

数理統計 補助資料 ～線形判別分析～

2024年度2学期: 月曜1限, 水曜3限
担当教員: 石垣 司


Fisher の線形判別分析 (Fisher 1936)

新しく観測されたデータがどの群(グループやクラス)に属するのかを分類(判別)するための手法


- 所属する群が既知のデータから群を区別する線形関数を構成
- 機械学習のデータ分類手法の元祖
- 応用例: 疾病の有無, 製品の不良発見, 優良顧客の判別など

多変量データ

ID	変数1	変数2	...	変数 P	群
1	x_{11}	x_{12}	...	x_{1P}	A
2	x_{21}	x_{21}	...	x_{2P}	B
⋮	⋮	⋮	⋮	⋮	
i	x_{i1}	x_{i2}	...	x_{iP}	A
⋮	⋮	⋮	⋮	⋮	
N	x_{N1}	x_{N2}	...	x_{NP}	?



ID番号 N のデータ
は群Aに所属



Ronald Fisher 1890-1962

ビジネスにおける応用例


クレジットカードの入会審査

- 過去のクレジットカード会員の属性データと結果を用いて判別関数(線形関数:直線や平面)を構成
- 新規入会希望者の将来の結果を予測

過去のデータ

顧客 No.	貯金額	年収	群 (良好or貸倒れ)
1	1200	600	良好
2	-100	250	貸倒れ
3	110	300	良好
4	300	400	良好
5	0	700	貸倒れ
6	770	250	良好
⋮	⋮	⋮	⋮
999	50	900	良好
1000	0	400	良好
1001	-200	1000	?
1002	1000	300	?

- 過去のデータから判別関数を構成
- 所属群が未知のデータの群を予測



判別関数により入会希望者の中から貸倒れ顧客を予測

Fisherの線形判別分析の基本事項

線形判別

- 判別関数は線形空間(直線や平面)による分類

データの次元が P の時, 判別関数の次元は $P - 1$

- 例: 2変数データの判別空間は1次元の判別線
- 例: 3変数データの判別空間は2次元の判別面

2群の判別

- 多群の判別は2群判別の拡張


教師あり学習

- 所属する群の正解(ラベル)が付与されたデータを用いて判別関数を構成


簡単じゃないですか？

2群間の平均のど真ん中を判別関数

【上手く判別できる例】



【上手く判別できない例】



Fisherの線形判別分析

群間分散と群内分散のバランスが良い射影軸を構成


- 群間分散: 両群の分離度
群間分散を大きく \Rightarrow 2群間のデータを判別しやすくする
- 群内分散: 射影後の各群のデータ分布の分散
群内分散を小さく \Rightarrow 2群間のデータの交わり部分を小さくする

群間分散と群内分散の比 r の最大化

- 目的関数 $r = \frac{\text{群間分散}}{\text{群内分散}}$ の制約付き最大化問題を考える
- ラグランジュ未定乗数法と固有値問題へ帰結

群間分散と群内分散

例: 3つの線形軸(→)へのデータの射影



線形判別関数の求め方 #1

Notation

- 群Aの i 番目データ: $x_{Ai} = [x_{Ai1}, \dots, x_{AiP}]^T$ ($i = 1, \dots, N_A$)
- 群Bの i 番目データ: $x_{Bi} = [x_{Bi1}, \dots, x_{BiP}]^T$ ($i = 1, \dots, N_B$)
 N_A : 群Aのデータ数, N_B : 群Bのデータ数, P : データの次元
- 射影関数の重み: $w = [w_1, \dots, w_P]^T$
- 群Aのデータ x_{Ai} を z 軸へ射影した値: $z_{Ai} = w^T x_{Ai}$
- 群Bのデータ x_{Bi} を z 軸へ射影した値: $z_{Bi} = w^T x_{Bi}$
- 群Aのデータの標本平均ベクトル: $\bar{x}_A = [\bar{x}_{A1}, \dots, \bar{x}_{AP}]^T$
- 群Bのデータの標本平均ベクトル: $\bar{x}_B = [\bar{x}_{B1}, \dots, \bar{x}_{BP}]^T$

線形判別関数の求め方 #2

群間分散

– z_{Ai} と z_{Bi} の平均

$$\bar{z}_A = \frac{1}{N_A} \sum_{i=1}^{N_A} z_{Ai} = \sum_{k=1}^P w_k \bar{x}_{Ak} = \mathbf{w}^T \bar{\mathbf{x}}_A,$$

$$\bar{z}_B = \frac{1}{N_B} \sum_{i=1}^{N_B} z_{Bi} = \sum_{k=1}^P w_k \bar{x}_{Bk} = \mathbf{w}^T \bar{\mathbf{x}}_B.$$

#メモ: 導出計算は前回の講義と同様

– 群間分散の定義

$$(\bar{z}_A - \bar{z}_B)^2 = \{\mathbf{w}^T (\bar{\mathbf{x}}_A - \bar{\mathbf{x}}_B)\}^2$$

