

167: Systèmes d'équations linéaires, opérations élémentaires, aspects algorithmiques et numériques.

Ref: [Gi] Grifone, Algèbre linéaire. [Gou] Gourdon, Algèbre linéaire. [Per] Perrin, Cours d'algèbre. [Qua] Quatrevin, Méthodes numériques pour le calcul numérique.

Deuts: 13 Cécile Rabreau, GE(S)LE  
23 Convergence methods, itératives  
30 Gradient à pas optimal.

[Rem] [Cis] [Cis]

I. Généralités sur les systèmes linéaires.  $k$  corps

1) Définitions.  
Def 1: On appelle système d'équations linéaires un système de la forme 
$$\begin{cases} a_{11}x_1 + \dots + a_{1p}x_p = b_1 \\ \vdots \\ a_{p1}x_1 + \dots + a_{pp}x_p = b_p \end{cases} \quad (1)$$

où les  $(a_{ij})$  et les  $(b_i)$  sont des éléments de  $k$  fixés. On appelle solution d'un tel système tout vecteur  $x = (x_1, \dots, x_p) \in k^p$  dont les coordonnées vérifient chacune des équations de (1).  
Le système est dit compatible si l'admet au moins une solution.  
Ex:  $\begin{cases} x+y=1 \\ x=0 \end{cases}$  est compatible  $\begin{cases} x+y=1 \\ x+y=0 \end{cases}$  ne l'est pas.

Expression matricielle. Dans l'expression (1), on pose  $A = (a_{ij}) \in \mathcal{M}_p(k)$  et  $b = (b_1, \dots, b_p) \in k^p$ . Un vecteur  $x = (x_1, \dots, x_p) \in k^p$  est solution du système (1) si et seulement si on a  $Ax = b$  dans  $k^p$ . On peut alors se fixer le rang du système comme le rang de la matrice  $A$ .  
Prop 3: En notant  $(A_1, \dots, A_m)$  les colonnes de  $A$ , le système  $Ax = b$  est compatible si et seulement si  $b \in \text{Vect}(A_1, \dots, A_m)$ .  
Ex 4:  $\begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 2 \\ 0 \end{pmatrix}$  est compatible ;  $\begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 2 \\ 0 \end{pmatrix}$  est incompatible.

2) Système de Cramer.  
Def 5: On dit que le système  $Ax = b$  est de Cramer si la matrice  $A$  est inversible. Un tel système admet une unique solution donnée par  $A^{-1}b$ .  
Théor 6: Un système de Cramer  $Ax = b$ , où  $A = (a_{ij}) = (A_1 \dots A_m)$   $A_{ij} \in k^n$  alors  $x_i$  est donné par  $\frac{\det(A_1, \dots, A_{i-1}, b, A_{i+1}, \dots, A_m)}{\det A}$ .

Prop 7: Cette méthode requiert  $(n+1)!$  opérations, c'est tout à fait impraticable (120 opérations pour un  $3 \times 3$ , c'est juste le top).  
On sera amené à chercher des algorithmes plus efficaces pour trouver (ou approx) la solution.

3) Cas général, théorème de Rouché-Frobenius.  
On considère  $A \in \mathcal{M}_p(k)$ ,  $b \in k^p$ ,  $A$  de rang  $r$ , quitte à faire des permutations lignes colonnes de  $A$ , on suppose

que la sous matrice  $(a_{ij})_{i,j \in \{1, \dots, r\}}$  est inversible. On note  $\delta$  le déterminant de cette sous matrice.

Théor 8: Pour  $A \in \mathcal{M}_p(k)$ ,  $b \in k^p$ ,  $A$  de rang  $r$ , telle que le mineur  $\delta$  soit non nul.

1) Le système est compatible si et seulement si tous les déterminants conditionnels  $\Delta_j = \begin{vmatrix} a_{11} & \dots & a_{1r} & b_1 \\ \vdots & \ddots & \vdots & \vdots \\ a_{r1} & \dots & a_{rn} & b_r \end{vmatrix} = 0 \quad j = (r+1, \dots, m)$

2) Si cette condition est réalisée, le système est équivalent au système des équations principales.

