1}[h_0(x) \neq y] p(x, y) dx \\ &= e(h_0) \end{aligned}$$

多値判別のベイズルール

- $(x, y) \in \mathcal{X} \times \mathcal{Y}$, $\mathcal{Y} = \{1, \dots, G\}$
- 確率分布 : $p(x, y) = \Pr(Y = y|x)p(x)$

$$\text{ベイズルール : } h_0(x) = \arg \max_{y \in \mathcal{Y}} \Pr(Y = y|x)$$

$$\text{ベイズ誤差 : } e(h_0) = \int (1 - \max_y p(x, y)) dx$$

note: 多値のときは(2値の拡張として)以下が成立 :

$$\sum_{y \neq h(x)} \mathbf{1}[h(x) \neq y] p(x, y) = 1 - p(x, h(x)) \geq 1 - \max_y p(x, y).$$

推定された仮説の精度

目標：推定された仮説の予測誤差を評価.

- データ $(x_1, y_1), \dots, (x_n, y_n) \sim_{i.i.d.} P$, ベイズルール $h_0(x)$.

2値判別を考える. 多値でも同様.

- 推定方法：
 - 仮説集合： $\mathcal{H} = \{h_1, \dots, h_M\}$, $|\mathcal{H}| = M < \infty$.
 - 学習誤差の最小化 (**empirical risk minimization, ERM**)

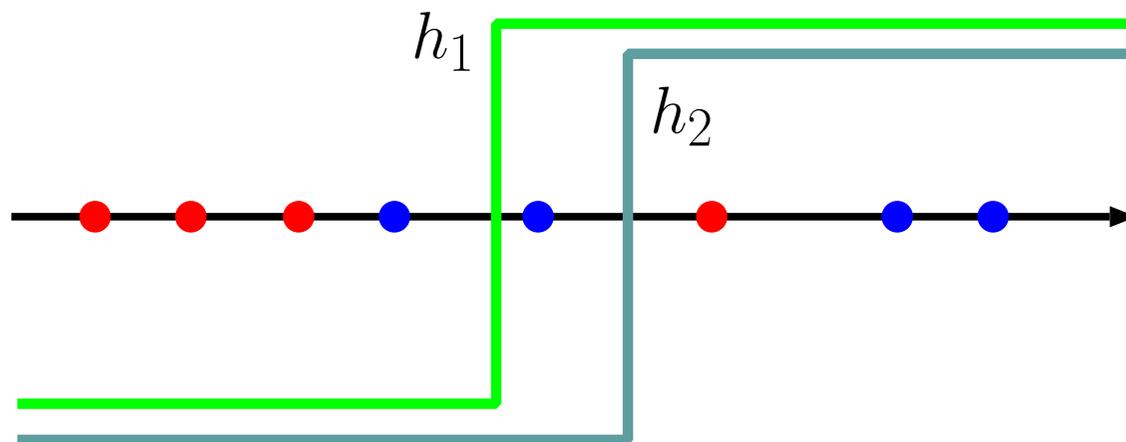
$$\hat{h} = \arg \min_{h \in \mathcal{H}} \hat{e}(h) = [\mathcal{H} \text{ のなかで } \hat{e}(h) \text{ を最小にする仮説}]$$

$$\text{補足： } \hat{e}(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}[h(x_i) \neq y_i].$$

- 目標：推定量 \hat{h} の予測誤差 $e(\hat{h})$ を評価.
note: $e(\hat{h})$ はデータに依存するので確率変数.

