
Méthodes numériques approximation et optimisation

Optimisation – Approximation

Approches non-linéaires

Méthodes non-linéaires

- Impossible de réduire le problème à un ensemble de contraintes linéaires
- Méthodes itératives
 - Aller pas à pas vers une solution
 - Convergence vers un minimum local
 - Lieu où les dérivées partielles sont nulles
 - Si solution unique, on la trouve

Rappel : Méthode de Newton 1D - $e(x) = 0$

- Approximation localement affine (développement de Taylor)

$$e(x^{(k)} + h) \simeq e(x^{(k)}) + \partial_x e(x^{(k)}) h$$

- On cherche le zéro

$$h = - \frac{e(x^{(k)})}{d_x e(x^{(k)})}$$

- On itère


$$x^{(k+1)} = x^{(k)} - \frac{e(x^{(k)})}{d_x e(x^{(k)})}$$

Méthode de Newton

- Illustration

$$y = \tanh(x)\cos(x^2) + x - 2$$

$$y' = (1 - \tanh^2(x))\cos(x^2) - 2\tanh(x)\sin(x^2)x + 1$$



Méthode de Newton

- Illustration

$$y = \tanh(x) \cos(x^2) + x - 2$$

$$y' = (1 - \tanh^2(x)) \cos(x^2) - 2 \tanh(x) \sin(x^2) x + 1$$


$$u_0 = 2$$

$$u_1 = 2.1627$$

$$u_2 = 2.1380$$

$$u_3 = 2.1378$$

$$u_4 = 2.1378$$



Méthode de Newton : convergence

- Convergence quadratique

$$\left| x^{(k+1)} - x \right| \simeq \left| x^{(k)} - x \right|^2 \left| \frac{d_{xx}^2 e(x)}{2 d_x e(x)} \right|$$

- Conditions

- Dérivée analytique connue
- Intersection de la tangente dans le domaine de définition

Optimisation 1D – $e'(x) = 0$

- Approximation localement affine

$$e(x^{(k)} + h) \simeq e(x^{(k)}) + d_x e(x^{(k)}) h + \frac{1}{2} d_{xx}^2 e(x^{(k)}) h^2$$

- On cherche le zéro de la dérivée

- On itère


$$h = - \frac{d_x e(x^{(k)})}{d_{xx}^2 e(x^{(k)})}$$

$$x^{(k+1)} = x^{(k)} - \frac{d_x e(x^{(k)})}{d_{xx}^2 e(x^{(k)})}$$

Extension du développement : Fonction 2D

- Comment étendre le développement de Taylor ?

$$e(x, y) = x \cos\left(\frac{x}{2}\right) \sin\left(\frac{y}{2}\right)$$




Extension du développement : Fonction 2D

- Comment étendre le développement de Taylor ?

- Gradient

$$\nabla e(x) = \begin{bmatrix} \partial_x e \\ \partial_y e \end{bmatrix}$$

$$e(x, y) = x \cos\left(\frac{x}{2}\right) \sin\left(\frac{y}{2}\right)$$



$$\nabla e(x) = \begin{bmatrix} \sin\left(\frac{y}{2}\right) \left(\cos\left(\frac{x}{2}\right) - \frac{x}{2} \sin\left(\frac{x}{2}\right) \right) \\ \frac{x}{2} \cos\left(\frac{x}{2}\right) \cos\left(\frac{y}{2}\right) \end{bmatrix}$$

Extension du développement : Fonction 2D

- Comment étendre le développement de Taylor ?


- Gradient $\nabla e(x) = \begin{bmatrix} \partial_x e \\ \partial_y e \end{bmatrix}$
-
- Dérivée 1ere ordre
 - Produit scalaire direction/gradient

$$\mathbf{d} = (d_x, d_y) \in \mathcal{R}^2$$

$$\partial_{\mathbf{d}} e = \langle \mathbf{d}, \nabla e \rangle$$

$$\partial_{\mathbf{d}} e = d_x \partial_x e + d_y \partial_y e$$

$$e(x, y) = x \cos\left(\frac{x}{2}\right) \sin\left(\frac{y}{2}\right)$$



$$\nabla e(x) = \begin{bmatrix} \sin\left(\frac{y}{2}\right) \left(\cos\left(\frac{x}{2}\right) - \frac{x}{2} \sin\left(\frac{x}{2}\right) \right) \\ \frac{x}{2} \cos\left(\frac{x}{2}\right) \cos\left(\frac{y}{2}\right) \end{bmatrix}$$

