

Analyse discriminante linéaire

Une approche pour rendre calculable $P(Y/X)$

Ricco RAKOTOMALALA



Théorème de Bayes

Probabilité conditionnelle

Estimer la probabilité conditionnelle

$$P(Y = y_k / X) = \frac{P(Y = y_k) \times P(X / Y = y_k)}{P(X)}$$
$$= \frac{P(Y = y_k) \times P(X / Y = y_k)}{\sum_{k=1}^K P(Y = y_k) \times P(X / Y = y_k)}$$

Déterminer la conclusion = déterminer le max.

$$y_{k^*} = \arg \max_k P(Y = y_k / X)$$

⇔

$$y_{k^*} = \arg \max_k P(Y = y_k) \times P(X / Y = y_k)$$

Probabilité a priori
Estimé facilement par n_k/n

Comment estimer $P(X/Y=y_k)$?

*Impossibilité à estimer avec des fréquences
Le tableau croisé serait trop grand et rempli de zéros*




[1] Hypothèse de normalité

La normalité de la probabilité conditionnelle $P(X/Y)$

Loi normale multidimensionnelle


$$P(X_1=v_1, \dots, X_J=v_J / y_k) = \frac{1}{\sqrt{2\pi \det(\Sigma_k)}} e^{-\frac{1}{2}(X - \mu_k) \Sigma_k^{-1} (X - \mu_k)'}$$



[2] Homoscédasticité

Égalité des matrices de variance co-variance conditionnelles

$$\Sigma = \Sigma_k, k = 1, \dots, K$$



analyse discriminante linéaire !



Fonction linéaire discriminante

Simplification des formules sous [1] et [2]

La probabilité conditionnelle est donc proportionnelle à

$$\ln P(X/y_k) \propto -\frac{1}{2} (X - \mu_k) \Sigma^{-1} (X - \mu_k)'$$

Avec les estimations sur l'échantillon de taille n , K classes et J descripteurs

$$\hat{\mu}_k = \begin{pmatrix} \bar{x}_{k,1} \\ \vdots \\ \bar{x}_{k,J} \end{pmatrix}$$

Moyennes conditionnelles

$$\hat{\Sigma} = \frac{1}{n - K} \sum_{k=1}^K n_k \times \hat{\Sigma}_k$$

Matrice de variance co-variance
intra-classes



Fonction linéaire discriminante

Linéarité du modèle d'affectation

Fonction discriminante linéaire proportionnelle à $P(Y=y_k/X)$

$$d(Y_k, X) = \ln[P(Y = y_k)] + \mu_k \Sigma^{-1} X' - \frac{1}{2} \mu_k \Sigma^{-1} \mu_k'$$

Règle d'affectation

$$d(Y_1, X) = a_{1,0} + a_{1,1}X_1 + a_{1,2}X_2 + \dots + a_{1,J}X_J$$

$$d(Y_2, X) = a_{2,0} + a_{2,1}X_1 + a_{2,2}X_2 + \dots + a_{2,J}X_J$$

...

$$y_{k^*} = \arg \max_k d(Y_k, X)$$

Avantages et inconvénients

ADL propose les mêmes performances que les autres méthodes linéaires

- » Elle est assez robuste par rapport à l'hypothèse de normalité
- » Elle est gênée par la forte violation de l'homoscédasticité (formes de nuages très différentes)
- » Elle est sensible à une forte dimensionnalité et/ ou la corrélation des descripteurs (inversion de matrice)
- » Elle n'est pas opérationnelle si la distribution est multimodale (ex. 2 ou + « blocs » de nuages pour $Y=Y_k$)

Montrer exemple avec le fichier BINARY WAVES - Lecture des résultats et déploiement




ADL

Caractéristiques géométriques de la règle d'affectation

$d(Y_k, X)$ pour un individu à classer ω dépend de

$$(X(\omega) - \mu_k) \Sigma^{-1} (X(\omega) - \mu_k)'$$

Règle géométrique d'affectation : *Distance par rapport aux centres de gravité avec la métrique de Mahalanobis*




On comprend mieux les problèmes sous hétéroscédasticité (le calcul de la distance est biaisée), et lorsque la distribution est multimodale (le centre de gravité ne représente plus rien)



ADL

Interprétation sous la forme d'un apprentissage par partitionnement

Forme de la frontière entre les groupes
Séparation linéaire entre les groupes



*ex. breast cancer = f (cellsize, cellshape)
dans Tanagra*

Formé par l'ensemble des points équidistants
par rapport aux deux centres de gravité : c'est une droite !