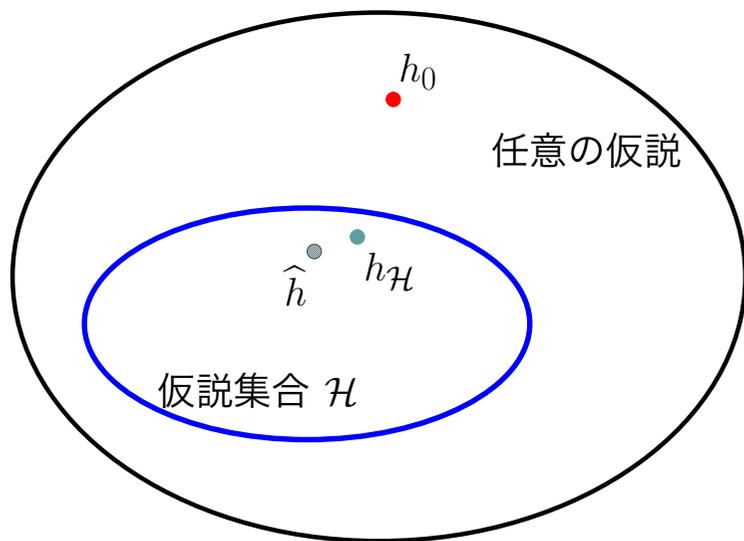
例 2.

$$\mathcal{H} = \{h_1, h_2\}, \quad \widehat{e}(h_1) = \frac{2}{8}, \quad \widehat{e}(h_2) = \frac{3}{8} \implies \widehat{h} = h_1$$



仮説集合 $\mathcal{H} = \{h_1, \dots, h_M\}$ で **Bayes**ルール h_0 を推定

- 一般に $h_0 \notin \mathcal{H}$



- $h_{\mathcal{H}} := \arg \min_{h \in \mathcal{H}} e(h)$

$$\hat{h} := \arg \min_{h \in \mathcal{H}} \hat{e}(h)$$

$$e(h_0) \leq e(h_{\mathcal{H}}) \leq e(\hat{h}), \quad \hat{e}(\hat{h}) \leq \hat{e}(h_{\mathcal{H}})$$

- 一般に $h_0 \neq h_{\mathcal{H}}$

- $e(\hat{h}) - e(h_0)$ が小さいほどよい
- $e(\hat{h}) - e(h_0) = \underbrace{[e(\hat{h}) - e(h_{\mathcal{H}})]}_{\text{推定誤差}} + \underbrace{[e(h_{\mathcal{H}}) - e(h_0)]}_{\text{近似誤差}}$

推定誤差 (≥ 0) : 観測データに依存する確率変数.

近似誤差 (≥ 0) : 仮説集合 \mathcal{H} と ベイズルール h_0 から定まる定数

推定誤差について調べる

推定量の誤差評価

$$\text{推定誤差の評価式： } \Pr\left(e(\hat{h}) - e(h_{\mathcal{H}}) < \varepsilon\right) \geq 1 - \delta$$

が成立するような ε と δ の関係を調べる.

$\varepsilon > 0, \delta \in (0, 1)$ は小さな値.

$\Pr(\dots)$: **i.i.d.** データ $(X_1, Y_1), \dots, (X_n, Y_n)$ に関する確率

- δ が与えられたとき, ε が小さいほどよい.

以下の確率を評価する.

$$\Pr\left(e(\hat{h}) - e(h_{\mathcal{H}}) \geq \varepsilon\right) \leq \delta$$

Lemma 1. 以下の不等式が成り立つ：

$$\begin{aligned} & \Pr\left(e(\hat{h}) - e(h_{\mathcal{H}}) \geq \varepsilon\right) \\ & \leq \Pr\left(e(\hat{h}) - \hat{e}(\hat{h}) \geq \varepsilon/2\right) + \Pr\left(\hat{e}(h_{\mathcal{H}}) - e(h_{\mathcal{H}}) \geq \varepsilon/2\right) \end{aligned}$$

Proof.

$$\begin{aligned} e(\hat{h}) - e(h_{\mathcal{H}}) &= (e(\hat{h}) - \hat{e}(\hat{h})) + \underbrace{(\hat{e}(\hat{h}) - \hat{e}(h_{\mathcal{H}}))}_{\geq 0} + (\hat{e}(h_{\mathcal{H}}) - e(h_{\mathcal{H}})) \\ &\leq (e(\hat{h}) - \hat{e}(\hat{h})) + (\hat{e}(h_{\mathcal{H}}) - e(h_{\mathcal{H}})) \end{aligned}$$

