

(83342) パターン認識特論

張 潮

zhang@u-fukui.ac.jp

0776-27-8477



本日の内容

- 第1回 パターン認識のための線形代数
- 第2回 パターン認識のための確率論
- 第3回 凸最適化の概念
- 第4回 線形回帰とLMSアルゴリズム
- 第5回 分類とロジスティック回帰
- 第6回 一般化線形モデル
- 第7回 **ガウシアン判別分析と単純ベイズ分類器**
- 第8回 サポートベクターマシン(1)
- 第9回 サポートベクターマシン(2)
- 第10回 正規化とモデル選択
- 第11回 k平均法
- 第12回 混合ガウスモデルとEMアルゴリズム
- 第13回 因子分析
- 第14回 主成分分析
- 第15回 未定

今までの分類アルゴリズム の考え方

- 分類問題

- 二項分類 → ロジスティクス回帰
- 多項分類 → softmax回帰

- 回帰問題と見なす

- 最尤推定によって θ を最適化 → $p(y|x; \theta)$

- 決定境界で分類

- $p(y|x; \theta) \geq 0.5 \rightarrow y:=1$
- $p(y|x; \theta) < 0.5 \leftarrow y:=0$

判別学習アルゴリズム
discriminative learning algorithms

新しい考え方

- 逆の考え方

- $p(y|x)$ の代わりに $p(x|y)$ をモデリングしましょう
- 例: ベイズの定理を使えば $p(y|x)$ が求まる

$$p(y|x) = \frac{p(x|y)p(y)}{p(x)}.$$

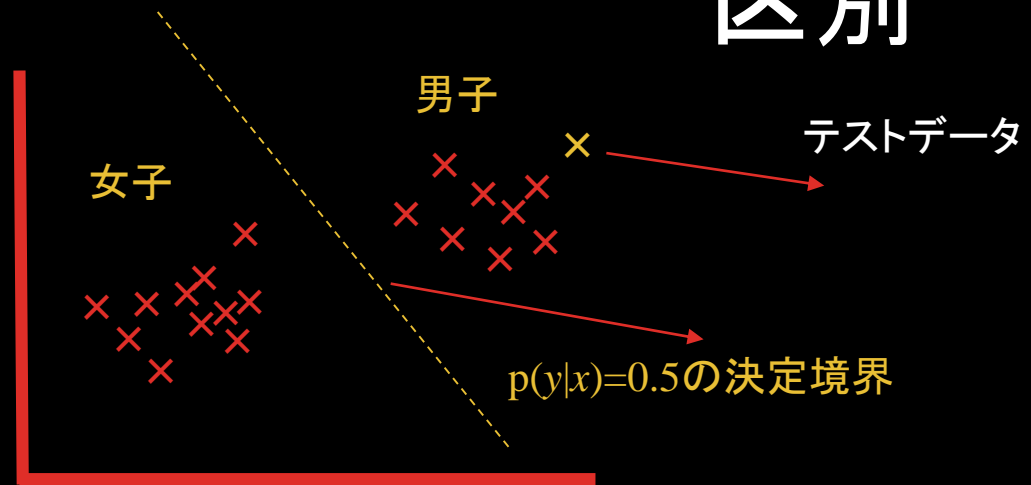
生成学習アルゴリズム
generative learning algorithms

