

Reconnaissance des formes et méthodes neuronales

Chapitre 3 : Régression

Michel Crucianu

<http://cedric.cnam.fr/~crucianm/rfmn.html>

25 septembre 2013

RCP208

1

Méthodes de régression

- Modélisation à but **décisionnel** (prédictif)
- Objectif : déterminer une **dépendance entre variables numériques**, permettant de prédire les valeurs de certaines (variables **expliquées**, ou dépendantes, ou prédictives, ou de sortie) à partir des valeurs prises par les autres (variables **explicatives**, ou « indépendantes », ou prédictives, ou d'entrée)
- Pourquoi utiliser les méthodes de régression :
 - ◆ La variable expliquée est difficile à mesurer alors que les variables explicatives sont faciles à mesurer
 - Exemple : estimer la résistance à la traction d'un polymère (dont la mesure destructive) à partir de variables caractérisant le monomère et le processus de polymérisation

25 septembre 2013

RCP208

2

Méthodes de régression (2)

- Pourquoi utiliser les méthodes de régression (suite) :
 - ◆ Les valeurs des variables explicatives peuvent être connues avant celle de la variable expliquée et une prédition de celle-ci est utile
 - Exemple : prédire le volume d'algues vertes sur des plages à partir de la quantité d'engrais utilisés lors de la campagne agricole précédente dans le bassin hydrographique correspondant et de la température moyenne de l'eau lors du trimestre précédent
 - ◆ Dans un ensemble de variables, on cherche à identifier celles dont dépend la variable expliquée
 - ◆ On cherche à savoir comment contrôler les variables d'entrée pour obtenir des valeurs désirées pour la variable de sortie
 - Exemple : la concentration d'un des produits d'une réaction chimique, à partir des quantités initiales de réactifs, de la température et de la pression


25 septembre 2013

RCP208

3

Méthodes de régression (3)

- Critères d'évaluation :
 - ◆ Précision de la prédition
 - ◆ Complexité du modèle
 - ◆ Lisibilité des dépendances
- Modèles linéaires généralisés : dépendance linéaire des **paramètres**
- Généralisations des modèles linéaires : modèles additifs généralisés, modèles non linéaires



25 septembre 2013

RCP208

4

Régression linéaire

- Objectif : obtenir un modèle linéaire avec une dépendance également linéaire des variables explicatives
- Intérêts
 - ◆ Simplicité de modélisation (estimation des paramètres) et de prévision
 - ◆ Lisibilité : la forme additive rend explicite la dépendance des variables prédictives individuelles (valable pour tout modèle additif)
 - ◆ Moyens statistiquement bien fondés d'évaluation
- Forme générale du modèle pour 1 variable de sortie et m variables d'entrée : $Y = \omega_0 + \sum_{j=1}^m \omega_j X_j + \varepsilon$
avec tirages indépendants identiquement distribués (iid)

25 septembre 2013

RCP208

5

Estimation des paramètres

- On considère un ensemble de n observations,
 $D_n = \{(y_i, \mathbf{x}_i)\}_{1 \leq i \leq n}$
 pour lesquelles on écrit (e_i sont les **résidus**)
 $y_i = w_0 + \sum_{j=1}^m w_j x_{ji} + e_i \quad 1 \leq i \leq n$
- On a aussi $\mathbf{y} = \mathbf{X}\mathbf{w} + \mathbf{e}$, où une colonne de 1 a été introduite dans la matrice \mathbf{X} , permettant d'inclure w_0 dans \mathbf{w}
- Estimation des paramètres : méthode des **moindres carrés** où
 on cherche à minimiser $C(\mathbf{w}) = \sum_{i=1}^n (e_i)^2$

25 septembre 2013

RCP208

6

Estimation des paramètres (2)

- Solution : $\mathbf{w}^* = \mathbf{X}^+ \mathbf{y}$, \mathbf{X}^+ étant la **pseudo-inverse Moore-Penrose** de la matrice \mathbf{X} (en général non carrée)
- Si ${}^T \mathbf{X} \mathbf{X}$ est inversible, alors $\mathbf{X}^+ = ({}^T \mathbf{X} \mathbf{X})^{-1} {}^T \mathbf{X}$
- Problèmes : singularité ou mauvais conditionnement de ${}^T \mathbf{X} \mathbf{X}$
 → réduction nécessaire du nombre m de variables explicatives, utilisant par exemple l'ACP, en conservant uniquement les composantes correspondant aux valeurs propres > 0 et assurant un bon conditionnement ($\lambda_{\max}/\lambda_{\min} \leq$ seuil numéro de condition)

25 septembre 2013

RCP208

7

Interprétation probabiliste

- On considère

$$Y = \omega_0 + \sum_{j=1}^m \omega_j X_j + \varepsilon$$
, avec ε suivant $\mathcal{N}(0, \sigma^2)$
- Étant données les observations D_n et un modèle \mathbf{w} , la vraisemblance (*likelihood*) est définie par $l(\mathbf{w} | D_n) = p(D_n | \mathbf{w})$
- Si les observations sont iid, alors $p(D_n | \mathbf{w}) = \prod_{i=1}^n p(y_i, \mathbf{x}_i | \mathbf{w})$
- Question : quel modèle **maximise la vraisemblance** ?
- Avec les hypothèses ci-dessus, on peut facilement montrer (voir page suivante) que la solution \mathbf{w}^* des moindres carrés est également celle du **maximum de vraisemblance**

