

EJCIM 2018

Géométrie Numérique (partie 2)

Gradient Conjugué

Plan

- **Introduction**

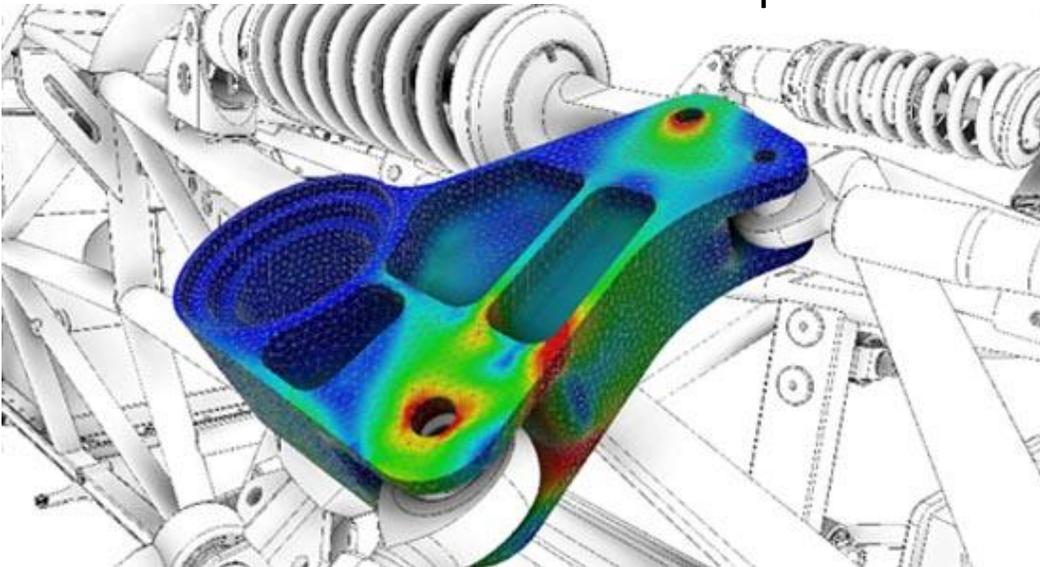
- Le problème
- Résolution par gradient
- Résolution par conjugaison
- Gradient conjugué
- Contemplation de performance pour des problèmes discrétisés

Introduction : problème

- Résoudre des systèmes linéaires
 - Soit une matrice A et un vecteur b ,
 - on veut trouver x tel que $Ax=b$,
 - sans calculer A^{-1}
- Limitation: A est symétrique définie positive
 - A et b sont composés de réels
 - A est carrée
 - $A^T=A$
 - $x^T Ax \geq 0$ pour tout x

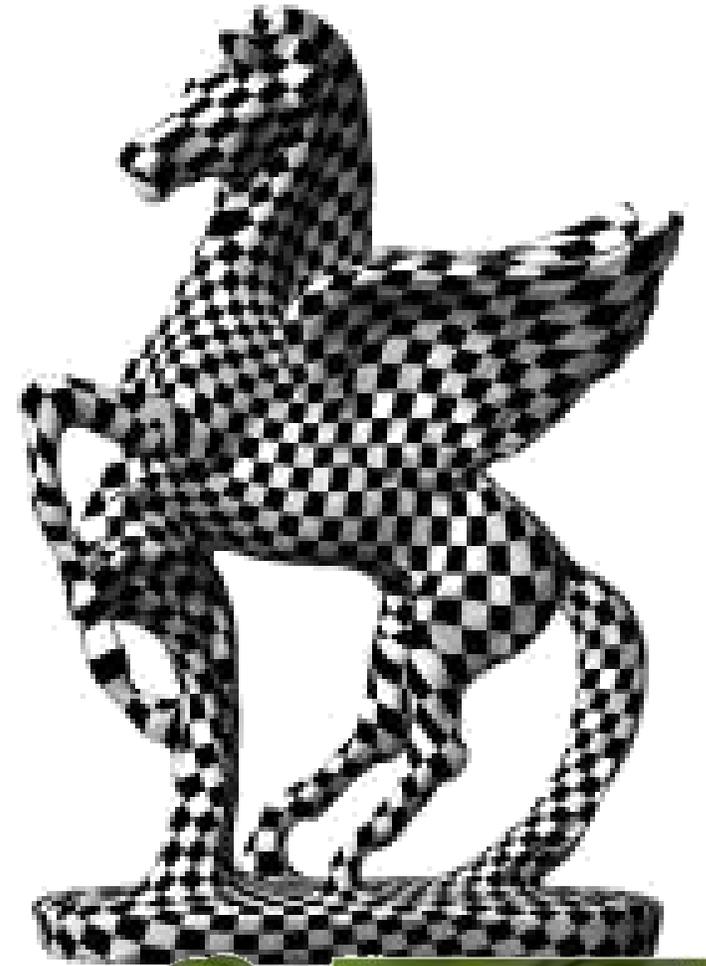
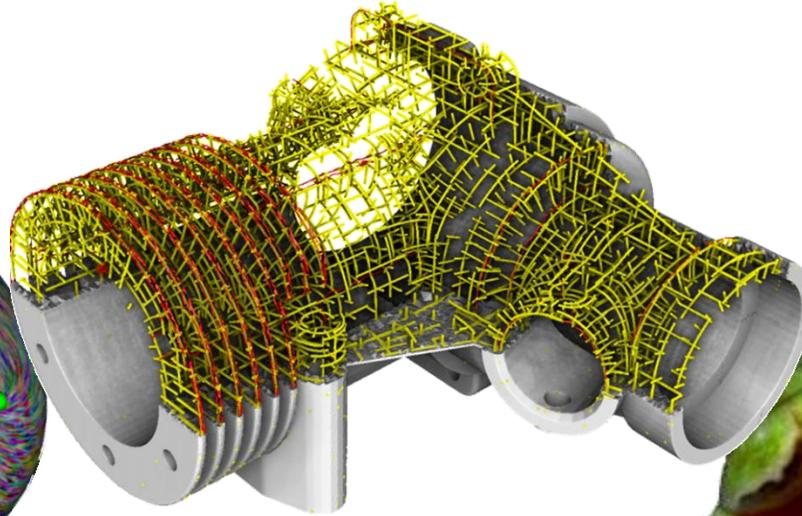
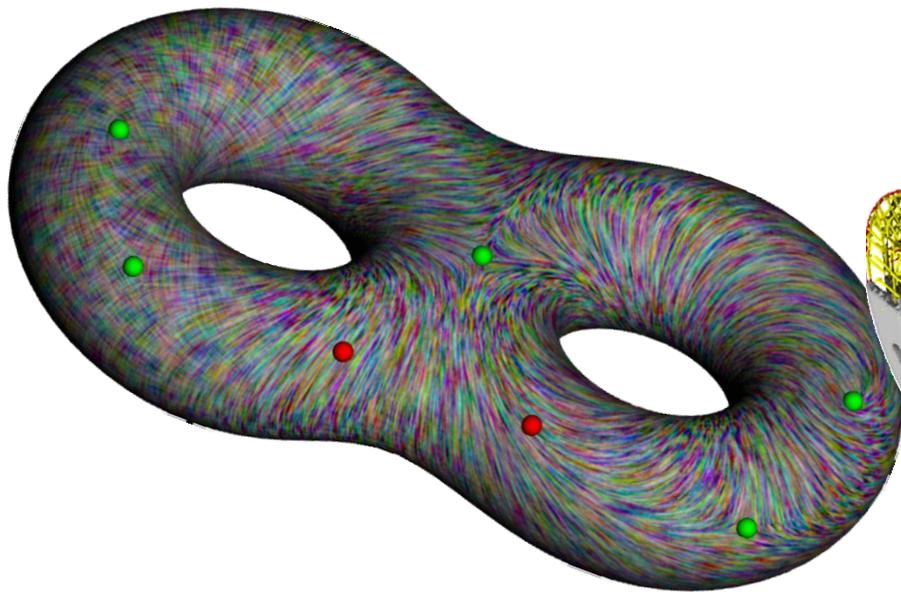
Introduction : applications

- Simulation numérique:
 - Définition d'un problème aux dérivées partielles
 - Discrétisation dans une base de fonction
 - Résolution des coefficients
 - Cas linéaire => juste résoudre $Ax=b$
 - Cas non linéaire => plusieurs itérations de $Ax=b$



Introduction: applications

- Moindres carrés
 - On aimerait avoir $Ax-b=0$
 - Mais on a plus d'équations que d'inconnues
 - Alors, on minimize $|Ax-b|^2$
 - En résolvant $A^T Ax=A^T b$



Plan

- *Introduction*
- **Le problème**
 - **Problème équivalent**
 - **Intérêt des petites lignes du contrat... (Sym. Def. +)**
- Résolution par gradient
- Résolution par conjugaison
- Gradient conjugué
- Contemplation de performance pour des problèmes discrétisés

Problème équivalent

- Résoudre $Ax-b=0$ équivaut à minimiser $f(x) = x^T Ax - 2b^T x$
- Pourquoi ?
 - Le vecteur x^* qui annule les dérivées df/dx_i est soit un extrema, soit un point selle de $f(x)$.

Problème équivalent

- Résoudre $Ax=b=0$ équivaut à minimiser $f(x) = x^T Ax - 2b^T x$
- Pourquoi ?
 - Le vecteur x^* qui annule les dérivées df/dx_i est soit un extrema, soit un point selle de $f(x)$.

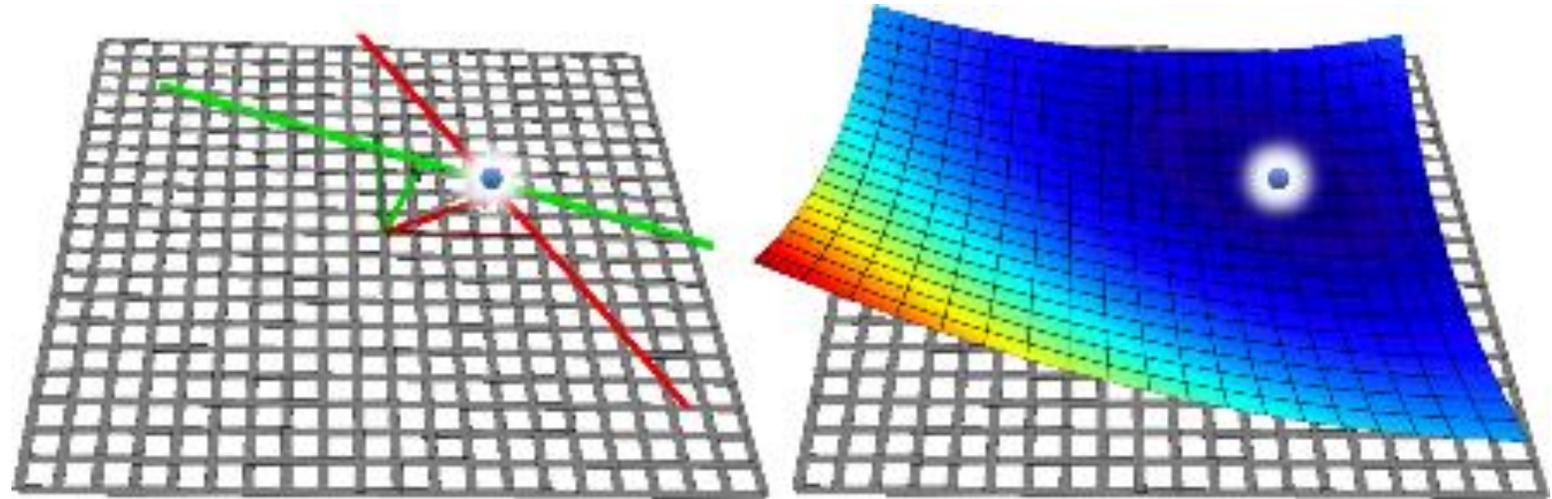
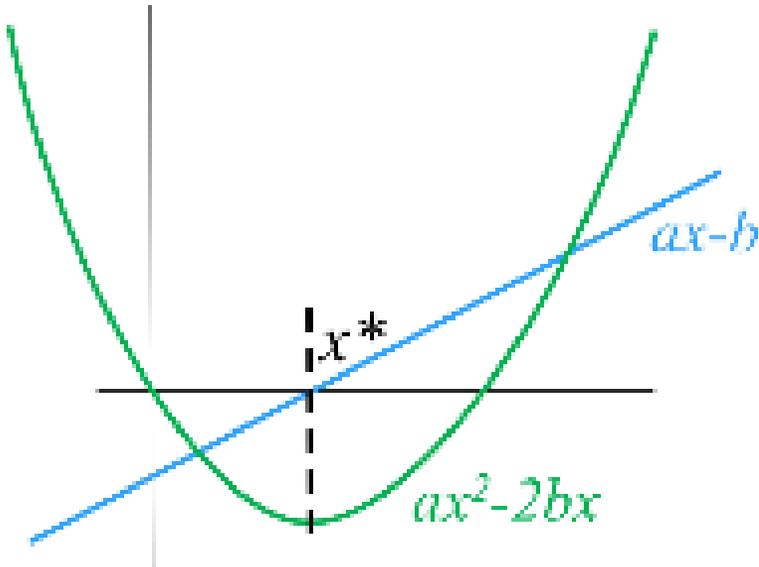
(A symétrique)

Problème équivalent

- Résoudre $Ax=b=0$ équivaut à minimiser $f(x) = x^T Ax - 2b^T x$
- Pourquoi ?
 - Le vecteur x^* qui annule les dérivées df/dx_i est soit un extrema, soit un point selle de $f(x)$.
 - Avec A définie positive, x^* est forcément un minimum.

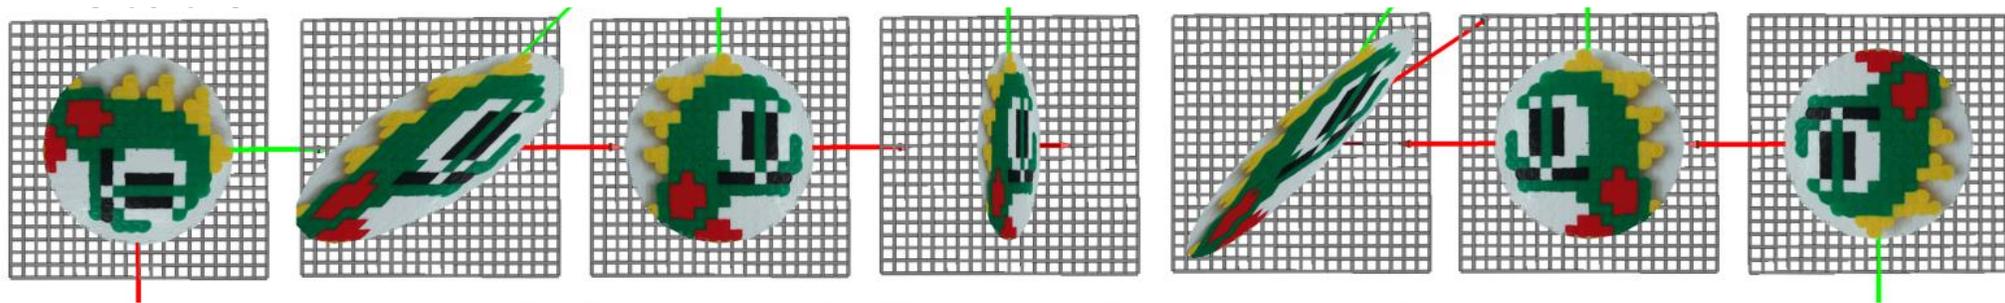
Problème équivalent

- Résoudre $Ax-b=0$ équivaut à minimiser $f(x) = x^T Ax - 2b^T x$
- Pourquoi ?
 - Le vecteur x^* qui annule les dérivées df/dx_i est soit un extrema, soit un point selle de $f(x)$.
 - Avec A définie positive, x^* est forcément un minimum.



A est définie positive... pourquoi ?

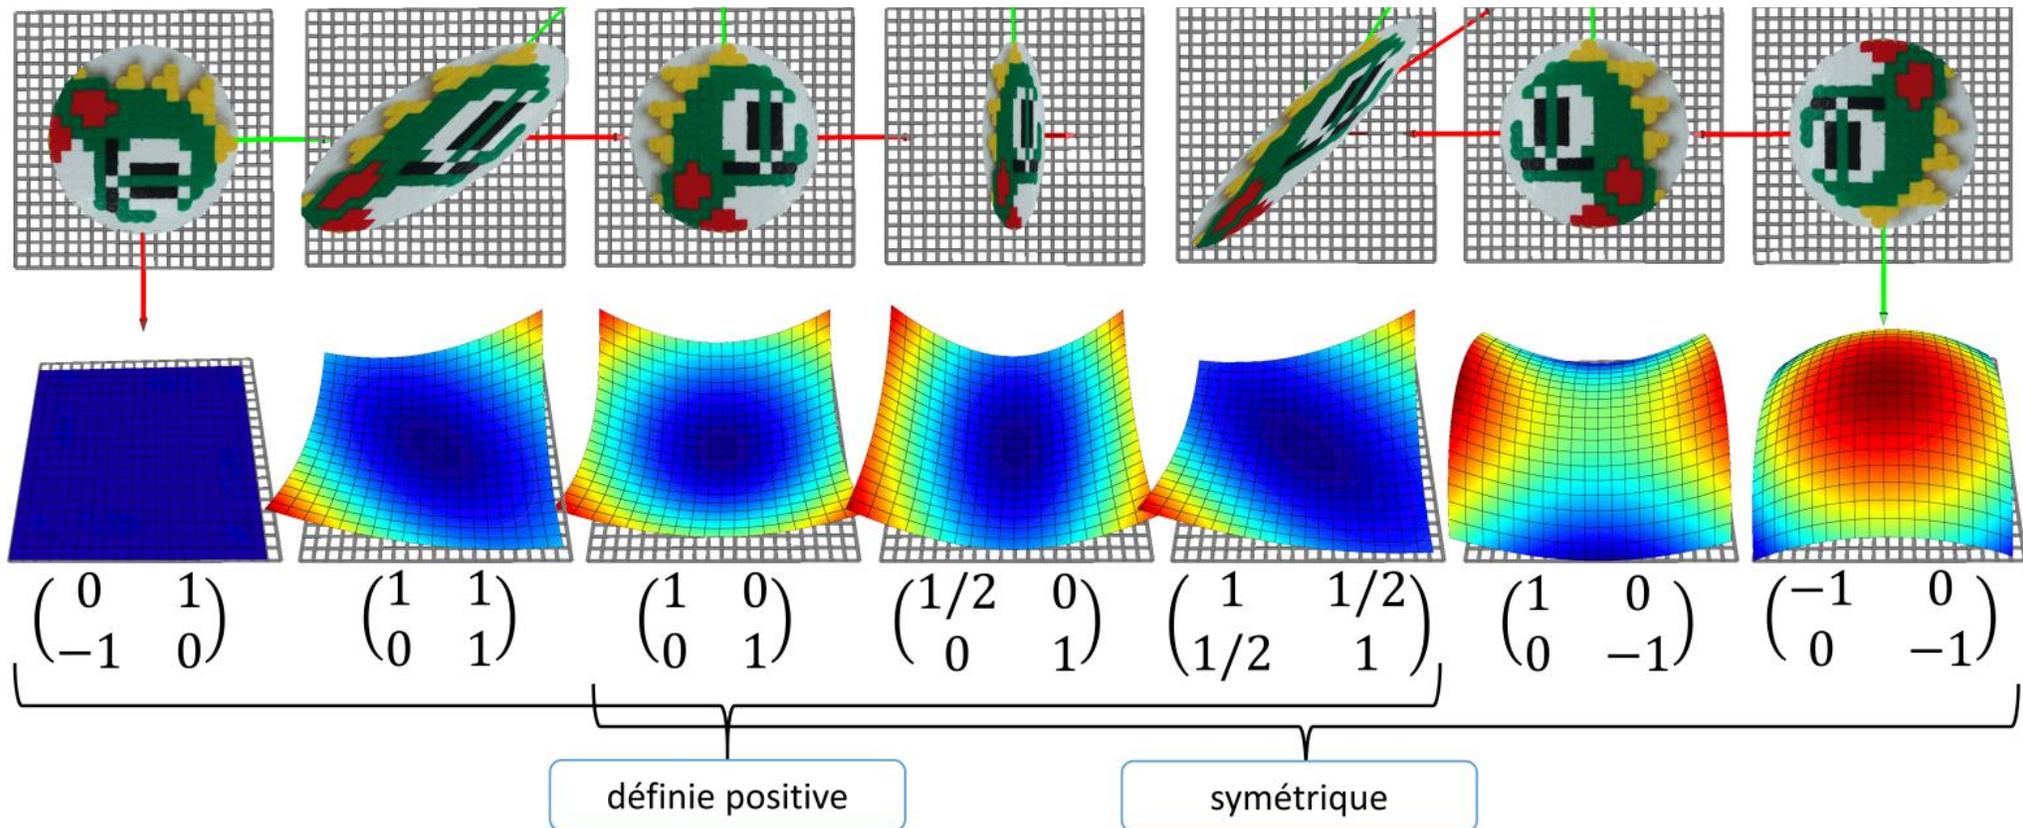
A est définie positive... pourquoi ?



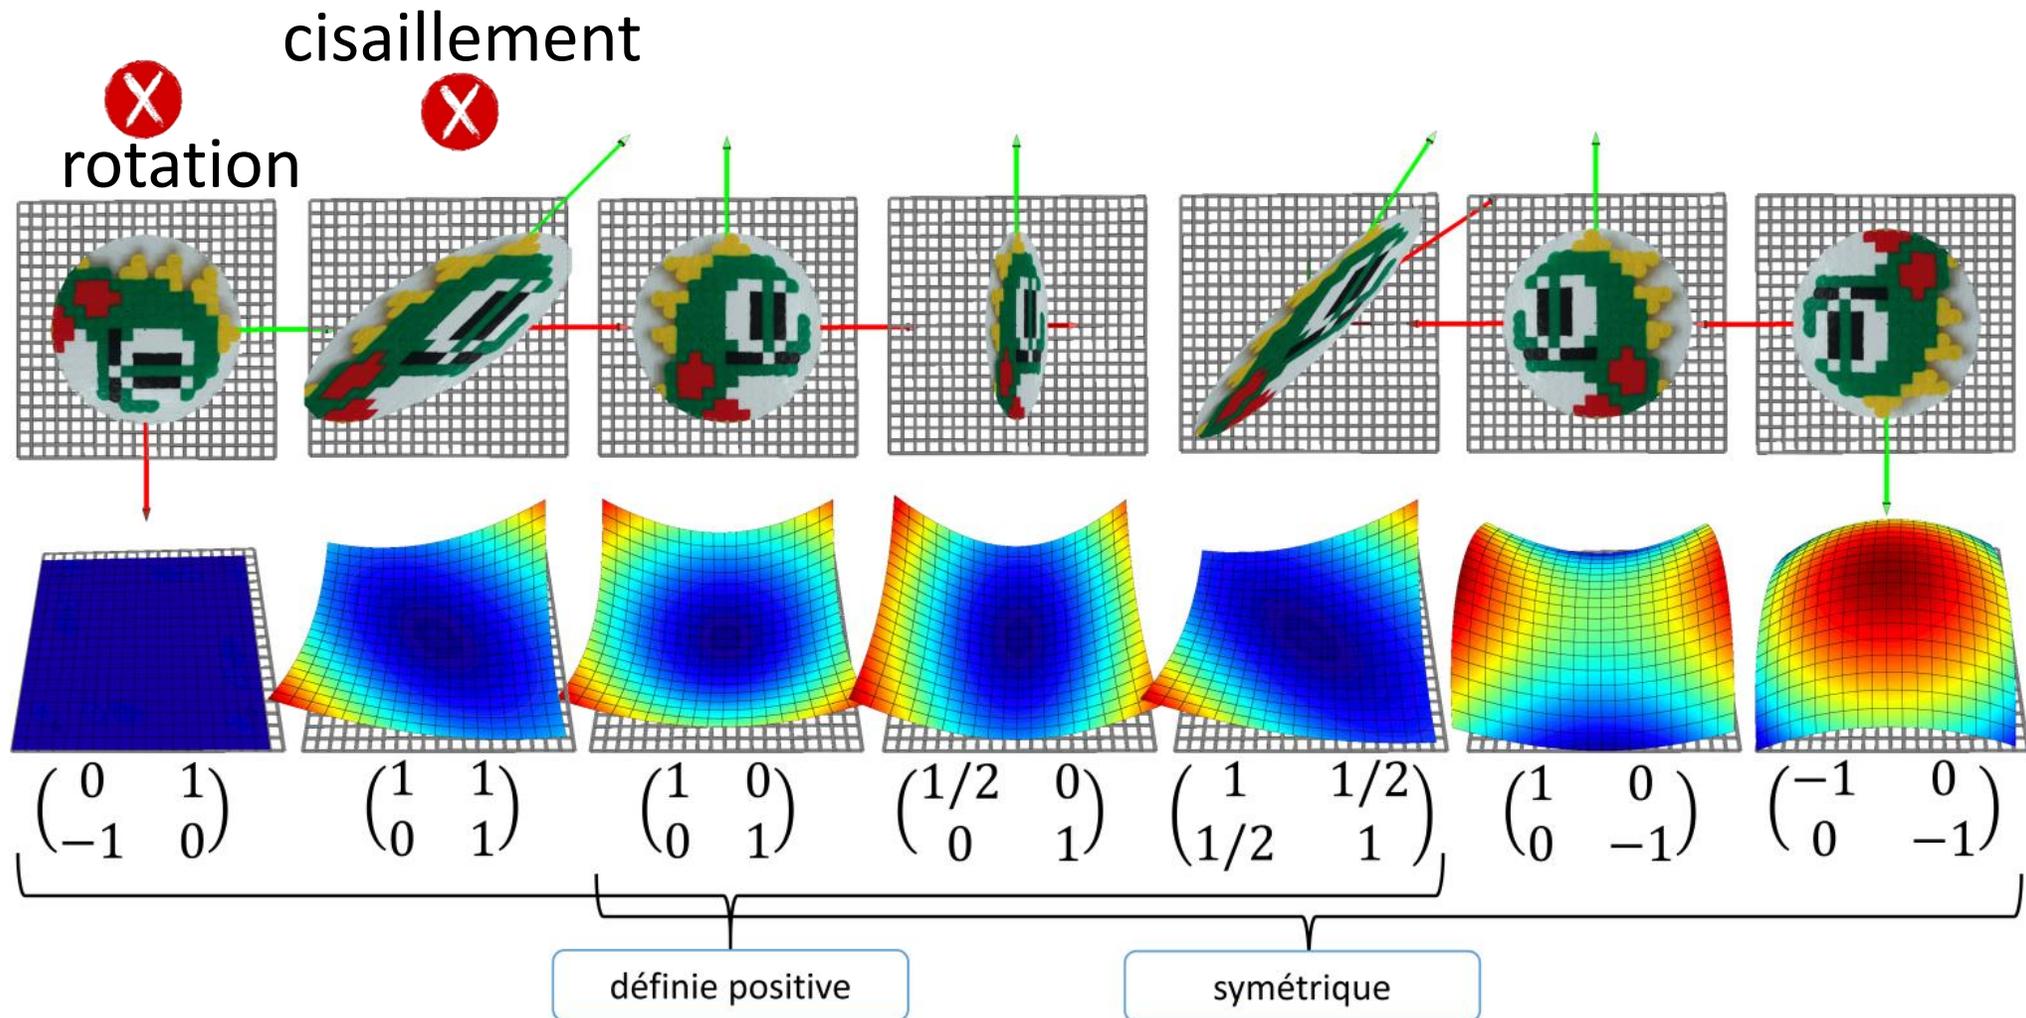
$$\left(\begin{array}{cc} 0 & 1 \\ -1 & 0 \end{array} \right) \quad \left(\begin{array}{cc} 1 & 1 \\ 0 & 1 \end{array} \right) \quad \left(\begin{array}{cc} 1 & 0 \\ 0 & 1 \end{array} \right) \quad \left(\begin{array}{cc} 1/2 & 0 \\ 0 & 1 \end{array} \right) \quad \left(\begin{array}{cc} 1 & 1/2 \\ 1/2 & 1 \end{array} \right) \quad \left(\begin{array}{cc} 1 & 0 \\ 0 & -1 \end{array} \right) \quad \left(\begin{array}{cc} -1 & 0 \\ 0 & -1 \end{array} \right)$$