区別

●判別モデル

$$p(y|x)$$

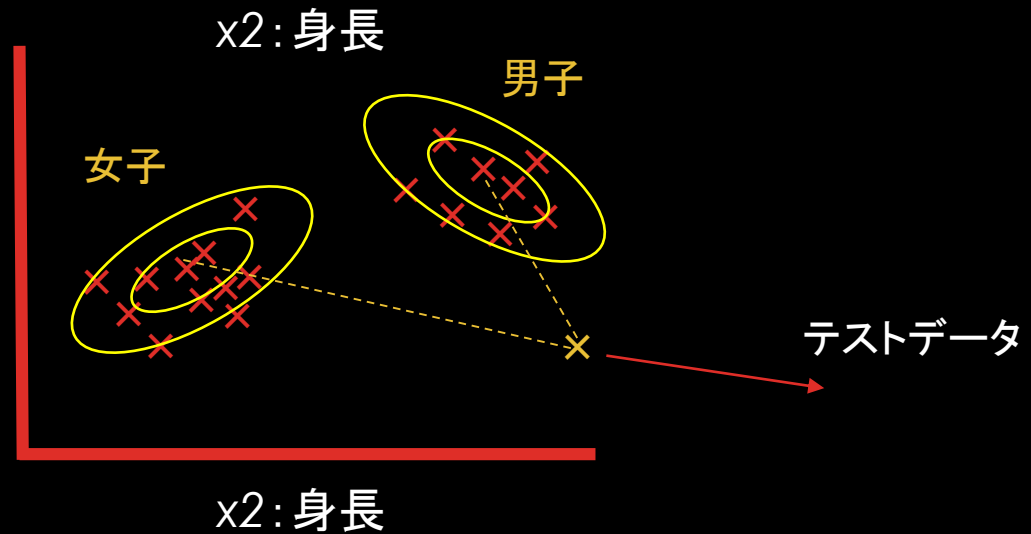
x1: 体重



●生成モデル

$$p(x|y)$$

x1: 体重



ガウシアン判別分析 Gaussian discriminant analysis (GDA)

- 生成モデルのアルゴリズム
- 多変量ガウス分布でトレーニングデータの分布をモデリング
- 多変量ガウス分布

$$p(x; \mu, \Sigma) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp \left(-\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu) \right).$$



$$\mathcal{N}(\mu, \Sigma)$$

$$\mu \in \mathbb{R}^n$$


: 平均 (mean)

$$\Sigma \in \mathbb{R}^{n \times n}$$

: 共分散行列 (covariance matrix)

ガウシアン判別分析 Gaussian discriminant analysis (GDA)

- 共分散行列は単位行列の定数倍のとき




$$\Sigma = I$$

$$\Sigma = 0.6I$$

$$\Sigma = 2I$$

ガウシアン判別分析 Gaussian discriminant analysis (GDA)


- 共分散行列は単位行列でないとき



$$\Sigma = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}; \quad \Sigma = \begin{bmatrix} 1 & 0.5 \\ 0.5 & 1 \end{bmatrix}; \quad \Sigma = \begin{bmatrix} 1 & 0.8 \\ 0.8 & 1 \end{bmatrix}$$

ガウシアン判別分析 Gaussian discriminant analysis (GDA)

- 等高線で2次元の多変量ガウス分布を描画



$$\Sigma = \begin{bmatrix} 1 & -0.5 \\ -0.5 & 1 \end{bmatrix}; \quad \Sigma = \begin{bmatrix} 1 & -0.8 \\ -0.8 & 1 \end{bmatrix}; \quad \Sigma = \begin{bmatrix} 3 & 0.8 \\ 0.8 & 1 \end{bmatrix}.$$

ガウシアン判別分析 Gaussian discriminant analysis (GDA)

● 二項分類問題

■ 考え方を式で表すと

$$\begin{aligned} y &\sim \text{Bernoulli}(\phi) \\ x|y=0 &\sim \mathcal{N}(\mu_0, \Sigma) \\ x|y=1 &\sim \mathcal{N}(\mu_1, \Sigma) \end{aligned}$$



$$\begin{aligned} p(y) &= \phi^y (1 - \phi)^{1-y} \\ p(x|y=0) &= \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} (x - \mu_0)^T \Sigma^{-1} (x - \mu_0)\right) \\ p(x|y=1) &= \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} (x - \mu_1)^T \Sigma^{-1} (x - \mu_1)\right) \end{aligned}$$

分布が違うため、平均パラメータが異なる

簡単のため、同じ設定

ガウシアン判別分析

Gaussian discriminant analysis (GDA)