$a_{11}x_1 + \dots + a_{1r}x_r = b_1 - a_{1r+1}x_{r+1} - \dots - a_{1m}x_m$   
 $\vdots$   
 $a_{r1}x_1 + \dots + a_{rn}x_r = b_r - a_{r2}x_{r+1} - \dots - a_{rn}x_m$   
Il admet alors une infinité de solutions dépendant de  $m-r$  paramètres, les solutions se calculent en résolvant le système de Cramer obtenu en donnant aux variables libres  $x_{r+1}, \dots, x_m$  des valeurs arbitraires.

Ex 9:  $A = \begin{pmatrix} 2 & -3 & 1 \\ 1 & 4 & -2 \\ 8 & -1 & -1 \end{pmatrix} X = \begin{pmatrix} 1 \\ 0 \\ 3 \end{pmatrix}$ , alors  $x = \frac{2\lambda + 4}{11}$ ,  $y = \frac{5\lambda - 1}{11}$ ,  $z = \lambda$ .

Cor 10: Équations d'un sous-espace vectoriel  $S$ : Espace de dimension finie  $m$ .  
- Soit  $p$  formes linéaires  $\varphi_1, \dots, \varphi_p$  de  $E^*$  telles que  $\text{rang}(\varphi_1, \dots, \varphi_p) = r$ . Le sous-espace  $F = \{x \in E \mid \varphi_i(x) = 0 \forall i\}$  est de dimension  $r$ .  
- Réciproquement si  $F$  est de dimension  $q$ , il existe  $m-q$  formes linéaires linéairement indépendantes  $\varphi_1, \dots, \varphi_{m-q}$  telles que  $F = \{x \in E \mid \forall i \in \{1, \dots, m-q\} \varphi_i(x) = 0\}$ .

II Systèmes à coefficients et résolution directe.

1) Réduction, non réduction, dilatation.  
Prop 11: Soit  $H \subseteq E$  un hyperplan de  $E$  et  $u \in \mathcal{GL}(E)$  tel que  $u|_H = \text{Id}_H$ ,  $u|_{H^\perp} = D$ .  
-  $\det u = \lambda \neq 1 \implies \exists \lambda \in \sigma(u) \setminus \{1\}$ ,  $u$  est diagonalisable et  $D = E_\lambda$ .  
- On a  $\text{Im}(u - \text{id}) \subseteq H$ . Dans une base convenable, on a  $M(u) = \text{Fig } 1$ .  
On dit alors que  $u$  est une dilatation, de droite  $D$ , d'hyperplan  $H$  et de rapport  $\lambda$ . Si  $\lambda = -1$  et car  $k \neq \mathbb{Z}$ , on dit que  $u$  est une réflexion.

Prop 12: Soit  $H \subseteq E$  un hyperplan, d'équation  $\{x \in E \mid \varphi(x) = 0\}$ . Soit  $u \in \mathcal{GL}(E)$ ,  $u \neq \text{Id}$  tel que  $u|_H = \text{Id}_H$ . On a équivalence entre

[Gi] p37

[Gi] 142 143

[Gi] 145 147

[Gou] 128

[Per] 96 97

[Pon] 99. 100

- on a  $\det u = 1$  -  $u$  n'est pas diagonalisable -  $D = \text{Im}(u - \text{Id}) \subseteq W$   
 - le morphisme  $\tilde{u}: E/W \rightarrow E/W$  est l'identité -  $\exists \alpha \in W \setminus \{0\} \forall x \in E, u(x) = x + \alpha f(x)$ .  
 - Dans une base convenable, la matrice de  $u$  a la forme (Fig 2).  
 On dit alors que  $u$  est une translation d'un hyperplan  $H$  d'axe droit  $D$ , on pose la notation  $Z(f, \alpha)$ .

