

Modèles probabilistes de classification - LDA, QDA & régression logistique

Master parcours SSD - UE Apprentissage Statistique I

Pierre Mahé - bioMérieux & Université de Grenoble-Alpes

1. Introduction
 - ▶ théorie de la décision statistique & k -ppv
2. Modèles génératifs
 - ▶ LDA, QDA
3. Modèles discriminatifs
 - ▶ régression logistique
4. En pratique

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Introduction

Rappel - Apprentissage supervisé, formalisation

Données d'entrée : échantillon $\{(x_i, y_i)\}_{i=1, \dots, n} \in \mathcal{X} \times \mathcal{Y}$.

Objectif : apprendre une fonction $f : \mathcal{X} \rightarrow \mathcal{Y}$ permettant de prédire la réponse associée à une nouvelle observation.

Rappel - Apprentissage supervisé, formalisation

Données d'entrée : échantillon $\{(x_i, y_i)\}_{i=1, \dots, n} \in \mathcal{X} \times \mathcal{Y}$.

Objectif : apprendre une fonction $f : \mathcal{X} \rightarrow \mathcal{Y}$ permettant de prédire la réponse associée à une nouvelle observation.

Critère : une fonction de perte L (pour "loss") mesurant l'erreur entre y et $f(x)$.

Typiquement :

- ▶ l'erreur quadratique pour la régression :

$$L(y, f(x)) = (y - f(x))^2$$

- ▶ le coût 0/1 pour la classification :

$$L(y, f(x)) = \mathbb{1}(y \neq f(x))$$

Rappel - Apprentissage supervisé, formalisation

Cadre probabiliste : on considère que nos observations (x_i, y_i) sont des variables aléatoires régies par une **loi jointe** $P(X, Y)$.

⇒ L'objectif de l'apprentissage supervisé est donc de trouver la fonction f minimisant **l'espérance de la fonction de perte** :

$$R(f) = E_{X,Y} [L(Y, f(X))],$$

à partir d'un échantillon $\{(x_i, y_i)\}, i = 1, \dots, n$.

$R(f)$ est appelée le **risque** (ou la **perte**) de la fonction f .

Théorie de la décision statistique

La quête du Graal : quel serait notre meilleur choix si on connaissait la loi $P(X, Y)$?

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Théorie de la décision statistique

La quête du Graal : quel serait notre meilleur choix si on connaissait la loi $P(X, Y)$?


Cas de la régression et de la perte quadratique :

$$\begin{aligned}R(f) &= E_{X,Y} [L(Y, f(X))] \\ &= E_{X,Y} [(Y - f(X))^2]\end{aligned}$$

⇒ meilleure solution : $f(x) = E[Y|X = x]$

- ▶ la valeur moyenne que peut prendre Y sachant X
- ▶ la "regression function"
- ▶ NB : valable pour la perte quadratique
 - ▶ $f(x) = \text{median}(Y|X = x)$ si $L(Y, f(X)) = |Y - f(X)|$

Illustration :



- ▶ $P(X, Y)$: vraie relation entre X et Y non déterministe
 - ▶ ici, $Y = f(X) + \epsilon$, $\epsilon \rightarrow \mathcal{N}(0, \sigma^2)$
 - ▶ en bleue : vraie fonction, en gris : réalisations bruitées
- ▶ On doit prendre une décision
- ▶ On minimise la perte quadratique en prenant $E[Y|X]$
 - ▶ l'espérance des points gris pour chaque valeur de x

Introduction

Modèles génératifs

introduction

LDA

QDA

Modèles discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Régression et perte quadratique : démonstration

$$\begin{aligned}R(f) &= E_{X,Y} [L(Y, f(X))] \\ &= E_{X,Y} [(Y - f(X))^2]\end{aligned}$$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Régression et perte quadratique : démonstration

$$\begin{aligned}R(f) &= E_{X,Y}[L(Y, f(X))] \\ &= E_{X,Y}[(Y - f(X))^2]\end{aligned}$$

⇒ on **conditionne** sur X : $E_{Y,X}(\cdot) = E_X E_{Y|X}(\cdot)$

$$R(f) = E_X E_{Y|X}[(Y - f(X))^2 | X]$$

Introduction

Modèles
génératifs
introduction
LDA
QDA

Modèles
discriminatifs
Régression
logistique

En pratique

Conclusion

Références

Régression et perte quadratique : démonstration

$$\begin{aligned}R(f) &= E_{X,Y}[L(Y, f(X))] \\ &= E_{X,Y}[(Y - f(X))^2]\end{aligned}$$

⇒ on **conditionne** sur X : $E_{Y,X}(\cdot) = E_X E_{Y|X}(\cdot)$

$$R(f) = E_X E_{Y|X}[(Y - f(X))^2 | X]$$

⇒ on minimise pour chaque valeur x prise par X :

$$\begin{aligned}f(x) &= \arg \min_c E_{Y|X}[(Y - c)^2 | X = x] \\ &= E[Y | X = x]\end{aligned}$$

Introduction

Modèles
génératifs
introduction
LDA
QDA

Modèles
discriminatifs
Régression
logistique

En pratique

Conclusion

Références

Théorie de la décision statistique - classification

La quête du Graal : quel serait notre meilleur choix si on connaissait la loi $P(X, Y)$?

Cas de la classification et de la perte 0/1 :

$$\begin{aligned}R(f) &= E_{X,Y} [L(Y, f(X))] \\ &= E_{X,Y} [\mathbb{1}(Y \neq f(X))]\end{aligned}$$


\Rightarrow meilleure solution : $f(x) = \arg \max_{k=1,\dots,K} P(Y = C_k | X = x)$

- ▶ la classe la plus vraisemblable sachant X
- ▶ le classifieur de Bayes
- ▶ NB : valable pour la perte / le coût 0/1
 - ▶ se généralise pour des coûts arbitraires $L(C_i, C_j)$

Théorie de la décision statistique - classification

Illustration : $P(Y = k|X = x)$

- ▶ pour une valeur x donnée et $K = 4$ catégories



- ▶ $P(X, Y)$: vraie relation entre X et Y non déterministe
- ▶ On doit prendre une décision
- ▶ Erreur : somme des probabilités des choix qu'on rejette
- ▶ Minimisée si on choisit la probabilité la plus élevée