ADL : Une règle d'affectation probabiliste peut s'interpréter comme une règle géométrique, elle peut également se voir comme une méthode de partitionnement de l'espace de représentation



ADL

Évaluation globale du modèle

(1) Évaluation standard d'un modèle de prédiction
Apprentissage + Test → Matrice de confusion

(2) Évaluation « statistique » utilisant l'hypothèse de normalité

$$H_0 : \mu_1 = \dots = \mu_K$$
$$H_1 : \text{un au moins s'écarte des autres}$$

Statistique du test : LAMBDA de WILKS

$$\Lambda = \frac{\det(W)}{\det(V)}$$

Matrice de variance co-variance intra

Matrice de variance co-variance totale



Voir l'analogie avec l'analyse de variance ANOVA (on parle alors de MANOVA)
Sa loi est peu tabulée, on utilise la transformation de RAO qui suit une loi de Fisher



ADL

Évaluation individuelle des coefficients (des variables)

On veut évaluer « la contribution » d'une variable dans le modèle de prédiction.

L'idée est de mesurer la variation du Λ de WILKS en passant du modèle à J variables au modèle à $(J-1)$ variables c.-à-d. sans la variable que l'on cherche à évaluer.

La statistique du test

$$\frac{n - K - J + 1}{K - 1} \left(\frac{\Lambda_{J-1}}{\Lambda_J} - 1 \right) \cong F(K - 1, n - K - J + 1)$$



Étant assez lourde à calculer, cette statistique est peu présente dans les logiciels
(on utilise alors un autre artifice)



ADL

Cas particulier du problème à 2 classes ($K = 2$)

La variable à prédire prend deux modalités :: $Y = \{+, -\}$

$$\left. \begin{array}{l} - \left\{ \begin{array}{l} d(+, X) = a_{+,0} + a_{+,1}X_1 + a_{+,2}X_2 + \dots + a_{+,J}X_J \\ d(-, X) = a_{-,0} + a_{-,1}X_1 + a_{-,2}X_2 + \dots + a_{-,J}X_J \end{array} \right. \\ \hline d(X) = c + c_1X_1 + c_2X_2 + \dots + c_JX_J \end{array} \right\} \begin{array}{l} \text{Règle d'affectation} \\ D(X) > 0 \rightarrow Y = + \end{array}$$

Interprétation

- » $D(X)$ est communément appelé un score, c'est la propension à être positif.
- » Le signe des coefficients « c » donne une idée sur le sens de la causalité.
- » Lorsque les X_j sont elles-mêmes des variables indicatrices (0/1), les coefficients « c » peuvent être lus comme des « points » attribués aux individus portant le caractère X_j

Évaluation

On peut voir une analogie forte entre la LDA et la régression linéaire multiple dans laquelle la variable endogène Y est codée 1/0 [1 = + ; 0 = -].

Nous pouvons nous inspirer des résultats de la régression pour évaluer globalement le modèle et surtout pour évaluer individuellement la « significativité » des coefficients « c »
→ test de Student (*attention, la transposition du test n'est pas totale*)



ADL

Mise en œuvre dans SPAD

- (1) Uniquement les problèmes à deux classes
- (2) Tous les descripteurs doivent être continus
- (3) Évaluation des variables par analogie avec la régression linéaire multiple

$$D = d(Y_1 / X) - d(Y_2 / X)$$

FONCTION LINEAIRE DISCRIMINANTE						
VARIABLES	CORRELATIONS	COEFFICIENTS	ECARTS	T	PROBA	
.....	VARIABLES	FONCTION	TYPES	STUDENT		
NUM LIBELLES	AVEC F.L.D.	DISC.	(RES. TYPE REG.)			
(SEUIL= 0.08)						
1 clump	-0.716	-0.8867	-0.0693	0.0076	9.15	0.000
2 ucellsize	-0.818	-0.6081	-0.0475	0.0136	3.50	0.000
3 ucellshape	-0.819	-0.4381	-0.0342	0.0133	2.58	0.010
4 mgadhesion	-0.697	-0.1749	-0.0137	0.0085	1.61	0.107
5 sepics	-0.683	-0.2153	-0.0168	0.0111	1.51	0.131
6 bnuclei	-0.815	-1.2181	-0.0952	0.0068	13.97	0.000
7 bchromatin	-0.757	-0.5589	-0.0437	0.0107	4.07	0.000
8 normnucl	-0.712	-0.4619	-0.0361	0.0079	4.57	0.000
9 mitoses	-0.423	-0.0773	-0.0060	0.0106	0.57	0.569
CONSTANTE		19.606468	1.258487	0.0347	*****	0.0000
.....						
R2 =	0.83612	F =	390.59235	PROBA =	0.000	
D2 =	22.52031	T2 =	3556.14746	PROBA =	0.000	
.....						

