

Algorithmique des Réseaux Sociaux

10 Décembre

Décomposition en valeurs singulières et complétion de matrices

1. Montrer que $\|A\|_2 \leq \|A\|_F \leq \sqrt{r}\|A\|_2$ où r est le rang de A .
2. Calculer les valeurs propres de la matrice symétrique :

$$H = \begin{pmatrix} 0 & A^T \\ A & 0 \end{pmatrix}.$$

3. Soit A, B des matrices réelles de dimensions $m \times n$. Montrer que pour tout $i + j \leq 1 + m \wedge n$, on a :

$$\sigma_{i+j-1}(A) \leq \sigma_i(B) + \sigma_j(A - B).$$

En déduire que

$$\max_{1 \leq k \leq m \wedge n} |\sigma_k(A) - \sigma_k(B)| \leq \|A - B\|_2.$$

4. Étant donné une matrice A , on note A_k la meilleur approximation de A de rang k . Montrer que

$$\|B - B_k\|_2 \leq \|A - A_k\|_2 + \|A - B\|_2.$$

En déduire que $\|A - B_k\|_2 \leq \|A - A_k\|_2 + 2\|A - B\|_2$.

On se place dans le cadre suivant : soit M une matrice de dimensions $m \times n$ avec $m \leq n$ (modélisant les notes des utilisateurs) de rang r .

Soit $p \in [0, 1]$. On suppose que chaque entrée de M est observée avec probabilité p et non observée avec probabilité $1 - p$ indépendamment des autres entrées.

Pour simplifier, on supposera $M_{ij} \in [0, 1]$ et que les paramètres p et r sont connus.

Nous construisons une estimation \hat{M} de M à partir des entées observées de la manière suivante :

a- Soit X la matrice avec $x_{ij} = m_{ij}$ si l'entrée est observée et $x_{ij} = 0$ sinon. Soit $X = \sum_{i=1}^m s_i \mathbf{u}_i \mathbf{v}_i^T$ sa décomposition en valeurs singulières.

b- On définit

$$W = \frac{1}{p} \sum_{i \leq r} s_i \mathbf{u}_i \mathbf{v}_i^T.$$

On définit alors la matrice \hat{M} par $\hat{m}_{ij} = m_{ij}$ si l'entrée (ij) est observée et sinon par :

$$\hat{m}_{ij} = \begin{cases} w_{ij} & \text{si } 0 \leq w_{ij} \leq 1, \\ 1 & \text{si } w_{ij} > 1, \\ 0 & \text{si } w_{ij} < 0. \end{cases}$$

On définit alors la mesure d'erreur :

$$MSE(\hat{M}) = \mathbb{E} \left[\frac{1}{mn} \|M - \hat{M}\|_F^2 \right].$$

5. Montrer que $\|M - W\|_F^2 \leq 8r\|M - \frac{1}{p}X\|_2^2$. En déduire

$$MSE(\hat{M}) \leq \frac{8r}{mnp^2} \mathbb{E} [\|pM - X\|_2^2]$$

Pour borner le dernier terme, nous allons utiliser l'inégalité matricielle de Bernstein : Soit $Z_1, \dots, Z_k \in \mathbb{R}^{m \times n}$ des matrices aléatoires symétriques telles que $\mathbb{E}[Z_t] = 0$, $\|Z_t\|_2 \leq 1$ et $\max \left\{ \left\| \sum_{t=1}^k \mathbb{E}[Z_t Z_t^T] \right\|_2; \left\| \sum_{t=1}^k \mathbb{E}[Z_t^T Z_t] \right\|_2 \right\} \leq \sigma^2$. On a

$$\mathbb{P} \left(\left\| \sum_{t=1}^k Z_t \right\|_2 \geq s \right) \leq (m+n) \exp \left(-\frac{s^2}{2(\sigma^2 + s/3)} \right).$$

6. On définit $Y = pM - X$. Calculer $\mathbb{E}[Y]$. Montrer que $\|Y\| \leq n$.

7. Montrer que

$$\mathbb{P} (\|Y\| \geq s) \leq (m+n) \exp \left(-\frac{s^2}{2(np + s/3)} \right)$$

8. En déduire que pour $np > \ln n$, il existe une constante C telle que :

$$MSE(\hat{M}) \leq \frac{Cr \log n}{mp}.$$