したがって $e(\hat{h}) - e(h_{\mathcal{H}}) \geq \varepsilon$ が成立するとき、以下のどちらかが成立する：

$$(i) \quad e(\hat{h}) - \hat{e}(\hat{h}) \geq \varepsilon/2, \quad (ii) \quad \hat{e}(h_{\mathcal{H}}) - e(h_{\mathcal{H}}) \geq \varepsilon/2$$



ヘフディング不等式

Lemma 2 (Hoeffding's inequality).

$$Z_1, \dots, Z_n \sim_{i.i.d.} P, \quad 0 \leq Z_i \leq 1, \quad \mu = E[Z_i]$$

$$\implies \Pr\left(\frac{1}{n} \sum_{i=1}^n Z_i - \mu \geq \varepsilon\right) \leq e^{-2n\varepsilon^2}.$$

$$\Pr\left(\frac{1}{n} \sum_{i=1}^n Z_i - \mu \leq -\varepsilon\right) \leq e^{-2n\varepsilon^2}$$

note: 大数の法則から $\frac{1}{n} \sum_{i=1}^n Z_i \xrightarrow{p} \mu$ は分かる.

- ヘフディング不等式から収束スピードが分かる.
- チェビシェフ不等式より良い上界.

- $\hat{e}(h) - e(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}[h(X_i) \neq Y_i] - \mathbf{E}[\mathbf{1}[h(X) \neq Y]]$

Hoeffding 不等式 で $Z_i = \mathbf{1}[h(X_i) \neq Y_i]$ とすると

$$\Pr\left(\hat{e}(h_{\mathcal{H}}) - e(h_{\mathcal{H}}) \geq \varepsilon/2\right) \leq e^{-2n(\varepsilon/2)^2},$$

$$\begin{aligned} \Pr\left(e(\hat{h}) - \hat{e}(\hat{h}) \geq \varepsilon/2\right) &\leq \Pr\left(\bigcup_{h \in \mathcal{H}} \{e(h) - \hat{e}(h) \geq \varepsilon/2\}\right) \\ &\leq \sum_{h \in \mathcal{H}} \Pr\left(e(h) - \hat{e}(h) \geq \varepsilon/2\right) \leq |\mathcal{H}|e^{-n\varepsilon^2/2}. \end{aligned}$$

note: $\mathbf{1}[\hat{h}(X_i) \neq Y_i]$, $i = 1, \dots, n$ は独立でない.

$|\mathcal{H}|$: \mathcal{H} の要素数.

$$\begin{aligned} \therefore \Pr\left(e(\hat{h}) - e(h_{\mathcal{H}}) \geq \varepsilon\right) &\leq \Pr\left(\hat{e}(\hat{h}) - e(\hat{h}) \geq \varepsilon/2\right) + \Pr\left(\hat{e}(h_{\mathcal{H}}) - e(h_{\mathcal{H}}) \geq \varepsilon/2\right) \\ &\leq (|\mathcal{H}| + 1)e^{-n\varepsilon^2/2} \\ &= \exp\{-n\varepsilon^2/2 + \log(|\mathcal{H}| + 1)\} \end{aligned}$$

したがって, $\varepsilon > 0$ に対して

$$e(\hat{h}) \geq \varepsilon + e(h_{\mathcal{H}})$$

となる確率は $\exp\{-n\varepsilon^2/2 + \log(|\mathcal{H}| + 1)\}$ 以下

$\delta = \exp\{-n\varepsilon^2/2 + \log(|\mathcal{H}| + 1)\}$ として書き直すと・・・

確率 $1 - \delta$ 以上の確率で

$$e(\hat{h}) < e(h_0) + \underbrace{[e(h_{\mathcal{H}}) - e(h_0)]}_{\text{近似誤差}} + \underbrace{\sqrt{\frac{2}{n} \log \frac{|\mathcal{H}| + 1}{\delta}}}_{\text{推定誤差}} \quad (1)$$

● 近似誤差： $b_{\mathcal{H}} := e(h_{\mathcal{H}}) - e(h_0)$.