**Théor 13:** Les translations engendrent  $SL(E)$ , les translations et dilatations engendrent  $GL(E)$ . PVP

[V2G2] 130 131

**Def 14:** Soit  $A \in \mathcal{M}_n(k)$ , on appelle  $i$ -pivot une ligne non nulle le premier coefficient non nul sur la ligne. On dit que  $A$  est dite réduite en ligne si  
 -  $S$ : la ligne  $i$  est nulle, c'est aussi le cas de toutes les lignes situées en dessous de la ligne  $i$ .  
 - la  $i$ -pivot d'une ligne est strictement plus à droite que le  $i$ -pivot des lignes précédentes.  
 On dira de plus que  $A$  est réduite si tous ses  $i$ -pivots sont égaux à 1.

On considère l'action de  $GL_n(k)$  sur  $\mathcal{M}_n(k)$  par multiplication à gauche, on cherche à obtenir des représentants agréables des orbites.

**Théor 15:** Soient  $p, m$  deux entiers  
 - deux matrices  $A, A'$  de  $\mathcal{M}_p(m)$  sont dans la même orbite sous l'action de  $GL_p(k)$  si et seulement si elles ont même rang.  
 - Toute matrice est dans l'orbite d'une unique matrice échelonnée en ligne réduite.

Cette dernière est en fait obtenue par la méthode de Gauss: Pour étudier un système linéaire  $Ax = b$ , on peut préférer considérer le système  $PA = B$  ou  $PE \in GL_n(k)$ .

-  $S$ : Peut de la forme 1 (dilatation),  $PAx = \lambda b$  ou le système initial où l'on a multiplié une ligne par  $\lambda \neq 1$ .  
 -  $S$ : Peut une translation,  $PAX = Pb$  est le système initial où l'on a ajouté une ligne à une autre.

Par composition, on obtient immédiatement les opérations élémentaires du pivot de Gauss, et le théorème précédent nous montre que l'on peut se ramener à un système triangulaire. Que l'on peut résoudre par méthode de remontée. Le théorème 13 permet de conclure que tous les éléments de  $GL_n(k)$  sont atteints.

[Lia] 80

**Cor 16:** La méthode de Gauss (et la remontée qui s'ensuit) demande  $\frac{n^3}{3}$  additions,  $\frac{n^3}{3}$  multiplications,  $\frac{n^3}{2}$  divisions.  
 Donc le coût total est en  $O(n^3)$ , cette amélioration depuis les factoriels.

**Exemple 16:** 
$$\begin{cases} 2x+y-4z=1 \\ 2x+2y-z=4 \\ 2x+3y+3z=5 \end{cases} \Leftrightarrow \begin{cases} 2x+y-4z=1 \\ -y+3z=3 \\ y+7z=4 \end{cases} \Leftrightarrow \begin{cases} 2x+y-4z=1 \\ -y+3z=3 \\ 13z=10 \end{cases} \Leftrightarrow \begin{cases} x=\frac{1}{2}(1+4z) \\ y=3-3z \\ z=\frac{10}{13} \end{cases}$$

**Appli 17:**  
 - Calcul du rang d'une matrice  
 - Calcul de l'inverse d'une matrice  
 - Recherche d'un système d'équations d'un sous-espace vectoriel défini par une famille génératrice.  
 - Recherche d'une base d'un sous-espace vectoriel défini par un système d'équations.

**2) Décomposition LU, Cholesky.**  
 On peut, plus généralement chercher à décomposer dans le cas d'une matrice inversible.  $A$  sous la forme  $LU$ , où  $L$  est triangulaire inférieure, et  $U$  triangulaire supérieure, on pourra alors résoudre  $Ax = b$  en faisant  $Ly = b$  puis  $Ux = y$  par des algorithmes de descente et de remontée.

[Lia] 85 86

**Théor 18:** Soit  $A = (a_{ij})$  une matrice carrée de taille  $n$ , telle que tous les mineurs principaux sont  $\Delta_k = \det(a_{ij})_{i,j \in \{1, \dots, k\}}$  soient non nuls. Alors il existe une matrice triangulaire inférieure  $L = (l_{ij})$  avec  $(l_{ii}) = 1 \forall i \in \{1, \dots, n\}$ , et une matrice  $U$  triangulaire supérieure, tels que  $A = LU$ . De plus, une telle décomposition est unique.