} définie positive symétrique }

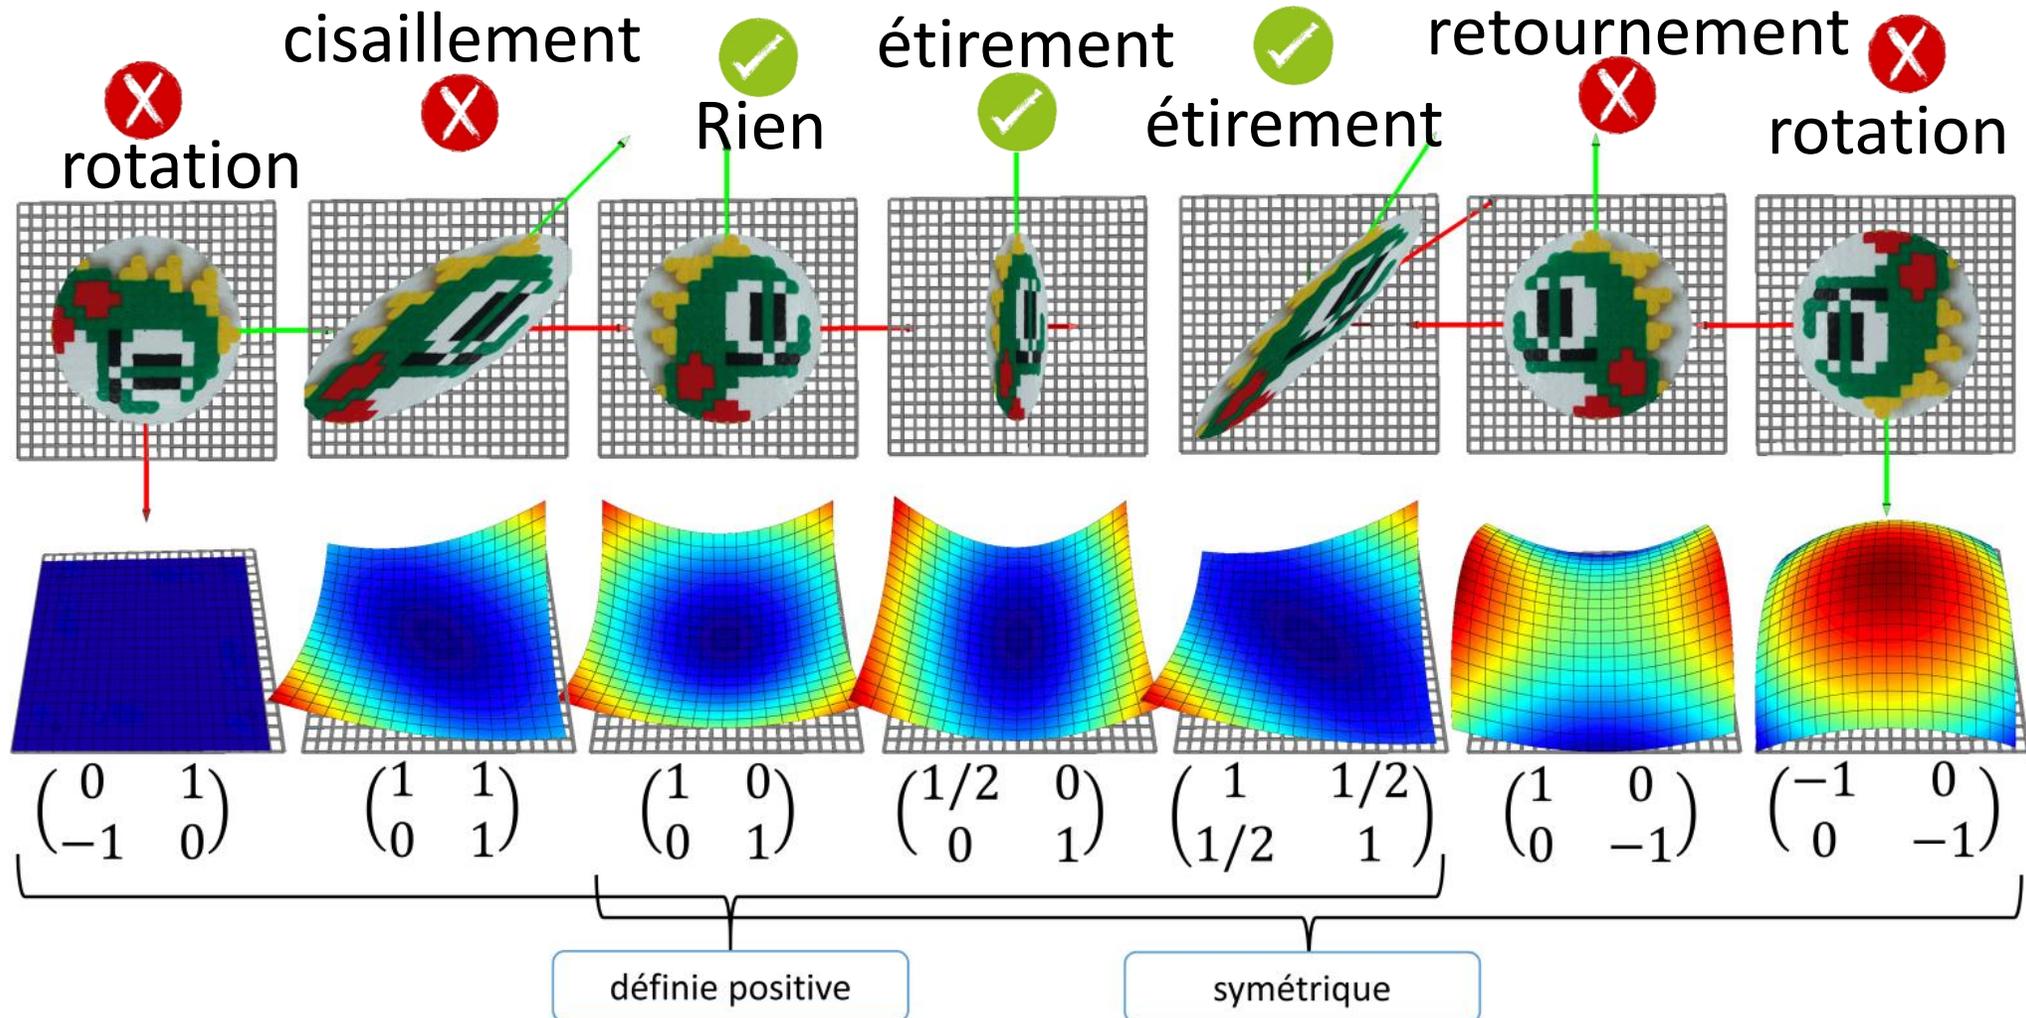
A est définie positive... pourquoi ?



A est définie positive... pourquoi ?

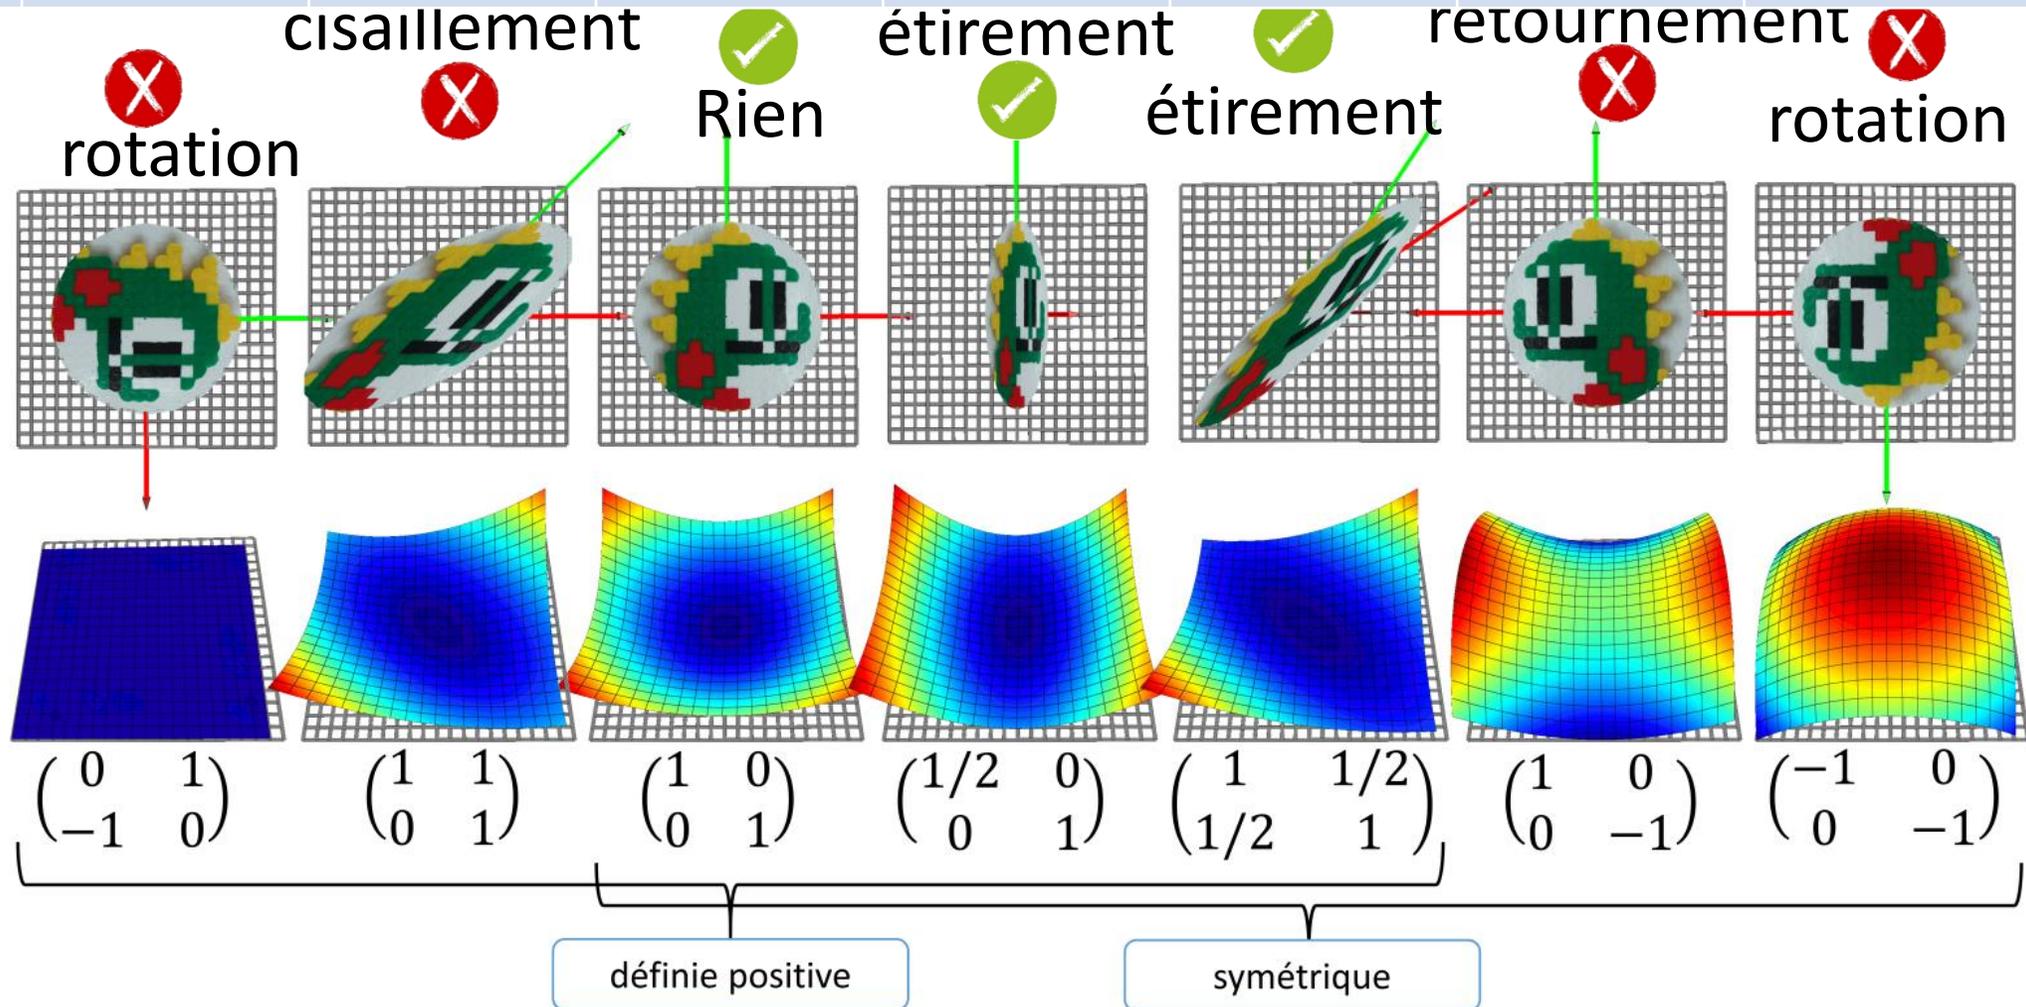


A est définie positive... pourquoi ?



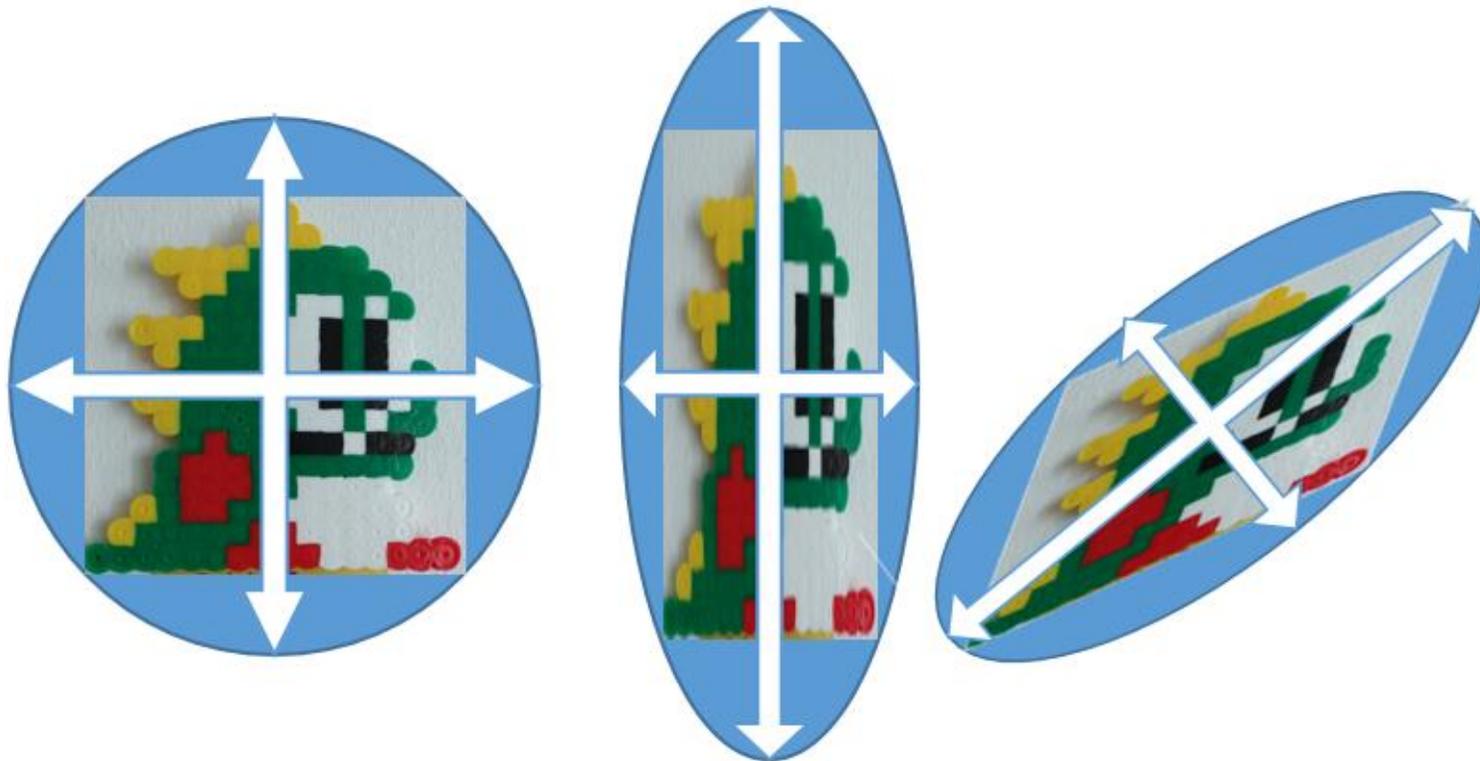
A est définie positive... pourquoi ?

Val. Propre	complexe	+	+	+	+	-+	--
Vect. propre	complexe	Non ortho	ortho	ortho	ortho	ortho	ortho



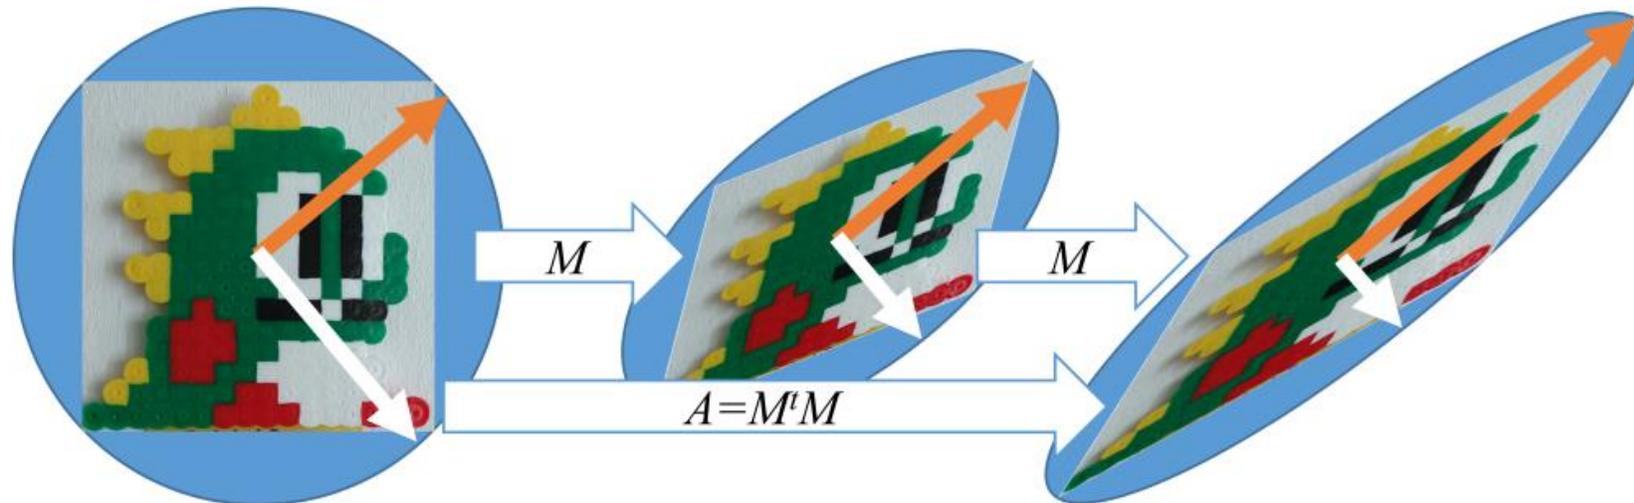
A est définie positive... pourquoi ?

- Cette application linéaire est simplement un étirement de l'espace dans des directions orthogonales



Soit M tel que $A = M^T M$: existence

- On peut même décomposer cette application linéaire en étirant en deux coups avec l'application associée à la matrice M définie comme suit
- M symétrique définie positive et étire dans les mêmes directions que A , mais avec des coefficients étant racines carrées de ceux de A .



Soit M tel que $A = M^T M$: intérêt

- On peut facilement calculer des produits scalaires entre des images de vecteurs par l'application M ... et ce, sans expliciter M !
- Pour ce faire, on utilise
 - la définition de M i.e. $M^T M = A$, ce qui donne

$$(Mu)^T \cdot (Mv) = u^T M^T M v = u^T A v$$

Soit M tel que $A = M^T M$: intérêt

- On peut facilement calculer des produits scalaires entre des images de vecteurs par l'application M ... et ce, sans expliciter M !
- Pour ce faire, on utilise
 - la définition de M i.e. $M^T M = A$, ce qui donne

$$(Mu)^T \cdot (Mv) = u^T M^T M v = u^T A v$$

- et ... $Ax^* = b$, qui permet de calculer

$$(Mu)^T \cdot (Mx^*) = u^T A x^* = u^T b$$

Soit M tel que $A = M^T M$: intérêt

- On peut facilement calculer des produits scalaires entre des images de vecteurs par l'application M ... et ce, sans expliciter M !
- Pour ce faire, on utilise
 - la définition de M i.e. $M^T M = A$, ce qui donne

$$(Mu)^T \cdot (Mv) = u^T M^T M v = u^T A v$$

- et ... $Ax^* = b$, qui permet de calculer

$$(Mu)^T \cdot (Mx^*) = u^T A x^* = u^T b$$

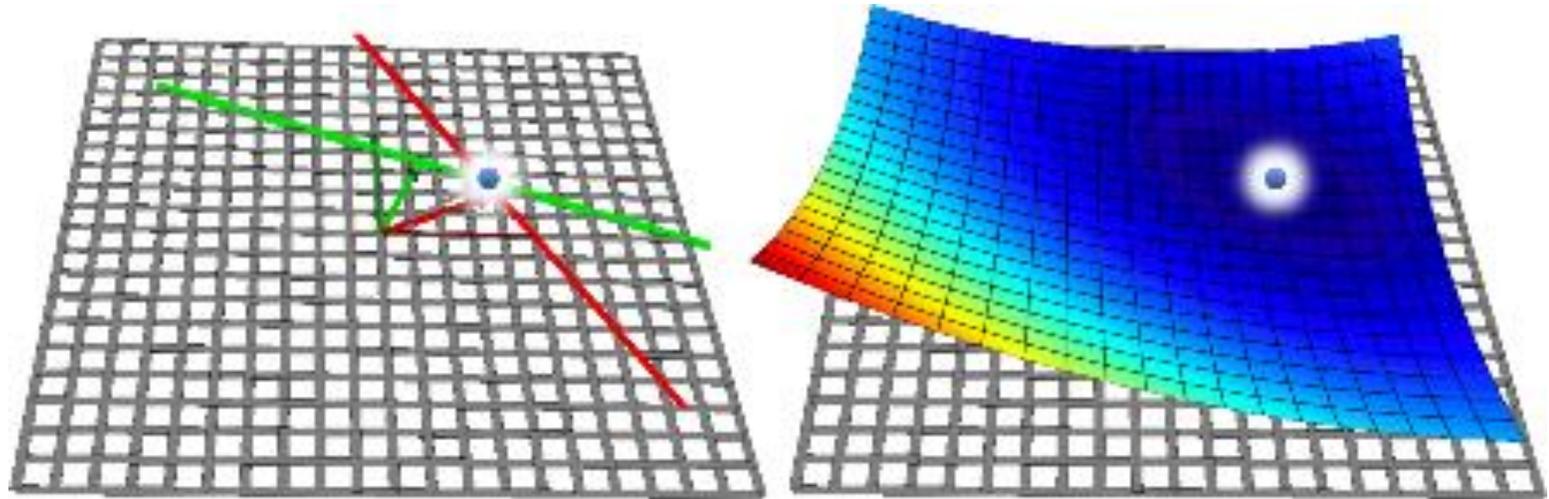
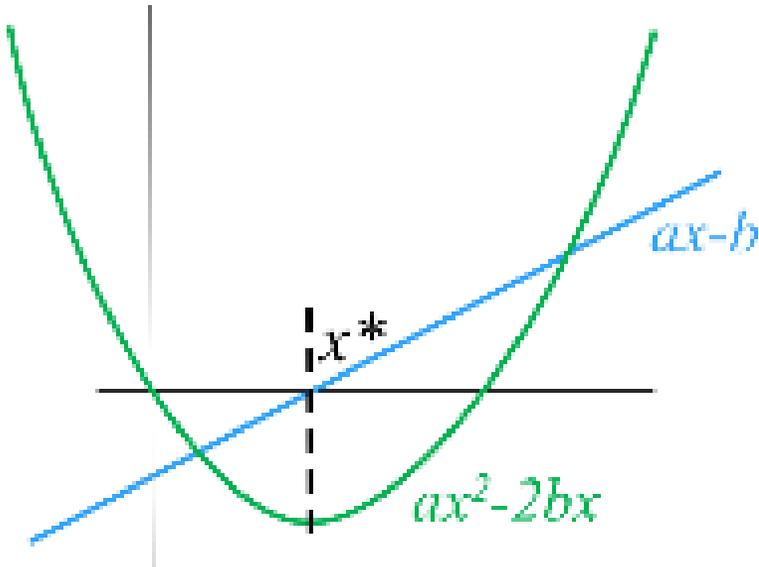
Ces produits scalaires donnent les **longueurs**, l'**orthogonalité**, et la **projection** des images de vecteurs par M .