● 推定誤差： $v_{\mathcal{H}}(n, \delta) := \sqrt{\frac{2}{n} \log \frac{|\mathcal{H}| + 1}{\delta}}$.

推定量 \hat{h} の推定誤差の上界 ($|\mathcal{H}|$ は \mathcal{H} の要素数)

(1) を書き直すと：データ数 n のとき $1 - \delta$ 以上の確率で

$$e(\hat{h}) < e(h_0) + b_{\mathcal{H}} + v_{\mathcal{H}}(n, \delta).$$

モデル選択

複数の仮説集合 $\mathcal{H}_1, \mathcal{H}_2, \dots, \mathcal{H}_K$ について次の包含関係を仮定：

$$\mathcal{H}_1 \subset \mathcal{H}_2 \subset \dots \subset \mathcal{H}_K$$

このとき以下が成立

- 近似誤差は減少： $\min_{h \in \mathcal{H}_1} e(h) \geq \min_{h \in \mathcal{H}_2} e(h) \geq \dots \geq \min_{h \in \mathcal{H}_K} e(h)$ より

$$b_{\mathcal{H}_1} \geq b_{\mathcal{H}_2} \geq \dots \geq b_{\mathcal{H}_K}$$

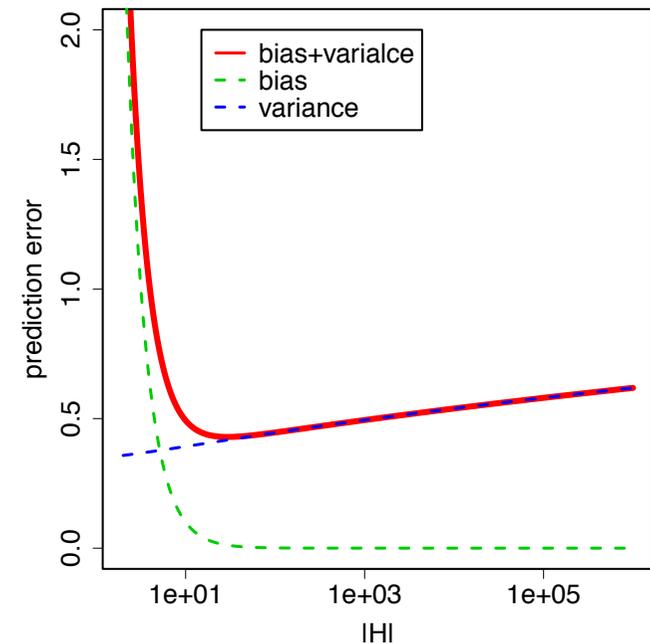
- 推定誤差は増加：データ数 n , 確率 δ が一定のとき
 $|\mathcal{H}_1| \leq |\mathcal{H}_2| \leq \dots \leq |\mathcal{H}_K|$ より

$$v_{\mathcal{H}_1}(n, \delta) \leq v_{\mathcal{H}_2}(n, \delta) \leq \dots \leq v_{\mathcal{H}_K}(n, \delta)$$

♣ $e(\hat{h})$ の上界 $e(h_0) + b_{\mathcal{H}} + v_{\mathcal{H}}(n, \delta)$ が小さいほうがよい.