- ガウシアン判別分析における最尤推定
- 対数尤度関数

$$\begin{aligned}\ell(\phi, \mu_0, \mu_1, \Sigma) &= \log \prod_{i=1}^m p(x^{(i)}, y^{(i)}; \phi, \mu_0, \mu_1, \Sigma) \\ &= \log \prod_{i=1}^m p(x^{(i)} | y^{(i)}; \mu_0, \mu_1, \Sigma) p(y^{(i)}; \phi).\end{aligned}$$

ガウシアン判別分析 Gaussian discriminant analysis (GDA)

- 対数尤度関数を最大化する

$$\ell(\theta) = \sum_{i=1}^m \log p(y^{(i)} | x^{(i)}; \theta)$$

判別モデル(線形回帰)における尤度関数

$$\begin{aligned} \ell(\phi, \mu_0, \mu_1, \Sigma) &= \log \prod_{i=1}^m p(x^{(i)}, y^{(i)}; \phi, \mu_0, \mu_1, \Sigma) \\ &= \log \prod_{i=1}^m p(x^{(i)} | y^{(i)}; \mu_0, \mu_1, \Sigma) p(y^{(i)}; \phi). \end{aligned}$$

生成モデル(GDA)における尤度関数

同時確率

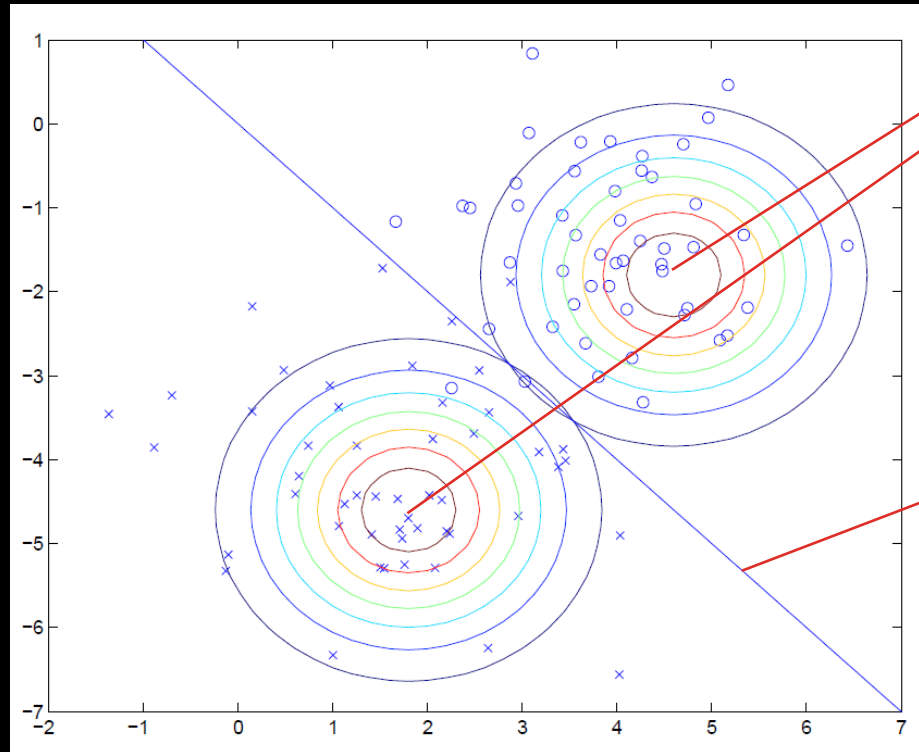
条件付き確率の定義

ガウシアン判別分析 Gaussian discriminant analysis (GDA)

- 最適なパラメータが求まる

$$\begin{aligned}\phi &= \frac{1}{m} \sum_{i=1}^m 1\{y^{(i)} = 1\} \\ \mu_0 &= \frac{\sum_{i=1}^m 1\{y^{(i)} = 0\} x^{(i)}}{\sum_{i=1}^m 1\{y^{(i)} = 0\}} \\ \mu_1 &= \frac{\sum_{i=1}^m 1\{y^{(i)} = 1\} x^{(i)}}{\sum_{i=1}^m 1\{y^{(i)} = 1\}} \\ \Sigma &= \frac{1}{m} \sum_{i=1}^m (x^{(i)} - \mu_{y^{(i)}})(x^{(i)} - \mu_{y^{(i)}})^T.\end{aligned}$$

