

## UV Des données aux modèles Partie - Problèmes inverses

*Mercredi 9 juin 2009 - 14 :00 à 15 :30*

*Les documents, calequettes et téléphones portables sont interdits.*

*Le barème entre crochets est donné à titre indicatif.*

Dans tout l'examen, on utilise le produit scalaire canonique noté  $\langle \cdot, \cdot \rangle$  et la norme associée notée  $\| \cdot \|_2$ .

### Exercice 1 - Cours (10 points)

1. Rappelez le théorème de décomposition en valeurs singulières [2 pts].
2. Est-ce que la SVD est unique ? Si oui, expliquez pourquoi. Si non, donnez un contre-exemple [1,5 pts].
3. Soit  $A \in \mathcal{M}_n(\mathbb{R})$  une matrice qui admet la décomposition SVD  $A = U\Sigma V^T$ . On admet que  $A$  est inversible. Donnez la SVD de  $A^{-1}$  [1,5 pt].
4. On souhaite résoudre le système  $Ax = b$  où  $A \in \mathcal{M}_{n,n}(\mathbb{R})$ . A quelle condition sur  $A$ , ce système est-t'il bien/mal posé [1 pt] ?
5. On s'intéresse à la résolution de  $Ax = b$  où  $A \in \mathcal{M}_{m,n}(\mathbb{R})$  et  $m > n$  ( $m$  lignes,  $n$  colonnes).
  - Expliquez à quelle condition ce système est bien/mal posé [1,5 pts].
  - Ecrivez le système des équations normales à  $Ax = b$  (les équations que satisfont les solutions au sens des moindres carrés) [1 pt].
  - A quelle condition sur  $A$  le système des équations normales est-il bien/mal posé [1,5 pts] ?

\*\*\*\*\*

### Exercice 2 - Directions privilégiées de la SVD (3,5 pts)


1. Soit  $A = \begin{pmatrix} 1 & 0 \\ 0 & 4 \end{pmatrix}$ . Comment choisir  $x \in \mathbb{R}^2$  tel que  $\|x\|_2 = 1$  et  $\|Ax\|_2$  soit maximal [1 pt] ?
2. Soit  $A = U\Sigma V^T$  avec  $U = (u_1, u_2, \dots, u_m)$  et  $V = (v_1, v_2, \dots, v_n)$ . Comment choisir  $x \in \mathbb{R}^n$  tel que  $\|x\|_2 = 1$  et  $\|Ax\|_2$  soit maximal (justifier) [2,5 pts] ?

\*\*\*\*\*

### Exercice 3 - Analyse en composantes principales (9 pts)

Cet exercice est une introduction à l'analyse en composantes principales.

On dispose d'un ensemble de  $n$  points  $a_i \in \mathbb{R}^m$ . Ces points peuvent être rangés dans une matrice  $A = (a_1, a_2, \dots, a_n)$ . L'idée de l'analyse en composante principale consiste à représenter ces points dans un sous-espace vectoriel de dimension inférieure à  $m$  en gardant l'information essentielle. La figure suivante illustre ce principe.



On voit à gauche un nuage de points de  $\mathbb{R}^3$ . La visualisation de ce nuage est compliquée (c'est encore plus vrai en dimension 4 ou plus). Pour effectuer une visualisation en 2D, on cherche deux axes principaux au nuage notés PC1 et PC2 (PC=Principal Component), et on représente le nuage 3D en projetant les points sur ces deux axes principaux. Cette représentation contient l'information principale du nuage.

Le but de cet exercice est de trouver l'expression des axes principaux. La recherche du premier axe peut être formulée ainsi : on cherche  $x \in \mathbb{R}^m$ , tel que  $\|x\|_2 = 1$ <sup>1</sup> et  $a_i \approx \alpha_i x$  pour un certain  $\alpha_i$ . De manière plus précise, on cherche :

$$\text{Trouver } x \in \arg \min_{x \in \mathbb{R}^m, \|x\|_2=1} \min_{\alpha \in \mathbb{R}^n} \sum_{i=1}^n \|\alpha_i x - a_i\|_2^2 \quad (1)$$

1. On note  $f_i(\alpha_i) = \|\alpha_i x - a_i\|_2^2$ . Calculez :

$$\arg \min_{\alpha_i \in \mathbb{R}} \|\alpha_i x - a_i\|_2^2 \quad [2 \text{ pts}].$$

2. En déduire que le problème (1) est équivalent à :

$$\text{Trouver } x \in \arg \min_{x \in \mathbb{R}^m, \|x\|_2=1} \sum_{i=1}^n \|\langle x, a_i \rangle x - a_i\|_2^2 \quad [1 \text{ pt}]. \quad (2)$$

3. En développant la somme des normes, montrez que le problème (2) est encore équivalent à :

$$\text{Trouver } x \in \arg \min_{x \in \mathbb{R}^m, \|x\|_2=1} -\|A^T x\|_2^2 \quad [3 \text{ pts}] \quad (3)$$

4. On admet que  $A = U\Sigma V^T$  avec  $U = (u_1, u_2, \dots, u_n)$  et  $V = (v_1, v_2, \dots, v_n)$ . En utilisant cette décomposition en valeurs singulières, trouvez la solution du problème (3) [3 pts].
5. On souhaite maintenant connaître le meilleur sous-espace de dimension  $k$  pour représenter nos données. Proposez un problème d'optimisation à résoudre pour trouver les  $k$ -vecteurs engendrant le sous-espace. Avez-vous une idée de la solution, c'est-à-dire pouvez-vous donner une expression explicite de ces  $k$  vecteurs [\* pts] ?

**Note :** vous reverrez ce type de représentation et l'utiliserez souvent dans les cours de statistique de 4ème année.

\*\*\*\*\*

<sup>1</sup>on choisit de le normaliser car il sert juste à définir un sous-espace vectoriel