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression logistique

En pratique

Conclusion

Références

Théorie de la décision statistique - classification

Classification et perte 0/1 : démonstration

$$R(f) = E_{X,Y}[L(Y, f(X))] = E_{X,Y}[\mathbb{1}(Y \neq f(X))]$$

Outline

Apprentissage
Statistique I

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression

logistique

En pratique

Conclusion

Références

Théorie de la décision statistique - classification

Classification et perte 0/1 : démonstration

$$R(f) = E_{X,Y}[L(Y, f(X))] = E_{X,Y}[\mathbb{1}(Y \neq f(X))]$$

\Rightarrow on **conditionne** sur X : $E_{Y,X}(\cdot) = E_X E_{Y|X}(\cdot)$

$$\begin{aligned} R(f) &= E_X E_{Y|X}[\mathbb{1}(Y \neq f(X)|X)] \\ &= E_X \sum_{k=1}^K \mathbb{1}(C_k \neq f(X)) P(Y = C_k|X) \end{aligned}$$

Théorie de la décision statistique - classification

Classification et perte 0/1 : démonstration

$$R(f) = E_{X,Y}[L(Y, f(X))] = E_{X,Y}[\mathbb{1}(Y \neq f(X))]$$

⇒ on **conditionne** sur X : $E_{Y,X}(\cdot) = E_X E_{Y|X}(\cdot)$

$$\begin{aligned} R(f) &= E_X E_{Y|X}[\mathbb{1}(Y \neq f(X)|X)] \\ &= E_X \sum_{k=1}^K \mathbb{1}(C_k \neq f(X)) P(Y = C_k|X) \end{aligned}$$

⇒ on minimise pour chaque valeur x prise par X :

$$\begin{aligned} f(x) &= \arg \min_c \sum_{k=1}^K \mathbb{1}(C_k \neq c) P(Y = C_k|X = x) \\ &= \arg \max_{k=1, \dots, K} P(Y = C_k|X = x) \end{aligned}$$

Dans le cas de la **classification binaire** on doit choisir entre :

1. $Y = 1$ selon $P(Y = 1|X = x)$
2. $Y = 0$ selon $P(Y = 0|X = x) = 1 - P(Y = 1|X = x)$

Le **classifieur de Bayes**

$$f(x) = \arg \max_{k=1,\dots,K} P(Y = C_k|X = x)$$

peut s'écrire comme :

$$f(x) = \begin{cases} 1 & \text{si } P(Y = 1|X = x) \geq 0.5 \\ 0 & \text{sinon} \end{cases}$$

Théorie de la décision statistique

En pratique...

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Théorie de la décision statistique

En pratique... on ne connaît pas $P(X, Y)$!!

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs
introduction
LDA
QDA

Modèles
discriminatifs
Régression
logistique

En pratique

Conclusion

Références

En pratique... on ne connaît pas $P(X, Y)$!!

Intérêt de cette démarche (théorique) :

- ▶ concevoir des algorithmes
 - ▶ définition d'estimateurs + stratégies d'estimation
- ▶ analyser des algorithmes
 - ▶ e.g., se comparer au classifieur de Bayes par simulations
 - ▶ étudier performance en fonction de n

Exemple des k -PPV

k -PPV pour la régression :

$$\hat{f}(x) = \text{Average}(y_i | i \in N_k(x))$$

\Rightarrow approxime directement la **regression function** $E[Y|X]$

Exemple des k -PPV

k -PPV pour la régression :

$$\hat{f}(x) = \text{Average}(y_i | i \in N_k(x))$$

\Rightarrow approxime directement la **regression function** $E[Y|X]$

Nature de l'approximation :

1. espérance \rightarrow moyenne empirique
2. point \rightarrow voisinage dans le conditionnement

\Rightarrow convergence asymptotique

- ▶ $n, k \rightarrow +\infty$; $k/n \rightarrow 0$

Exemple des k -PPV

k -PPV pour la classification :

$$\begin{aligned}\hat{f}(x) &= \text{Majority}(y_i | i \in N_k(x)) \\ &= \arg \max_{l=1, \dots, K} \tilde{P}_l = \frac{1}{k} \sum_{i \in N_k(x)} \mathbb{1}(y_i = l)\end{aligned}$$

\Rightarrow approxime directement le **classifieur de Bayes** :

$$\arg \max_{l=1, \dots, K} P(Y = C_l | X = x)$$

Exemple des k -PPV

k -PPV pour la classification :

$$\begin{aligned}\hat{f}(x) &= \text{Majority}(y_i | i \in N_k(x)) \\ &= \arg \max_{l=1, \dots, K} \tilde{P}_l = \frac{1}{k} \sum_{i \in N_k(x)} \mathbb{1}(y_i = l)\end{aligned}$$

\Rightarrow approxime directement le **classifieur de Bayes** :

$$\arg \max_{l=1, \dots, K} P(Y = C_l | X = x)$$

Nature de l'approximation :

1. probabilité \rightarrow proportion empirique
2. point \rightarrow voisinage dans le conditionnement

\Rightarrow convergence asymptotique

- ▶ $n, k \rightarrow +\infty$; $k/n \rightarrow 0$

Exemple des k -PPV

En dépit de sa simplicité, l'algorithme des k -PPV :

1. approxime les bonnes fonctions
 - ▶ regression function & classifieur de Bayes
2. possède des propriétés de convergence

⇒ pourquoi chercher plus loin ?

Exemple des k -PPV

En dépit de sa simplicité, l'algorithme des k -PPV :

1. approxime les **bonnes fonctions**
 - ▶ regression function & classifieur de Bayes
2. possède des **propriétés de convergence**

⇒ pourquoi chercher plus loin ?

Car la convergence est **asymptotique** :

- ▶ $n, k \rightarrow +\infty$; $k/n \rightarrow 0$

⇒ en pratique on dispose d'un **nombre d'observations limité**

- ▶ k -PPV rarement optimal à n fixé

Exemple des k -PPV

En dépit de sa simplicité, l'algorithme des k -PPV :

1. approxime les **bonnes fonctions**
 - ▶ regression function & classifieur de Bayes
2. possède des **propriétés de convergence**

⇒ pourquoi chercher plus loin ?