Dérivation en dimension N

- Une équation, N inconnues :

$$e(\mathbf{x} + \mathbf{h}) = e(\mathbf{x}) + \nabla^T e(\mathbf{x}) \mathbf{h} + \frac{1}{2} \mathbf{h}^T \mathbf{H}_e(\mathbf{x}) \mathbf{h} + o(\|\mathbf{h}\|_2^2)$$

gradient

matrice Hessienne

$$\nabla e = \begin{bmatrix} \partial_{x_1} e \\ \vdots \\ \partial_{x_i} e \\ \vdots \\ \partial_{x_N} e \end{bmatrix}$$

$$\mathbf{H}_e(\mathbf{x}) = \begin{bmatrix} \partial_{x_1 x_1}^2 e & \cdots & \partial_{x_1 x_i}^2 e & \cdots & \partial_{x_1 x_N}^2 e \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \partial_{x_i x_1}^2 e & \cdots & \partial_{x_i x_i}^2 e & \cdots & \partial_{x_i x_N}^2 e \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \partial_{x_N x_1}^2 e & \cdots & \partial_{x_N x_i}^2 e & \cdots & \partial_{x_N x_N}^2 e \end{bmatrix}$$

Dérivation en dimension N

- Une équation, N inconnues :

$$e(\mathbf{x} + \mathbf{h}) = e(\mathbf{x}) + \nabla^T e(\mathbf{x}) \mathbf{h} + \frac{1}{2} \mathbf{h}^T \mathbf{H}_e(\mathbf{x}) \mathbf{h} + o(\|\mathbf{h}\|_2^2)$$

gradient = tenseur 1D

matrice Hessienne = tenseur 2D

$$\nabla e = \begin{bmatrix} \partial_{x_1} e \\ \vdots \\ \partial_{x_i} e \\ \vdots \\ \partial_{x_N} e \end{bmatrix}$$

$$\mathbf{H}_e(\mathbf{x}) = \begin{bmatrix} \partial_{x_1 x_1}^2 e & \cdots & \partial_{x_1 x_i}^2 e & \cdots & \partial_{x_1 x_N}^2 e \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \partial_{x_i x_1}^2 e & \cdots & \partial_{x_i x_i}^2 e & \cdots & \partial_{x_i x_N}^2 e \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \partial_{x_N x_1}^2 e & \cdots & \partial_{x_N x_i}^2 e & \cdots & \partial_{x_N x_N}^2 e \end{bmatrix}$$

Matrice Hessienne

- Tenseur d'ordre 2
 - Associée à une forme quadratique
- Symétrique
 - Théorème de Schawrz

$$\frac{1}{2} \mathbf{h}^T \mathbf{H}_e(\mathbf{x}) \mathbf{h}$$

Pour une fonction n-dérivable et dont les dérivées sont continues, l'ordre de dérivation n'a pas d'influence sur le résultat.

- Mise en application

$$e(x, y) = x \cos\left(\frac{x}{2}\right) \sin\left(\frac{y}{2}\right)$$

$$\mathbf{H}_e(\mathbf{x}) = \begin{bmatrix} -\sin\left(\frac{y}{2}\right) \left(\sin\left(\frac{x}{2}\right) + \frac{x}{4} \cos\left(\frac{y}{2}\right) \right) & \frac{1}{2} \cos\left(\frac{y}{2}\right) \left(\cos\left(\frac{x}{2}\right) - \frac{x}{2} \sin\left(\frac{x}{2}\right) \right) \\ \frac{1}{2} \cos\left(\frac{y}{2}\right) \left(\cos\left(\frac{x}{2}\right) - \frac{x}{2} \sin\left(\frac{x}{2}\right) \right) & -\frac{x}{4} \cos\left(\frac{x}{2}\right) \sin\left(\frac{y}{2}\right) \end{bmatrix}$$