Plan

- *Introduction*
- *Le problème*
- **Résolution par gradient**
- Résolution par conjugaison
- Gradient conjugué
- Contemplation de performance pour des problèmes discrétisés

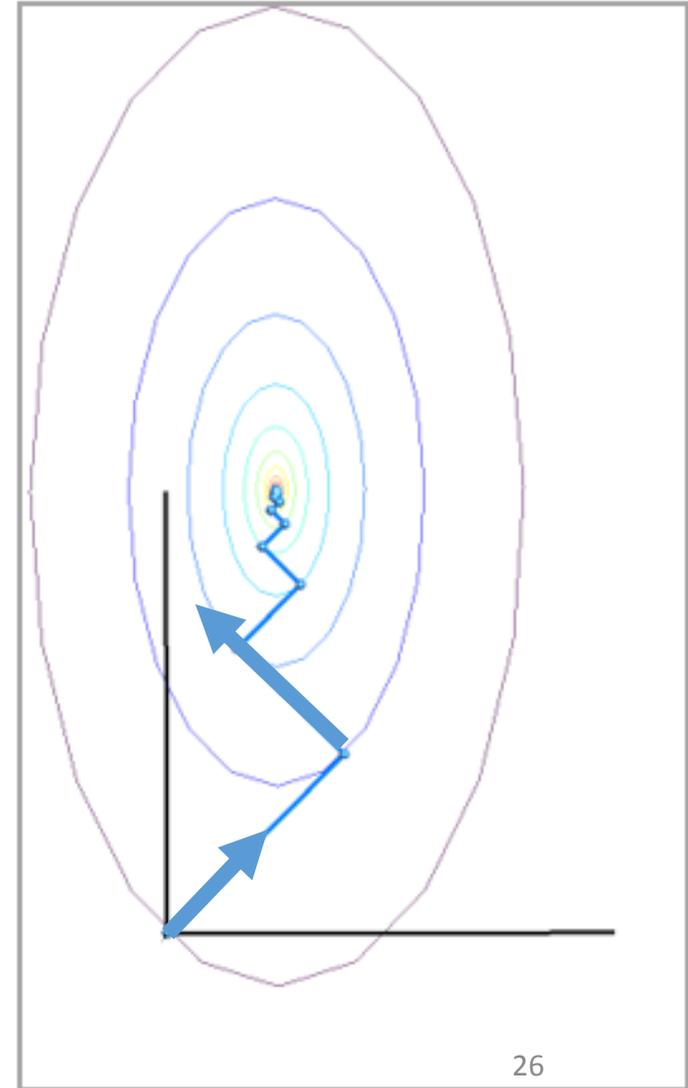
RAPPEL: Problèmes équivalents

- Résoudre $Ax-b=0$ équivaut à minimiser $f(x) = x^T Ax - 2b^T x$
- Pourquoi ?
 - Le vecteur x^* qui annule les dérivées df/dx_i est soit un extrema, soit un point selle de $f(x)$.
 - Avec A définie positive, x^* est forcément un minimum.



Descente de gradient: minimiser $x^T Ax - 2b^T x$

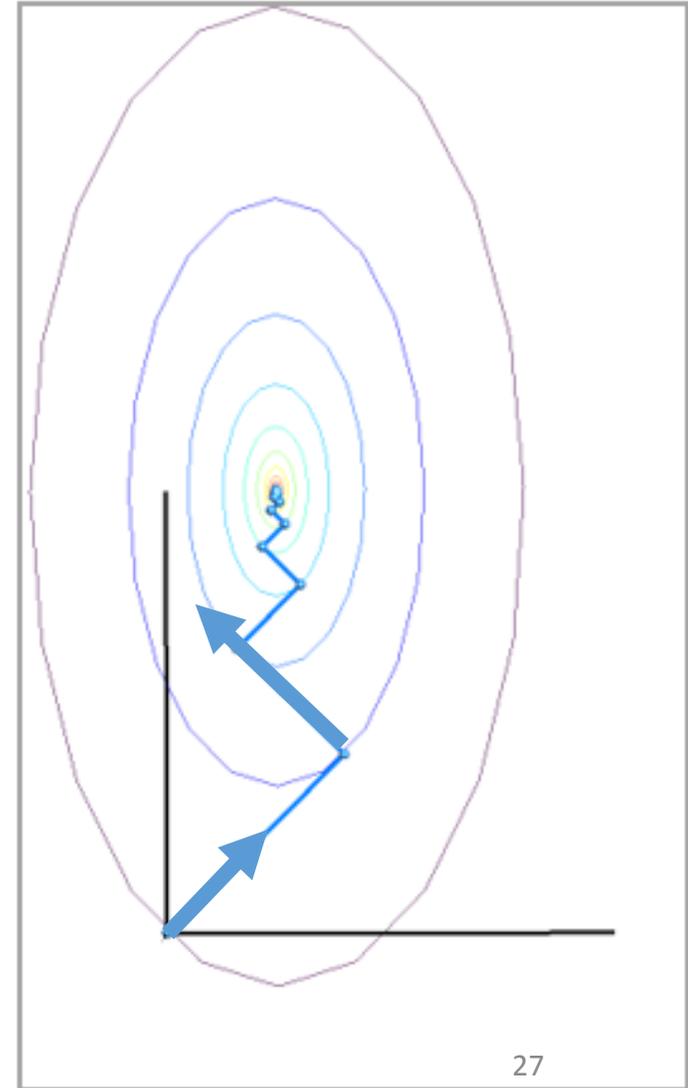
- Initialiser $x^{(0)} = 0$
- On itère sur k :
 - On calcule la direction $d^{(k)} = r^{(k)} = -\nabla f(x^{(k)})/2 = b - Ax^{(k)}$
 - On calcule le pas de descente $\alpha^{(k)}$
 - On met à jour: $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$



Descente de gradient: minimiser $x^T Ax - 2b^T x$

- Initialiser $x^{(0)} = 0$
- On itère sur k :
 - On calcule la direction $d^{(k)} = r^{(k)} = -\nabla f(x^{(k)})/2 = b - Ax^{(k)}$
 - On calcule le pas de descente $\alpha^{(k)}$
 - On met à jour: $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$

$\alpha^{(k)}$ est choisit pour que $r^{(k)}$ soit orthogonal à $\nabla f(x^{(k+1)})$

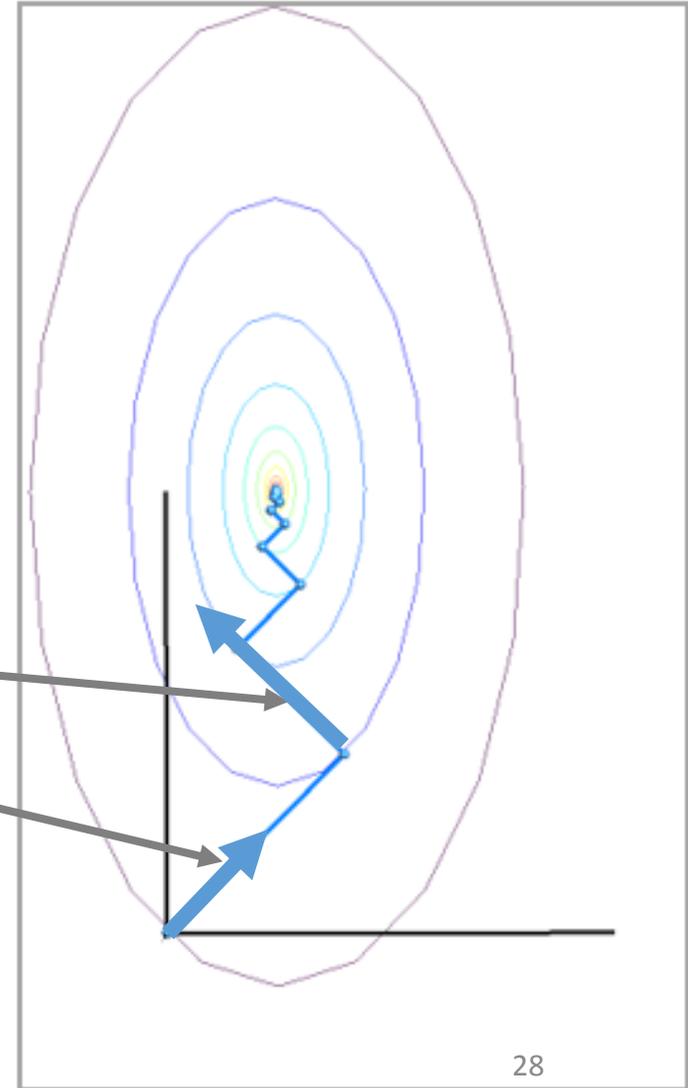


Descente de gradient: minimiser $x^T Ax - 2b^T x$

- Initialiser $x^{(0)} = 0$
- On itère sur k :
 - On calcule la direction $d^{(k)} = r^{(k)} = -\nabla f(x^{(k)})/2 = b - Ax^{(k)}$
 - On calcule le pas de descente $\alpha^{(k)}$
 - On met à jour: $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$

$\alpha^{(k)}$ est choisit pour que $r^{(k)}$ soit orthogonal à $\nabla f(x^{(k+1)})$

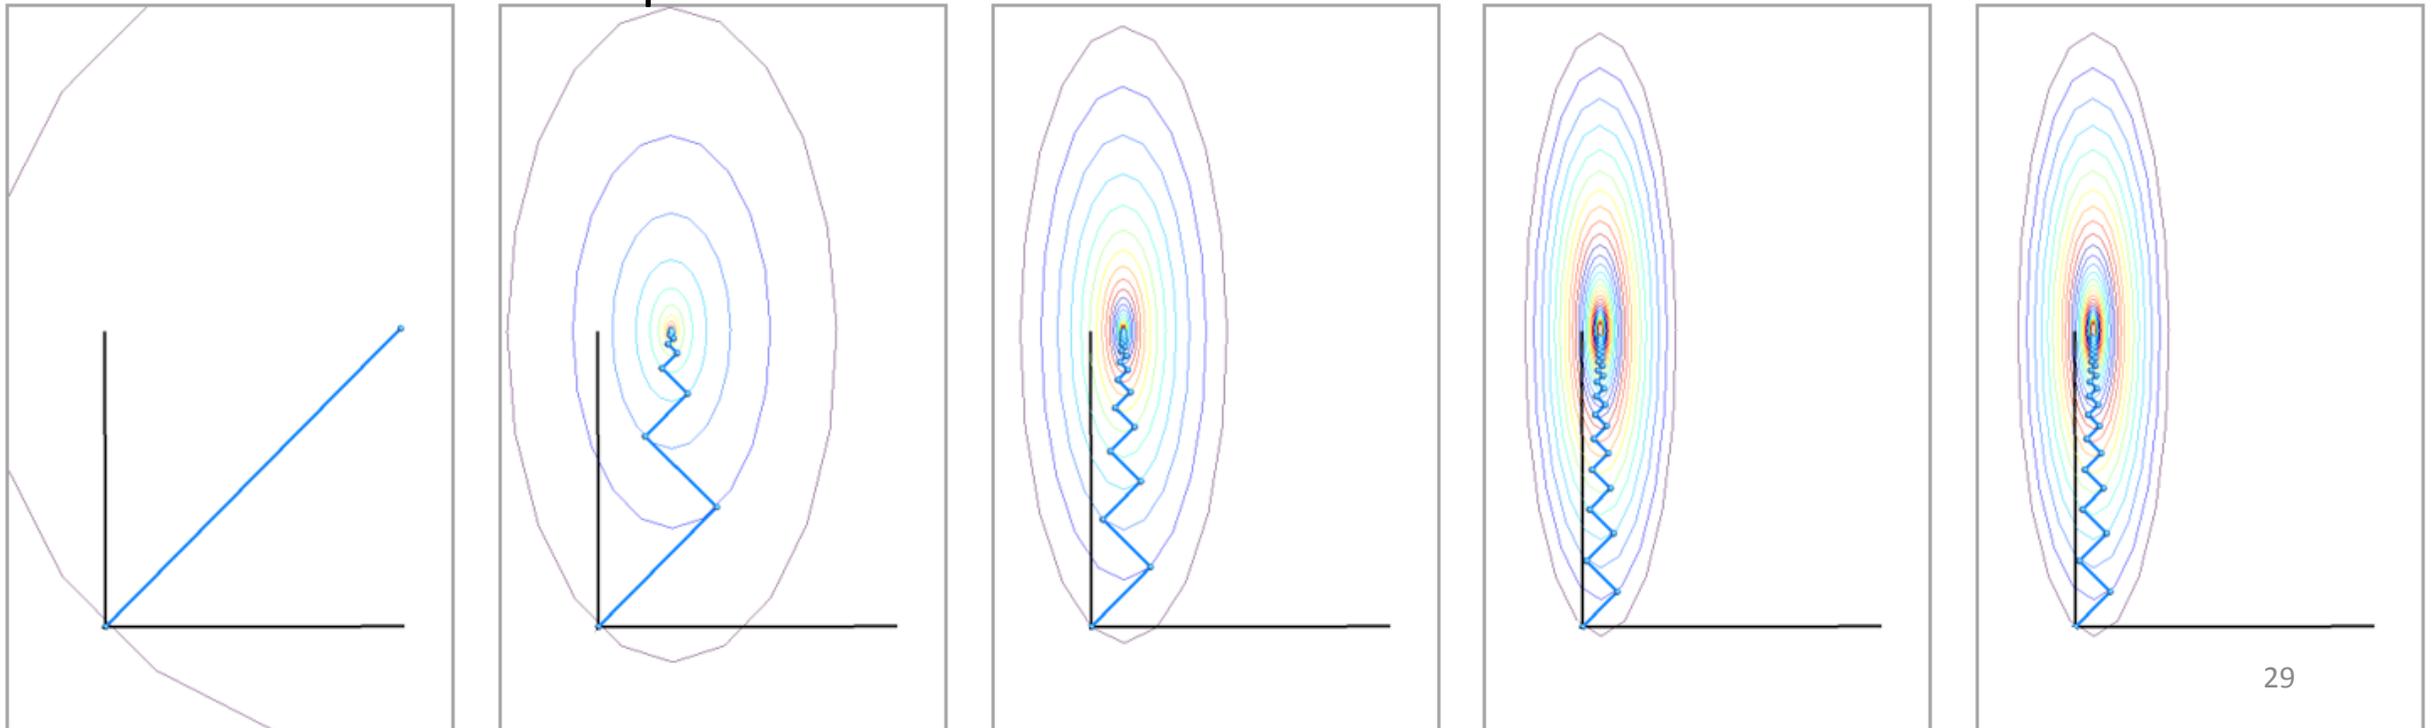
$$\begin{aligned}d^{(k)\top} r^{(k+1)} &= 0 \\d^{(k)\top} (b - Ax^{(k+1)}) &= 0 \\d^{(k)\top} (b - A(x^{(k)} + \alpha^{(k)} r^{(k)})) &= 0 \\ \alpha^{(k)} &= \frac{d^{(k)\top} (Ax^{(k)} - b)}{d^{(k)\top} Ar^{(k)}} \\ \alpha^{(k)} &= \frac{d^{(k)\top} r^{(k)}}{d^{(k)\top} Ar^{(k)}}\end{aligned}$$



Descente de gradient: efficacité

La méthode est sensible au conditionnement de A (ratio entre valeurs propres extrêmes):

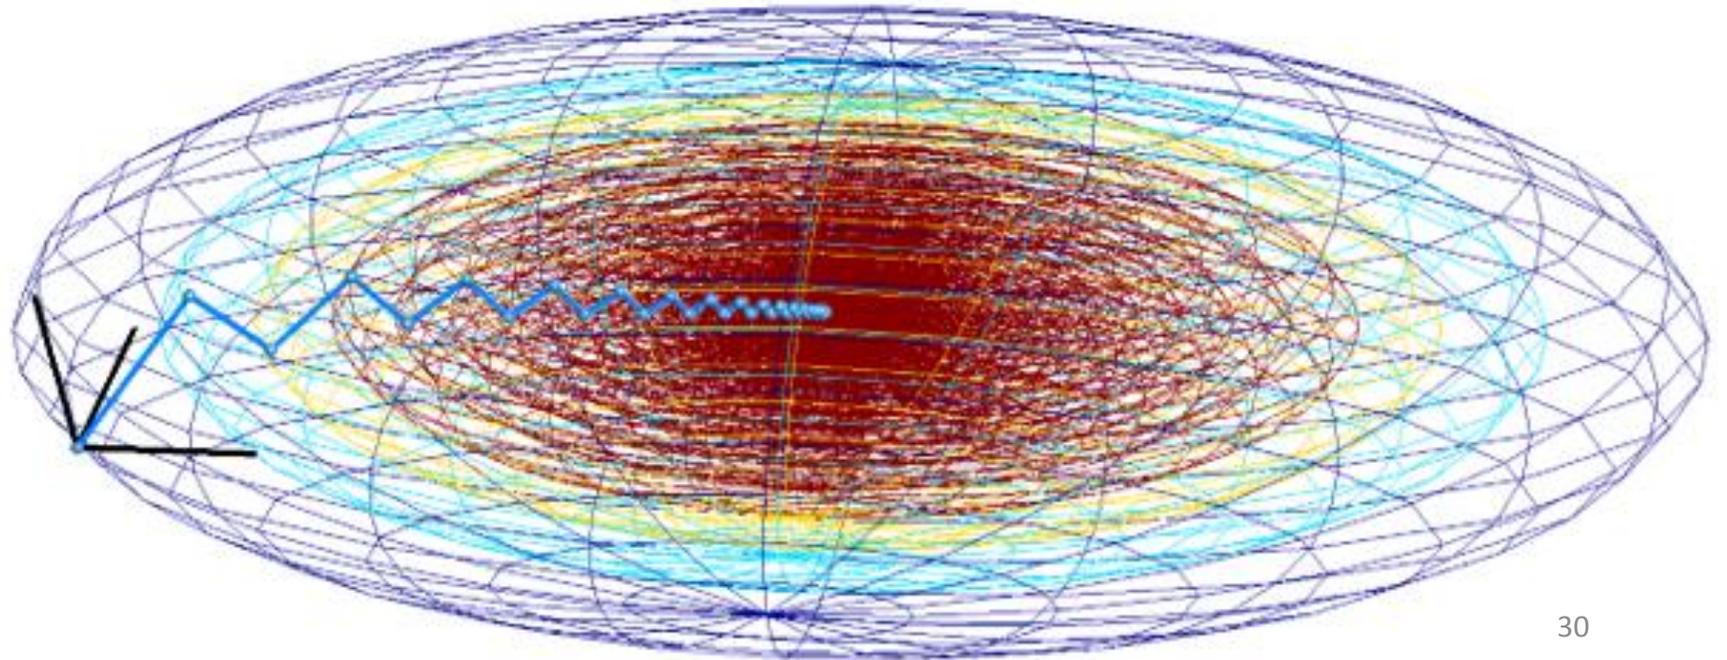
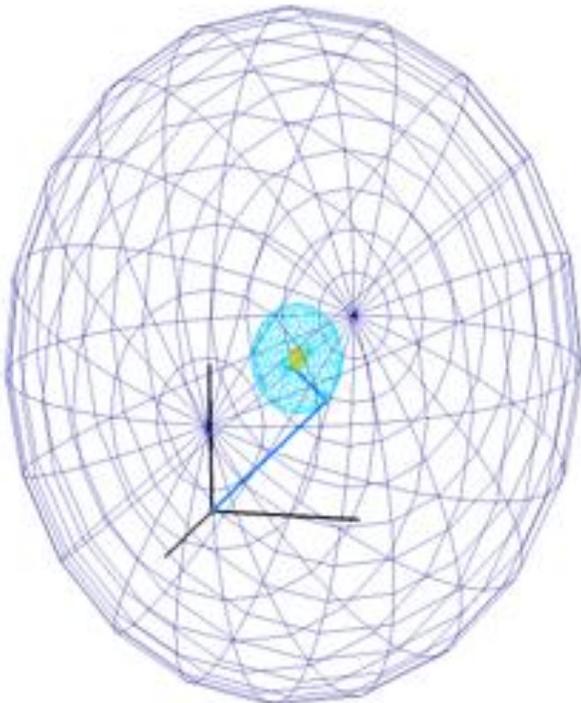
- Si $f(x)$ est isotrope, la convergence est immédiate
- Sinon elle peut être très lente...



Descente de gradient: efficacité

La méthode est sensible au conditionnement de A (ratio entre valeurs propres extrêmes):

- Si $f(x)$ est isotrope, la convergence est immédiate
- Sinon elle peut être très lente...

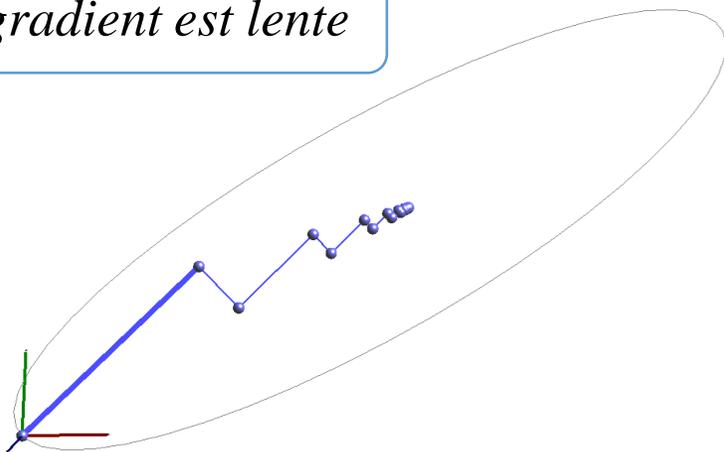


Plan

- *Introduction*
- *Le problème*
- *Résolution par gradient*
- **Résolution par conjugaison**
 - **Vue d'ensemble**
 - **Construction d'une base A-orthogonale**
- Gradient conjugué
- Contemplation de performance pour des problèmes discrétisés

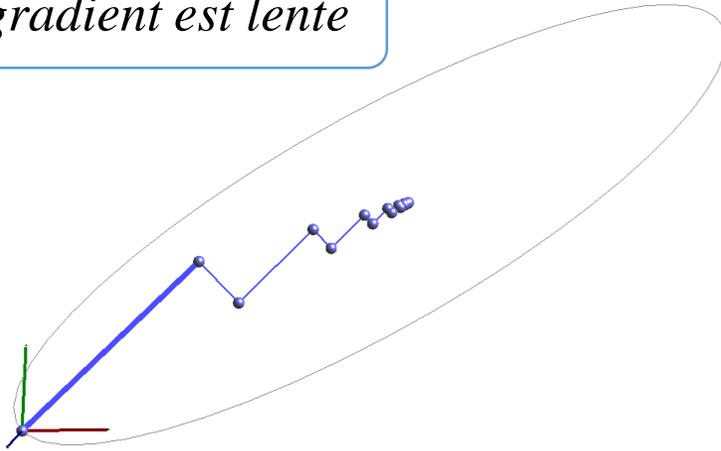
Conjugaison: idée de base

La descente de gradient est lente

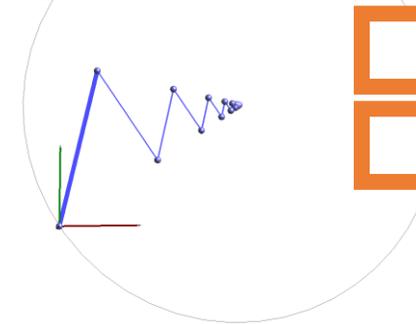


Conjugaison: idée de base

La descente de gradient est lente



*La notion d'orthogonalité dans M
est accessible*

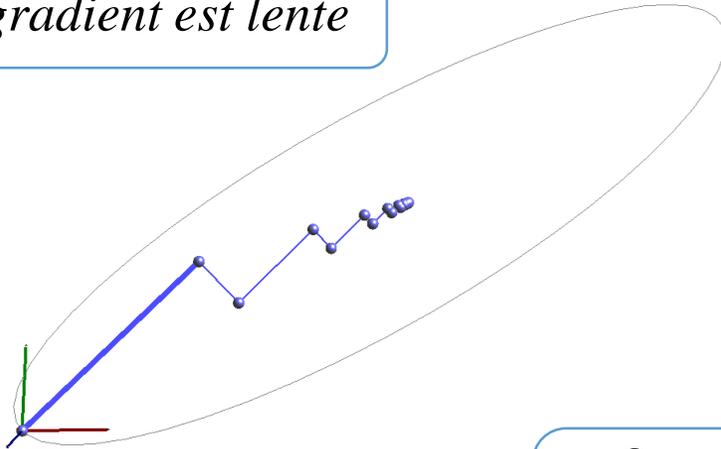


$$(Mu)^T(Mx^*) = u^T Ax^* = u^T b$$

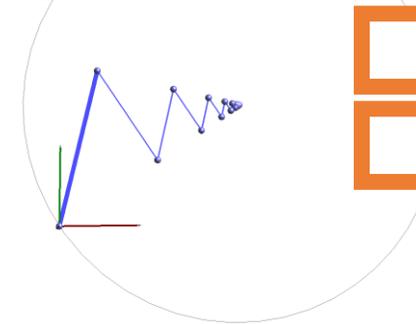
$$(Mu)^T(Mv) = u^T M^T M v = u^T A v$$

Conjugaison: idée de base

La descente de gradient est lente



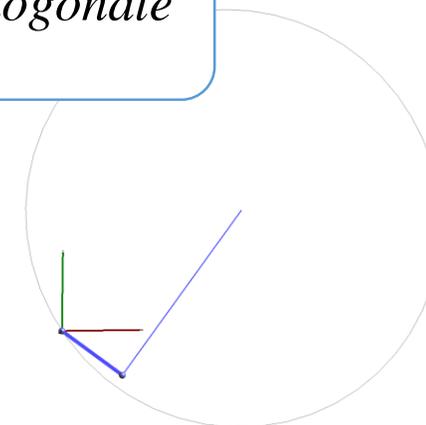
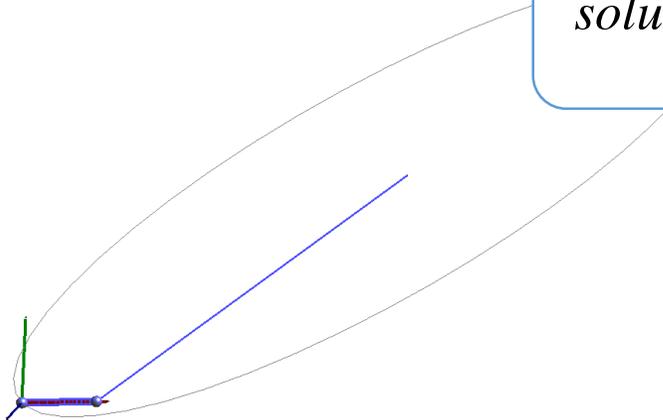
La notion d'orthogonalité dans M est accessible