Car la convergence est **asymptotique** :

- ▶ $n, k \rightarrow +\infty$; $k/n \rightarrow 0$

⇒ en pratique on dispose d'un **nombre d'observations limité**

- ▶ k -PPV rarement optimal à n fixé

(de plus, ça se complique en haute dimension)

- ▶ "fléau de la dimension"

Modèles probabilistes de classification

Ce cours : cadre de la classification

Graal = classifieur de Bayes :

$$f(x) = \arg \max_{k=1, \dots, K} P(Y = C_k | X = x)$$

Modèles probabilistes de classification : estimer $P(Y|X)$

⇒ Deux approches :

- ▶ **générationnelle** : modélise $P(X|Y)$
- ▶ **discriminative** : estime directement $P(Y|X)$

Modèles génératifs

Modèles génératifs

Objectif : estimer $P(Y|X)$

Approche générative :

1. définir un modèle pour $P(X|Y)$
 - ▶ densité conditionnelle des données au sein des classes
2. appliquer la loi de Bayes pour en déduire $P(Y|X)$:

$$\begin{aligned}P(Y = C_k|X = x) &= \frac{P(X = x, Y = C_k)}{P(X = x)} \\ &= \frac{P(X = x|Y = C_k)P(Y = C_k)}{P(X = x)}\end{aligned}$$

⇒ on "inverse" $P(X|Y)$ en $P(Y|X)$

- ▶ X permet de "mettre à jour" $P(Y)$ en $P(Y|X)$

Terminologie :

- ▶ $P(Y)$ = loi a priori
- ▶ $P(X, Y)$ = loi jointe
- ▶ $P(X)$ = loi marginale
- ▶ $P(X|Y)$ = loi conditionnelle
- ▶ $P(Y|X)$ = loi a posteriori

Illustration : X =poids; Y = sexe

	X = 50	X = 60	X = 70	X = 80	X = 90	Total
Y = ♂	1	3	15	17	12	48
Y = ♀	5	13	5	3	2	28
Total	6	16	20	20	14	76

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Illustration : X =poids; Y = sexe

	$X = 50$	$X = 60$	$X = 70$	$X = 80$	$X = 90$	Total
$Y = \text{♂}$	1	3	15	17	12	48
$Y = \text{♀}$	5	13	5	3	2	28
Total	6	16	20	20	14	76

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Illustration : X =poids; Y = sexe

	$X = 50$	$X = 60$	$X = 70$	$X = 80$	$X = 90$	Total
$Y = \text{♂}$	1	3	15	17	12	48
$Y = \text{♀}$	5	13	5	3	2	28
Total	6	16	20	20	14	76

► loi a priori : $P(Y = \text{♀}) = 28/76$

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Illustration : X =poids; Y = sexe

	$X = 50$	$X = 60$	$X = 70$	$X = 80$	$X = 90$	Total
$Y = \sigma$	1	3	15	17	12	48
$Y = \varphi$	5	13	5	3	2	28
Total	6	16	20	20	14	76

- ▶ loi a priori : $P(Y = \varphi) = 28/76$
- ▶ loi jointe : $P(X = 80, Y = \sigma) = 17/76$

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Illustration : X =poids; Y = sexe

	$X = 50$	$X = 60$	$X = 70$	$X = 80$	$X = 90$	Total
$Y = \sigma$	1	3	15	17	12	48
$Y = \varphi$	5	13	5	3	2	28
Total	6	16	20	20	14	76

- ▶ loi a priori : $P(Y = \varphi) = 28/76$
- ▶ loi jointe : $P(X = 80, Y = \sigma) = 17/76$
- ▶ loi marginale : $P(X = 80) = 20/76$
 - ▶ $P(X = 80) = P(X = 80, Y = \sigma) + P(X = 80, Y = \varphi)$

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Illustration : X =poids; Y = sexe

	$X = 50$	$X = 60$	$X = 70$	$X = 80$	$X = 90$	Total
$Y = \sigma$	1	3	15	17	12	48
$Y = \varphi$	5	13	5	3	2	28
Total	6	16	20	20	14	76

- ▶ loi a priori : $P(Y = \varphi) = 28/76$
- ▶ loi jointe : $P(X = 80, Y = \sigma) = 17/76$
- ▶ loi marginale : $P(X = 80) = 20/76$
 - ▶ $P(X = 80) = P(X = 80, Y = \sigma) + P(X = 80, Y = \varphi)$
- ▶ loi conditionnelle : $P(X = 80|Y = \sigma) = 17/48$

Illustration : X =poids; Y = sexe

	$X = 50$	$X = 60$	$X = 70$	$X = 80$	$X = 90$	Total
$Y = \sigma$	1	3	15	17	12	48
$Y = \varphi$	5	13	5	3	2	28
Total	6	16	20	20	14	76

- ▶ loi a priori : $P(Y = \varphi) = 28/76$
- ▶ loi jointe : $P(X = 80, Y = \sigma) = 17/76$
- ▶ loi marginale : $P(X = 80) = 20/76$
 - ▶ $P(X = 80) = P(X = 80, Y = \sigma) + P(X = 80, Y = \varphi)$
- ▶ loi conditionnelle : $P(X = 80|Y = \sigma) = 17/48$
- ▶ loi a posteriori : $P(Y = \sigma|X = 80) = 17/20$

Grâce à la **loi de Bayes** on a donc :

$$\begin{aligned}P(Y = C_k | X = x) &= \frac{P(X = x, Y = C_k)}{P(X = x)} \\ &= \frac{P(X = x | Y = C_k)P(Y = C_k)}{P(X = x)} \\ &= \frac{P(X = x | Y = C_k)P(Y = C_k)}{\sum_{i=1}^K P(X = x | Y = C_i)P(Y = C_i)}\end{aligned}$$

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Grâce à la **loi de Bayes** on a donc :

$$\begin{aligned}P(Y = C_k | X = x) &= \frac{P(X = x, Y = C_k)}{P(X = x)} \\&= \frac{P(X = x | Y = C_k)P(Y = C_k)}{P(X = x)} \\&= \frac{P(X = x | Y = C_k)P(Y = C_k)}{\sum_{i=1}^K P(X = x | Y = C_i)P(Y = C_i)}\end{aligned}$$

⇒ on notera :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

avec $f_k(x) = P(X = x | Y = C_k)$ et $\pi_k = P(Y = C_k)$.

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Modèles génératifs

LA question : comment choisir $f_k(x)$?

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique


Conclusion

Références

LA question : comment choisir $f_k(x)$?

Une première possibilité : lois normales (multivariées) :

$$\begin{aligned}f_k(x) &= \mathcal{MN}(x; \mu_k, \Sigma_k) \\ &= \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)\end{aligned}$$



⇒ approches LDA et QDA.

Introduction

Modèles
génératifs**introduction**

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

Modèles génératifs - LDA

LDA - définition

LDA - Linear Discriminant Analysis :

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

LDA - définition

LDA - Linear Discriminant Analysis :

1. modèle **génératif** :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

LDA - définition

LDA - Linear Discriminant Analysis :

1. modèle **génératif** :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

2. basé sur des **lois normales** multivariées :

$$f_k(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

LDA - définition

LDA - Linear Discriminant Analysis :

1. modèle **génératif** :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

2. basé sur des **lois normales** multivariées :


$$f_k(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

3. avec la **même matrice de covariance** par classe

$$\Sigma_k = \Sigma, \quad \forall k \in \{1, \dots, K\}.$$

LDA - Illustration

Modèle considéré :



⇒ toutes les classes ont la **même matrice de covariance**.