Rappel : dérivation en dimension $N \times M$

- M équations, N inconnues :

$$\mathbf{e}(\mathbf{x} + \mathbf{h}) = \mathbf{e}(\mathbf{x}) + \mathbf{J}_e(\mathbf{x})\mathbf{h} + o(\|\mathbf{h}\|_2)$$

La matrice jacobienne

$$\mathbf{J}_e(\mathbf{x}) = \begin{bmatrix} \partial_{x_1} \mathbf{e}_1(\mathbf{x}) & \partial_{x_2} \mathbf{e}_1(\mathbf{x}) & \cdots & \partial_{x_N} \mathbf{e}_1(\mathbf{x}) \\ \partial_{x_1} \mathbf{e}_2(\mathbf{x}) & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ \partial_{x_1} \mathbf{e}_N(\mathbf{x}) & \cdots & \cdots & \partial_{x_N} \mathbf{e}_N(\mathbf{x}) \end{bmatrix}$$

Matrice Jacobienne

- Attention : dérivée à l'ordre 1
 - Équivalent du gradient pour des fonctions multivaluées
 - Différente de la matrice hessienne
- Utilisé pour le changement de variable pour l'intégration
 - \mathbf{e} est une fonction bijective
 - $N = M$ (matrice carrée)

$$\iiint_D \mathbf{f}(\mathbf{x}) \, dx_1 \dots dx_N = \iiint_{\mathbf{e}^{-1}(D)} \mathbf{f}(\mathbf{e}(\mathbf{x})) |\det J_{\mathbf{e}}(\mathbf{x})| \, de_1 \dots de_N$$

Optimisation trouver $\nabla e(\mathbf{x}) = 0$

- Approximation localement polynomiale

$$e(\mathbf{x}^{(k)} + \mathbf{h}) = e(\mathbf{x}^{(k)}) + \mathbf{h}^T \nabla e(\mathbf{x}^{(k)}) + \frac{1}{2} \mathbf{h}^T \mathbf{H}_e(\mathbf{x}^{(k)}) \mathbf{h}$$

- On cherche le zéro du gradient

$$\mathbf{h} = -(\mathbf{H}_e(\mathbf{x}^{(k)}))^{-1} \nabla e(\mathbf{x}^{(k)})$$

- On itère

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - (\mathbf{H}_e(\mathbf{x}^{(k)}))^{-1} \nabla e(\mathbf{x}^{(k)})$$

Problème de la méthode de Newton

- Si la Hessienne n'est pas semi-définie positive
 - Le pas accroît l'erreur

Descente de gradient

- Suivre la pente de la fonction
 - Pente = gradient
- Choisir un pas pour avancer dans cette direction


$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \rho \nabla e(\mathbf{x}^{(k)}) \text{ avec } \rho \text{ tel que } e(\mathbf{x}^{(k+1)}) < e(\mathbf{x}^{(k)})$$

$$\min_{\rho} e(\mathbf{x}^{(k)} + \rho \nabla e(\mathbf{x}^{(k)}))$$

$$\partial_{\rho} e(\mathbf{x}^{(k)} + \rho \nabla e(\mathbf{x}^{(k)})) = 0 = (\nabla e(\mathbf{x}^{(k)}))^T \nabla e(\mathbf{x}^{(k)} + \rho \nabla e(\mathbf{x}^{(k)}))$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \frac{\nabla^T e(\mathbf{x}^{(k)}) \nabla e(\mathbf{x}^{(k)})}{\nabla^T e(\mathbf{x}^{(k)}) \mathbf{H}_e(\mathbf{x}^{(k)}) \nabla e(\mathbf{x}^{(k)})} \nabla e(\mathbf{x}^{(k)})$$

Descente de gradient



Descente de gradient : méthode itérative

- Soit K le conditionnement de M
 - Convergence

$$\| \mathbf{e} \|_Q^2 = \mathbf{e}^T \mathbf{Q} \mathbf{e} \quad \| \mathbf{e}^{(i)} \|_Q \leq \left(\frac{K-1}{K+1} \right)^{(i)} \| \mathbf{e}^{(0)} \|_Q$$

- Le point de départ est très important
 - Ex : Partir du résultat d'une méthode directe
- Autre question
 - Une meilleure direction ?