♣ 適切な仮説集合: $\min_{k=1, \dots, K} b_{\mathcal{H}_k} + v_{\mathcal{H}_k}(n, \delta)$ を達成する \mathcal{H}_k

- 仮説集合: 大
⇒ 近似誤差: 小, 推定誤差: 大
- 両者の和を小さくする, ほどよい大きさの仮説集合を用いる.



note: 上の考察は $e(\hat{h})$ の確率的上界に基づいている.
期待値 $E[e(\hat{h})]$ で考えても同様の結論が得られる

仮説集合の複雑度

- 仮説集合 \mathcal{H} を用いたときの推定誤差：

$$v_{\mathcal{H}}(n, \delta) = \sqrt{\frac{2}{n} \log \frac{|\mathcal{H}| + 1}{\delta}} \leq \sqrt{\frac{2 \log(|\mathcal{H}| + 1)}{n}} + \sqrt{\frac{2 \log(1/\delta)}{n}}$$

→ \mathcal{H} の要素数が大きいほど、推定誤差が大きい。

- \mathcal{H} の要素数が ∞ のときは？
 - 仮説集合の本質的な複雑度を測る：
VC次元, ラデマツハ複雑度, 被覆数.

例 3. 基底関数 $\phi_1(x), \dots, \phi_k(x)$,

$$\mathcal{H} = \{\text{sign}(f(x)) \mid f(x) = \sum_{j=1}^k c_j \phi_j(x), c_j \in \mathbb{R}\}.$$

$$v_{\mathcal{H}}(n, \delta) = 4\sqrt{\frac{2k}{n} \log \frac{en}{k}} + \sqrt{\frac{2 \log(2/\delta)}{n}}$$

$$b_{\mathcal{H}} = e(h_{\mathcal{H}}) - e(h_0)$$

とすると, ERMは確率 $1 - \delta$ 以上で次式を満たす:

$$e(\hat{h}) < e(h_0) + b_{\mathcal{H}} + v_{\mathcal{H}}(n, \delta).$$

線形判別 $h(x) = \text{sign}(w^T x + b)$, $w \in \mathbb{R}^d, b \in \mathbb{R}$ なら $k = d + 1$.

VC theoryから得られる. cf. 「統計的学習理論」2章

代替損失 (surrogate loss)

仮説 $h(x) = \text{sign}(f(x))$ の **0-1** 損失 :

$$\mathbf{1}[h(x) \neq y] = \mathbf{1}[yf(x) \leq 0] \quad (f(x) = 0 \text{ はひとまず無視}).$$

$yf(x)$ を $((x, y)$ に対する $f(x)$ の) マージンという.

$$\hat{e}(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}[y_i f(\mathbf{x}_i) \leq 0],$$

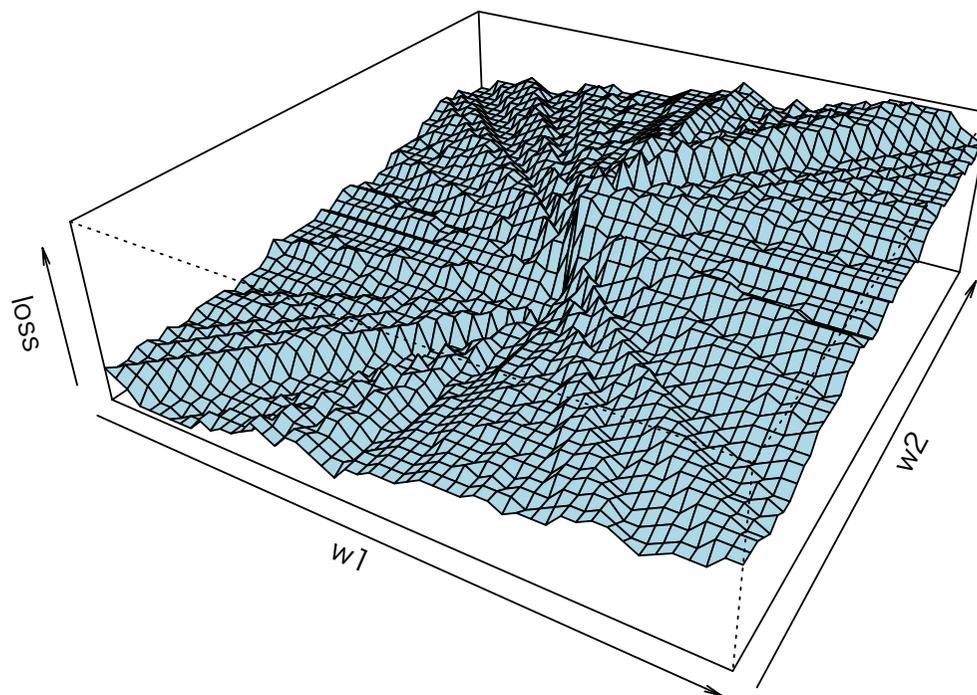
$$e(h) = \Pr(yf(x) \leq 0) = \mathbb{E}[\mathbf{1}[yf(x) \leq 0]]$$