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression

logistique

En pratique

Conclusion

Références

LDA - règle de décision

Motivation = classifieur de Bayes :

$$f(x) = \arg \max_{k=1,\dots,K} P(Y = C_k | X = x)$$

LDA - règle de décision

Motivation = classifieur de Bayes :

$$f(x) = \arg \max_{k=1,\dots,K} P(Y = C_k | X = x)$$

Approche générative :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i} \quad (1)$$

LDA - règle de décision

Motivation = classifieur de Bayes :

$$f(x) = \arg \max_{k=1, \dots, K} P(Y = C_k | X = x)$$

Approche générative :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i} \quad (1)$$

⇒ règle de décision :

$$\begin{aligned} \hat{f}(x) &= \arg \max_{k=1, \dots, K} \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i} \\ &= \arg \max_{k=1, \dots, K} f_k(x)\pi_k \end{aligned}$$

(dénominateur de (1) = $P(X) \sim$ normalisation)

LDA - règle de décision

Règle de décision :

$$\hat{f}(x) = \arg \max_{k=1,\dots,K} f_k(x)\pi_k = \arg \max_{k=1,\dots,K} \ln f_k(x) + \ln \pi_k$$

Outline

Apprentissage
Statistique I

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression

logistique

En pratique

Conclusion

Références

LDA - règle de décision

Règle de décision :

$$\hat{f}(x) = \arg \max_{k=1, \dots, K} f_k(x) \pi_k = \arg \max_{k=1, \dots, K} \ln f_k(x) + \ln \pi_k$$

Or :

$$f_k(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

$$\begin{aligned} \ln f_k(x) &= -\ln \sqrt{(2\pi)^p} - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) \\ &= C - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \end{aligned}$$

LDA - règle de décision

Règle de décision :

$$\hat{f}(x) = \arg \max_{k=1, \dots, K} f_k(x) \pi_k = \arg \max_{k=1, \dots, K} \ln f_k(x) + \ln \pi_k$$

Or :

$$f_k(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

$$\begin{aligned} \ln f_k(x) &= -\ln \sqrt{(2\pi)^p} - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) \\ &= C - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \end{aligned}$$

On a donc :

$$\Rightarrow \hat{f}(x) = \arg \max_{k=1, \dots, K} \left\{ \ln \pi_k - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \right\}$$

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Forme générale de la règle de décision :

$$\hat{f}(x) = \arg \max_{k=1, \dots, K} \left\{ \ln \pi_k - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \right\}$$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifsRégression
logistique

En pratique

Conclusion

Références

LDA - règle de décision

Forme générale de la règle de décision :

$$\hat{f}(x) = \arg \max_{k=1, \dots, K} \left\{ \ln \pi_k - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \right\}$$

Si $\Sigma_k = \Sigma$ (modèle LDA) alors¹ :

$$\begin{aligned} \hat{f}(x) &= \arg \max_{k=1, \dots, K} \left\{ \ln \pi_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + x^T \Sigma^{-1} \mu_k \right\} \\ &= \arg \max_{k=1, \dots, K} \delta_k(x) \end{aligned}$$

\Rightarrow où $\delta_k(x)$ est une fonction linéaire de x .

1. $\ln |\Sigma_k|$ et $\frac{1}{2} x^T \Sigma_k^{-1} x$ ne dépendent plus de k

LDA - règle de décision

Règle de décision linéaire ?

$$\hat{f}(x) = \arg \max_{k=1, \dots, K} \delta_k(x)$$

où :

$$\begin{aligned} \delta_k(x) &= \ln \pi_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + x^T \Sigma^{-1} \mu_k \\ &= a_k + x^T b_k, \end{aligned}$$


avec :

- ▶ $a_k = \ln \pi_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k \Rightarrow a_k \in \mathbb{R}$
- ▶ $b_k = \Sigma^{-1} \mu_k \Rightarrow b_k \in \mathbb{R}^p$

⇒ fonction définie à partir des paramètres de la loi normale

LDA - règle de décision

Conséquence :



⇒ les frontières entre les classes sont linéaires.

- ▶ NB : frontière entre les classes k et l : $\{x : \delta_k(x) = \delta_l(x)\}$
- ▶ on vérifie facilement que c'est une droite

LDA - règle de décision

Frontières linéaires ?

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Frontières linéaires ?

Si :

$$\hat{f}(x) = \arg \max_{k=1, \dots, K} \delta_k(x)$$

alors la **frontière** entre les classes k et l est :

$$\left\{ \begin{array}{l} x : \delta_k(x) = \delta_l(x) \\ : \delta_k(x) - \delta_l(x) = 0 \\ : (a_k + x^T b_k) - (a_l + x^T b_l) = 0 \\ : (a_k - a_l) + x^T (b_k - b_l) = 0 \end{array} \right\}$$

⇒ une **fonction linéaire** (une droite, un plan ou un hyperplan)

Introduction

Modèles
génératifs
introduction
LDA
QDAModèles
discriminatifs
Régression
logistique

En pratique

Conclusion

Références

LDA - implémentation

En pratique, il faut estimer $\{\pi_k, \mu_k\}_{k=1, \dots, K}$ et Σ .

LDA - implémentation

En pratique, il faut estimer $\{\pi_k, \mu_k\}_{k=1, \dots, K}$ et Σ .

On considère les estimateurs standards :

- ▶ $\hat{\pi}_k = \frac{n_k}{n}$
 - ▶ les proportions relatives des classes
- ▶ $\hat{\mu}_k = \frac{1}{n_k} \sum_{i: y_i=k} x_i$
 - ▶ la moyenne empirique au sein de chaque classe
- ▶ $\Sigma = \frac{1}{n - K} \sum_{k=1}^K \sum_{i: y_i=k} (x_i - \hat{\mu}_k)(x_i - \hat{\mu}_k)^T$
 - ▶ la covariance empirique "poolée"
 - ▶ \sim moyenne des covariances par classe

(NB : ici pas de $P(Z|X)$ dans l'estimation, on connaît les catégories)

Modèles génératifs - QDA

QDA - définition

QDA - Quadratic Discriminant Analysis :

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

QDA - définition

QDA - Quadratic Discriminant Analysis :

1. modèle **génératif** :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

QDA - Quadratic Discriminant Analysis :

1. modèle **génératif** :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

2. basé sur des **lois normales** multivariées :

$$f_k(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

Régression
logistique

En pratique

Conclusion

Références

QDA - Quadratic Discriminant Analysis :

1. modèle **génératif** :

$$P(Y = C_k | X = x) = \frac{f_k(x)\pi_k}{\sum_{i=1}^K f_i(x)\pi_i}$$

2. basé sur des **lois normales** multivariées :

$$f_k(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

3. où chaque classe à sa propre matrice de covariance

$$\Sigma_k \neq \Sigma, \quad \forall k \in \{1, \dots, K\}.$$

Introduction

Modèles
génératifs

introduction

LDA

QDAModèles
discriminatifsRégression
logistique


En pratique

Conclusion

Références

QDA - Illustration

Modèle considéré :



⇒ chaque classe à sa propre matrice de covariance.