Gradient conjugué

- Principe

- M est symétrique définie positive
- Directions de descente orthogonales au sens M

$$\mathbf{x} \perp \mathbf{y} \Leftrightarrow \mathbf{x}^T \mathbf{Q} \mathbf{x} = 0$$

- Pour chaque itération

- Direction orthogonale (Gram-Schmidt)

$$\mathbf{d}_i = \mathbf{r}_i - \sum_{k < i} \frac{\mathbf{d}_k^T \mathbf{Q} \mathbf{r}_i}{\mathbf{d}_k^T \mathbf{Q} \mathbf{d}_k} \mathbf{d}_k$$

- Nouveau pas

$$a = \frac{\mathbf{d}_i^T \mathbf{r}_i}{\mathbf{d}_i^T \mathbf{Q} \mathbf{d}_i}$$

Comparaison des convergences

- Soit K le conditionnement de la matrice M
- Descente de gradient

$$\| \mathbf{e}^{(i)} \|_Q \leq \left(\frac{K-1}{K+1} \right)^{(i)} \| \mathbf{e}^{(0)} \|_Q$$

- Gradient conjuguée

$$\| \mathbf{e}^{(i)} \|_Q \leq 2 \left(\frac{\sqrt{K}-1}{\sqrt{K}+1} \right)^{(i)} \| \mathbf{e}^{(0)} \|_Q$$

Préconditionnement

- Principe

- Remplacer le système à résoudre par un système équivalent mieux conditionné

$$\mathbf{A} \mathbf{x} = \mathbf{b} \Leftrightarrow \mathbf{C}^{-1} \mathbf{A} \mathbf{x} = \mathbf{C}^{-1} \mathbf{b}$$

- Idée : uniformiser les valeurs propres

- Ex : Préconditionnement de Jacobi

- Prendre les éléments diagonaux de A

$$c_{ij} = \begin{cases} A_{ii} & \text{si } i = j \\ 0 & \text{sinon} \end{cases}$$

Formalisation en fonction du résidu r

- Cas scalaire
- Cas vectoriel

- Autre formalisation

Formalisation en fonction du résidu r

$$\mathbf{r}_n(\mathbf{v}) = y_n - f_{\mathbf{v}}(\mathbf{x}_n)$$

$$e(\mathbf{v}) = \sum_{n=1}^N r_n^2(\mathbf{v})$$

$$\mathbf{J}_r = \begin{bmatrix} \partial_{v_1} \mathbf{r}_1 & \partial_{v_2} \mathbf{r}_1 & \cdots & \partial_{v_M} \mathbf{r}_1 \\ \partial_{v_1} \mathbf{r}_2 & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ \partial_{v_1} \mathbf{r}_N & \cdots & \cdots & \partial_{v_M} \mathbf{r}_N \end{bmatrix}$$

$$\nabla e = 2 \left(\mathbf{J}_r^T \mathbf{r} \right)$$

Matrice Hessienne

$$\mathbf{r}_n(\mathbf{v}) = y_n - \mathbf{f}_v(\mathbf{x}_n)$$

$$e(\mathbf{v}) = \sum_{n=1}^N \mathbf{r}_n^2(\mathbf{v})$$

$$\mathbf{J}_r = \begin{bmatrix} \partial_{v_1} \mathbf{r}_1 & \partial_{v_2} \mathbf{r}_1 & \cdots & \partial_{v_M} \mathbf{r}_1 \\ \partial_{v_1} \mathbf{r}_2 & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ \partial_{v_1} \mathbf{r}_N & \cdots & \cdots & \partial_{v_M} \mathbf{r}_N \end{bmatrix}$$

$$\mathbf{H}_e = 2 \left(\mathbf{J}_r^T \mathbf{J}_r + \sum_{n=1}^N \mathbf{r}_n \mathbf{H}_{r_n} \right)$$

Méthode de Gauss-Newton

- Remplacer la Hessienne

$$\mathbf{H}_e \simeq \mathbf{J}_r^T \mathbf{J}_r \quad \mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - (\mathbf{H}_e(\mathbf{x}^{(k)}))^{-1} \nabla e(\mathbf{x}^{(k)})$$