データ上でマージン $yf(x)$ が大きいほどよい.

例：線形仮説 $f(x) = w^T x, x, w \in \mathbb{R}^2$

$$\min_w \frac{1}{n} \sum_{i=1}^n \mathbf{1}[y_i(w^T x_i) \leq 0] \quad \longrightarrow \quad \text{計算困難}$$

0-1 loss



- $\mathbf{1}[yf(x) \leq 0]$ の代わりに, 計算しやすい関数 $\ell(yf(x))$ を用いる.

例 :
$$\min_{w,b} \frac{1}{n} \sum_{i=1}^n \ell(y_i(w^T x_i + b))$$

- $\ell(u)$ が単調減少 \implies データ上で大きなマージン $yf(x)$.
- ベイズ・ルールを推定できるか？

例：(0-1 損失と共にグラフを描く)

サポートベクターマシン： ヒンジ損失

$$\ell(u) = [1 - u]_+ \quad ([z]_+ = \max\{z, 0\})$$

ブースティング： 指数損失

$$\ell(u) = e^{-u}$$

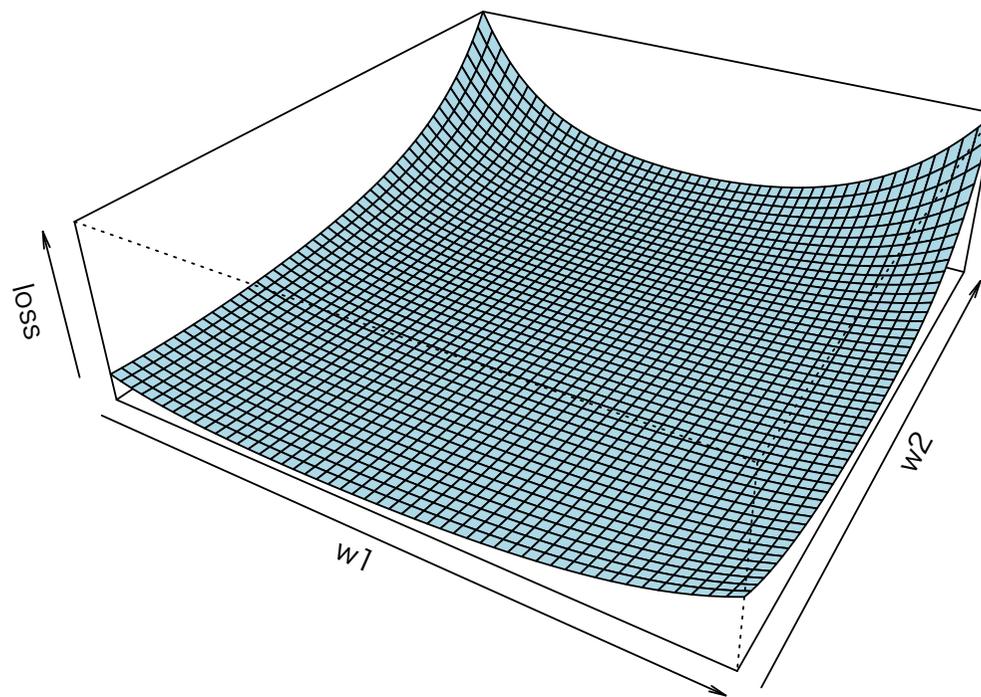
ロジスティック回帰： ロジスティック損失

$$\ell(u) = \log_2(1 + e^{-u})$$

例：線形仮説 $f(x) = w^T x, x, w \in \mathbb{R}^2$

$$\min_w \frac{1}{n} \sum_{i=1}^n e^{-y_i(w^T x_i)} \quad \longrightarrow \quad \text{計算しやすい}$$

exp loss



代替損失の下で最適な判別関数

例. 指数損失 :

$$\mathbb{E}[\ell(yf(x))] = \int \sum_y e^{-yf(x)} \Pr(Y = y|x) p(x) dx \longrightarrow f \text{ について min}$$

各 x で $\sum_y e^{-yf(x)} \Pr(Y = y|x)$ を最小にする $f(x)$ が最適 :

以下を解く.

$$\frac{\partial}{\partial f(x)} \sum_y e^{-yf(x)} \Pr(Y = y|x) = - \sum_y e^{-yf(x)} y \Pr(Y = y|x) = 0$$

$$\begin{aligned} & - e^{-f(x)} \Pr(Y = +1|x) + e^{f(x)} \Pr(Y = -1|x) = 0 \\ \implies f(x) &= \frac{1}{2} \log \frac{\Pr(Y = +1|x)}{\Pr(Y = -1|x)} \end{aligned}$$