QDA - règle de décision

(rappel) Règle de décision - forme générale :

$$\begin{aligned}\hat{f}(x) &= \arg \max_{k=1, \dots, K} f_k(x) \pi_k \\ &= \arg \max_{k=1, \dots, K} \ln f_k(x) + \ln \pi_k \\ &= \arg \max_{k=1, \dots, K} \left\{ \ln \pi_k - \frac{1}{2} \ln |\Sigma_k| \right. \\ &\quad \left. - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \right\}\end{aligned}$$

QDA - règle de décision

(rappel) Règle de décision - forme générale :

$$\begin{aligned}\hat{f}(x) &= \arg \max_{k=1,\dots,K} f_k(x)\pi_k \\ &= \arg \max_{k=1,\dots,K} \ln f_k(x) + \ln \pi_k \\ &= \arg \max_{k=1,\dots,K} \left\{ \ln \pi_k - \frac{1}{2} \ln |\Sigma_k| \right. \\ &\quad \left. - \frac{1}{2} x^T \Sigma_k^{-1} x - \frac{1}{2} \mu_k^T \Sigma_k^{-1} \mu_k + x^T \Sigma_k^{-1} \mu_k \right\}\end{aligned}$$


⇒ si $\Sigma_k \neq \Sigma$ (modèle QDA) ne se simplifie pas :

$$\hat{f}(x) = \arg \max_{k=1,\dots,K} \delta_k(x),$$

où $\delta_k(x)$ est une fonction quadratique de x .

QDA - règle de décision

Conséquence² :



⇒ les frontières entre classes sont **non-linéaires**

En pratique, il faut (toujours) **estimer** $\{\pi_k, \mu_k\}_{k=1, \dots, K}$ et Σ .

On conserve :



- ▶ $\hat{\pi}_k = \frac{n_k}{n}$
 - ▶ les proportions relatives des classes
- ▶ $\hat{\mu}_k = \frac{1}{n_k} \sum_{i: y_i=k} x_i$
 - ▶ la moyenne empirique au sein de chaque classe

On estime une matrice de covariance par classe :

- ▶ $\Sigma_K = \frac{1}{n_k - 1} \sum_{i: y_i=k} (x_i - \hat{\mu}_k)(x_i - \hat{\mu}_k)^T$

LDA ou QDA ?

Pourquoi hésiter entre LDA et QDA ?



- ▶ **LDA** : hypothèse très contraignante (et peu réaliste)
- ▶ **QDA** : beaucoup plus de paramètres à estimer
 - ▶ $\frac{p(p+1)}{2}$ paramètres par Σ_k


⇒ dépend du jeu de données

⇒ compromis complexité (modèle) / stabilité (estimation)

LDA ou QDA ?

Solution intermédiaire : LDA sur données "transformées"³

- ▶ Gauche : LDA sur $(X_1, X_2, X_1X_2, X_1^2, X_2^2)$
- ▶ Droite : QDA sur (X_1, X_2)



- ▶ séparations non-linéaires
- ▶ contrôle du nombre de paramètres à estimer

Modèles discriminatifs

Modèles discriminatifs

Objectif : estimer $P(Y|X)$

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

**Modèles
discriminatifs**

Régression
logistique

En pratique

Conclusion

Références

Objectif : estimer $P(Y|X)$

Approche générative :

1. définir un modèle pour $P(X|Y)$
2. l'inverser en $P(Y|X)$ grâce à la loi de Bayes :

$$P(Y = C_k | X = x) = \frac{P(X = x | Y = C_k)P(Y = C_k)}{P(X = x)}$$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Modèles discriminatifs

Objectif : estimer $P(Y|X)$

Approche générative :

1. définir un modèle pour $P(X|Y)$
2. l'inverser en $P(Y|X)$ grâce à la loi de Bayes :

$$P(Y = C_k | X = x) = \frac{P(X = x | Y = C_k)P(Y = C_k)}{P(X = x)}$$

Avantages / inconvénients :

- ▶ + : LDA / QDA simple à mettre en oeuvre
- ▶ + : $P(X|Y)$ pour la détection de points aberrants
- ▶ - : sensible à l'adéquation modèle / données
- ▶ - : beaucoup de paramètres à estimer

Approche générative : estimer directement $P(Y|X)$

Introduction

Modèles
génératifs

introduction

LDA

QDA

**Modèles
discriminatifs**

Régression
logistique

En pratique

Conclusion

Références

Approche générative : estimer directement $P(Y|X)$

Motivation : s'attacher à la fonction de classification

- ▶ (en soi connaître $P(X|Y)$ est accessoire)

Introduction

Modèles
génératifs

introduction

LDA

QDA

**Modèles
discriminatifs**

Régression
logistique

En pratique

Conclusion

Références

Modèles discriminatifs

Approche générative : estimer directement $P(Y|X)$

Motivation : s'attacher à la fonction de classification

- ▶ (en soi connaître $P(X|Y)$ est accessoire)

Objectif : obtenir de meilleures performances prédictives

1. modèle optimisé en ce sens
2. en pratique, permet de limiter le nombre de paramètres

Approche générative : estimer directement $P(Y|X)$

Motivation : s'attacher à la fonction de classification

- ▶ (en soi connaître $P(X|Y)$ est accessoire)

Objectif : obtenir de meilleures performances prédictives

1. modèle optimisé en ce sens
2. en pratique, permet de limiter le nombre de paramètres

⇒ modèle incontournable : la **régression logistique**

Régression logistique - formalisation

On considèrera la **classification binaire** : $Y \in \{C_1, C_2\}$

Régression logistique - formalisation

On considèrera la **classification binaire** : $Y \in \{C_1, C_2\}$

Le **classifieur de Bayes** :

$$f(x) = \arg \max_{k=1, \dots, K} P(Y = C_k | X = x)$$

peut s'écrire

$$f(x) = \begin{cases} C_1 & \text{si } \frac{P(Y=C_1|X=x)}{P(Y=C_2|X=x)} > 1 \\ C_2 & \text{sinon} \end{cases}$$