- Avantages
 - Pas de dérivée seconde
 - La matrice est semi-définie positive
- Limitations
 - Approximations valides si petits résidus
 - Le point initial doit être près de la solution finale

Levenberg-Marquardt

- Méthode très couramment utilisée
- A chaque étape, la direction de descente h est

$$\left(J_r^T J_r + \lambda \text{diag} (J_r^T J_r) \right) \mathbf{h} = J_r^T \mathbf{r}$$

- Le choix de λ conditionne la méthode
 - Petit, on a Newton
 - Grand, on a une méthode de descente rapide
- Meilleur conditionnement au bruit

Résolution itérative de système linéaire

- Rappel: résoudre
- Problèmes
 - Grande dimension : méthodes directes coûteuses
 - Problème de précision
- Principe
 - Reformuler le problème au moindres carrés

$$A \mathbf{x} = \mathbf{b}$$

$$\min_x \|A \mathbf{x} - \mathbf{b}\|^2 = \min_x \frac{1}{2} \mathbf{x}^T M \mathbf{x} - \mathbf{c}^T \mathbf{x}$$

- Progressivement améliorer le résultat

Descente de gradient : méthode itérative

- M est symétrique définie positive
- Le gradient en x_i est le résidu
- Pas de descente a tel que

$$\min_x \frac{1}{2} \mathbf{x}^T \mathbf{M} \mathbf{x} - \mathbf{c}^T \mathbf{x}$$

$$\nabla_i = \mathbf{M} \mathbf{x}_i - \mathbf{c} = \mathbf{r}_i$$


$$\min_x \left\| \frac{1}{2} (\mathbf{x}_i + a \mathbf{r}_i)^T \mathbf{M} (\mathbf{x}_i + a \mathbf{r}_i) - \mathbf{c}^T (\mathbf{x}_i + a \mathbf{r}_i) \right\|^2$$

$$a = \frac{\mathbf{r}_i^T \mathbf{r}_i}{\mathbf{r}_i^T \mathbf{M} \mathbf{r}_i}$$

Autres systèmes : Valeurs propres - SVD

Moindres carrés sous-constraint

- Moins de mesures que de variables
 - Impossible théoriquement d'utiliser les moindres carrés
 - Le système à résoudre a la forme $A^T A x = A^T b$
 - A a plus de colonnes que de lignes
 - $A^T A$ est donc singulière
- Les mesures sont de mauvaises contraintes
 - $A^T A$ est presque singulière : mauvais conditionnement
 - Ex : approcher avec la parabole $y = ax^2 + bx + c$



Décomposition singulière SVD

- Soit une matrice A de dimension $M \times N$
 - Il existe 2 matrices orthogonales U ($M \times M$) et V ($N \times N$) et une matrice diagonale Σ de dimension $P = \min(M, N)$ telle que

$$A = U \Sigma V^T$$

- Avec $\Sigma = \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sigma_P \end{bmatrix} \quad \sigma_1 \geq \sigma_2 \geq \cdots \geq \sigma_P \geq 0$

- Les σ_i sont les valeurs singulières
- Les colonnes de U et V sont les vecteurs singuliers de gauche et de droite

Interpretations


- Lien avec les valeurs propres

$$\Sigma^T \Sigma = (U^T A V)^T U^T A V = V^T A^T U U^T A V = V^T A^T A V$$

- Donc : les σ_i^2 sont les valeurs propres de $A^T A$ et $A A^T$

- Demi-longueurs des axes de l'hyperellipse

$$\mathbf{x}^T A^T A \mathbf{x} - 1 = 0$$



- Conditionnement

$$K(A) = \frac{\sigma_{max}}{\sigma_{min}}$$

$$K(A) = \frac{\sigma_1}{\sigma_p}$$

Calcul de pseudo inverse

- On définit la matrice

$$A^+ = V \Sigma^+ U^T$$

$$\Sigma^+ = \begin{bmatrix} \frac{1}{\sigma_1} & 0 & \dots & \dots & \dots & \dots & 0 \\ 0 & \ddots & \ddots & & & & \vdots \\ \vdots & \ddots & \frac{1}{\sigma_R} & \ddots & & & \vdots \\ \vdots & & \ddots & 0 & \ddots & & \vdots \\ \vdots & & & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & \dots & \dots & 0 & 0 & 0 \end{bmatrix}$$

