

FONDEMENTS DU MACHINE LEARNING


12 novembre 2024

Aujourd'hui

- * Dernière cours: Extensions de la régression linéaire
Projet: Classification
- * TD/TP (Notebook sur la régression linéaire)

① Régression linéaire généralisée

Notation



→ On veut pouvoir généraliser la régression linéaire pour déterminer des modèles non linéaires des données

→ Partant d'un jeu de données $X \in \mathbb{R}^{m \times p}$ et $y \in \mathbb{R}^m$
avec $X = \begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix}$ et $y = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}$, on fait

l'hypothèse que $y = \phi(X)^T \beta + \varepsilon$

avec $\phi(x) = \begin{bmatrix} \phi(x_1)^T \\ \vdots \\ \phi(x_m)^T \end{bmatrix} \in \mathbb{R}^{m \times n}$ avec ε bruit aléatoire dans \mathbb{R}^m

et $\beta \in \mathbb{R}^n$

→ Si $\phi : \mathbb{R}^p \rightarrow \mathbb{R}^p$, $x \mapsto x$, on retrouve la régression linéaire classique ($\phi(x) = x$ et $n = p$)

→ Si $\phi : \mathbb{R}^p \rightarrow \mathbb{R}^n$ avec $n \gg p$, alors on peut modéliser des relations non linéaires entre x_i et y_i

Exemples classiques de ϕ : polynômes, noyaux gaussiens ($\sim \exp(-\frac{\|x\|^2}{2})$), ...

Exemple : Modèle quadratique

↳ On suppose que $\forall i=1..m,$

$$y_i = \frac{1}{2} x_i^T H x_i + g^T x_i + \varepsilon_i$$

$$\varepsilon_i \sim \mathcal{N}(0, \sigma^2 I)$$

avec $H=H^T > 0$ et $g \in \mathbb{R}^p$
 $H \in \mathbb{R}^{p \times p}$

$$y_i = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^p H_{jk} [x_i]_j [x_i]_k + \sum_{j=1}^p g_j [x_i]_j + \varepsilon_i$$

$$y_i = \phi(x_i)^T \beta^* + \varepsilon_i$$

$$\phi(x) = \begin{bmatrix} [x]_1 \\ \vdots \\ [x]_p \\ \frac{1}{2} [x]_1^2 \\ \frac{1}{2} [x]_1 [x]_2 \\ \vdots \\ \frac{1}{2} [x]_1 [x]_p \\ \frac{1}{2} [x]_2^2 \\ \frac{1}{2} [x]_2 [x]_3 \\ \vdots \\ \frac{1}{2} [x]_p^2 \end{bmatrix}$$

monômes
d'ordre 2

$$\beta^* = \begin{bmatrix} g_1 \\ \vdots \\ g_p \\ H_{11} \\ H_{12} \\ \vdots \\ H_{1p} \\ H_{22} \\ H_{23} \\ \vdots \\ H_{pp} \end{bmatrix}$$

→ On peut donc obtenir un modèle quadratique des données en résolvant un problème de régression linéaire

(+) Expressivité, capacité de modélisation

(-) Le problème de régression linéaire est de taille plus grande qu'un problème de modèle linéaire

$$x_i \in \mathbb{R}^p$$

Modèle linéaire: $\beta \in \mathbb{R}^p$

$$\hat{\beta} = X^T y$$

$X \in \mathbb{R}^{m \times p}$

Modèle quadratique: $\beta \in \mathbb{R}^m$

avec $m = p + \frac{p(p+1)}{2} = O(p^2)$

$$\hat{\beta} = \Phi(X)^T y$$

$\Phi(x) \in \mathbb{R}^{m \times O(p^2)}$

↳ cf TD/TP: Courbes de Bézier

② Projet: Classification et modèles linéaires

a) Régression linéaire et classification binaire

$$\begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix} = X \in \mathbb{R}^{m \times m}, \quad y \in \mathbb{R}^m \quad \text{avec } y_i \in \{-1, 1\} \quad \forall i=1..m$$

↳ Étant donné X et y , on peut calculer un modèle linéaire qui explique au mieux les données, typiquement en minimisant $\frac{1}{2} \|X\beta - y\|^2$ par rapport à $\beta \in \mathbb{R}^m$

↳ Si le but est de classer les x_i en deux catégories, un modèle linéaire $x \mapsto x^T \beta$ à valeurs réelles peut sembler inapproprié

→ Une approche possible: considérer le modèle

$$x \mapsto \text{signe}(x^T \beta)$$

$$\text{signe}(t) = \begin{cases} 1 & \text{si } t \geq 0 \\ -1 & \text{sinon} \end{cases}$$

si $X\beta = y$, alors $\text{signe}(x_i^T \beta) = \text{type}(y_i) = y_i$

plus généralement, le signe du modèle linéaire peut donner un bon "classifieur"