$$(Mu)^T(Mx^*) = u^T Ax^* = u^T b$$

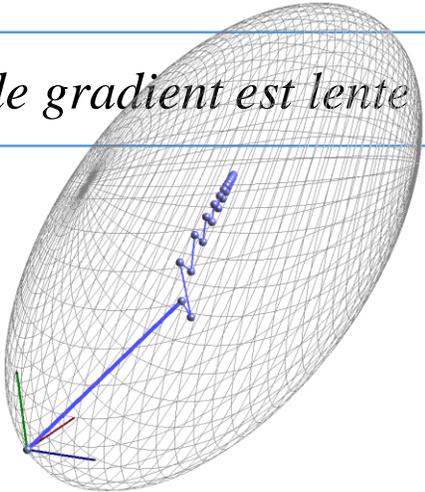
$$(Mu)^T(Mv) = u^T M^T M v = u^T A v$$

On va essayer de décomposer la solution dans une base orthogonale dans M

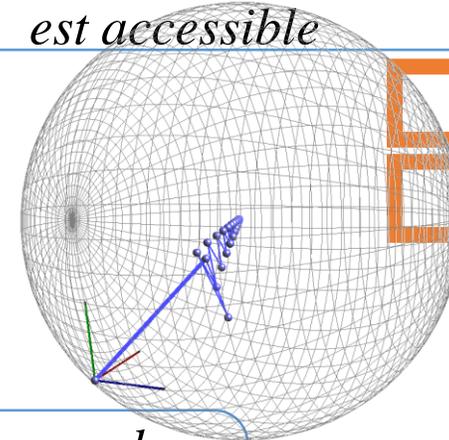


Conjugaison: idée de base

La descente de gradient est lente



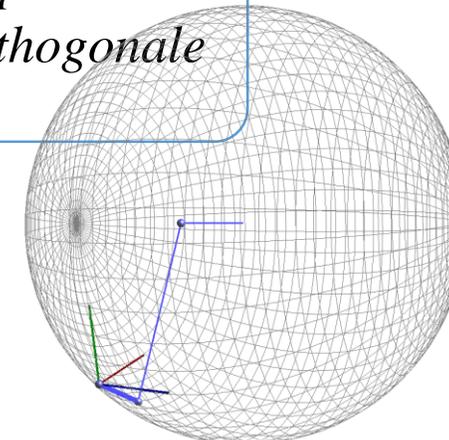
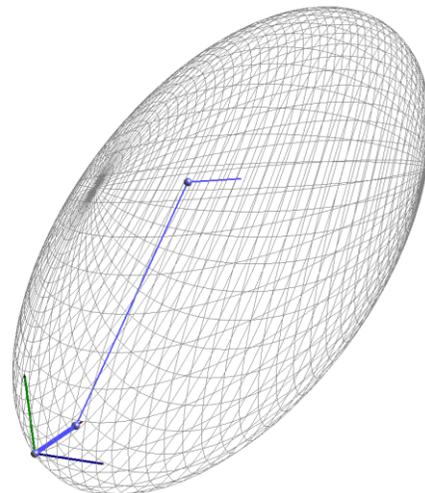
La notion d'orthogonalité dans M est accessible



$$(Mu)^T(Mx^*)=u^T Ax^*=u^T b$$

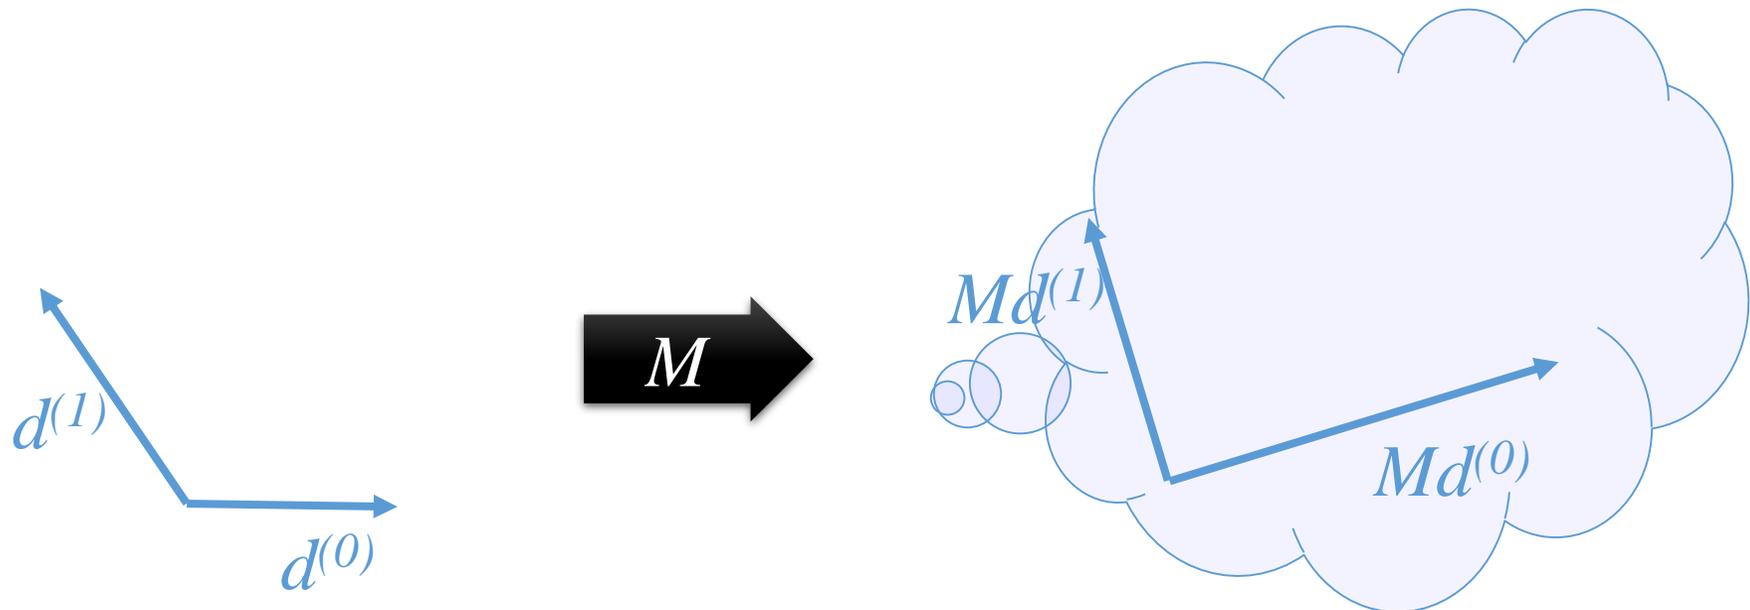
$$(Mu)^T(Mv)=u^T M^T M v=u^T A v$$

On va essayer de décomposer la solution dans une base orthogonale dans M



Conjugaison: vue d'ensemble

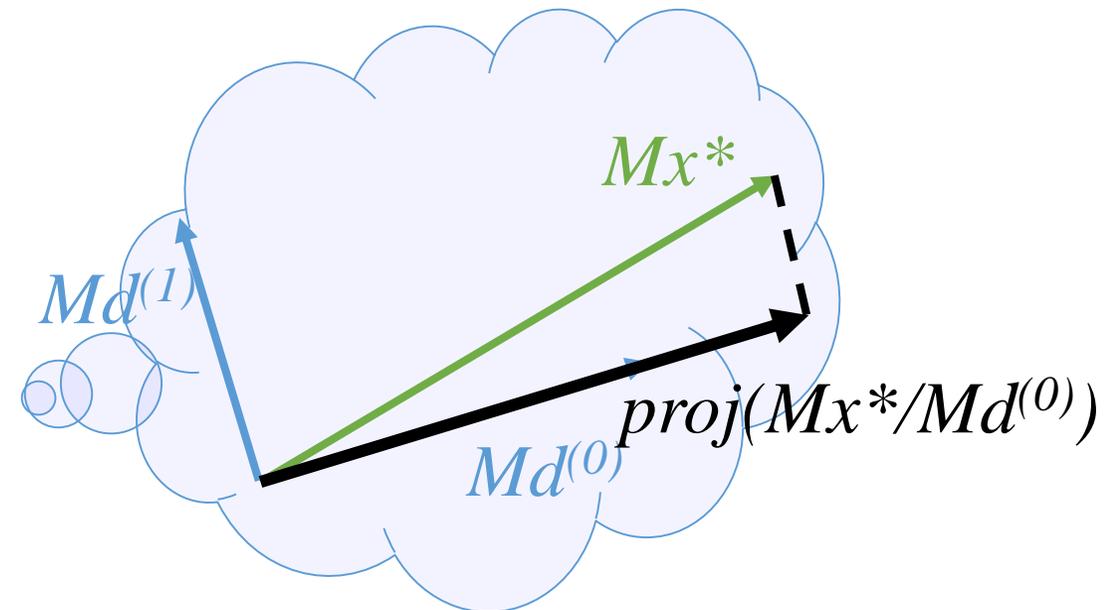
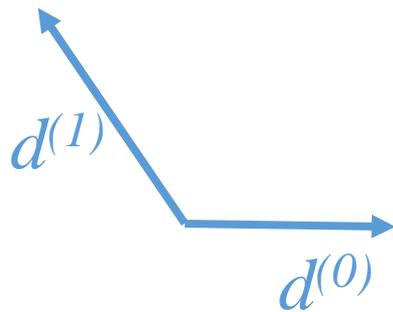
- Supposons que:
 - on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux



Conjugaison: vue d'ensemble

- Supposons que:
 - on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
 - on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

Les coordonnées de Mx^* dans $\{Md^{(k)}\}$

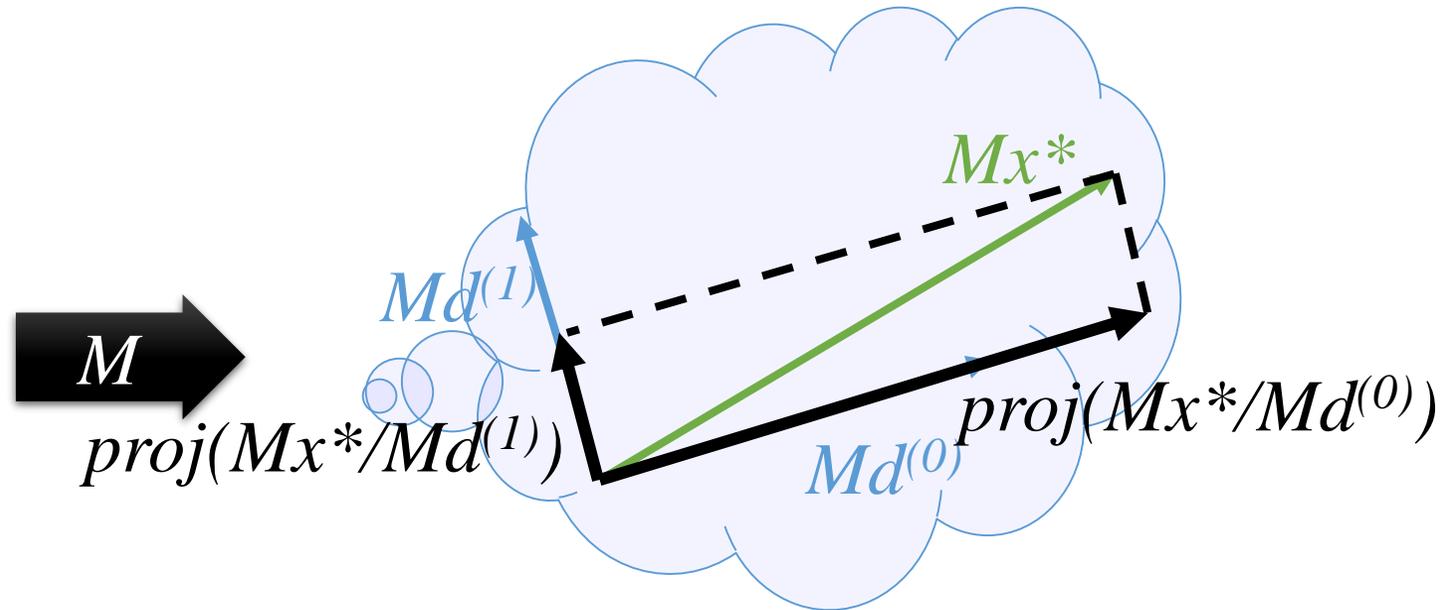
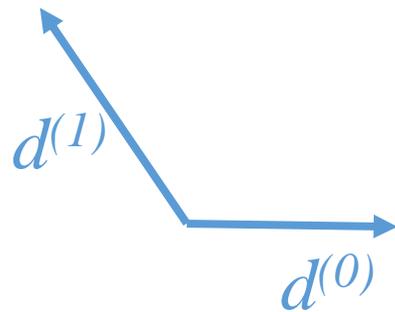


Conjugaison: vue d'ensemble

- Supposons que:
 - on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
 - on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

- Alors:

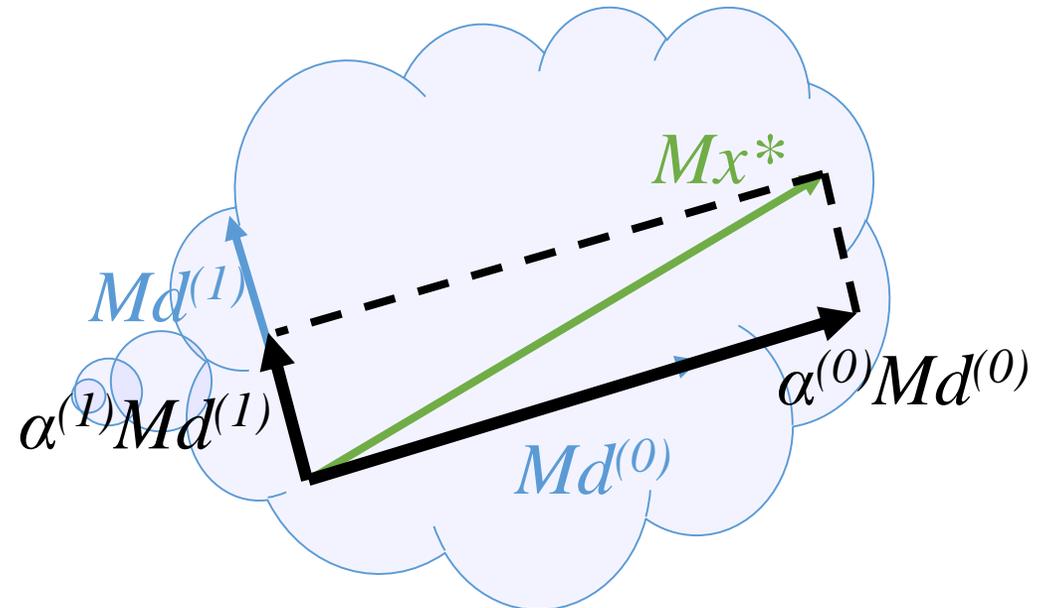
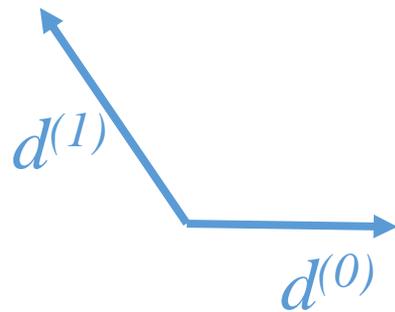
- $Mx^* = \sum_k \text{proj}(Mx^*/Md^{(k)})$



Conjugaison: vue d'ensemble

- Supposons que:
 - on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
 - on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

- Alors:
 - $Mx^* = \sum_k \text{proj}(Mx^*/Md^{(k)}) = \sum_k \alpha^{(k)}Md^{(k)}$



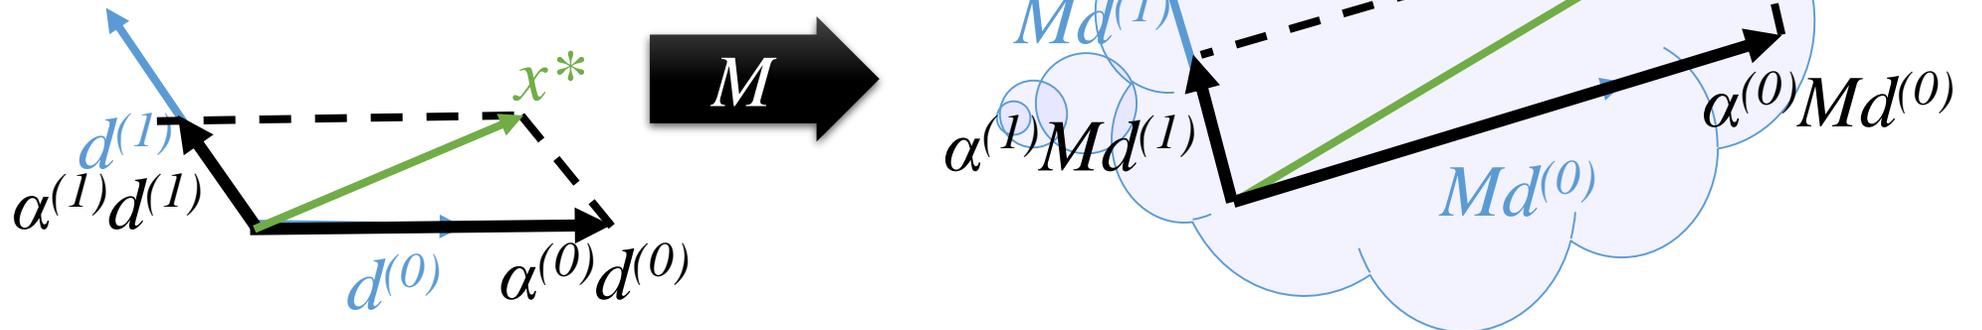
Conjugaison: vue d'ensemble

- Supposons que:
 - on connait $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
 - on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

- Alors:

- $Mx^* = \sum_k \text{proj}(Mx^*/Md^{(k)}) = \sum_k \alpha^{(k)}Md^{(k)}$

- $x^* = \sum_k \alpha^{(k)} d^{(k)}$



Conjugaison: vue d'ensemble

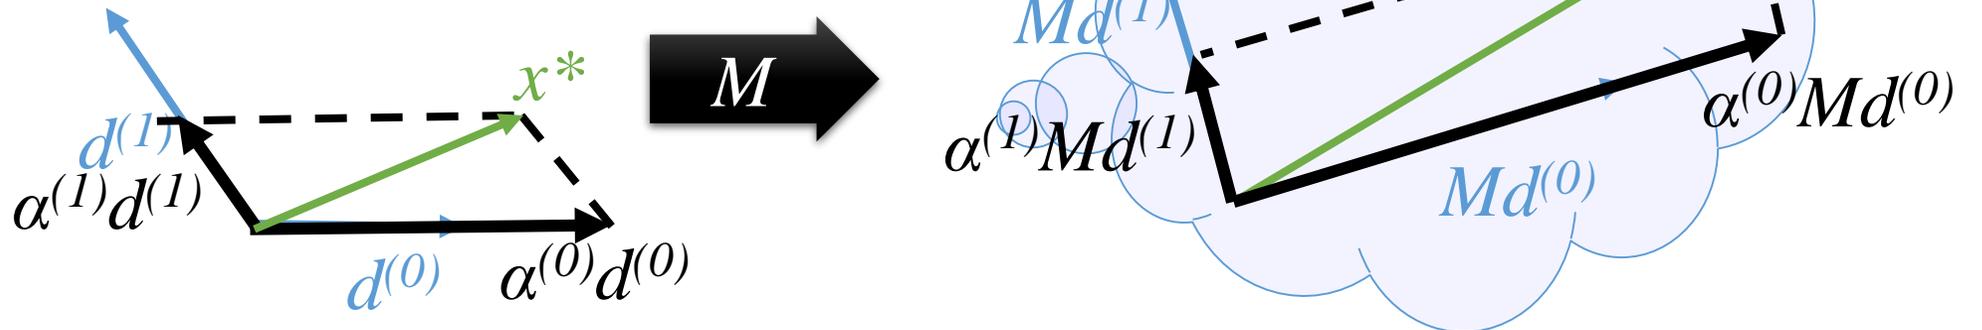
- Supposons que:

- ~~X~~ on connait $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ~~X~~ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

- Alors:

- $Mx^* = \sum_k \text{proj}(Mx^*/Md^{(k)}) = \sum_k \alpha^{(k)}Md^{(k)}$

- $x^* = \sum_k \alpha^{(k)} d^{(k)}$



Conjugaison: vue d'ensemble

- Supposons que:

 on connait $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux

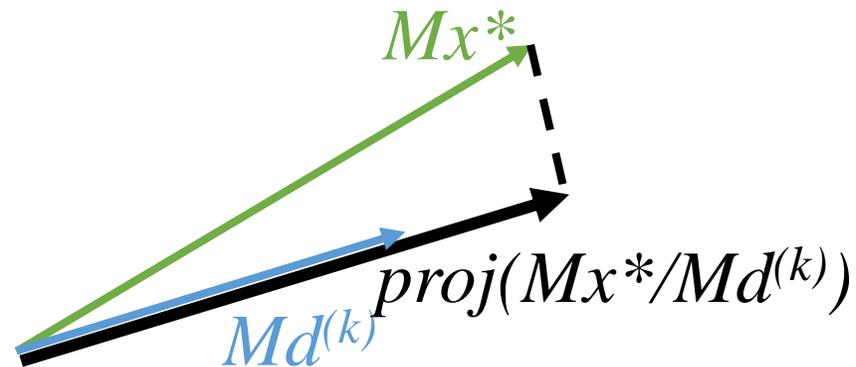


on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

Conjugaison: vue d'ensemble

- Supposons que:

- ✗ on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

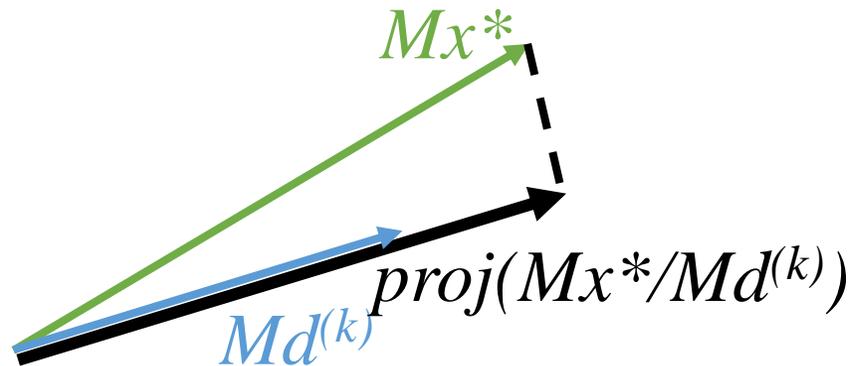


Conjugaison: vue d'ensemble

- Supposons que:

- ✗ on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

$$\begin{cases} \text{proj}(Mx^*/Md^{(k)})^T Md^{(k)} & = (Mx^*)^T Md^{(k)} \\ \text{proj}(Mx^*/Md^{(k)}) & = \alpha^{(k)} Md^{(k)} \end{cases}$$



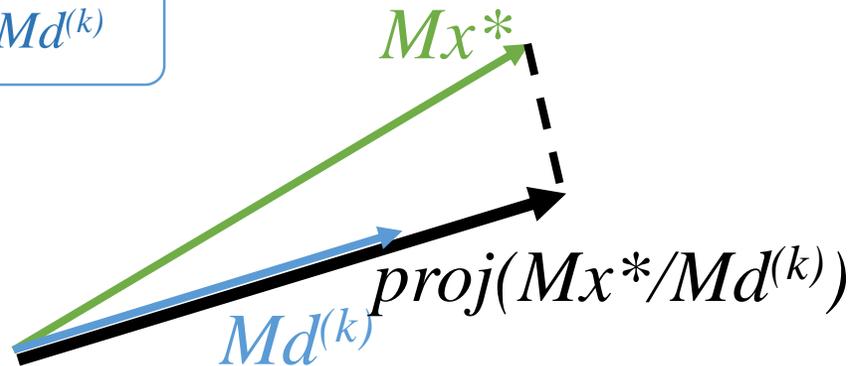
Conjugaison: vue d'ensemble

• Supposons que:

- ✗ on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

$$\begin{cases} \text{proj}(Mx^*/Md^{(k)})^T Md^{(k)} & = (Mx^*)^T Md^{(k)} \\ \text{proj}(Mx^*/Md^{(k)}) & = \alpha^{(k)} Md^{(k)} \end{cases}$$

$$(\alpha^{(k)} Md^{(k)})^T Md^{(k)} = (Mx^*)^T Md^{(k)}$$



Conjugaison: vue d'ensemble

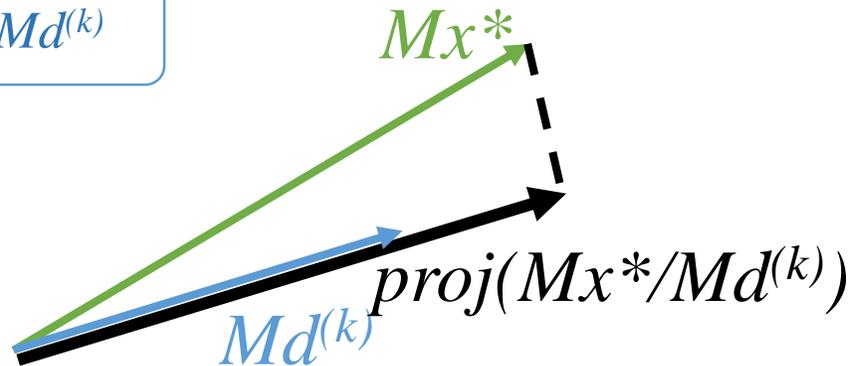
• Supposons que:

- ✗ on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

$$\begin{cases} \text{proj}(Mx^*/Md^{(k)})^T Md^{(k)} & = (Mx^*)^T Md^{(k)} \\ \text{proj}(Mx^*/Md^{(k)}) & = \alpha^{(k)} Md^{(k)} \end{cases}$$

$$(\alpha^{(k)} Md^{(k)})^T Md^{(k)} = (Mx^*)^T Md^{(k)}$$

$$\alpha^{(k)} = \frac{(Mx^*)^T Md^{(k)}}{(Md^{(k)})^T Md^{(k)}}$$



Conjugaison: vue d'ensemble

- Supposons que:

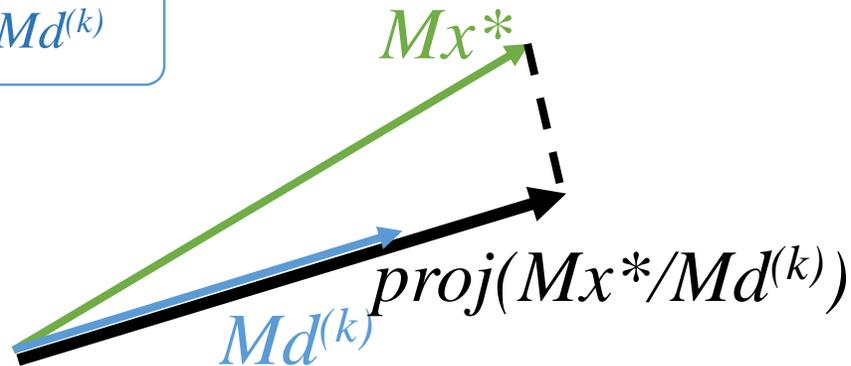
- ✗ on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

$$\alpha^{(k)} = \frac{(Mx^*)^T Md^{(k)}}{(Md^{(k)})^T Md^{(k)}}$$

$$\begin{cases} \text{proj}(Mx^*/Md^{(k)})^T Md^{(k)} &= (Mx^*)^T Md^{(k)} \\ \text{proj}(Mx^*/Md^{(k)}) &= \alpha^{(k)} Md^{(k)} \end{cases}$$

$$(\alpha^{(k)} Md^{(k)})^T Md^{(k)} = (Mx^*)^T Md^{(k)}$$

$$\alpha^{(k)} = \frac{(Mx^*)^T Md^{(k)}}{(Md^{(k)})^T Md^{(k)}}$$



Conjugaison: vue d'ensemble

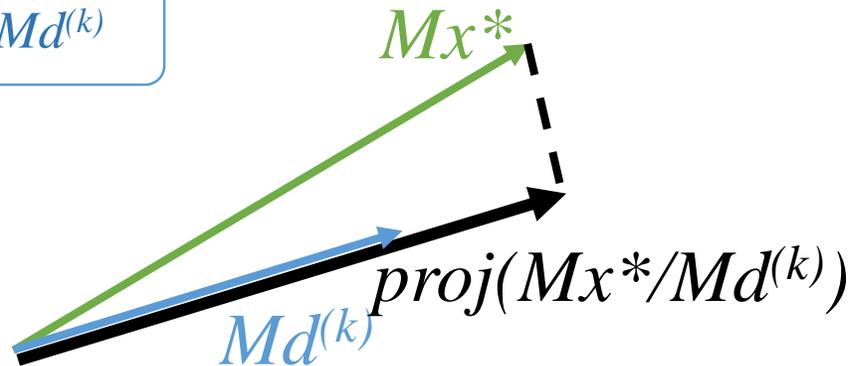
• Supposons que:

- ✗ on connait $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

$$\begin{cases} \text{proj}(Mx^*/Md^{(k)})^T Md^{(k)} &= (Mx^*)^T Md^{(k)} \\ \text{proj}(Mx^*/Md^{(k)}) &= \alpha^{(k)} Md^{(k)} \end{cases}$$

$$(\alpha^{(k)} Md^{(k)})^T Md^{(k)} = (Mx^*)^T Md^{(k)}$$

$$\alpha^{(k)} = \frac{(Mx^*)^T Md^{(k)}}{(Md^{(k)})^T Md^{(k)}}$$



$$\alpha^{(k)} = \frac{(Mx^*)^T Md^{(k)}}{(Md^{(k)})^T Md^{(k)}}$$

$$\alpha^{(k)} = \frac{d^{(k)b}}{d^{(k)} A d^{(k)}}$$

$$(Mu)^T (Mx^*) = u^T A x^* = u^T b$$

$$(Mu)^T (Mv) = u^T M^T M v = u^T A v$$

Conjugaison: vue d'ensemble

- Supposons que:

 on connaît $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux

 on sait calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

Conjugaison: définir une base A-orthogonale

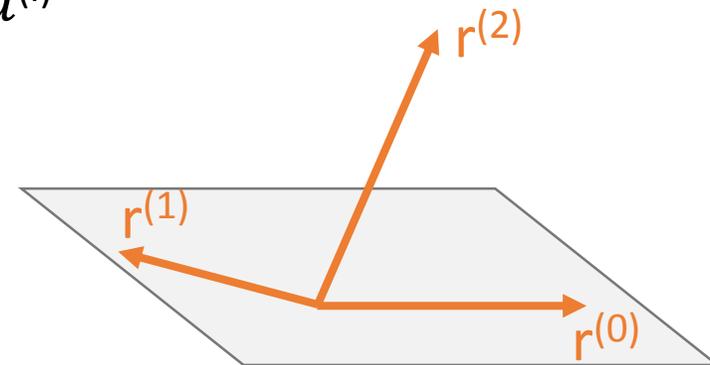
- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$

Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

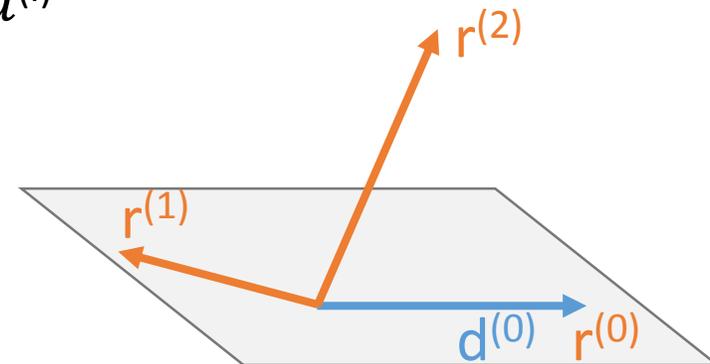
$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$



Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

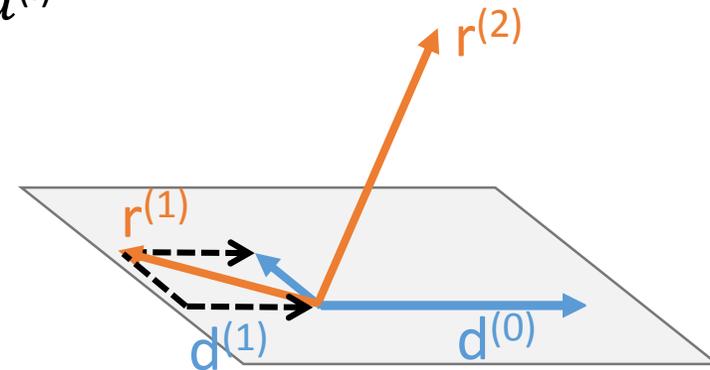
$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$



Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

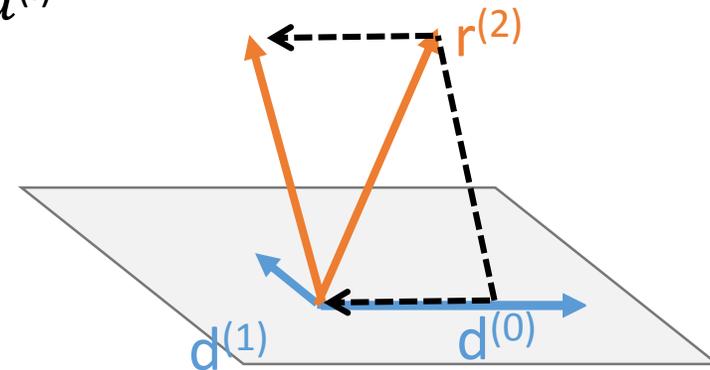
$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$



Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

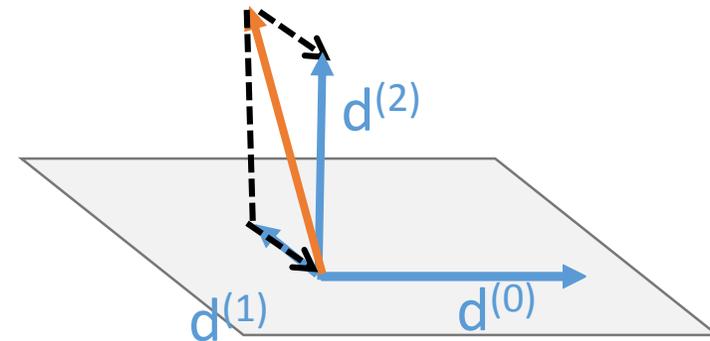
$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$



Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

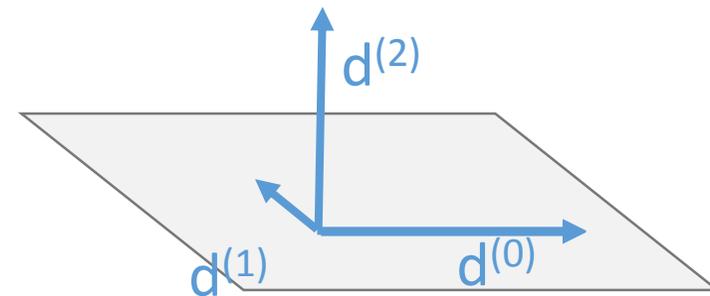
$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$



Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:
 - On choisit n vecteurs indépendants $\{r^{(k)}\}$
 - Pour chaque vecteur $r^{(k)}$
 - On lui retire sa projection sur les vecteurs précédents

$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$



Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:

- On choisit n vecteurs indépendants $\{r^{(k)}\}$

- Pour chaque vecteur $r^{(k)}$

- On lui retire sa projection sur les vecteurs précédents

$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} \cdot d^{(i)}}{d^{(i)} \cdot d^{(i)}} d^{(i)}$$

- Cet algorithme n'utilise que le produit scalaire...
- si on utilisait le produit scalaire des images par M...
- on aurait une base dont l'image par M est orthogonale !

Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:

- On choisit n vecteurs indépendants $\{r^{(k)}\}$

- Pour chaque vecteur $r^{(k)}$

- On lui retire sa projection sur les vecteurs précédents

$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{Mr^{(k)} \cdot Md^{(i)}}{Md^{(i)} \cdot Md^{(i)}} d^{(i)}$$

- Cet algorithme n'utilise que le produit scalaire...
- si on utilisait le produit scalaire des images par M...
- on aurait une base dont l'image par M est orthogonale !

Conjugaison: définir une base A-orthogonale

- Pour construire une base orthogonale, on peut utiliser l'algorithme de Gram Schmidt:

- On choisit n vecteurs indépendants $\{r^{(k)}\}$

- Pour chaque vecteur $r^{(k)}$

- On lui retire sa projection sur les vecteurs précédents

$$d^{(k)} = r^{(k)} - \sum_{i=0}^{k-1} \frac{r^{(k)} A d^{(i)}}{d^{(i)} A d^{(i)}} d^{(i)}$$

- Cet algorithme n'utilise que le produit scalaire...
- si on utilisait le produit scalaire des images par M...
- on aurait une base dont l'image par M est orthogonale !

Conjugaison: vue d'ensemble

- On sait:

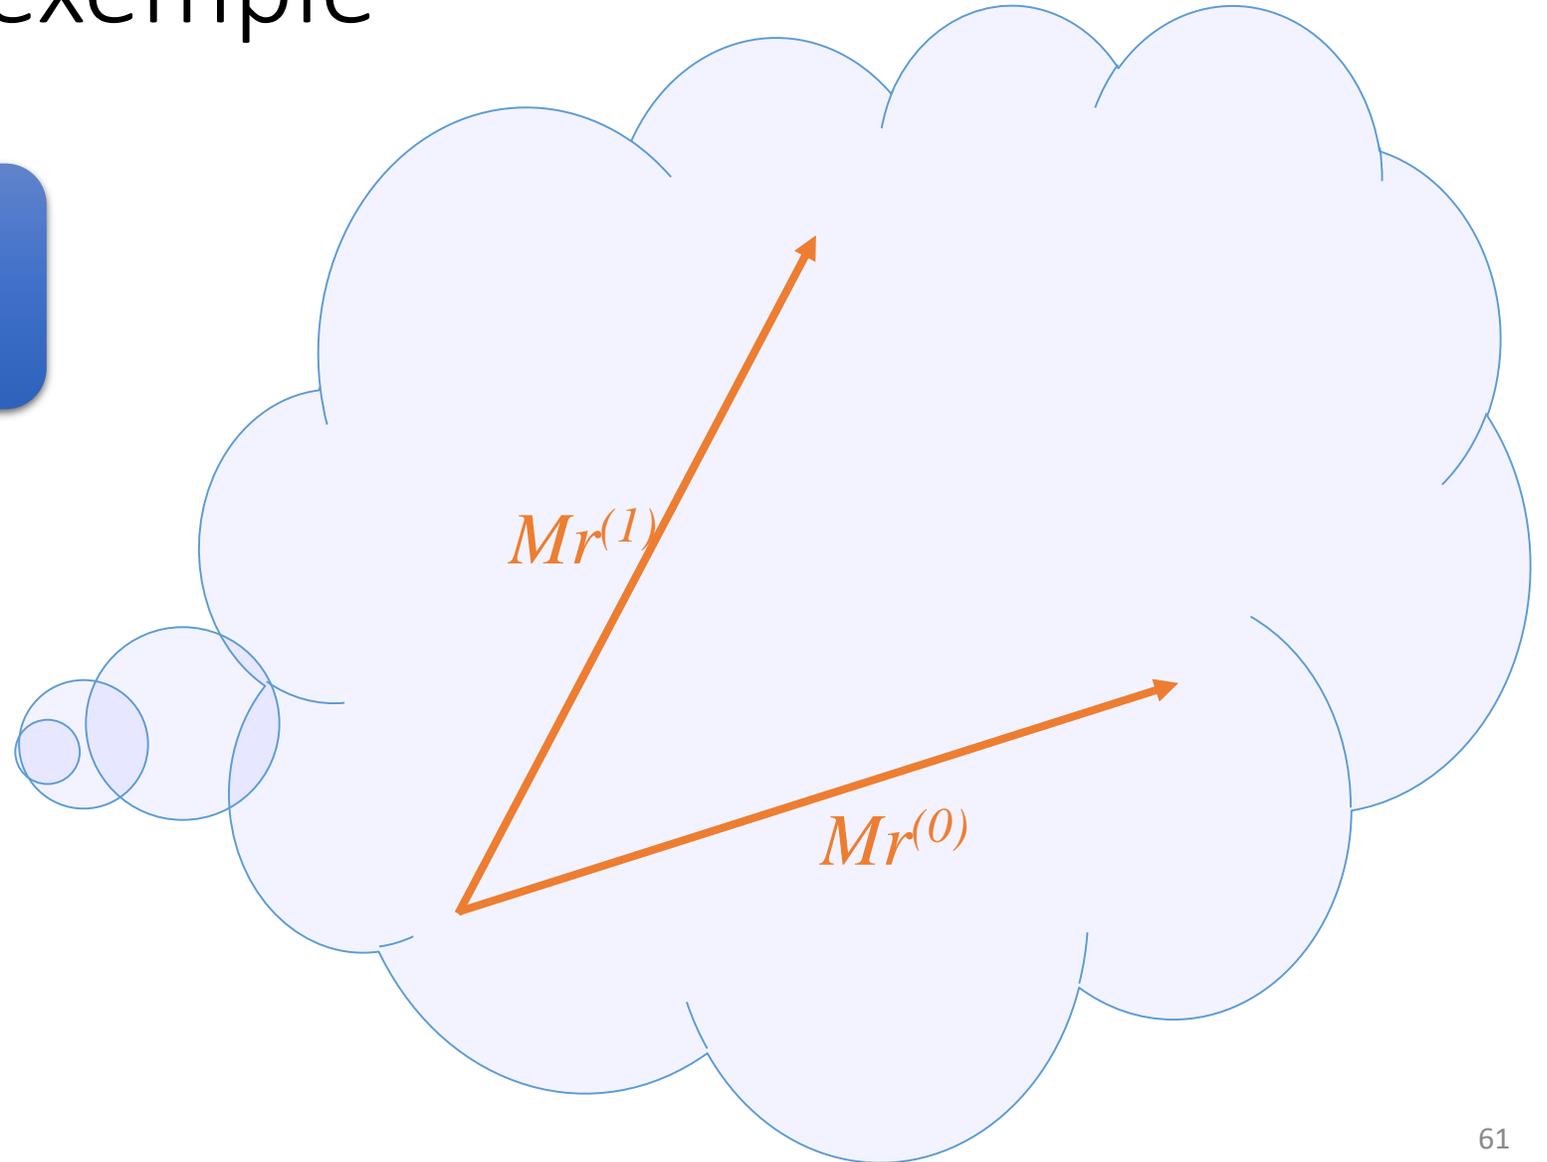
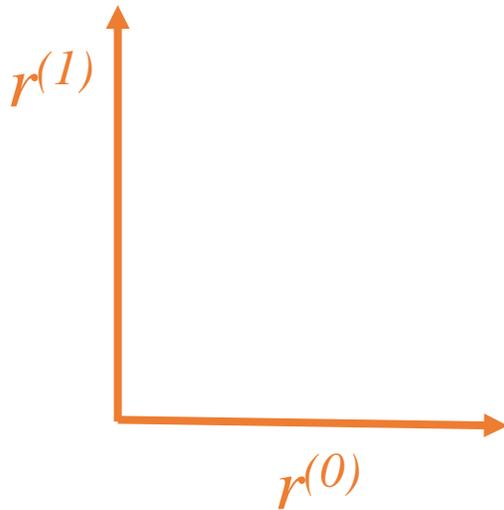
- ✓ Calculer $\{d^{(k)}\}$ une base telle que les $Md^{(k)}$ soient orthogonaux deux à deux
- ✓ Calculer $\alpha^{(k)}$ tel que $\text{proj}(Mx^*/Md^{(k)}) = \alpha^{(k)}Md^{(k)}$

- Donc la solution est:

- $x^* = \sum_k \alpha^{(k)} d^{(k)}$

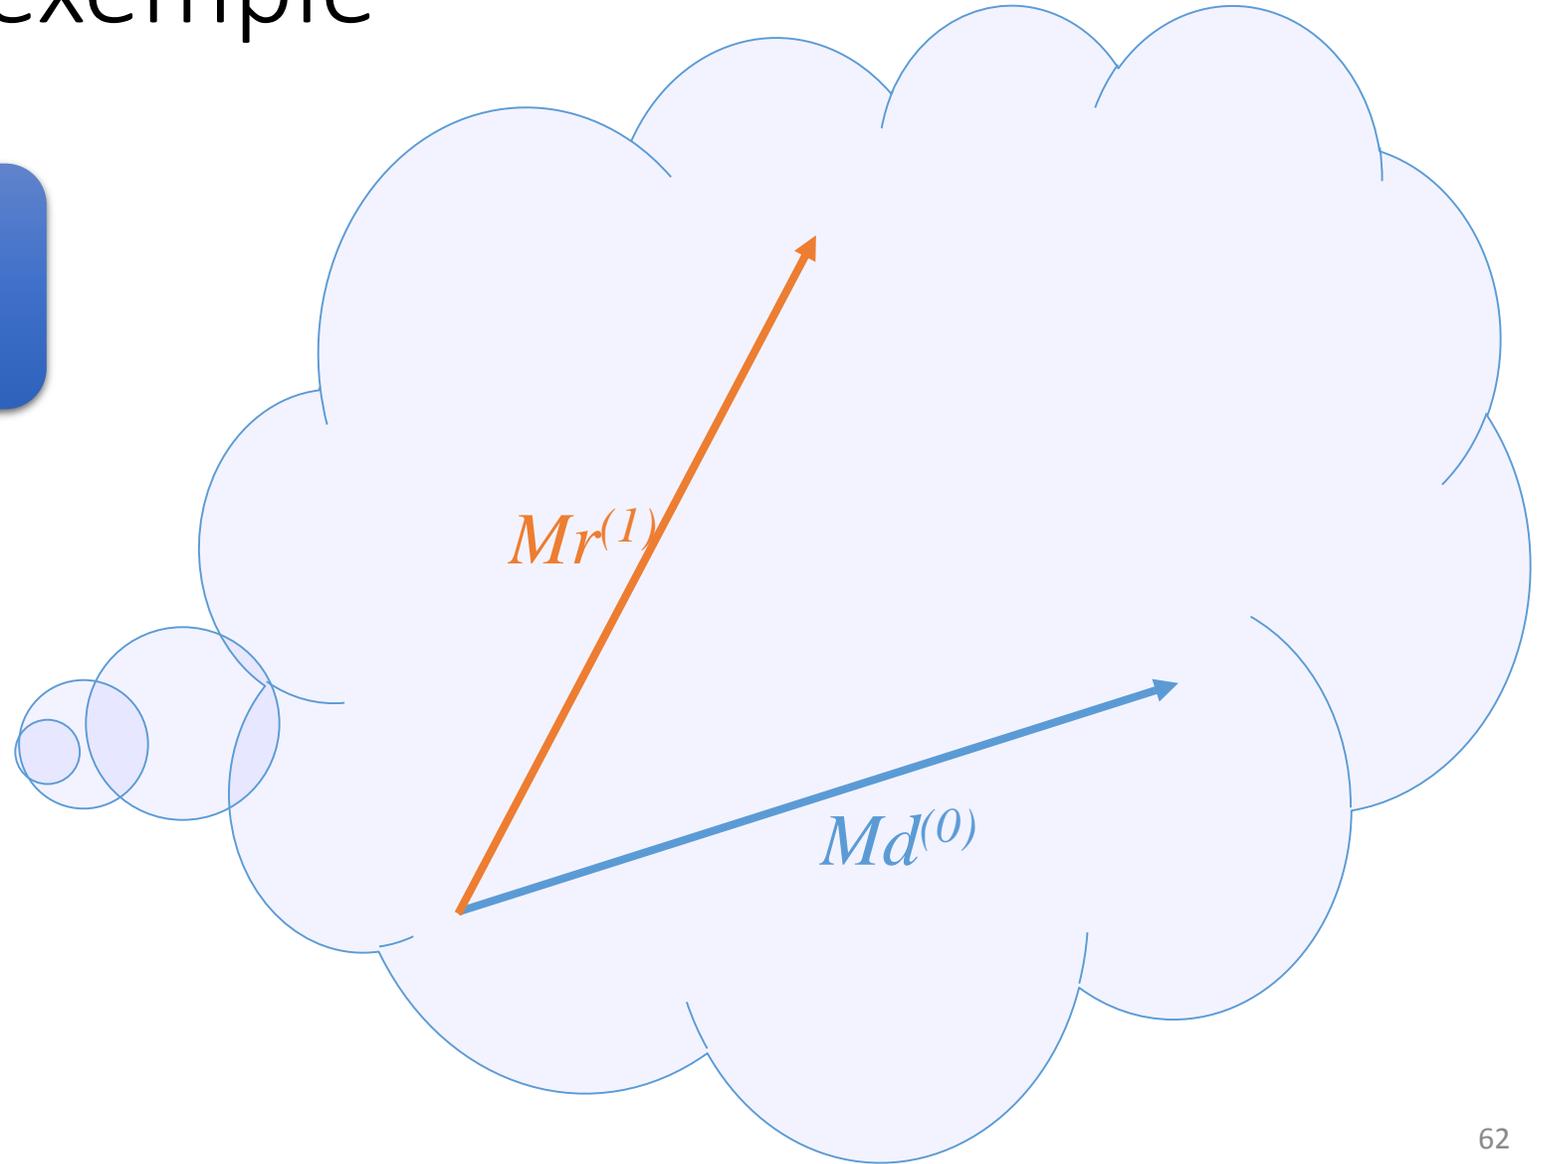
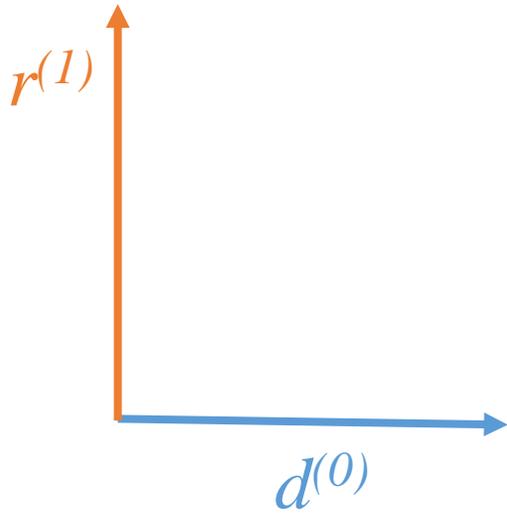
Conjugaison: exemple