結果の可視化



生成モデルで
求めた $p(x|y)$

判別モデルで
求めた決定境界

$$p(y = 1|x) = 0.5$$

判別モデルvs.生成モデル

- トレーニングデータの分布が仮定した分布に近づくほど、生成モデルがより有効と言える
 - non-Gaussian dataにGDAを適用しても効果が低い
- トレーニングデータの分布が仮定した分布に近いと分かれば、生成モデルは判別モデルに比べて、より少ないデータで学習できる
- サンプル数が多いかつサンプルの分布はガウスではない場合
 - ロジスティクス回帰がGDAより有効

単純ベイズ分類器

Naive Bayes

- 今までの分類問題においての特徴量ベクトル x

- 連続値



- 離散値

- 迷惑メールの分類問題で考えよう

- 一通のメールを特徴量ベクトルで表現

$$x = \begin{bmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix} \begin{array}{l} a \\ \text{aardvark} \\ \text{aardwolf} \\ \vdots \\ \text{buy} \\ \vdots \\ \text{zygmurgy} \end{array}$$

} 用語数 (vocabulary)

単純ベイズ分類器

Naive Bayes

- 生成モデル作りましょう！
 - $p(x|y)$ をモデリングする
- 用語数: 50,000
 - $x \in \{0, 1\}^{50000}$
 - 50,000次元の多変量ガウス分布を作る？ → 現実的ではない



解決方法

強い仮説を設ける



条件付き確率の定義

各特徴量の次元は条件付き独立である

$$\begin{aligned}
 & p(x_1, \dots, x_{50000} | y) \\
 &= p(x_1 | y) p(x_2 | y, x_1) p(x_3 | y, x_1, x_2) \cdots p(x_{50000} | y, x_1, \dots, x_{49999}) \\
 &= p(x_1 | y) p(x_2 | y) p(x_3 | y) \cdots p(x_{50000} | y)
 \end{aligned}$$

単純ベイズ分類器 Naive Bayes

- つまり、 $p(x|y)$ を下記通りの計算で近似する
 - (本当は、単語同士が独立していないはず)
 - 例:loveが出てきたら、youが現れる確率が高くなるはず...

$$\begin{aligned} & p(x_1, \dots, x_{50000} | y) \\ &= p(x_1 | y) p(x_2 | y, x_1) p(x_3 | y, x_1, x_2) \cdots p(x_{50000} | y, x_1, \dots, x_{49999}) \\ &= p(x_1 | y) p(x_2 | y) p(x_3 | y) \cdots p(x_{50000} | y) \\ &= \prod_{i=1}^n p(x_i | y) \end{aligned}$$

ベルヌーイ分布

単純ベイズ分類器

Naive Bayes

- 最適化したいパラメータ

- 50,000個: $\phi_{i|y=1} = p(x_i = 1|y = 1)$

- 50,000個: $\phi_{i|y=0} = p(x_i = 1|y = 0)$

- 1個: $\phi_y = p(y = 1)$

- 同時分布を利用して尤度関数を作る

$$\mathcal{L}(\phi_y, \phi_{i|y=0}, \phi_{i|y=1}) = \prod_{i=1}^m p(x^{(i)}, y^{(i)}).$$

単純ベイズ分類器

Naive Bayes

- 尤度関数を最大化することにより最適解を求める

$$\phi_{j|y=1} = \frac{\sum_{i=1}^m 1\{x_j^{(i)} = 1 \wedge y^{(i)} = 1\}}{\sum_{i=1}^m 1\{y^{(i)} = 1\}}$$

$y=1$ の迷惑メールにおいてのある
単語 x_j の出現頻度

$$\phi_{j|y=0} = \frac{\sum_{i=1}^m 1\{x_j^{(i)} = 1 \wedge y^{(i)} = 0\}}{\sum_{i=1}^m 1\{y^{(i)} = 0\}}$$