→ Les coefficients de β les plus larges en valeur absolue sont ceux qui contribuent le plus à définir le label

But de cette partie du projet: Étudier l'intérêt pratique de ce modèle

Remarque: Extension à plusieurs classes

Pour K classes, on regarde $\max_{k=1..K} \text{signe}(x_i^T \beta_k)$

où β_k est calculé pour séparer/classer la classe k par rapport aux autres.

b) LDA (Linear Discriminant Analysis)

⇒ Variante de l'ACP adaptée à la classification

⇒ Calculs réalisables via la SVD et/ou des calculs de valeurs propres

Données: $X \in \mathbb{R}^{m \times n}$, $X = \begin{bmatrix} X_1 \\ \vdots \\ X_k \end{bmatrix}$ \leftarrow K groupes clusters

But: Trouver une représentation des lignes de X en plus petite dimension qui préserve au mieux la distinction entre les clusters.

$$X = \begin{bmatrix} X_1 \\ \vdots \\ X_k \end{bmatrix} \quad \forall k=1..K, \quad X_k = \begin{bmatrix} x_1^{(k)T} \\ \vdots \\ x_{p_k}^{(k)T} \end{bmatrix} \in \mathbb{R}^{p_k \times n}$$

$$c = \frac{1}{m} \sum_{k=1}^K \sum_{j=1}^{p_k} x_j^{(k)} \quad : \text{individu moyen}$$

$$\forall k=1..K, \text{ on pose } c_k = \frac{1}{p_k} \sum_{j=1}^{p_k} x_j^{(k)} \quad \left. \vphantom{c_k} \right\} \text{Distinction entre les clusters}$$

\rightarrow On centre les données par clusters

$$\forall h=1..K, \quad X_{k,c} = \underbrace{X_h}_{p_h \times n} - \underbrace{1}_{p_h \times 1} \underbrace{(c^{(h)})^T}_{1 \times n} \quad \text{avec } 1_{p_k} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

$$= \begin{bmatrix} (x_1^{(h)} - c^{(h)})^T \\ \vdots \\ (x_{p_h}^{(h)} - c^{(h)})^T \end{bmatrix}$$

$$\text{et on pose } X_w = \begin{bmatrix} X_{1,c} \\ \vdots \\ X_{K,c} \end{bmatrix} \in \mathbb{R}^{m \times n}$$

↳ Permet de définir la matrice de dispersion intra-clusters ("within clusters")

$$S_w = X_w X_w^T \in \mathbb{R}^{m \times m}$$

Une bonne représentation des données devrait minimiser la dispersion

des points d'un même cluster

$$= \sum_{k=1}^K X_{k,c} X_{k,c}^T$$

→ On considère également

$$\bar{X}_c = \bar{X} - 1c^T$$

avec c vecteurs moyen et

$$\bar{X}_c = \begin{bmatrix} (c^{(1)} - c)^T \\ (c^{(2)} - c)^T \\ \vdots \\ (c^{(K)} - c)^T \end{bmatrix}$$

$\uparrow P_1$
 $\downarrow P_K$

$$\bar{X} = \begin{bmatrix} \bar{X}_1 \\ \vdots \\ \bar{X}_K \end{bmatrix}$$

$$X_k = \begin{bmatrix} c^{(k)T} \\ c^{(k)T} \end{bmatrix}$$

chaque vecteur de cluster est remplacé par l'individu moyen de ce cluster

On définit alors la matrice de dispersion inter-clusters ("between clusters")

$$S_b = \bar{X}_c \bar{X}_c^T : \text{indique la dispersion des clusters les uns par rapport aux autres}$$

Une bonne représentation en plus petite dimension devrait maximiser la dispersion des clusters les uns par rapport aux autres

Approche LDA: • Les composantes discriminantes, qui permettent d'identifier au mieux les clusters en plus

⚠ S_w n'est pas forcément inversible
($S_w \geq 0$)

petite dimension, sont données par les valeurs propres et les valeurs propres de $S_w^{-1} S_b$. calculés par ordre décroissant sur les valeurs propres

• Liens avec l'ACP

* Plus grande valeur propre donne le sous-espace de dimension 1 dans lequel la dispersion des clusters est maximale

* Cumulatif. Les q plus grandes valeurs propres donnent le sous-espace de dimension q le plus discriminant.

But du projet : Comparer les résultats de l'ACP et de LDA en termes d'identification de classe / de cluster

Logistique du projet

- Sujet complet \Rightarrow sous 1 semaine (PDF + Notebook)
- Groupes de n étudiant(s) avec $n \in \{1, 2\}$
- Date de rendu : Fin janvier 2025
- Format de rendu : Notebook (+ autres fichiers Python si besoin, PDF)

Examen

- 1^{re} semaine de janvier
- Exercices style TD
- 2 heures
- Autorisé : 1 feuille A4 recto-verso de notes manuscrites ou imprimées