On choisit une base
quelconque $\{r^{(k)}\}$



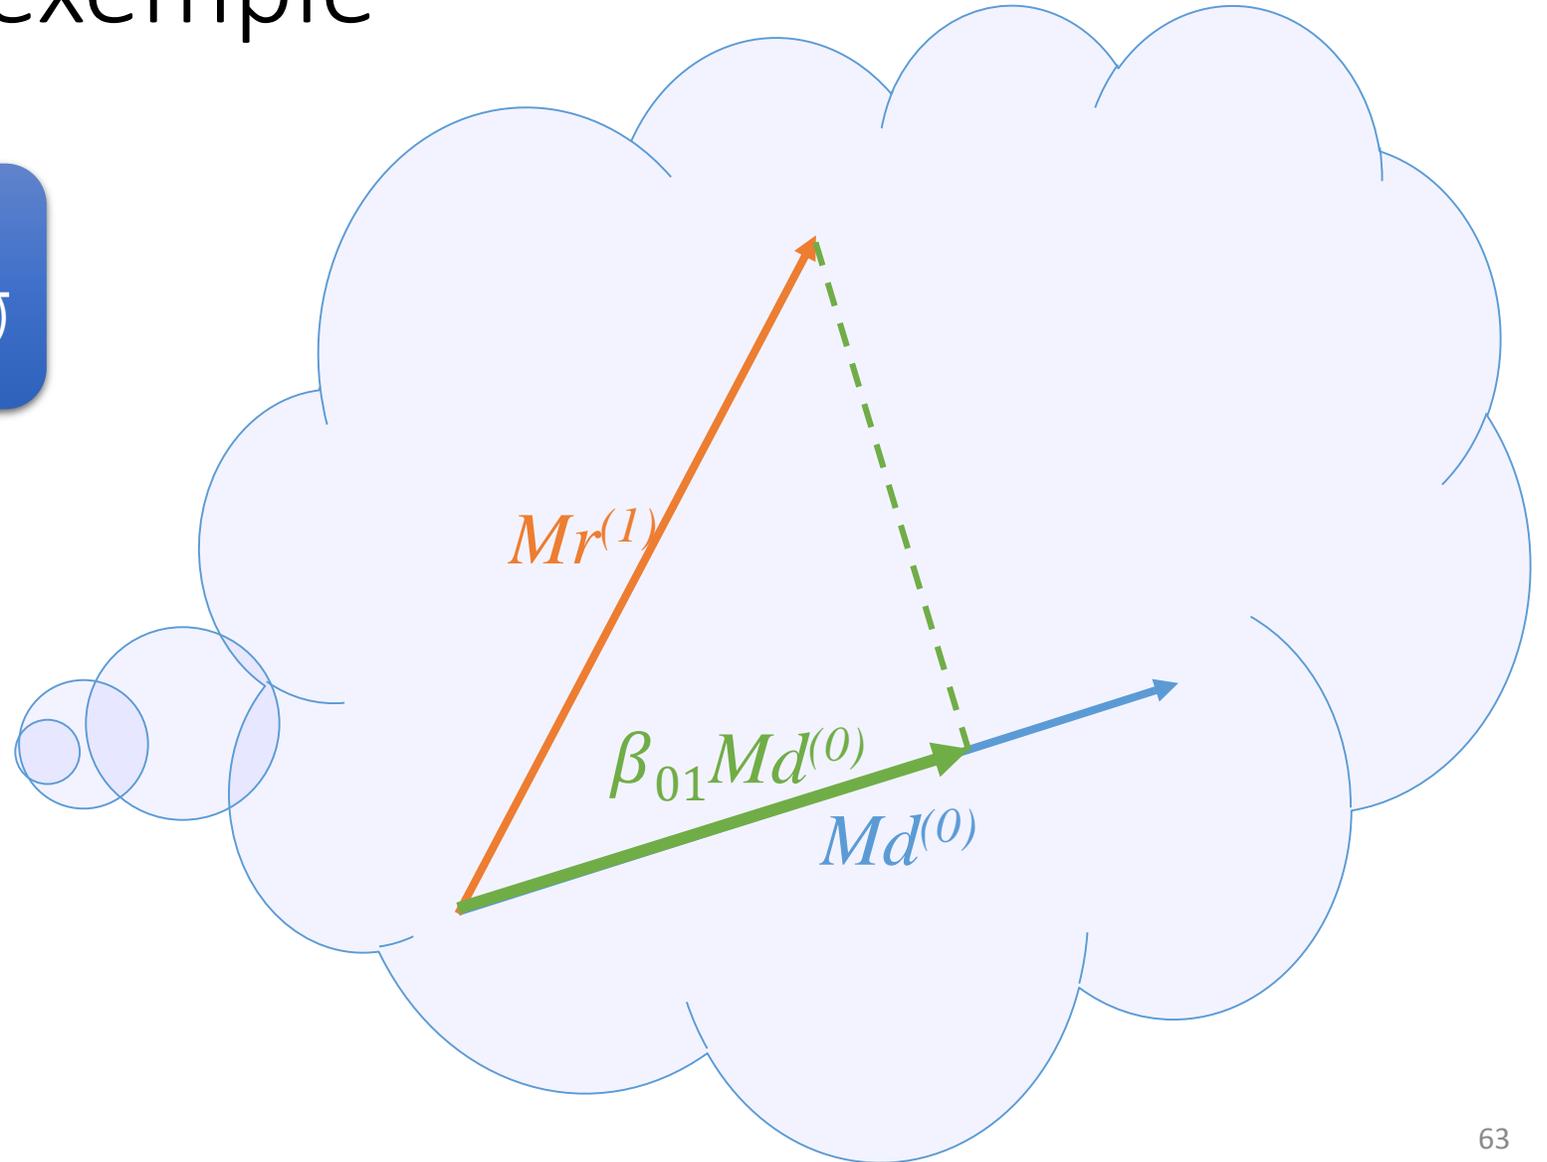
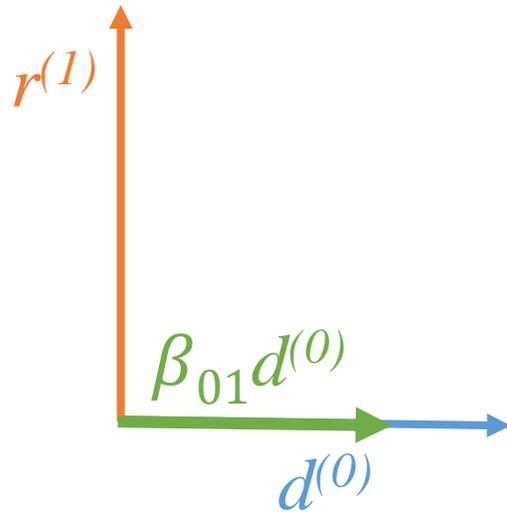
Conjugaison: exemple

On fixe $d^{(0)} = r^{(0)}$



Conjugaison: exemple

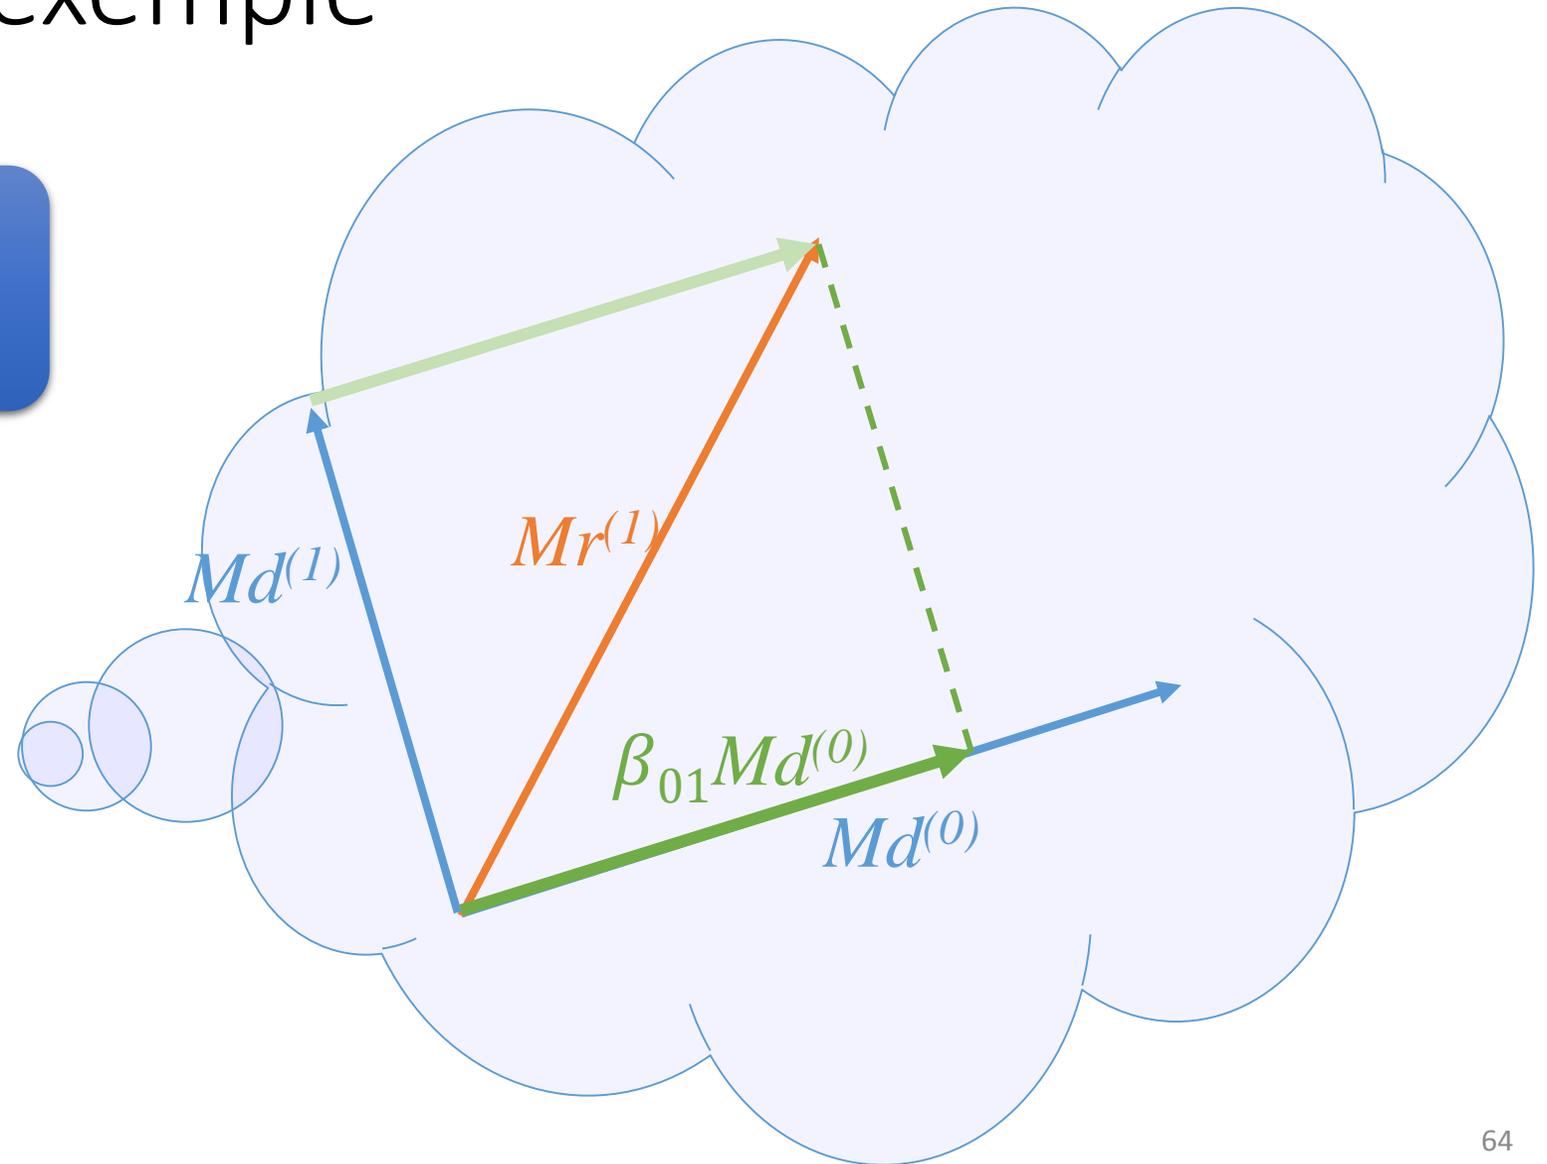
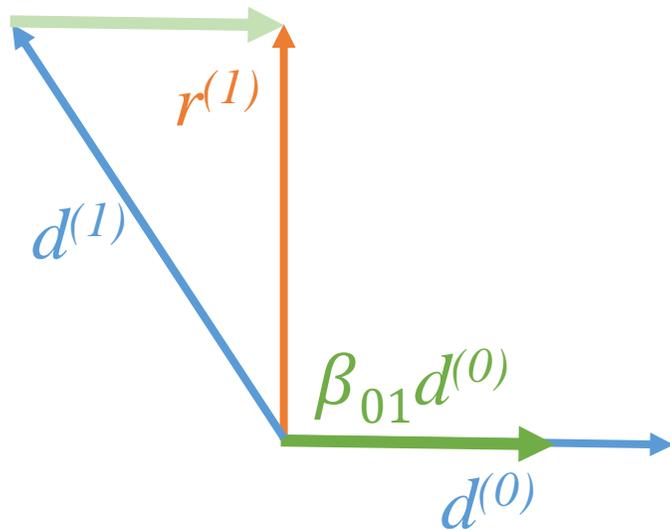
On calcule $\beta_{01} = \frac{r^{(0)}Ad^{(1)}}{d^{(0)}Ad^{(0)}}$



Conjugaison: exemple

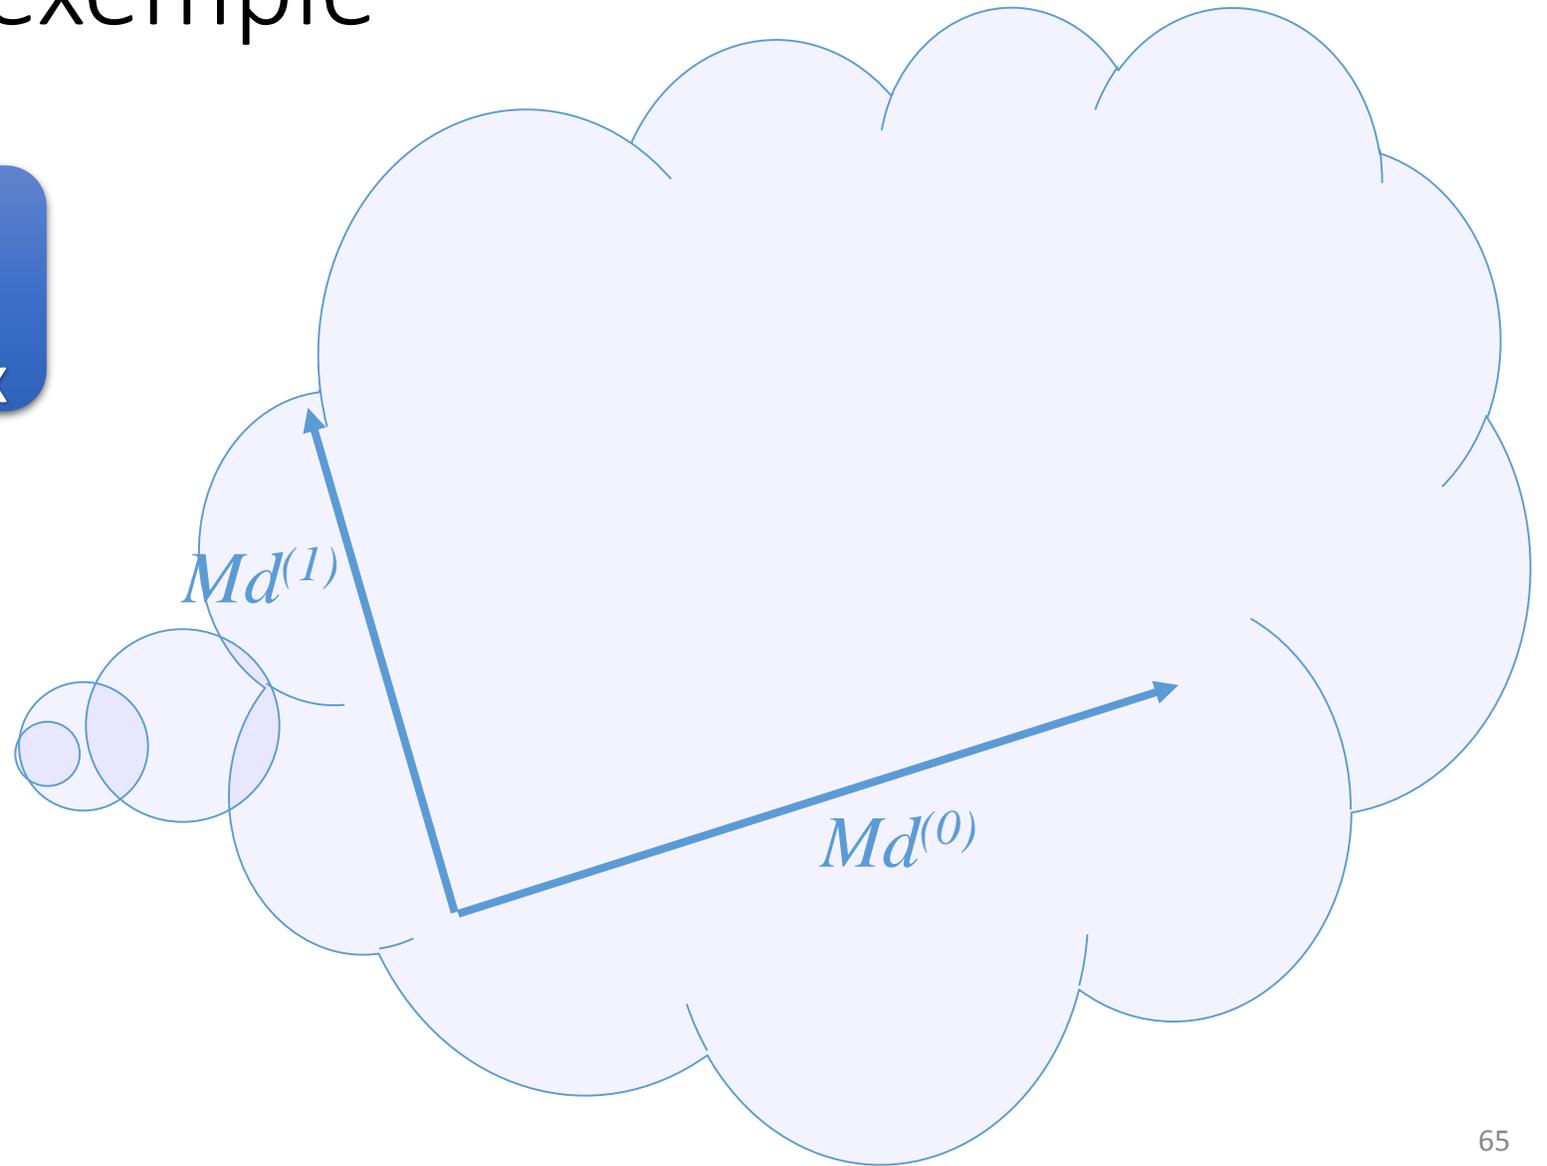
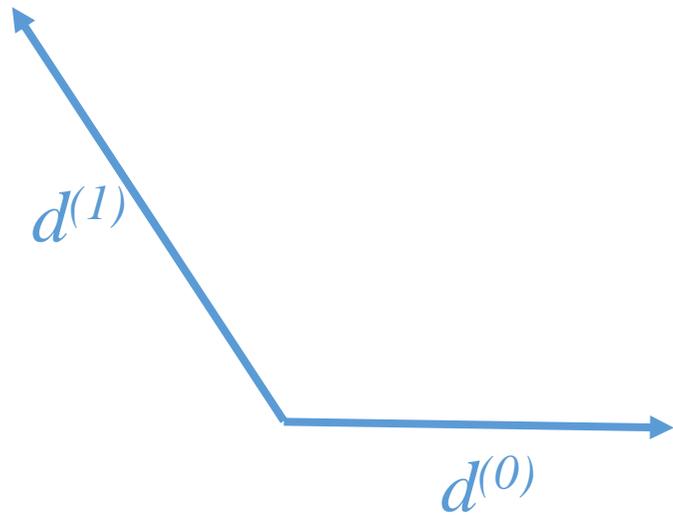
On choisit

$$d^{(1)} = r^{(1)} - \beta_{01}d^{(0)}$$



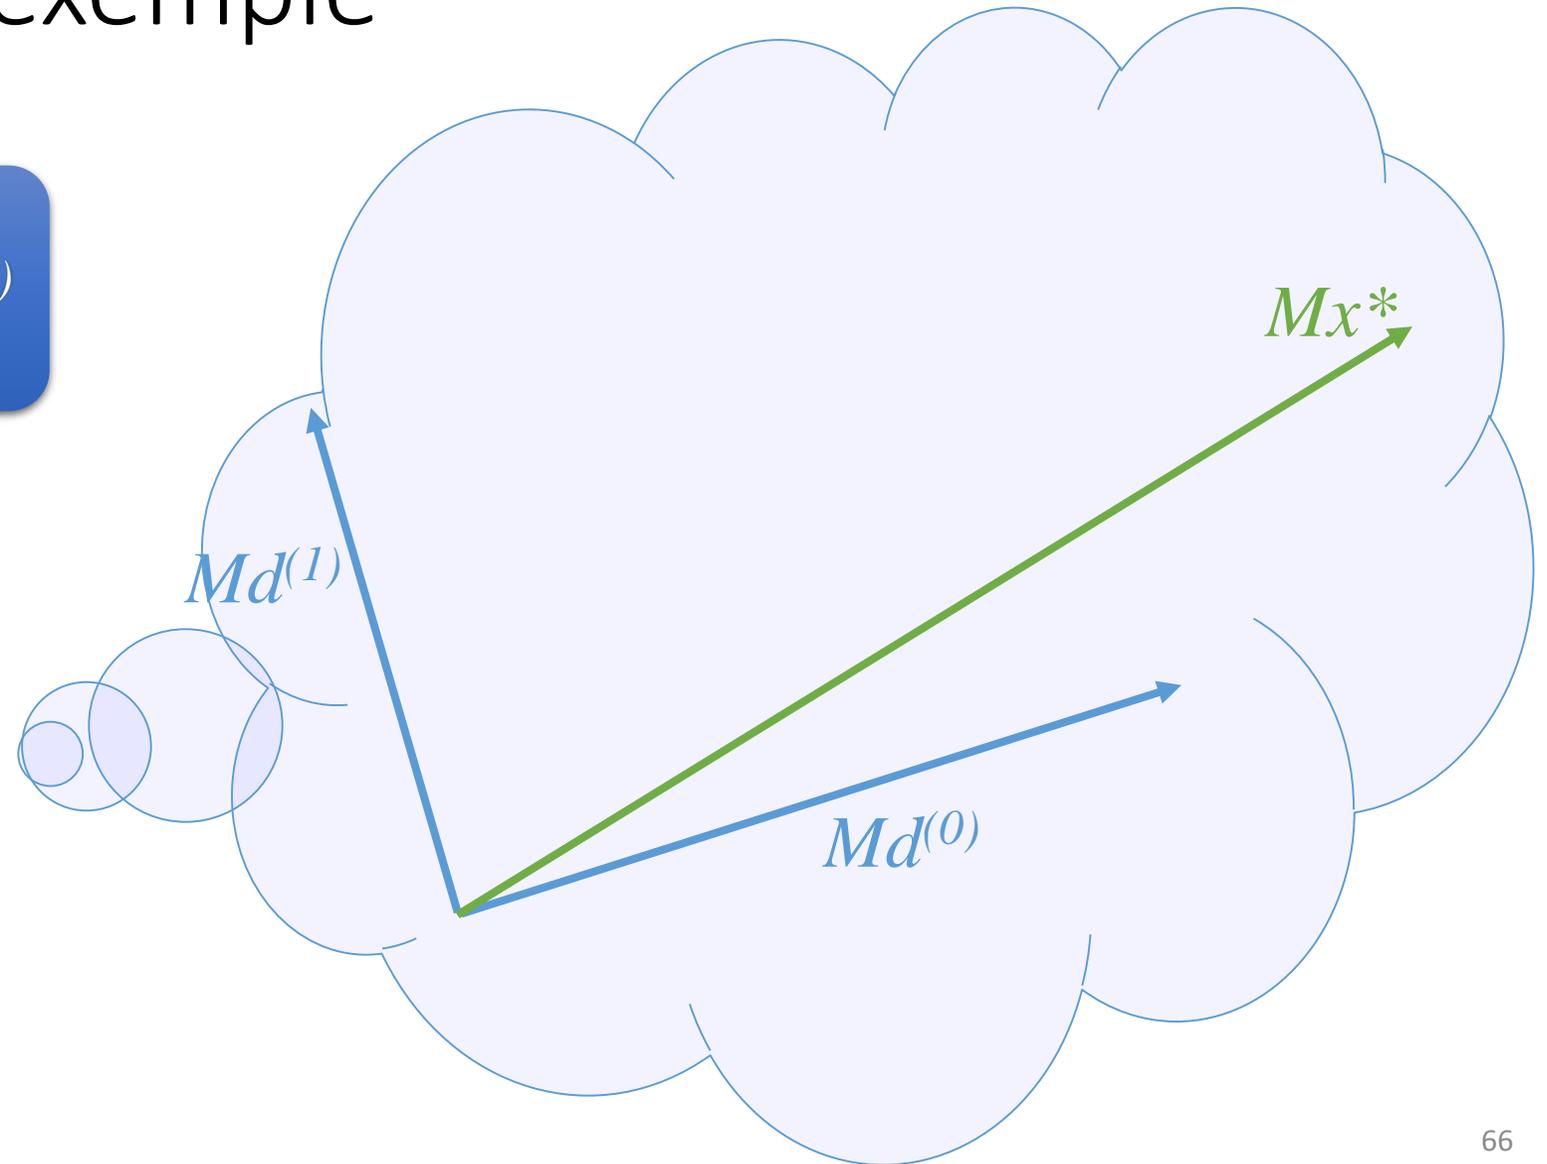
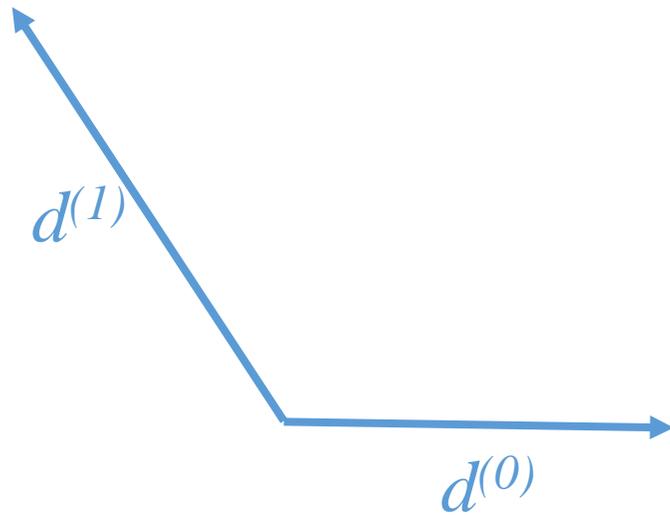
Conjugaison: exemple

On a une base $\{d^{(k)}\}$ telle que les $Md^{(k)}$ soient orthogonaux deux à deux