$$\text{sign}(f(x)) = \begin{cases} +1, & \Pr(Y = +1|x) \geq \Pr(Y = -1|x), \\ -1, & \Pr(Y = +1|x) < \Pr(Y = -1|x) \end{cases}$$

- 期待指数損失を最小にする判別関数：ベイズ・ルールに対応
- ヒンジ損失, ロジスティック損失でも同様の結果.

代替lossの理論

$\ell(u)$ の条件 :

(a) $\mathbf{1}[u \leq 0] \leq \ell(u)$ を満たす.

$$\frac{1}{n} \sum_{i=1}^n \ell(y_i f(\mathbf{x}_i)) \text{ が小さい} \implies \hat{e}(\text{sign}(f)) \text{ も小さい}$$

(b) $\ell(u)$ は凸関数 (定義を示す) : 凸関数は最適化しやすい. 停留点なら最適解.

(c) $u = 0$ で $\ell(u)$ は微分可能で $\ell'(0) < 0$.

- 条件 **(a)**, **(b)**, **(c)** を満たす損失を $\ell(u)$ と判別関数の列 $\{f_n(x)\}_{n \in \mathbb{N}}$ に対して以下が成り立つ.

$$\begin{aligned} \mathbb{E}[\ell(yf_n(x))] &\longrightarrow \inf_f \mathbb{E}[\ell(yf(x))], \quad (n \rightarrow \infty) \\ \implies e(\text{sign}(f_n)) &\longrightarrow e(h_0), \quad (n \rightarrow \infty) \end{aligned}$$

意味： f_n が $n \rightarrow \infty$ で $\ell(u)$ 損失の最小値に収束するとき、 $\text{sign}(f_n)$ の予測誤差はベイズ誤差に収束する.

→ $\ell(u)$ -損失最小化を正当化

- 例に示した損失 (ヒンジ, 指数, ロジスティック) は条件を満たす.
- $\ell(u)$ は単調減少でなくてもよい. 例. $\ell(u) = (1 - u)^2$.

- Reference: Bartlett, P. L, et al., Convexity, Classification, and Risk Bounds, Journal of the American Statistical Association, 2006
- 多値判別では, $l'(u) < 0$ のような簡単な条件は得られていない.
ongoing research.