$y=0$ の迷惑メールにおいてのある
単語 x_j の出現頻度

$$\phi_y = \frac{\sum_{i=1}^m 1\{y^{(i)} = 1\}}{m}$$

$y=1$ の迷惑メールの出現頻度

単純ベイズ分類器

Naive Bayes

● 予測

$$\begin{aligned}
 p(y = 1|x) &= \frac{p(x|y = 1)p(y = 1)}{p(x)} \\
 &= \frac{(\prod_{i=1}^n p(x_i|y = 1)) p(y = 1)}{(\prod_{i=1}^n p(x_i|y = 1)) p(y = 1) + (\prod_{i=1}^n p(x_i|y = 0)) p(y = 0)},
 \end{aligned}$$

● 多項分類の場合

$$x_i \in \{1, 2, \dots, k_i\}$$

$$\begin{aligned}
 &p(x_1, \dots, x_{50000}|y) \\
 &= p(x_1|y)p(x_2|y, x_1)p(x_3|y, x_1, x_2) \cdots p(x_{50000}|y, x_1, \dots, x_{49999}) \\
 &= p(x_1|y)p(x_2|y)p(x_3|y) \cdots p(x_{50000}|y) \\
 &= \prod_{i=1}^n p(x_i|y)
 \end{aligned}$$

ベルヌーイ分布の代わりにN=1の多項分布で考えればいい

単純ベイズ分類器

Naive Bayes

- 離散値と連続値が混ざっているような特徴量の場合
 - 離散化を行う

Living area (sq. feet)	< 400	400-800	800-1200	1200-1600	>1600
x_i	1	2	3	4	5

- 広く使われているアルゴリズム
- 多くの場合、GDAより性能がいい

単純ベイズは生成モデル！（ベイズの定理を使っているため、判別モデルに見えるのですが...）

単純ベイズ分類器の改良

● 問題点

$$\phi_{j|y=1} = \frac{\sum_{i=1}^m 1\{x_j^{(i)} = 1 \wedge y^{(i)} = 1\}}{\sum_{i=1}^m 1\{y^{(i)} = 1\}}$$

→ $y=1$ の迷惑メールにおいてのある
単語 x_j の出現頻度

● 例えば、学習データに j 番目の単語:hacker が一度も現れなかったら

$$\phi_{j|y=1} = \frac{\sum_{i=1}^m 1\{x_j^{(i)} = 1 \wedge y^{(i)} = 1\}}{\sum_{i=1}^m 1\{y^{(i)} = 1\}}$$

→ 0 (まずい!)

$$\begin{aligned} p(y=1|x) &= \frac{\prod_{i=1}^n p(x_i|y=1)p(y=1)}{\prod_{i=1}^n p(x_i|y=1)p(y=1) + \prod_{i=1}^n p(x_i|y=0)p(y=0)} \\ &= \frac{0}{0} \end{aligned}$$

→ どう予測すれば分からなくなる

単純ベイズ分類器の改良

- 教師あり学習の弱み
 - 見たことないことは予測できない
- Laplace smoothing

$$\phi_j = \frac{\sum_{i=1}^m 1\{z^{(i)} = j\}}{m}.$$



$$\phi_j = \frac{\sum_{i=1}^m 1\{z^{(i)} = j\} + 1}{m + k}.$$



ϕ_j が0にならない
かつ

$\sum_{j=1}^k \phi_j = 1$ が不変

単純ベイズ分類器の改良

- The multi-variate Bernoulli event model

$$x = \begin{bmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix} \begin{array}{l} a \\ \text{aardvark} \\ \text{aardwolf} \\ \vdots \\ \text{buy} \\ \vdots \\ \text{zygmurgy} \end{array}$$

- multinomial event model

$$x = \begin{bmatrix} 1 \\ 500 \\ \vdots \\ 1500 \\ \vdots \end{bmatrix} \begin{array}{l} a \\ \text{boy} \\ \vdots \\ \text{buy} \\ \vdots \end{array}$$

次元数が減る！
(メールによって次元数が違う)