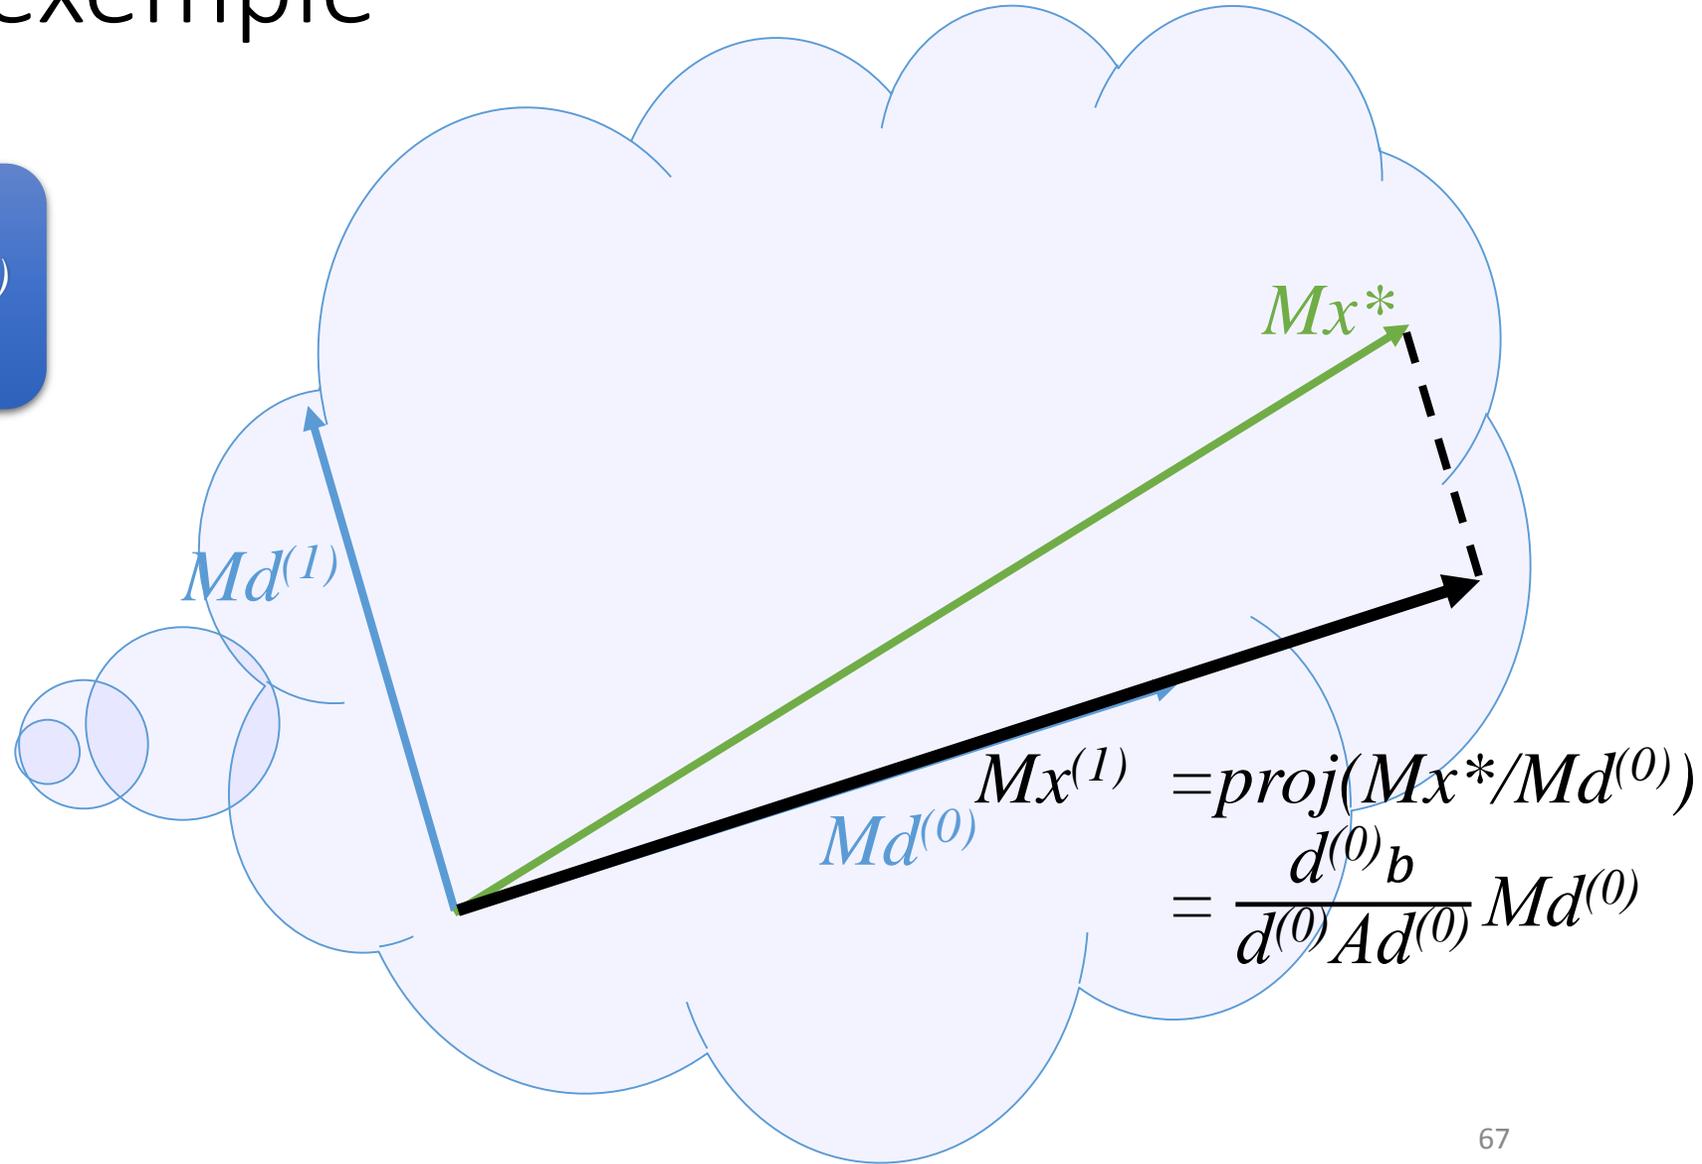
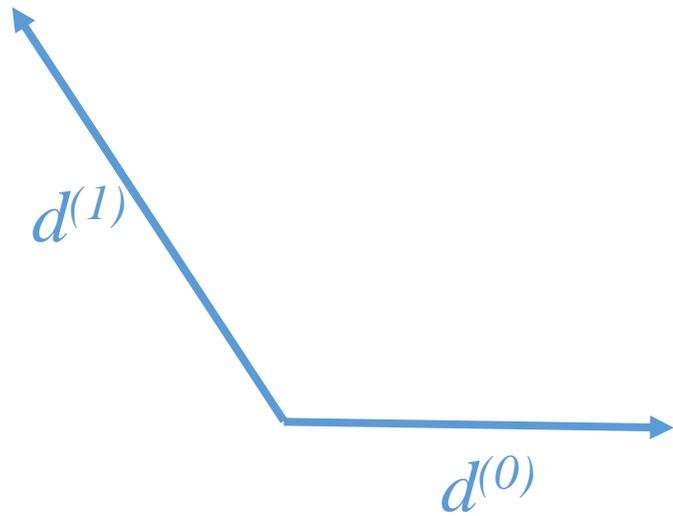
Conjugaison: exemple

On projette Mx^* sur $Md^{(0)}$



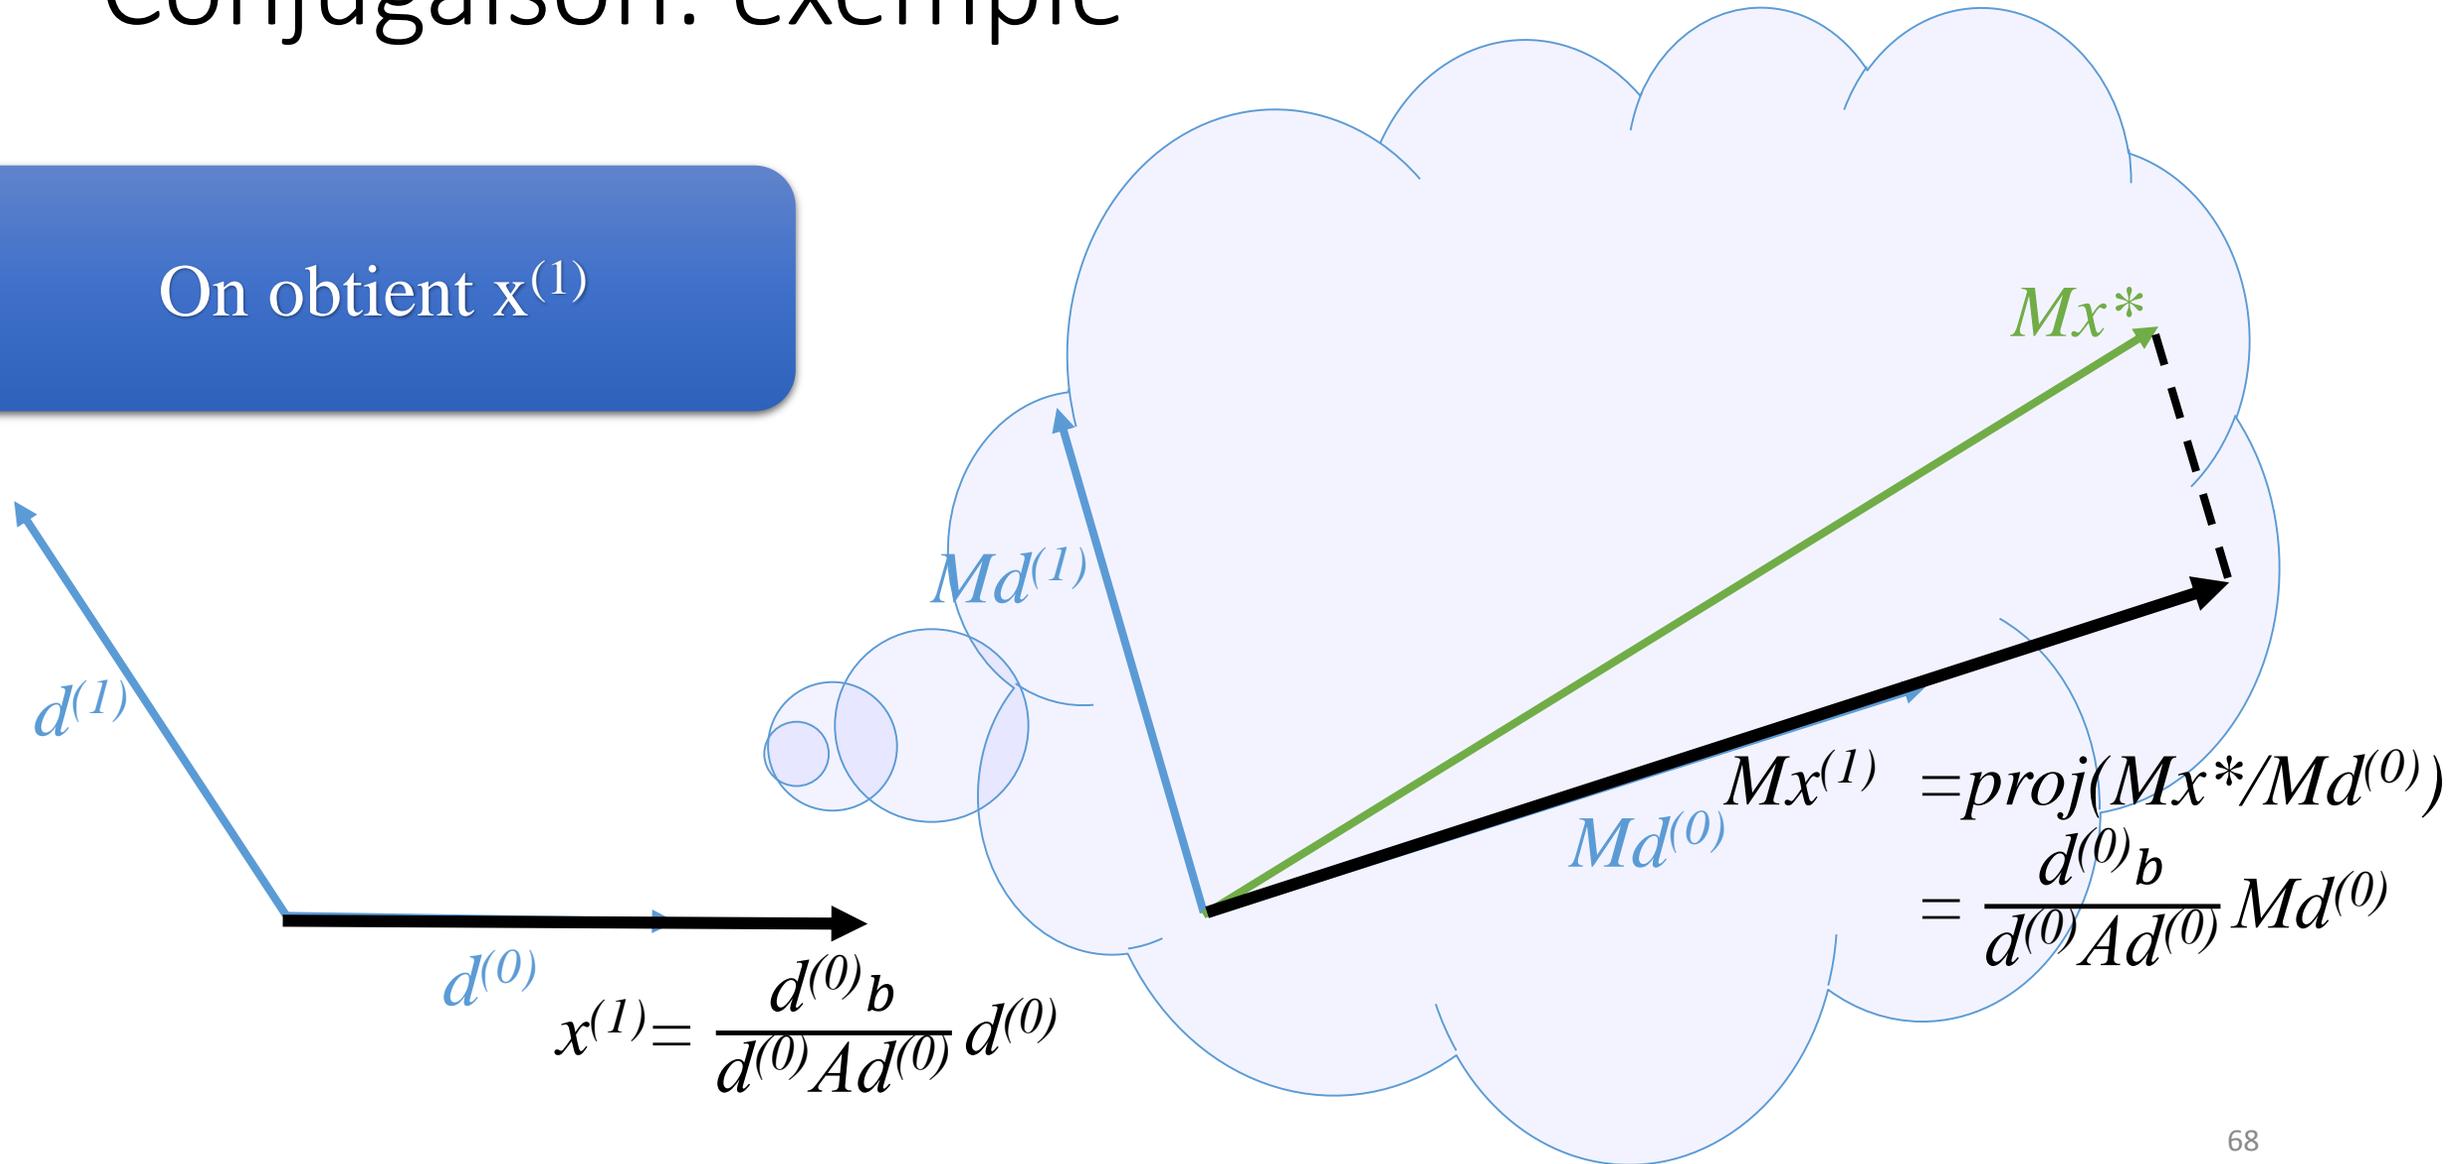
Conjugaison: exemple

On projette Mx^* sur $Md^{(0)}$



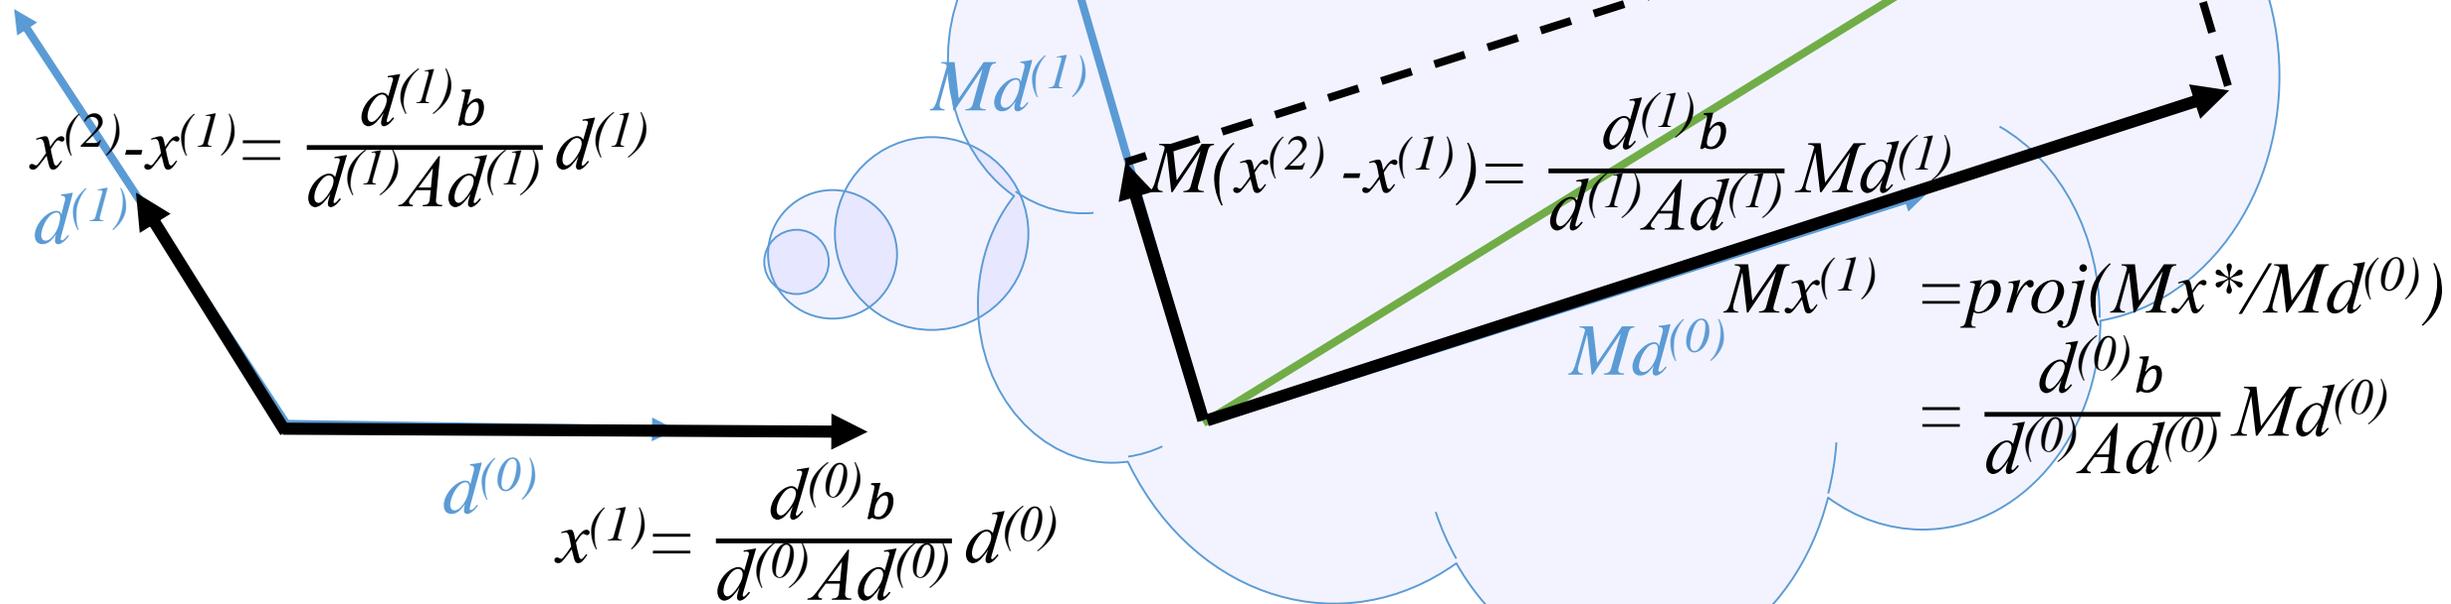
Conjugaison: exemple

On obtient $x^{(1)}$



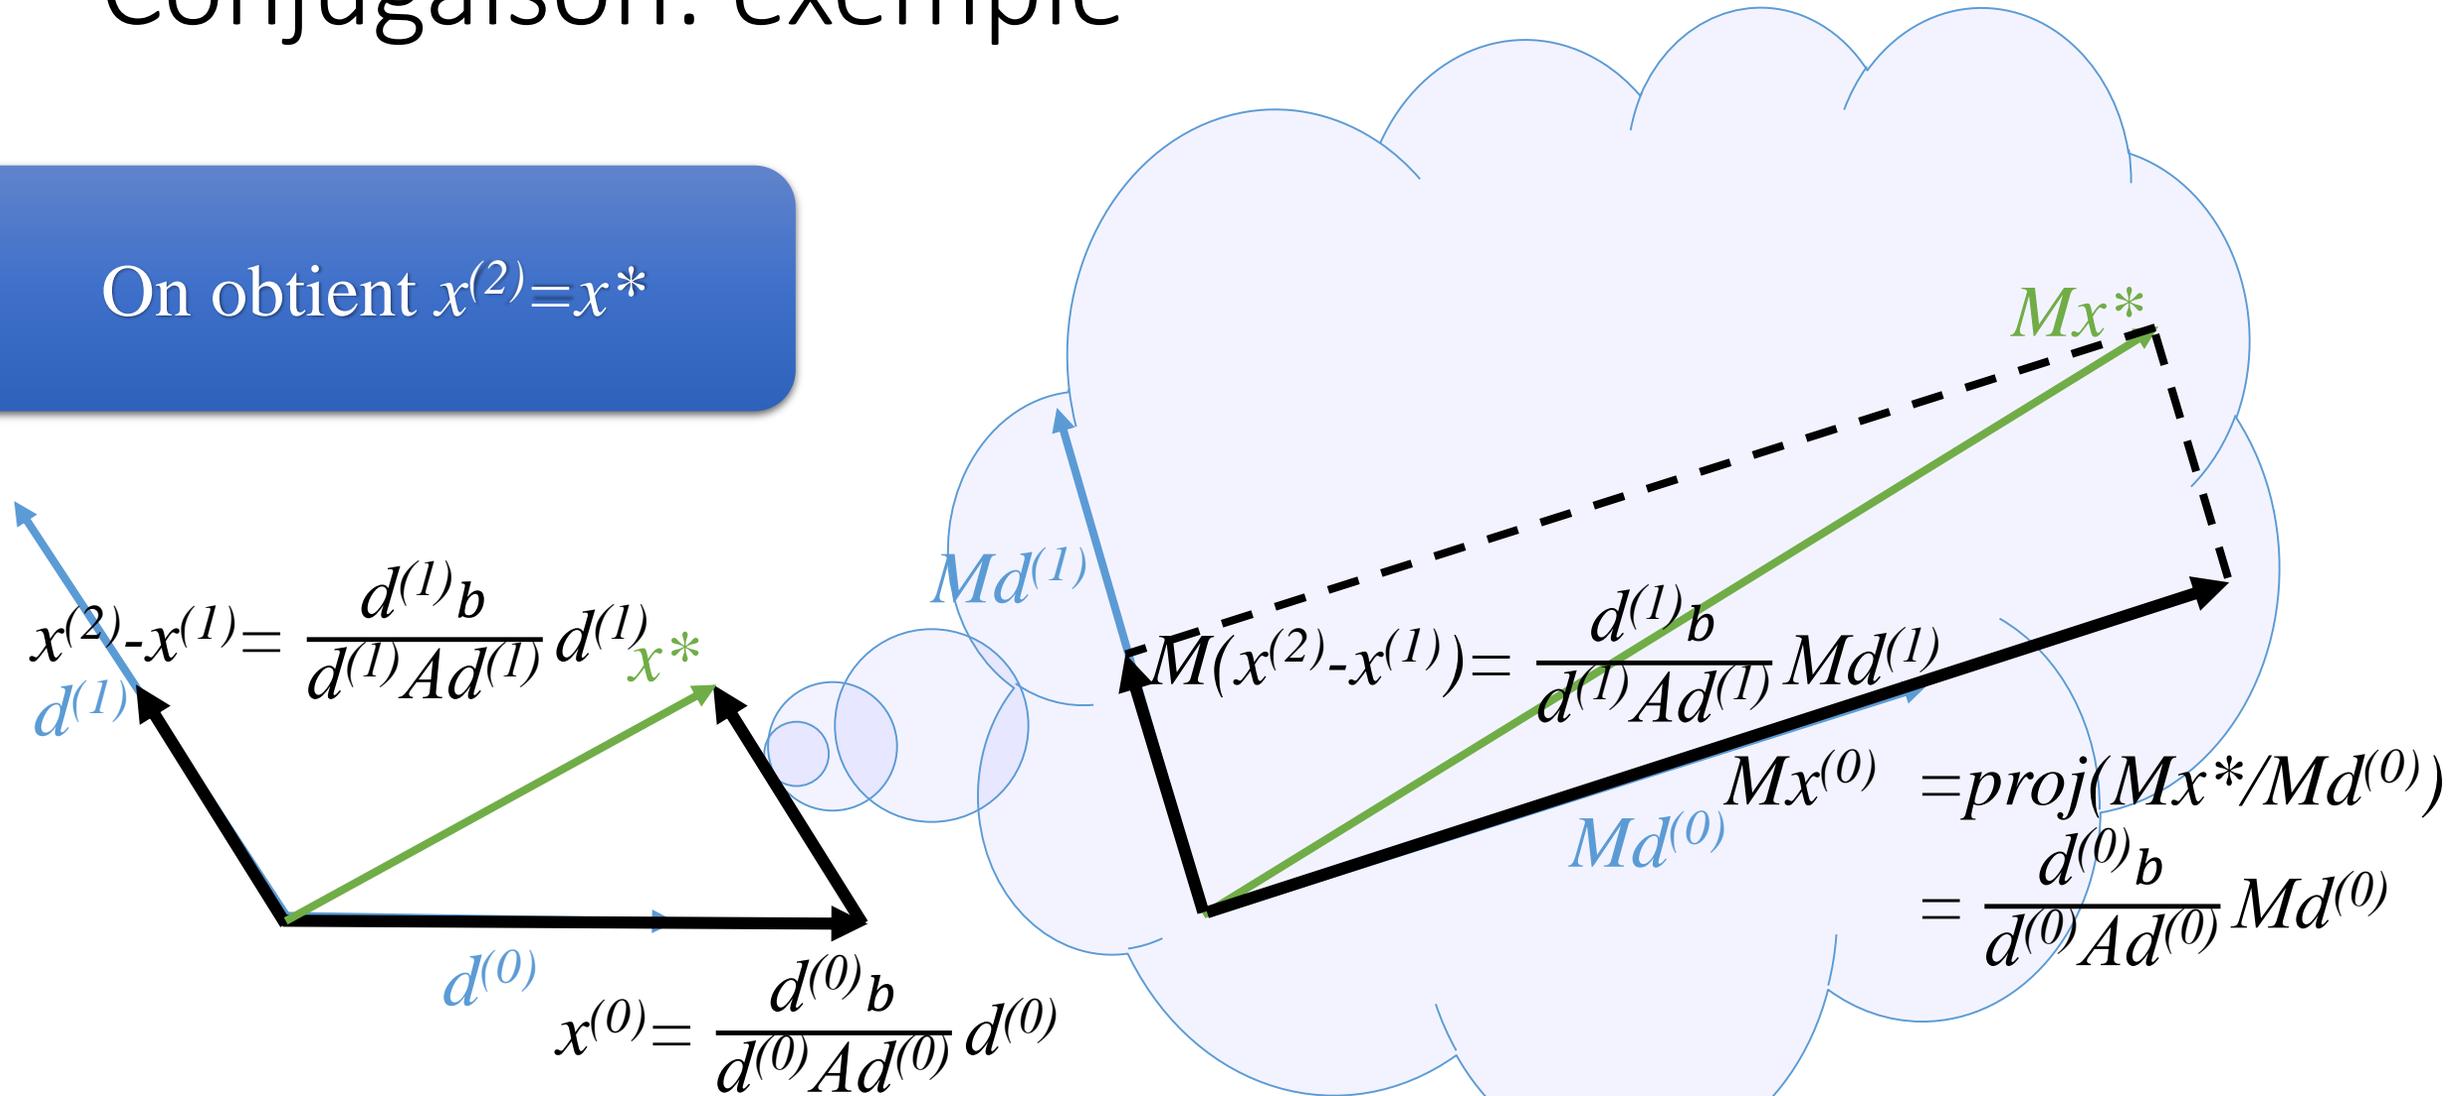
Conjugaison: exemple

On obtient $x^{(2)} - x^{(1)}$



Conjugaison: exemple

On obtient $x^{(2)} = x^*$



Conjugaison: algorithme

// construction de la base

- On choisit n vecteurs indépendants $\{r^{(k)}\}$
- Pour chaque vecteur $r^{(k)}$
 - $d^{(k)}$ reçoit $r^{(k)}$ moins sa M -projection sur les $d^{(i)}$ précédents