25 septembre 2013

RCP208

8

Interprétation probabiliste (2)

- On suppose que ε suit une loi $\mathcal{N}(0, \sigma^2)$
- En explicitant la loi normale et en remplaçant ε par son expression on obtient

$$p(y_i, \mathbf{x}_i | \mathbf{w}) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(y_i - w_0 - \sum_{j=1}^m w_j x_{ji})^2}$$
et donc

$$p(D_n | \mathbf{w}) = \prod_{i=1}^n p(y_i, \mathbf{x}_i | \mathbf{w}) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - w_0 - \sum_{j=1}^m w_j x_{ji})^2}$$
- Cette expression étant strictement monotone et décroissante dans l'argument

$$C(\mathbf{w}) = \sum_{i=1}^n (y_i - w_0 - \sum_{j=1}^m w_j x_{ji})^2$$
ses maxima par rapport à \mathbf{w} correspondent aux minima de $C(\mathbf{w})$
- ⇒ La solution du maximum de vraisemblance est donc celle des moindres carrés


25 septembre 2013

RCP208

9

Validité du modèle

- Somme des carrés des résidus : $\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$
- Somme des carrés de régression : $\sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
- Somme totale des carrés : $\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
 (équation d'analyse de la variance)
- Coefficient de corrélation multiple (coefficient de détermination) :



25 septembre 2013

RCP208

10

Validité du modèle (2)

- Degrés de liberté : nombre de composantes indépendantes qui contribuent à chaque somme
 - ◆ $n-1$ pour $\sum_{i=1}^n (y_i - \bar{y})^2$, m pour $\sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
 - ◆ $n-m-1$ pour $\sum_{i=1}^n (y_i - \hat{y}_i)^2$
- **Test global** du modèle : les observations peuvent-elles être le fruit du hasard ? Revient à tester l'hypothèse H_0 : tous les ω sont 0
 - ◆ On peut montrer que le rapport

$$\frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2 / m}{\sum_{i=1}^n (y_i - \bar{y})^2 / (n-m-1)}$$
 suit une distribution $F(m, n-m-1)$
 - ◆ Si la valeur de ce rapport dépasse la valeur limite de la distribution pour un niveau de confiance recherché, on rejette l'hypothèse nulle H_0 et on peut considérer que la relation linéaire trouvée est significative

25 septembre 2013

RCP208

11

Validité du modèle (3)

- La matrice des covariances pour l'estimation $\hat{\omega} = \mathbf{w}^*$ est $(^T \mathbf{X} \mathbf{X})^{-1} \sigma^2$ et permet de tester les paramètres **individuellement** :
 - ◆ Le rapport $w_j / \sqrt{v_j}$ (v_j étant l'élément j de la diagonale de $(^T \mathbf{X} \mathbf{X})^{-1} \sigma^2$ c'est à dire la variance de l'estimation de w_j) suit une distribution $t(n-m-1)$, on peut donc tester chaque hypothèse « w_j est 0 »
- **Choix** entre 2 modèles, \mathcal{M} avec m paramètres, \mathcal{M}^* avec $p > m$ paramètres :
 - ◆ Le rapport

$$\frac{\left[\sum_{i=1}^n (\hat{y}_i^* - \bar{y})^2 - \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \right] / (p-m)}{\left[\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (\hat{y}_i^* - \bar{y})^2 \right] / (n-p-1)}$$
 suit une distribution $F(p-m, n-p-1)$
 - ⇒ On peut tester si la différence entre les 2 modèles est significative

25 septembre 2013

RCP208

12

Construction et inspection du modèle

- Approches :

- ◆ Incrémentale : **ajout** de nouvelles variables une par une (à chaque pas, celle qui réduit le plus la somme des carrés des résidus) et nouveau calcul des paramètres de régression
- ◆ Par élimination : **élimination** progressive de variables (à chaque pas, celle dont l'exclusion fait augmenter le moins la somme des carrés des résidus) et nouveau calcul des paramètres de régression

- Inspection pour évaluer l'adéquation des hypothèses initiales :




- ◆ Vérifier la **constance** de la variance des résidus (homoscédasticité)
- ◆ Vérifier le caractère **linéaire** de la dépendance entre les variables
- Différents graphiques, par exemple celui des résidus par rapport à la variable expliquée (on reste en 2 dimensions !)

25 septembre 2013

RCP208

13

Exemples d'inspection



25 septembre 2013

RCP208

14

Généralisations de la régression

- Modèle linéaire généralisé : Y peut ne pas être normale et

$$g(E[Y]) = \omega_0 + \sum_{j=1}^m \omega_j X_j , g(\cdot) \text{ étant monotone et différentiable}$$

- Modèle additif généralisé :

$$g(E[Y]) = \omega_0 + \sum_{j=1}^m f_j(X_j) , f_j(\cdot) \text{ étant continues, arbitraires}$$

- Modèle non linéaire :


$$Y = f(X_1, \dots, X_m, \varepsilon)$$

25 septembre 2013

RCP208

15

Choix de modèle en régression



25 septembre 2013

RCP208

16