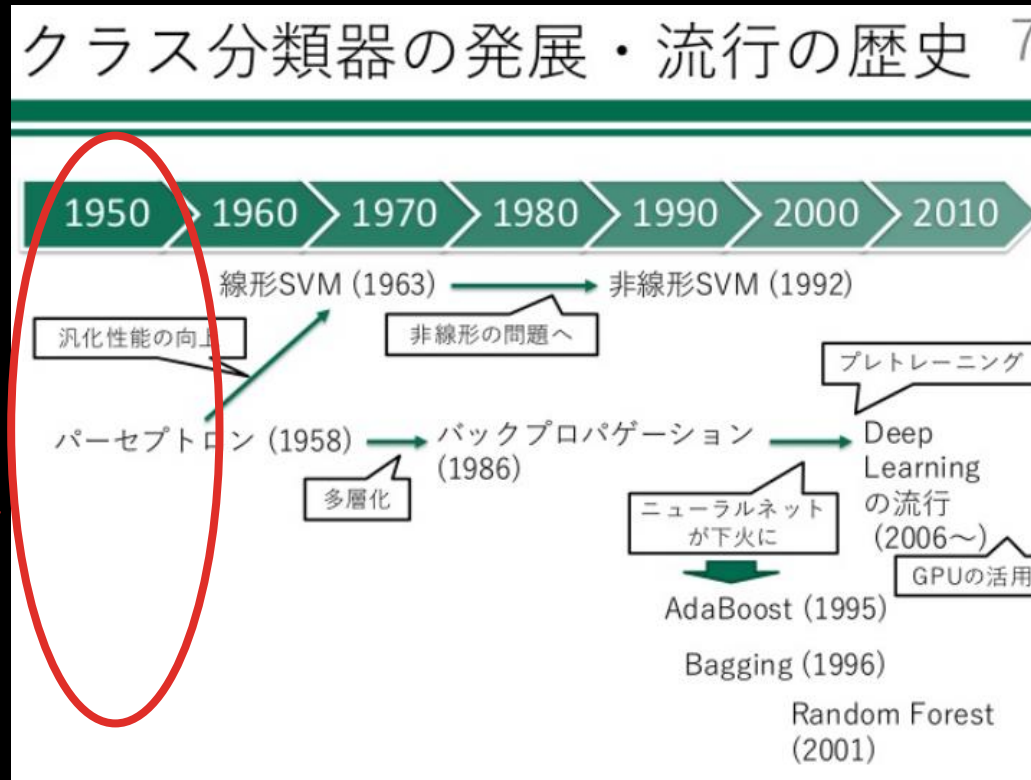
$$\phi_{k|y=1} = \frac{\sum_{i=1}^m \sum_{j=1}^{n_i} 1\{x_j^{(i)} = k \wedge y^{(i)} = 1\} + 1}{\sum_{i=1}^m 1\{y^{(i)} = 1\}n_i + |V|}$$

$$\phi_{k|y=0} = \frac{\sum_{i=1}^m \sum_{j=1}^{n_i} 1\{x_j^{(i)} = k \wedge y^{(i)} = 0\} + 1}{\sum_{i=1}^m 1\{y^{(i)} = 0\}n_i + |V|}$$

First thing to try!

余談

- <https://image.slidesharecdn.com/tutorialpublic-160607132749/95/python-svmdeep-learning-8-638.jpg?cb=1465372124>



分類問題に関して
今まで紹介した内容



次回は

- 第1回 パターン認識のための線形代数
- 第2回 パターン認識のための確率論
- 第3回 凸最適化の概念
- 第4回 線形回帰とLMSアルゴリズム
- 第5回 分類とロジスティック回帰
- 第6回 一般化線形モデル
- 第7回 ガウシアン判別分析と単純ベイズ分類器
- 第8回 サポートベクターマシン(1)
- 第9回 サポートベクターマシン(2)
- 第10回 正規化とモデル選択
- 第11回 k平均法
- 第12回 混合ガウスモデルとEMアルゴリズム
- 第13回 因子分析
- 第14回 主成分分析
- 第15回 未定