9

線形判別関数の求め方 #3

群内分散

– 群Aと群Bのデータの z 軸上での標本分散

S_A と S_B はそれぞれの群の標本分散共分散行列

$$\frac{1}{N_A - 1} \sum_{i=1}^{N_A} (z_{Ai} - \bar{z}_A)^2 = \mathbf{w}^T S_A \mathbf{w}$$

$$\frac{1}{N_B - 1} \sum_{i=1}^{N_B} (z_{Bi} - \bar{z}_B)^2 = \mathbf{w}^T S_B \mathbf{w}$$

#メモ: 導出計算は前回の講義と同様

– 群内分散の定義

群Aと群Bの z 軸上での標本分散の重み付け和

$$\frac{1}{N_A + N_B - 2} \{(N_A - 1)\mathbf{w}^T S_A \mathbf{w} + (N_B - 1)\mathbf{w}^T S_B \mathbf{w}\} = \mathbf{w}^T S \mathbf{w}$$

$$\text{ここで, } S = \frac{1}{N_A + N_B - 2} \{(N_A - 1)S_A + (N_B - 1)S_B\}$$

10

線形判別関数の求め方 #4

群間分散と群内分散の比 r の最大化

$$r = \frac{\{\mathbf{w}^T (\bar{\mathbf{x}}_A - \bar{\mathbf{x}}_B)\}^2}{\mathbf{w}^T S \mathbf{w}}$$

– 目的関数 r , 制約条件 $\mathbf{w}^T S \mathbf{w} = 1$

– 制約条件付き最適化問題

⇒ ラグランジュ未定乗数法と固有値問題

– 最適解:

$$\mathbf{w}^* = S^{-1} (\bar{\mathbf{x}}_A - \bar{\mathbf{x}}_B) \quad \text{check!}$$

#メモ: マハラノビス距離を用いる定式化も有名。その解は \mathbf{w}^* に一致する

11

線形判別関数の求め方 #5

Fisher の線形判別関数

– 両群データの平均の z 軸上への正射影の midpoint で定義

z 軸上での群Aの平均: $\mathbf{w}^{*T} \bar{\mathbf{x}}_A$

z 軸上での群Bの平均: $\mathbf{w}^{*T} \bar{\mathbf{x}}_B$

– 中点 $m = \frac{1}{2} \{\mathbf{w}^{*T} \bar{\mathbf{x}}_A + \mathbf{w}^{*T} \bar{\mathbf{x}}_B\}$


– 判別関数 $f(x)$

$$f(x) = \mathbf{w}^{*T} \mathbf{x} - m$$

– 判別線 $-$: $f(x) = 0$

$f(x) \geq 0$ ならば未知の x を群Aに分類

$f(x) < 0$ ならば未知の x を群Bに分類



12

分類の良さの評価 #1

分類の間違い方(誤分類)の種類

これ以降は線形判別分析のみに限らないより一般的な分類の話

		分類結果	
		群A(陽性)	群B(陰性)
正答	群A(陽性)	True Positive(TP)	False Negative(FN)
	群B(陰性)	False Positive(FP)	True Negative(TN)

– もちろん, FPとFNの割合が小さい分類が望ましい

① 正答率(精度, Accuracy): $\frac{TP+TN}{TP+FP+FN+TN}$

– 未知データを正しく分類できた割合

		分類結果	
		陽性	陰性
正答	陽性	45	5
	陰性	5	45

Accuracy = 0.9

		分類結果	
		陽性	陰性
正答	陽性	25	25
	陰性	25	25

Accuracy = 0.5

		分類結果	
		陽性	陰性
正答	陽性	0	5
	陰性	0	95

Accuracy = 0.95

全て陰性と分類した意味のない分類結果

分類の良さの評価 #2

正答率は自然で直感的な分類性能の評価指標であるが、正答率による評価が適さない場合もあるので注意

– 例: 健康診断や定期がん検診の評価

多くの受診者の正答は陰性(H28年肺がん発見率 0.03%)

日本医師会HP(最終閲覧2024.12.16)
https://www.med.or.jp/forest/gankenshin/data/detection/

		分類結果	
		陽性	陰性
正答	陽性	0	3
	陰性	0	9997

テキトーな検査で全員を「問題なし」と分類したとき、正答率(Accuracy) = 0.9997



– 例: 迷惑メールフィルタの分類性能の評価

陽性: 迷惑メール, 陰性: 仕事のメール

		分類結果	
		陽性	陰性
正答	陽性	45	0
	陰性	10	45

迷惑メールを仕事メールと分類

仕事メールを迷惑メールと分類

正答率(Accuracy) = 0.9 だが、仕事のメールを10%も取り逃している



分類の良さの評価 #3

		分類結果	
		群A(陽性)	群B(陰性)
正答	群A	True Positive(TP)	False Negative(FN)
	群B	False Positive(FP)	True Negative(TN)