Indicateurs de « séparabilité » des groupes
F du Lambda de Wilks, T2 de Hotelling

Résultats indicatifs de la régression
(pour l'évaluation individuelle des variables)


Voir le parallèle avec le « vrai » test du LAMBDA
de WILKS dans TANAGRA



ADL

Traitement des descripteurs discrets

- (1) Codage 0/1 des variables catégorielles (attention à la dernière modalité)
- (2) Régularisation : ADL sur les axes factoriels de l'ACM → DISQUAL (G. Saporta)



! SPAD fourni directement les coefficients sur les variables originelles codées en disjonctif complet (0/1), nous n'avons pas à réaliser les transformations à partir des facteurs.



ADL

Sélection automatique des variables (1/2) -- Principe

Principe : S'appuyer sur la statistique F

Démarche : Évaluer l'adjonction d'une (J+1)^{ème} variable dans le modèle au sens de F

$$\frac{n - K - J}{K - 1} \left(\frac{\Lambda_J}{\Lambda_{J+1}} - 1 \right) \cong F(K - 1, n - K - J)$$

Sélection FORWARD

J=0

REPETER

Pour chaque variable candidate, calculer F

Choisir la variable qui maximise F

Est-ce que l'adjonction entraîne une amélioration « significative » du modèle ?

Si OUI, Ajouter la variable dans la sélection

JUSQU'À Plus de variable à ajouter

Remarque :

- (1) Il faut s'entendre sur le terme « significatif » → attention à la p-value calculée
- (2) Autres stratégies : BACKWARD et STEPWISE
- (3) A rapprocher avec l'idée de la corrélation partielle en régression linéaire



ADL

Sélection des variables (2/2) – Un exemple

Qualité des vins de Bordeaux (Tenenhaus, pp. 256-260)
 Ex. Règle d'arrêt - Signif. Value = 0.05

Temperature	Sun (h)	Heat (days)	Rain (mm)	Quality
3064	1201	10	361	medium
3000	1053	11	338	bad
3155	1133	19	393	medium
3085	970	4	467	bad
3245	1258	36	294	good
...

The screenshot shows the TANAGRA 1.4.13 interface. The 'Analysis' pane on the left shows a dataset 'tan5B.txt' with a 'Define status 1' step. The main window displays 'Selection results' for 2 selected attributes: Temperature (°C) and Sun (h). Below this, 'Detailed results' are shown for three solutions (Sol.1 to Sol.5). Large numbers 1, 2, and 3 are overlaid on the table to indicate the order of selection. The bottom toolbar contains various statistical and machine learning tools, with an arrow pointing to the 'Remove constant' option.

Selection results
 [2] selected attributes on [4]

Selected attributes' subset

N°	Selected atts
1	Temperature (°C)
2	Sun (h)

Detailed results

N°	d.f	Best	Sol.1	Sol.2	Sol.3	Sol.4	Sol.5
1	(2, 31)	Temperature (°C) L: 0.361 F: 27.39 p: 0.0000	Temperature (°C) L: 0.361 F: 27.39 p: 0.0000	Sun (h) L: 0.382 F: 25.06 p: 0.0000	Heat (days) L: 0.503 F: 15.33 p: 0.0000	Rain (mm) L: 0.647 F: 8.44 p: 0.0012	1
2	(2, 30)	Sun (h) L: 0.261 F: 5.80 p: 0.0074	Sun (h) L: 0.261 F: 5.80 p: 0.0074	Rain (mm) L: 0.280 F: 4.36 p: 0.0217	Heat (days) L: 0.349 F: 0.54 p: 0.5876	-	2
3	(2, 29)	-	Rain (mm) L: 0.219 F: 2.74 p: 0.0810	Heat (days) L: 0.248 F: 0.72 p: 0.4966	-	-	3

MANOVA

Stat	Value	p-value
Wilks' Lambda	0.26057	-
Bartlett -- C(4)	41.01913	0.00000
Rao -- F(4, 60)	14.38531	0.00000

LDA Summary

Attribute	Classification functions			Statistical Evaluation			
	medium	bad	good	Wilks L.	Partial L.	F(2,30)	p-value
Temperature (°C)	0.389654	0.380641	0.408796	0.382143	0.681861	6.99861	0.003202
Sun (h)	0.081305	0.062977	0.091231	0.361395	0.721007	5.80425	0.007398
constant	-664.402665	-614.577030	-739.145806				



Bibliographie

M. BARDOS -- « Analyse discriminante - Application au risque et scoring financier », DUNOD, 2001.

L. LEBART, A. MORINEAU, M. PIRON - « Statistique exploratoire multidimensionnelle », DUNOD, 2000 (3ème édition).

M. TENENHAUS - « Méthodes statistiques en gestion », DUNOD, 1996.

R. TOMASSONE, M. DANZART, J.J. DAUDIN, J.P. MASSON -
« Discrimination et classement », Masson, 1988.