- Principes
 - On annule les valeurs inverses trop grandes
 - On laisse libre un certain nombre de paramètres

Applications

- Avantage : méthode numérique stable
 - Coût : $O(n^3)$
 - Plus rapide si l'on ne cherche Σ , U et Σ , ou Σ et V
- Calcul du rang R

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_R > \sigma_{R+1} = \dots = \sigma_P = 0$$

- En matlab

```
s=svd(X);
```

```
tol=max(size(X))*s(1)*eps;
```

```
rang=sum(s > tol);
```

- Approximation par une somme de matrice de rang $\uparrow A = \sum_{i=1}^P \sigma_i \mathbf{u}_i \mathbf{v}_i^T$

$$A_K = \sum_{i=1}^K \sigma_i \mathbf{u}_i \mathbf{v}_i^T \quad \left\| A - A_K \right\|_2 = \sigma_{K+1}$$

Analyse en composantes principales (PCA)

- Une méthode de réduction de dimension des données
 - Projection au sens des moindres carrés
 - Capturer les principales variations

- Une première approximation

- Meilleur représentant au sens des moindres carrés $\min_a \sum_{m=1}^M \|\mathbf{y}_m - \mathbf{a}\|_2^2$

$$\mathbf{a} = \frac{1}{M} \sum_{m=1}^M \mathbf{y}_m$$

- Quelles sont le ou les directions principales ?
- Représenter les données par une ligne passant par la moyenne

$$\mathbf{y}_m = \mathbf{a} + \alpha_m \mathbf{e}$$

$$\min_{\alpha_1, \dots, \alpha_M, \mathbf{e}} \sum_{m=1}^M \|\mathbf{y}_m - \mathbf{a} - \alpha_m \mathbf{e}\|_2^2$$

PCA – Intuitions (suite)

- Calculer les α_m par différentiation partielle

$$\alpha_m = \mathbf{e}^T (\mathbf{y}_m - \mathbf{a})$$

- Nouvelle erreur pour calculer la direction principale

$$\begin{aligned} \sum_{m=1}^M \|\mathbf{y}_m - \mathbf{a} - \alpha_m \mathbf{e}\|_2^2 &= \sum_{m=1}^M \alpha_m^2 - 2 \sum_{m=1}^M \alpha_m \mathbf{e}^T (\mathbf{y}_m - \mathbf{a}) + \sum_{m=1}^M \|\mathbf{y}_m - \mathbf{a}\|^2 \\ &= - \sum_{m=1}^M \mathbf{e}^T (\mathbf{y}_m - \mathbf{a}) (\mathbf{y}_m - \mathbf{a})^T \mathbf{e} + \sum_{m=1}^M \|\mathbf{y}_m - \mathbf{a}\|^2 \\ &= - \mathbf{e}^T \mathbf{S} \mathbf{e} + \sum_{m=1}^M \|\mathbf{y}_m - \mathbf{a}\|^2 \end{aligned}$$

- Matrice de covariance (scatter matrix)
- Minimisation sous contrainte

$$\mathbf{S} = \sum_{m=1}^M (\mathbf{y}_m - \mathbf{a})(\mathbf{y}_m - \mathbf{a})^T$$

$$\max_{\mathbf{e}} \mathbf{e}^T \mathbf{S} \mathbf{e}$$

$$\|\mathbf{e}\|^2 = 1$$

PCA – Intuitions (fin)

- Utilisation des multiplicateurs de Lagrange
- Par dérivation
 - \mathbf{e} est un vecteur propre de la matrice S
- Peut-être étendue à M directions principales
 - Calcul d'une SVD
 - Amplitude de variation = valeur propre
 - Direction de variation = vecteur propre

$$\mathbf{e}^T S \mathbf{e} - \lambda (\mathbf{e}^T \mathbf{e} - 1)$$

$$S \mathbf{e} = 2 \lambda \mathbf{e}$$