② 適合率(Precision): $\frac{TP}{TP+FP}$

– 陽性と分類したデータが本当に陽性である割合

		分類結果	
		陽性	陰性
正答	陽性	45	5
	陰性	5	45

Precision = 0.9

		分類結果	
		陽性	陰性
正答	陽性	25	25
	陰性	25	25

Precision = 0.5

		分類結果	
		陽性	陰性
正答	陽性	0	5
	陰性	0	95

Precision 算出不可

③ 再現率(網羅率, Recall, Hit rate): $\frac{TP}{TP+FN}$

– 正答が陽性であるデータが正しく陽性に分類されている割合

		分類結果	
		陽性	陰性
正答	陽性	45	5
	陰性	5	45

Recall = 0.9

		分類結果	
		陽性	陰性
正答	陽性	25	25
	陰性	25	25

Recall = 0.5

		分類結果	
		陽性	陰性
正答	陽性	0	5
	陰性	0	95

Recall = 0

分類の良さの評価 #4

不均衡データ(imbalanced data)に注意

– 不均衡データ: 一方の群のサンプルサイズが極端に小さいデータセット

– 健康診断の検査, クレジットカードの貸倒れ, 不良品の検査など, 実応用の多くの場面で現れる

– 妥当ではない分類でも各指標が良好な値を示す場合あり

妥当な分類結果

妥当ではない分類結果

		分類結果	
		陽性	陰性
正答	陽性	45	5
	陰性	5	45

Accuracy = 0.9
Precision = 0.9
Recall = 0.9

		分類結果	
		陽性	陰性
正答	陽性	25	25
	陰性	25	25

Accuracy = 0.5
Precision = 0.5
Recall = 0.5

		分類結果	
		陽性	陰性
正答	陽性	95	0
	陰性	5	0

Accuracy = 0.95
Precision = 0.95
Recall = 1.0


		分類結果	
		陽性	陰性
正答	陽性	0	5
	陰性	0	95

Accuracy = 0.95
Precision = 算出不可
Recall = 0


未知データの分類性能の評価 #1

汎化性能(復習): 未知データをうまく分類できる性能

- 実問題への応用の多くで必要なのは未知データの予測




- 既知データへの過剰適合(過学習)は未知データの分類性能を低下させる



未知データの分類性能の評価 #2

ホールドアウトサンプルを用いた分類性能評価

- ホールドアウトサンプル: 分類器の作成に用いないテストデータ
- 訓練データ(学習データ)とテストデータを分けて分類性能を検証



- 分類器は訓練に利用したデータの正答を知っているため、訓練データを正確に分類できるのは当たり前

未知データの分類性能の評価 #3

再掲: 交差検証法(Cross-validation)

- 例: 3-fold クロスバリデーション
- データを3分割し、その3つの分類性能の平均で性能を評価



評価: この分類モデルの分類性能は正答率 0.86

Leave one out 法

- 1つのサンプルのみをテストデータ、それ以外のデータを訓練データとして、交差検証を行う
- 比較的サンプルサイズが少数の時に利用


線形判別分析の実行 #1

クレジットカードの貸倒れデータ

- ISLRパッケージ内の10,000人分の疑似データ
- 分類したい変数: Default (Yes or No)
- 分類に利用する変数: Student, Balance, Income

	Default	Student	Balance	Income
Yes	333	2944		
No	9667	7056		
最小値			0	772
最大値			2654	73554
平均値			835	33517

不均衡データ



線形判別分析の実行 #2

10-fold 交差検証法による分類性能評価:


Accuracy = 0.97, Precision = 0.80, Recall = 0.24

分類の結果と解釈

- 分類の正答率が高い
(ただし, 不均衡データ)
- 陽性と分類された人の80%は
実際に貸倒れを起こした人
- 実際に貸倒れを起こした人の
24%を正しく分類

貸倒れを起こす人の76%を見逃してしまうが、
陽性と判断された人に対しては80%の確率
で正しく結果を予測できる手法である

複数の検証内でこのような判別線



演習問題

1. $\bar{x}_A = [1 \ 1]^T$, $\bar{x}_B = [0 \ 0]^T$, $S = \begin{bmatrix} 2 & 0.5 \\ 0.5 & 1 \end{bmatrix}$ のとき,
新しく観測されたデータ $x = [0.6 \ 0.4]^T$ は群Aと群Bの
どちらに判別されるか答えなさい
2. 次の分類性能を評価するための適切な指標を正答率
(Accuracy), 適合率(Precision), 再現率(Recall)の中か
ら選び, その理由も答えなさい
 - 健康診断や定期がん検診の評価
ヒント: がんや病気が発生している受診者の見逃しは許されない
 - 迷惑メールフィルタの分類性能の評価
ヒント: 迷惑メールを仕事メールとする誤分類は許せるが, 仕事メールを
迷惑メールとする誤分類は許されない