Introduction

Modèles

génératifs

introduction

LDA

QDA

Modèles

discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

Régression logistique - formalisation

On considèrera la **classification binaire** : $Y \in \{C_1, C_2\}$

Le **classifieur de Bayes** :

$$f(x) = \arg \max_{k=1, \dots, K} P(Y = C_k | X = x)$$

peut s'écrire

$$f(x) = \begin{cases} C_1 & \text{si } \frac{P(Y=C_1|X=x)}{P(Y=C_2|X=x)} > 1 \\ C_2 & \text{sinon} \end{cases}$$

⇒ la quantité :

$$\frac{P(Y = C_1 | X = x)}{P(Y = C_2 | X = x)} = \frac{P(Y = C_1 | X = x)}{1 - P(Y = C_1 | X = x)}$$

est appelée "rapport des cotes", ou **odds-ratio**.

Le "rapport des cotes", ou **odds-ratio** :

$$\frac{P(Y = C_1|X = x)}{P(Y = C_2|X = x)} = \frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)}$$

Le "rapport des cotes", ou **odds-ratio** :

$$\frac{P(Y = C_1|X = x)}{P(Y = C_2|X = x)} = \frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)}$$

1. est compris entre 0 et $+\infty$

- ▶ 0 si $P(C_1|x) = 0$; $+\infty$ si $P(C_1|x) = 1$

Le "rapport des cotes", ou **odds-ratio** :

$$\frac{P(Y = C_1|X = x)}{P(Y = C_2|X = x)} = \frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)}$$

1. est compris entre 0 et $+\infty$
 - ▶ 0 si $P(C_1|x) = 0$; $+\infty$ si $P(C_1|x) = 1$
2. définit la fonction de décision
 - ▶ $f(x) = C_1$ si > 1

Le "rapport des cotes", ou **odds-ratio** :

$$\frac{P(Y = C_1|X = x)}{P(Y = C_2|X = x)} = \frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)}$$

1. est compris entre 0 et $+\infty$
 - ▶ 0 si $P(C_1|x) = 0$; $+\infty$ si $P(C_1|x) = 1$
2. définit la fonction de décision
 - ▶ $f(x) = C_1$ si > 1
3. quantifie la confiance dans la prédiction
 - ▶ si ~ 1 , alors $P(C_1|x) \sim P(C_2|x)$

Régression logistique - formalisation

Inconvénient de l'odd-ratio : pas symétrique

- ▶ si $P(C_2|x) \geq P(C_1|x)$: entre 0 et 1
- ▶ si $P(C_1|x) \geq P(C_2|x)$: entre 1 et $+\infty$

Régression logistique - formalisation

Inconvénient de l'odd-ratio : pas symétrique

- ▶ si $P(C_2|x) \geq P(C_1|x)$: entre 0 et 1
- ▶ si $P(C_1|x) \geq P(C_2|x)$: entre 1 et $+\infty$

⇒ on le considère souvent en échelle log :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)} \right)$$

Inconvénient de l'odd-ratio : pas symétrique

- ▶ si $P(C_2|x) \geq P(C_1|x)$: entre 0 et 1
- ▶ si $P(C_1|x) \geq P(C_2|x)$: entre 1 et $+\infty$

⇒ on le considère souvent en échelle log :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)} \right)$$

Ainsi :

1. il est compris entre $-\infty$ et $+\infty$ (et est symétrique)
2. la règle de décision devient :
 - ▶ $f(x) = C_1$ si $\text{score}(x) > 0$
 - ▶ ou encore $f(x) = \text{signe}(\text{score}(x))$
3. la confiance est directement liée à $|\text{score}(x)|$



Régression logistique - formalisation

Lien entre $p = P(C_1|x)$ et $score(x) = \ln(p/(1 - p))$:

- ▶ On passe de p à $score(x)$ par la fonction **logit** :
- ▶ On passe de $score(x)$ à p par la fonction **logistique** :

$$s = \text{logit}(p) = \ln \frac{p}{1 - p}$$

$$p = \sigma(s) = \frac{\exp^s}{1 + \exp^s}$$



Régression logistique - formalisation

En bref :

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

En bref :

1. classifieur de Bayes & odd-ratios - **fonction de score** :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1 | X = x)}{1 - (Y = C_1 | X = x)} \right) \in] - \infty, +\infty [$$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

En bref :

1. classifieur de Bayes & odd-ratios - **fonction de score** :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1 | X = x)}{1 - (Y = C_1 | X = x)} \right) \in] - \infty, +\infty [$$

2. règle de décision :

$$f(x) = \begin{cases} C_1 & \text{si } \text{score}(x) > 0 \\ C_2 & \text{sinon} \end{cases}$$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs**Régression
logistique**

En pratique

Conclusion

Références

En bref :

1. classifieur de Bayes & odd-ratios - **fonction de score** :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1 | X = x)}{1 - (Y = C_1 | X = x)} \right) \in] - \infty, +\infty [$$

2. règle de décision :

$$f(x) = \begin{cases} C_1 & \text{si } \text{score}(x) > 0 \\ C_2 & \text{sinon} \end{cases}$$

⇒ **Objectif de la régression logistique** : **modéliser** $\text{score}(x)$

- ▶ (et ainsi éviter de définir $P(X|Y = C_k)$ et $P(Y = C_k)$)

Introduction

Modèles
génératifsintroduction
LDA
QDAModèles
discriminatifs**Régression
logistique**

En pratique

Conclusion

Références

La **régression logistique** considère un **modèle linéaire** :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1 | X = x)}{1 - (Y = C_1 | X = x)} \right) = \langle w, x \rangle = \sum_{j=1}^p w_j x_j$$

⇒ le modèle met donc en jeu **p paramètres** pour $x \in \mathbb{R}^p$.

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

La **régression logistique** considère un **modèle linéaire** :

$$\text{score}(x) = \ln \left(\frac{P(Y = C_1 | X = x)}{1 - (Y = C_1 | X = x)} \right) = \langle w, x \rangle = \sum_{j=1}^p w_j x_j$$

⇒ le modèle met donc en jeu **p paramètres** pour $x \in \mathbb{R}^p$.