[Qua] 79

**Algorithme de calcul d'une factorisation LU:** méthode de Doolittle. On se donne  $A = (a_{ij})_{i,j \in \{1, \dots, n\}}$ , pour  $k \in \{1, \dots, n\}$ , on pose  

$$-u_{kj} = a_{kj} - \sum_{r=1}^{k-1} l_{kr}u_{rj} \quad \forall j \in \{k, \dots, n\} \quad -l_{ik} = \frac{1}{u_{kk}} \left( a_{ik} - \sum_{r=1}^{k-1} l_{ir}u_{rk} \right) \quad i \in \{k+1, \dots, n\}$$

**Prop 19:** Soit  $A \in GL_n(\mathbb{R})$  n'a pas tous ses mineurs principaux non nuls, on peut se ramener au cas précédent en permutant certaines lignes et colonnes de  $A$ .

Des supports de normis  $k = \mathbb{R}$  ou  $\mathbb{C}$ , jusqu'à la fin de la planche.  
 Soit  $A$  hermitienne définie positive, la factorisation  $LU$  peut être obtenue plus rapidement avec la méthode de Cholesky.

**Théor 20:** Soit  $A \in GL_n(\mathbb{R})$  est symétrique définie positive, il existe une matrice, réelle triangulaire inférieure  $S$  telle que  $A = SS^t$ . On peut de plus imposer que les coefficients diagonaux de la matrice  $S$  soient tous  $> 0$ . La factorisation correspondante est alors unique.

[Cia] 88 89

Algorithme de calcul. on pose  $b_{11} = \sqrt{a_{11}}$ , et pour  $i=2, m$   
 $j=i \Rightarrow b_{ii} = (a_{ii} - \sum_{h=1}^{i-1} b_{ih}^2)^{1/2}$  ;  $j > i \Rightarrow b_{ji} = \frac{a_{ij} - \sum_{h=1}^{i-1} b_{ih} b_{jh}}{b_{ii}}$

Rq 21: les calculs peuvent s'interpréter comme des produits scalaires.  
Cout: La méthode de Cholesky comporte  $\frac{m^3}{6}$  additions,  $\frac{m^3}{6}$  multiplications  
 $\frac{m^2}{2}$  divisions d'où un coût en  $O(m^3)$ .

Ex 22: pour  $A = \begin{pmatrix} 2 & -1 & 0 \\ 1 & 2 & 0 \\ 0 & 0 & 2 \end{pmatrix}$ , on trouve  $S = \begin{pmatrix} \sqrt{2} & -1/\sqrt{2} & 0 \\ 0 & 1/\sqrt{2} & -\sqrt{2}/3 \\ 0 & 0 & 2/\sqrt{5} \end{pmatrix}$ .

### III Méthodes itératives de résolution

#### 1) Méthodes itératives usuelles.

Une autre méthode pour résoudre un système  $Ax=b$  est de construire une suite qui converge vers la solution. On compte etudier des suites de la forme  $u_{i+1} = Bu_i + C$ , ou la solution de  $Ax=b$  est point fixe de  $x \mapsto Bx + C$ : si  $(I-B)$  est inversible et si:  $u = Bu + C$  équivaut à  $Au = b$ . On dit que  $B$  est la matrice de la méthode.

Théor 23: On a équivalence entre

- (1) La méthode itérative  $u_{i+1} = Bu_i + C$  est convergente.
- (2)  $\rho(B) < 1$
- (3)  $\|B\| < 1$  pour au moins une norme matricielle subordonnée l.l.1

DVP

Empirique, on cherchera à décomposer  $A = M - N$ , où  $M$  est inversible et facile à inverser (plus facile que  $A$ ). On a alors

$Au = b \Leftrightarrow Mu = Nu + b \Leftrightarrow u = M^{-1}Nu + M^{-1}b$ . On remarque d'ailleurs que  $I - B = M^{-1}A$  est inversible.

Notation: Pour  $A \in GL_n(\mathbb{R})$ , on pose  $D$  la partie diagonale de  $A$ ,  $-E$  sa partie triangulaire inférieure stricte et  $-F$  sa partie triangulaire supérieure stricte, de sorte que  $A = D + E - F$ .