Remarques :

- ▶ en général, on introduit un **biais/intercept**
 - ▶ $\text{score}(x) = \langle \tilde{w}, \tilde{x} \rangle$ avec $\tilde{x} = [1 \ x] \Rightarrow p + 1$ paramètres
- ▶ moins de paramètres que les approches génératives
 - ▶ LDA : 2 pour π_1/π_2 + $2p$ pour μ_1/μ_2 + $p(p+1)/2$ pour Σ
 - ▶ QDA : $p(p+1)/2$ en plus pour Σ_1/Σ_2

Frontière de décision :

$$\left\{ \begin{array}{l} x : P(Y = C_1|X = x) = P(Y = C_2|X = x) \\ : \ln \left(\frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)} \right) = 0 \\ : \langle w, x \rangle = 0 \end{array} \right\}$$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

Frontière de décision :

$$\left\{ \begin{array}{l} x : P(Y = C_1|X = x) = P(Y = C_2|X = x) \\ : \ln \left(\frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)} \right) = 0 \\ : \langle w, x \rangle = 0 \end{array} \right\}$$

⇒ une **fonction linéaire** (une droite, un plan ou un hyperplan)

Introduction

Modèles
génératifs

introduction
LDA
QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

Frontière de décision :

$$\left\{ \begin{array}{l} x : P(Y = C_1|X = x) = P(Y = C_2|X = x) \\ : \ln \left(\frac{P(Y = C_1|X = x)}{1 - P(Y = C_1|X = x)} \right) = 0 \\ : \langle w, x \rangle = 0 \end{array} \right\}$$

⇒ une **fonction linéaire** (une droite, un plan ou un hyperplan)

Régression logistique vs LDA ?

- ▶ ici : on estime directement les p paramètres
- ▶ LDA : on estime les paramètres des gaussiennes et on en déduit les p paramètres

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs**Régression
logistique**

En pratique

Conclusion


Références

Régression logistique - formalisation

Expression des probabilités a posteriori :

$$P(Y = C_1 | X = x) = \sigma(\langle w, x \rangle) = \frac{\exp^{\langle w, x \rangle}}{1 + \exp^{\langle w, x \rangle}}$$

$$P(Y = C_2 | X = x) = 1 - P(Y = C_1 | X = x) = \frac{1}{1 + \exp^{\langle w, x \rangle}}$$



Rappel : $\langle w, x \rangle = \ln \frac{P(C_1|x)}{1-P(C_1|x)}$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

Régression logistique - implémentation

En pratique il faut donc estimer **le vecteur w** .

Outline

Apprentissage
Statistique I

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

**Régression
logistique**

En pratique

Conclusion

Références

Régression logistique - implémentation

En pratique il faut donc estimer le vecteur w .

On procède par maximum de (log-) vraisemblance :

$$\begin{aligned}\hat{w} &= \arg \max_w \prod_{i=1}^n P(Y = y_i | X = x_i) \\ &= \arg \max_w \sum_{i=1}^n \ln P(Y = y_i | X = x_i)\end{aligned}$$

⇒ problème d'optimisation, pas de solution analytique

Régression logistique - implémentation

En pratique il faut donc estimer le vecteur w .

On procède par maximum de (log-) vraisemblance :

$$\begin{aligned}\hat{w} &= \arg \max_w \prod_{i=1}^n P(Y = y_i | X = x_i) \\ &= \arg \max_w \sum_{i=1}^n \ln P(Y = y_i | X = x_i)\end{aligned}$$

⇒ problème d'optimisation, pas de solution analytique

Remarques :

- ▶ problème convexe, solution unique (minimum global)
- ▶ algorithme itératif de moindres carrés pondérés
 - ▶ Iterative Reweighted Least-Squares (IRLS)

Régression logistique en pratique

1. **Apprentissage** : estimer w / calculer \hat{w}

Régression logistique en pratique

1. **Apprentissage** : estimer w / calculer \hat{w}
2. **Prédiction** d'une instance x' :

1. **Apprentissage** : estimer w / calculer \hat{w}

2. **Prédiction** d'une instance x' :

2.1 calcul du **score** :

▶ $score(x') = \langle \hat{w}, x' \rangle$

1. **Apprentissage** : estimer w / calculer \hat{w}

2. **Prédiction** d'une instance x' :

2.1 calcul du **score** :

▶ $score(x') = \langle \hat{w}, x' \rangle$

2.2 calcul des **probabilités a posteriori** :

▶ $P(C_1|x') = \exp^{score(x')} / (1 + \exp^{score(x')})$

▶ $P(C_2|x') = 1 / (1 + \exp^{score(x')})$

1. **Apprentissage** : estimer w / calculer \hat{w}

2. **Prédiction** d'une instance x' :

2.1 calcul du **score** :

▶ $score(x') = \langle \hat{w}, x' \rangle$

2.2 calcul des **probabilités a posteriori** :

▶ $P(C_1|x') = \exp^{score(x')} / (1 + \exp^{score(x')})$

▶ $P(C_2|x') = 1 / (1 + \exp^{score(x')})$

2.3 prise de **décision** – on prédit C_1 si : $score(x') > 0$

▶ ce qui est équivalent à $P(C_1|x') > 0.5$

▶ ou encore $P(C_1|x') > P(C_2|x')$

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

En pratique

Classification multi-classe (vs binaire)

Approches génératives : "nativement" multi-classes

- ▶ même expression si $K = 2$ ou $K > 2$

Régression logistique : un peu plus compliqué

- ▶ on modélise $K - 1$ odds-ratio
- ▶ on estime $K - 1$ vecteurs w_k de p (ou $p + 1$) paramètres
- ▶ (reste bien moins de paramètres que LDA/QDA)

⇒ voir Hastie et al. (2001)[sec. 4.4] pour plus de détails.

Approches probabilistes et critères de rejet

Modèles probabilistes de classification : fournissent $P(C_k|x)$

⇒ définit un critère de confiance dans la prédiction

Approches probabilistes et critères de rejet

Modèles probabilistes de classification : fournissent $P(C_k|x)$

⇒ définit un **critère de confiance** dans la prédiction

Illustration (cadre binaire) :

- ▶ $P(C_1|x) \sim 0.5 \rightarrow$ confiance faible
- ▶ $P(C_1|x) \sim 1$ ou $\sim 0 \rightarrow$ confiance forte (dans C_1 ou C_2)

Approches probabilistes et critères de rejet

Modèles probabilistes de classification : fournissent $P(C_k|x)$

⇒ définit un **critère de confiance** dans la prédiction

Illustration (cadre binaire) :

- ▶ $P(C_1|x) \sim 0.5 \rightarrow$ confiance faible
- ▶ $P(C_1|x) \sim 1$ ou $\sim 0 \rightarrow$ confiance forte (dans C_1 ou C_2)