Méthode de Jacob: On prend  $M = D$ , la matrice d'itération est  $J = D^{-1}(E + F)$

Méthode de Gauss Seidel:  $M = D - E$ , matrice d'itération  $S_1 = (D - E)^{-1}F$

Méthode de relaxation: On introduit un paramètre  $\omega$  et on pose  $M = \frac{D}{\omega} - E$ .  
d'où la matrice d'itération  $S_\omega = (\frac{D}{\omega} - E)^{-1}(\frac{1-\omega}{\omega}D + F)$ .

[Cia] 97, 106

Théor 24: Si  $A$  est hermitienne définie positive, la méthode de relaxation converge pour  $\omega \in ]0, 2[$ . En particulier, la méthode de Gauss Seidel converge.

Théor 25: On a l'inégalité  $\rho(S_\omega) \geq |\omega - 1|$ , pour  $\omega \neq 0$ . Ainsi la méthode de relaxation ne peut converger que pour  $\omega \in ]0, 2[$

Théor 26: Si  $A$  est tri-diagonale par blocs. On a  $\rho(S_1) = \rho(J)^2$ : les méthodes de Jacobi et de Gauss Seidel convergent simultanément, et si elles convergent, la méthode de Gauss Seidel converge plus rapidement.

Si  $A$  est de plus hermitienne définie positive. Alors le paramètre de relaxation optimal est  $\omega = 2 / (1 + \sqrt{1 - \rho(J)})$  si  $\rho(J) > 0$  et si  $\rho(J) = 0$ .

#### 2) Méthodes d'optimisation.

On considère  $J: X \mapsto J(x)$  une fonctionnelle,  $d$ -convexe (moralement une fonctionnelle quadratique  $(x \mapsto \frac{1}{2}(Ax, x) - bx)$  où  $A \in S_m^{++}(\mathbb{R})$ )  
On construit des méthodes de la forme  $x^{i+1} = x^i + \rho^i d^i$  ( $\rho^i$  taille pas,  $d^i$  la direction).

Méthode de relaxation: On prend successivement les vecteurs de base canonique comme direction: pour  $x^m \in \mathbb{R}^m$  on construit  $x^{m+1}$  comme suit:  $\forall i \in \{1, m\}$   $x^{m+1}_i$  est défini comme minimisant la fonctionnelle.  $x \mapsto J(x^m_1, \dots, x^m_{i-1}, x, x^m_{i+1}, \dots, x^m_m)$

Théor 27: Si  $J$  est une fonctionnelle elliptique, la méthode de relaxation converge.

Rq 29: C'est en fait l'équivalent de Gauss Seidel dans le cas d'un fct quad.  
On peut également prendre  $-\nabla J(x^m)$  comme direction, ce donne les méthodes de gradient

- gradient à pas fixe:  $\rho^m = \rho$  est constant
- gradient à pas optimal:  $\rho^m$  choisi pour minimiser  $\rho \mapsto J(x^m + \rho \nabla J(x^m))$

Théor 29: Si  $J$  est  $d$ -convexe,  $\nabla J$  est  $L$  lipschitzien, alors pour  $\rho \in ]0, \frac{2}{L}[$  la méthode de gradient à pas fixe converge.

Théor 30: Si  $J$  est  $d$ -convexe,  $\nabla J$  lipschitzien sur les bornes, alors le gradient optimal converge. DVP

Rq 31: L'encadrement du théorème 29 est le meilleur sous-optimal pour une quadratique, l'opti est  $\frac{2}{L+2\mu}$  et le max est  $\frac{2}{L-\mu}$ .

Rq 32: de pas optimal et en général coûteux à calculer, mais pour une quadratique, c'est explicite et donne par  $\frac{\|r_k\|}{\|Ax_k - b\|}$  où  $r_k = Ax_k - b$ .

[Cia] 97, 106

[Cia] 99 192

Fig 1:  $\begin{pmatrix} 1 & 0 \\ 0 & 1_\lambda \end{pmatrix} \lambda \in k^*, \lambda \neq 1$

Fig 2:  $\begin{pmatrix} 1 & 0 \\ 0 & 11 \end{pmatrix}$