Critère de rejet : on ne prédit que si $\max_k P(C_k|x) > \delta$

- ▶ **seuil de décision** $\delta \in [1/K, 1]$
- ▶ $\delta = 1/K$ / $\delta = 1$: on prédit toujours / jamais

Approches probabilistes et critères de rejet

Modèles probabilistes de classification : fournissent $P(C_k|x)$

⇒ définit un critère de confiance dans la prédiction

Illustration (cadre binaire) :

- ▶ $P(C_1|x) \sim 0.5 \rightarrow$ confiance faible
- ▶ $P(C_1|x) \sim 1$ ou $\sim 0 \rightarrow$ confiance forte (dans C_1 ou C_2)

Critère de rejet : on ne prédit que si $\max_k P(C_k|x) > \delta$

- ▶ seuil de décision $\delta \in [1/K, 1]$
- ▶ $\delta = 1/K$ / $\delta = 1$: on prédit toujours / jamais

⇒ compromis - en augmentant δ :

1. on effectue moins de prédictions
2. mais on peut espérer faire moins d'erreurs

Impact du nombre de paramètres

Inconvénient du cadre génératif : nombre de paramètres

- ▶ LDA/QDA : augmente quadratiquement avec p

Conséquence :

- ▶ estimation instable
- ▶ mauvaise généralisation

Solution : sélection de variable ou réduction de dimension

- ▶ e.g., commencer par faire une ACP puis choisir entre LDA et QDA

Quel modèle choisir ?




FIGURE 4.10. Boxplots of the test error rates for each of the linear scenarios described in the main text.




FIGURE 4.11. Boxplots of the test error rates for each of the non-linear scenarios described in the main text.

⇒ voir James et al. (2013)[4.5] : dépend du jeu de données !

► (non) linéaire, gaussiennes, bruit, nombre d'observations, ... 59/64

LDA et QDA : implémentés dans le package MASS.

- ▶ **apprentissage** : fonction `lda` et `qda`
 - ▶ arguments principaux : X et y
- ▶ **prédiction** : fonctions `predict.lda` et `predict.qda`
 - ▶ NB : possibilité de spécifier les a priori à utiliser
 - ▶ utile pour dé-conditionner des effectifs d'apprentissage

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Mise en oeuvre en R

LDA et QDA : implémentés dans le package MASS.

- ▶ **apprentissage** : fonction `lda` et `qda`
 - ▶ arguments principaux : `X` et `y`
- ▶ **prédiction** : fonctions `predict.lda` et `predict.qda`
 - ▶ NB : possibilité de spécifier les a priori à utiliser
 - ▶ utile pour dé-conditionner des effectifs d'apprentissage

Régression logistique : un modèle linéaire généralisé (`glm`)

- ▶ **apprentissage** : fonction `glm`
 - ▶ avec option **family** = **"binomial"**
 - ▶ même syntaxe que fonction `lm`
- ▶ **prédiction** : fonction `predict.glm`
 - ▶ avec option **type** = **"link"** : renvoie $score(x)$
 - ▶ avec option **type** = **"response"** : renvoie $P(C_1|x)$
 - ▶ même syntaxe que fonction `lm`

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Conclusion

Théorie statistique de la décision :

- ▶ meilleur choix si on connaissait $P(X, Y)$
- ▶ régression : $E(Y|X)$ - **regression function**
- ▶ classification : $\arg \max_k P(Y_k|X)$ - **classifieur de Bayes**

Introduction

Modèles
génératifs

introduction

LDA

QDA

Modèles
discriminatifs

Régression
logistique

En pratique

Conclusion

Références

Conclusion

Théorie statistique de la décision :

- ▶ meilleur choix si on connaissait $P(X, Y)$
- ▶ régression : $E(Y|X)$ - **regression function**
- ▶ classification : $\arg \max_k P(Y_k|X)$ - **classifieur de Bayes**

Modèles probabilistes de classification : estimer $P(Y_k|X)$

- ▶ des modèles incontournables - populaires et performants

Théorie statistique de la décision :

- ▶ meilleur choix si on connaissait $P(X, Y)$
- ▶ régression : $E(Y|X)$ - **regression function**
- ▶ classification : $\arg \max_k P(Y_k|X)$ - **classifieur de Bayes**

Modèles probabilistes de classification : estimer $P(Y_k|X)$

- ▶ des modèles incontournables - populaires et performants

Modèles génératifs :

- ▶ définir $P(X|Y_k)$ et l'inverser en $P(Y_k|X)$ - **loi de Bayes**
- ▶ modèle classique : $P(X|Y_k) = \mathcal{MN}(x; \mu_k, \Sigma_k)$
- ▶ LDA : $\Sigma_k = \Sigma \Rightarrow$ frontières linéaires
- ▶ QDA : $\{\Sigma_k\}_{k=1, \dots, K} \Rightarrow$ frontières non-linéaires

Conclusion

LDA vs QDA :

- ▶ compromis complexité (modèle) / stabilité (estimation)
- ▶ hypothèse QDA moins contraignante, mais plus de paramètres à estimer

LDA vs QDA :

- ▶ compromis complexité (modèle) / stabilité (estimation)
- ▶ hypothèse QDA moins contraignante, mais plus de paramètres à estimer

Modèles discriminatifs :

- ▶ modéliser $P(Y_k|X)$ - la fonction de prédiction
 - ▶ pas d'hypothèse sur la distribution des données (X)
- ▶ modèle de la **régression logistique**
 - ▶ modélise **log(odds-ratio)** comme une **fonction linéaire**
 - ▶ p (ou $p + 1$) paramètres à estimer
 - ▶ estimation = problème d'optimisation (convexe)

Conclusion

LDA vs QDA :

- ▶ compromis complexité (modèle) / stabilité (estimation)
- ▶ hypothèse QDA moins contraignante, mais plus de paramètres à estimer

Modèles discriminatifs :

- ▶ modéliser $P(Y_k|X)$ - la fonction de prédiction
 - ▶ pas d'hypothèse sur la distribution des données (X)
- ▶ modèle de la **régression logistique**
 - ▶ modélise **log(odds-ratio)** comme une **fonction linéaire**
 - ▶ p (ou $p + 1$) paramètres à estimer
 - ▶ estimation = problème d'optimisation (convexe)

TP : classifieur de Bayes & loi normales, comparaison LDA/QDA/LogReg.

T. Hastie, R. Tibshirani, and J. Friedman. *The Elements of Statistical Learning*. Springer, 2001.

G. James, D. Witten, T. Hastie, and R. Tibshirani. *An Introduction to Statistical Learning with Applications in R*. Springer, 2013.