// projection de x^* sur la base

- On calcule les coefficients $\alpha^{(k)}$ tels que $Mx^* = \sum \alpha^{(k)} Md^{(k)}$, en projetant Mx^* sur les $Md^{(k)}$
- On définit $x^* = \sum \alpha^{(k)} d^{(k)}$

Conjugaison: algorithme

// construction de la base

- On choisit n vecteurs indépendants $\{r^{(k)}\}$
- Pour chaque vecteur $r^{(k)}$
 - $d^{(k)}$ reçoit $r^{(k)}$ moins sa M -projection sur les $d^{(i)}$ précédents

// projection de x^* sur la base

- On calcule les coefficients $\alpha^{(k)}$ tels que $Mx^* = \sum \alpha^{(k)} Md^{(k)}$, en projetant Mx^* sur les $Md^{(k)}$
- On définit $x^* = \sum \alpha^{(k)} d^{(k)}$

On va factoriser les boucles différemment

Conjugaison: algorithme

// construction de la base

- On choisit n vecteurs indépendants $\{r^{(k)}\}$
- Pour chaque vecteur $r^{(k)}$
 - $d^{(k)}$ reçoit $r^{(k)}$ moins sa M -projection sur les $d^{(i)}$ précédents

// projection de x^* sur la base

- Initialiser $x^{(0)} = 0$
- On itère sur k :
 - On calcule le coefficient $\alpha^{(k)}$, en projetant Mx^* sur $Md^{(k)}$
 - On définit $x^{(k)} = x^{(k-1)} + \alpha^{(k)}d^{(k)}$

Conjugaison: algorithme

// construction de la base

- On choisit n vecteurs indépendants $\{r^{(k)}\}$
- Pour chaque vecteur $r^{(k)}$
 - $d^{(k)}$ reçoit $r^{(k)}$ moins sa M -projection sur les $d^{(i)}$ précédents

// projection de x^* sur la base

- Initialiser $x^{(0)} = 0$
- On itère sur k :
 - On calcule le coefficient $\alpha^{(k)}$, en projetant Mx^* sur $Md^{(k)}$
 - On définit $x^{(k)} = x^{(k-1)} + \alpha^{(k)}d^{(k)}$

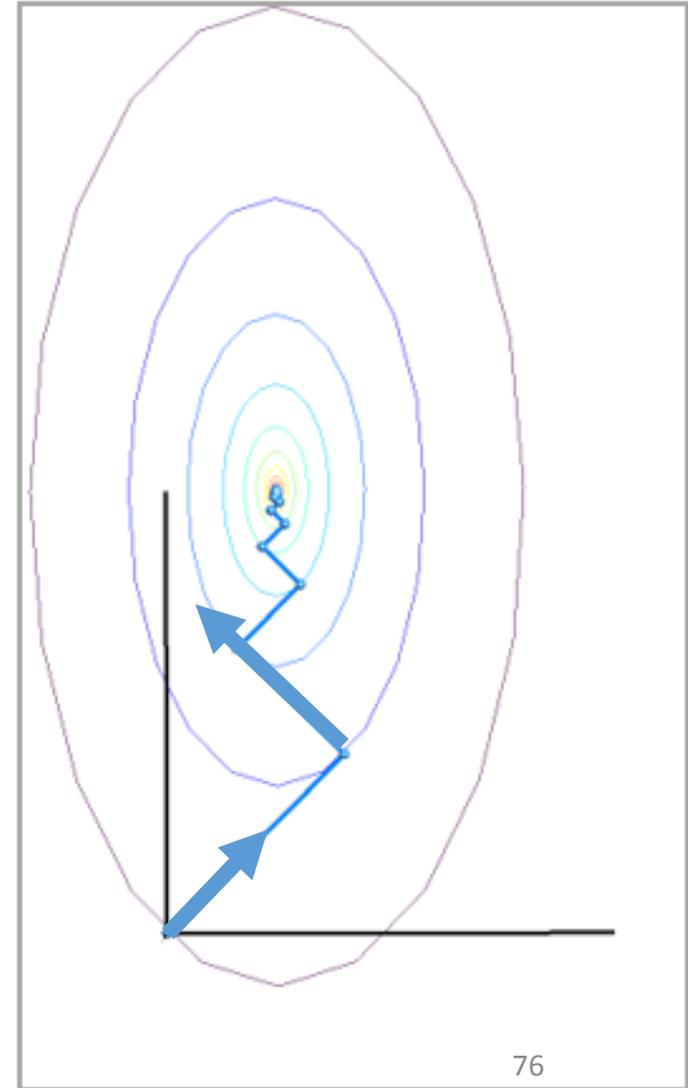
On va factoriser les
boucles différemment

Conjugaison: algorithme

- On choisit n vecteurs indépendants $\{r^{(k)}\}$
- Initialiser $x^{(0)} = 0$
- Pour chaque dimension k
 - // construction de la base
 - $d^{(k)}$ reçoit $r^{(k)}$ moins sa M -projection sur les $d^{(i)}$ précédents
 - // projection de x^* sur la base
 - On calcule le coefficient $\alpha^{(k)}$, en projetant Mx^* sur $Mr^{(k)}$
 - On définit $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$

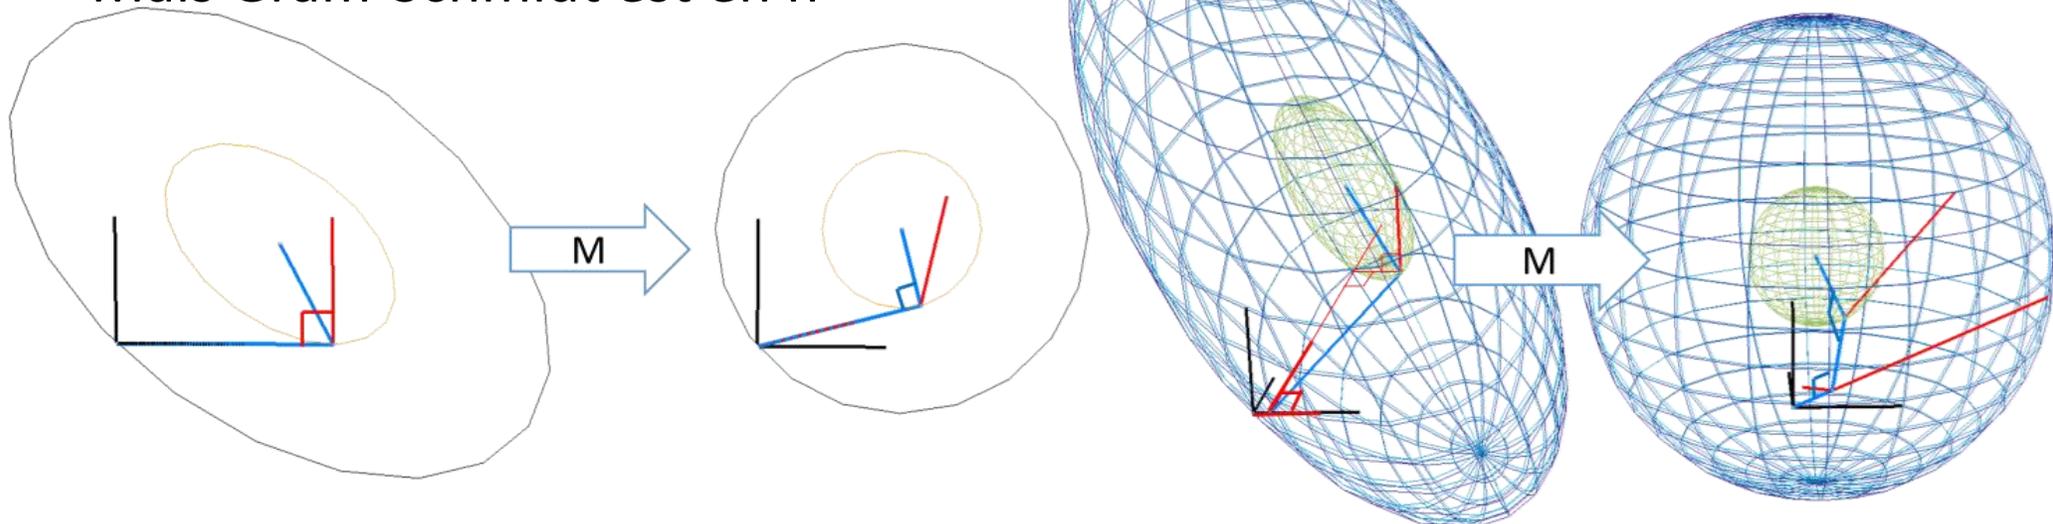
Descente de gradient: minimiser $x^T Ax - 2b^T x$

- Initialiser $x^{(0)} = 0$
- On itère sur k:
 - // calcul de la direction de descente
 - On calcule la direction $r^{(k)} = d^{(k)} = b - Ax^{(k)} = -\nabla f(x^{(i)})/2$
 - // déplacement de la solution
 - On calcule le pas de descente $\alpha^{(k)}$
 - On définit : $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$



Conjugaison: récapitulatif

- Algorithmme:
 - On construit une base orthogonale dans M
 - On projette la solution sur cette base
- Performances:
 - Méthode directe en n itérations
 - Mais Gram-Schmidt est en n^2



Plan

- *Introduction*
- *Le problème*
- *Résolution par gradient*
- *Résolution par conjugaison*
- **Gradient conjugué**
 - **Utiliser le gradient pour construire la base A-orthogonale**
 - **Une simplification bienvenue**
- Contemplation de performance pour des problèmes discrétisés
 - Laplacien 1D
 - Laplacien 2D

Gradient conjugué: idée de base

- Remarque:
 - Choisir les vecteurs r_i au hasard est sous-optimal
- Idée... et si on prenait $r^{(k)} = -\nabla f(x^{(k)})$?
- Conséquence:
 - On se rapproche plus vite de la solution au début (comme le gradient)
 - Mais on reste assuré de finir en n itérations (par la conjugaison)
 - En pratique, ça converge bien plus vite !

Conjugaison: algorithme

- On choisit n vecteurs indépendants $\{r^{(k)}\}$
- Initialiser $x^{(0)} = 0$
- Pour tout k :
 - // construction de la base
 - On retire à $r^{(k)}$ sa projection sur les vecteurs précédents
 - // projection de x^* sur la base
 - On calcule le coefficient $\alpha^{(k)}$, en projetant Mx^* sur $Mr^{(k)}$
 - On définit $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$

Gradient conjugué : algorithme

- ~~On choisit n vecteurs indépendants $\{r^{(k)}\}$~~

- Initialiser $x^{(0)}, r^{(0)} = 0$

- Pour tout k:

- // construction de la base

- On retire à $r^{(k)}$ sa projection sur les vecteurs précédents

- // projection de x^* sur la base

- On calcule le coefficient $\alpha^{(k)}$, en projetant Mx^* sur $Mr^{(k)}$

- On définit $x^{(k+1)} = x^{(k)} + \alpha^{(k)} r^{(k)}$

On calcule la direction $r^{(k)} = d^{(k)} = b - Ax^{(k)} = -\nabla f(x^{(k)})/2$

Gradient conjugué

Adaptation directe	Adaptation optimisée
$x^{(0)} \leftarrow 0$ $r^{(0)} \leftarrow b - Ax^{(0)}$ $d^{(0)} \leftarrow r^{(0)}$ <p>Pour k de 0 à $n - 1$:</p> $\alpha^{(k)} \leftarrow \frac{b^\top d^{(k)}}{d^{(k)\top} Ad^{(k)}}$ $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} d^{(k)}$ $r^{(k+1)} \leftarrow b - Ax^{(k+1)}$ $\beta_i^{k+1} \leftarrow \frac{r^{(k+1)\top} Ad^{(i)}}{d^{(i)\top} Ad^{(i)}}, \forall i$ $d^{(k+1)} \leftarrow r^{(k+1)} - \sum_{i=0}^k \beta_i^{(k+1)} d^{(i)}$	$x^{(0)} \leftarrow 0$ $r^{(0)} \leftarrow b - Ax^{(0)}$ $d^{(0)} \leftarrow r^{(0)}$ <p>Pour k de 0 à $n - 1$:</p> $\alpha^{(k)} \leftarrow \frac{r^{(k)\top} r^{(k)}}{d^{(k)\top} Ad^{(k)}}$ $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} d^{(k)}$ $r^{(k+1)} \leftarrow r^{(k)} - \alpha^{(k)} Ad^{(k)}$ $\beta^{(k+1)} \leftarrow -\frac{r^{(k+1)\top} r^{(k+1)}}{r^{(k)\top} r^{(k)}}$ $d^{(k+1)} \leftarrow r^{(k+1)} - \beta^{(k+1)} d^{(k)}$

Gradient conjugué: final trick

Adaptation directe	Adaptation optimisée
$x^{(0)} \leftarrow 0$ $r^{(0)} \leftarrow b - Ax^{(0)}$ $d^{(0)} \leftarrow r^{(0)}$ <p>Pour k de 0 à $n - 1$:</p> $\alpha^{(k)} \leftarrow \frac{b^\top d^{(k)}}{d^{(k)\top} Ad^{(k)}}$ $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} d^{(k)}$ $r^{(k+1)} \leftarrow b - Ax^{(k+1)}$ $\beta_i^{k+1} \leftarrow \frac{r^{(k+1)\top} Ad^{(i)}}{d^{(i)\top} Ad^{(i)}}, \forall i$ $d^{(k+1)} \leftarrow r^{(k+1)} - \sum_{i=0}^k \beta_i^{(k+1)} d^{(i)}$	$x^{(0)} \leftarrow 0$ $r^{(0)} \leftarrow b - Ax^{(0)}$ $d^{(0)} \leftarrow r^{(0)}$ <p>Pour k de 0 à $n - 1$:</p> $\alpha^{(k)} \leftarrow \frac{r^{(k)\top} r^{(k)}}{d^{(k)\top} Ad^{(k)}}$ $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} d^{(k)}$ $r^{(k+1)} \leftarrow r^{(k)} - \alpha^{(k)} Ad^{(k)}$ $\beta^{(k+1)} \leftarrow -\frac{r^{(k+1)\top} r^{(k+1)}}{r^{(k)\top} r^{(k)}}$ $d^{(k+1)} \leftarrow r^{(k+1)} - \beta^{(k+1)} d^{(k)}$

Le gradient est naturellement orthogonal avec toutes les directions précédentes sauf la dernière

Gradient conjugué: final trick

Adaptation directe	Adaptation optimisée
$x^{(0)} \leftarrow 0$ $r^{(0)} \leftarrow b - Ax^{(0)}$ $d^{(0)} \leftarrow r^{(0)}$ <p>Pour k de 0 à $n - 1$:</p> $\alpha^{(k)} \leftarrow \frac{b^\top d^{(k)}}{d^{(k)\top} Ad^{(k)}}$ $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} d^{(k)}$ $r^{(k+1)} \leftarrow b - Ax^{(k+1)}$ $\beta_i^{k+1} \leftarrow \frac{r^{(k+1)\top} Ad^{(i)}}{d^{(i)\top} Ad^{(i)}}, \forall i$ $d^{(k+1)} \leftarrow r^{(k+1)} - \sum_{i=0}^k \beta_i^{(k+1)} d^{(i)}$	$x^{(0)} \leftarrow 0$ $r^{(0)} \leftarrow b - Ax^{(0)}$ $d^{(0)} \leftarrow r^{(0)}$ <p>Pour k de 0 à $n - 1$:</p> $\alpha^{(k)} \leftarrow \frac{r^{(k)\top} r^{(k)}}{d^{(k)\top} Ad^{(k)}}$ $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} d^{(k)}$ $r^{(k+1)} \leftarrow r^{(k)} - \alpha^{(k)} Ad^{(k)}$ $\beta^{(k+1)} \leftarrow -\frac{r^{(k+1)\top} r^{(k+1)}}{r^{(k)\top} r^{(k)}}$ $d^{(k+1)} \leftarrow r^{(k+1)} - \beta^{(k+1)} d^{(k)}$

Tant que $r^{(k)} > \epsilon$

Le gradient est naturellement orthogonal avec toutes les directions précédentes sauf la dernière

Gradient conjugué: final trick

- Grosso modo, la dérivée $(Ax-b)$ est linéaire donc quand une direction est annulée, elle le reste...
- La preuve par calcul est plus laborieuse qu'élégante
- Ca ne veut rien dire en 2D, et ce n'est pas simple en 3D
- On va essayer de s'en convaincre sur le cas du Laplacien 1D...

Plan

- *Introduction*
- *Le problème*
- *Résolution par gradient*
- *Résolution par conjugaison*
- *Gradient conjugué*
- **Contemplation de performance pour des problèmes discrétisés**
 - **Laplacien 1D**
 - **Laplacien 2D**

Gradient conjugué: Laplacien discretisé

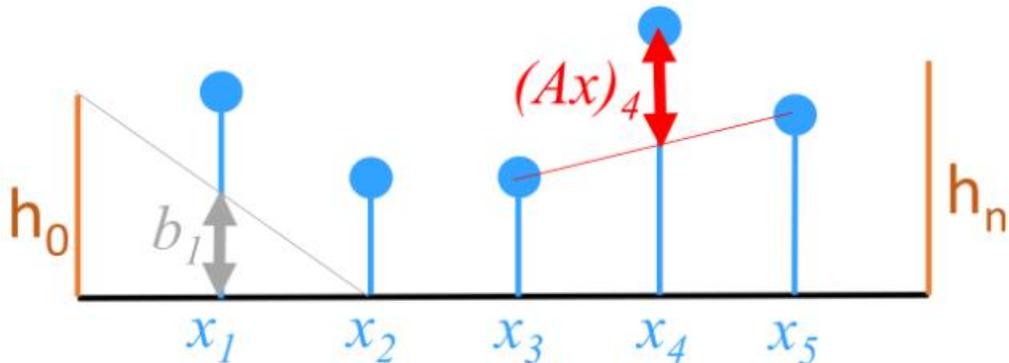
- Objectif:
 - Observer CG sur des problèmes plus intéressants
- Problème de Dirichlet: trouver une fonction f sur Ω
 - Dont le Laplacien est nul
 - Qui soit connue sur le bord de Ω
- Intérêt:
 - On obtient le même système pour différences finies, FEM linéaire, et minimisation L^2 d'un gradient
 - Méthode de lissage / terme de régulation extrêmement utilisés
 - Types de matrices creuses extrêmement commun

Gradient conjugué: Laplacien 1D/2D

- Discrétisation du Laplacien 1D/2D
 - On place une grille sur le domaine Ω
 - f est représentée par sa valeur aux nœuds de la grille (le vecteur x)
 - Le Laplacien est approximé par différences finie (la matrice A)
 - La valeur du Laplacien (le vecteur b) assure les contraintes du bord

Gradient conjugué: Laplacien 1D

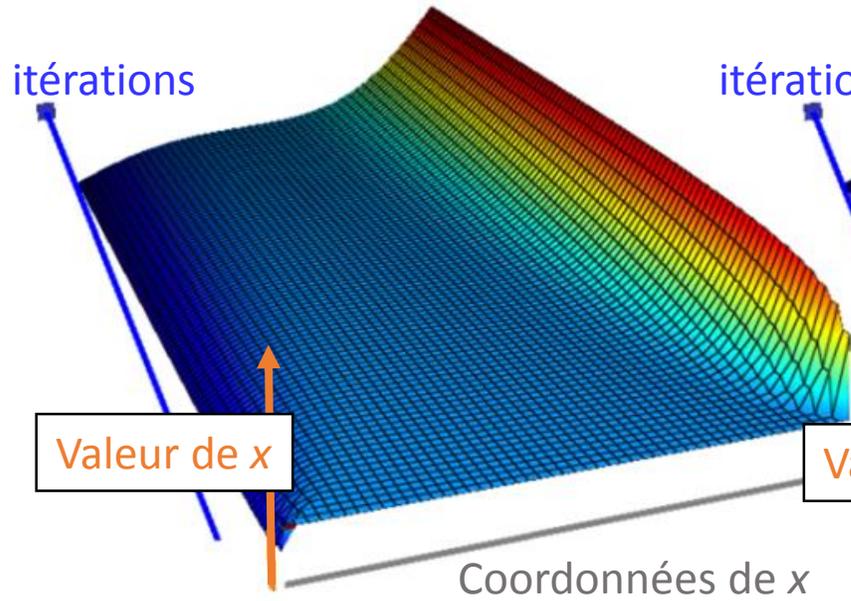
- Problème du Laplacien 1D:
 - $x_i = f(i)$
 - La $i^{\text{ème}}$ ligne de A est $-1/2 x_{i-1} + x_i - 1/2 x_{i+1}$
 - b représente des contraintes (au bord)



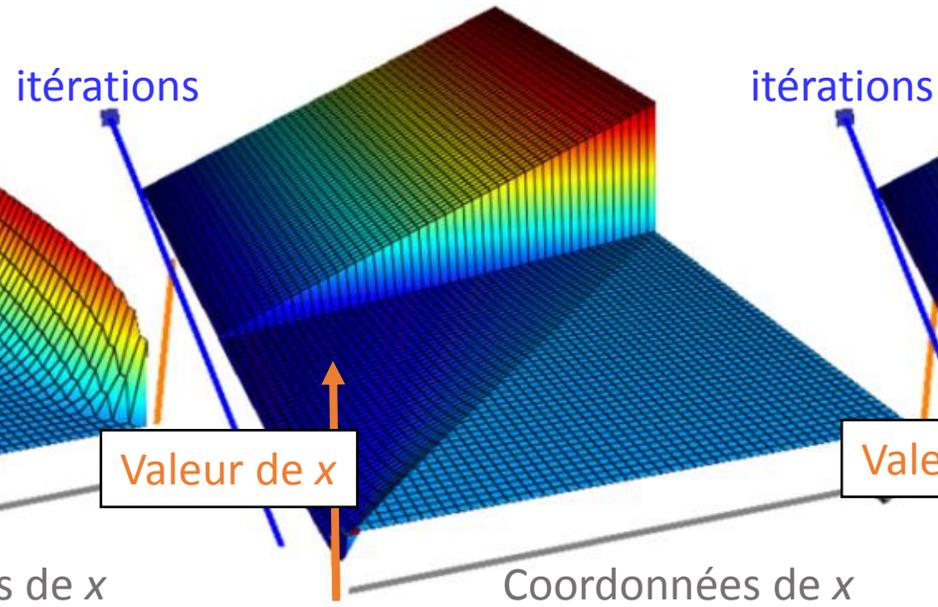
$$A = \begin{pmatrix} 1 & -1/2 & 0 & 0 & 0 \\ -1/2 & 1 & -1/2 & 0 & 0 \\ 0 & -1/2 & 1 & -1/2 & 0 \\ 0 & 0 & -1/2 & 1 & -1/2 \\ 0 & 0 & 0 & -1/2 & 1 \end{pmatrix}, b = \begin{pmatrix} h_0/2 \\ 0 \\ 0 \\ 0 \\ h_n/2 \end{pmatrix}$$

Laplacien 1D

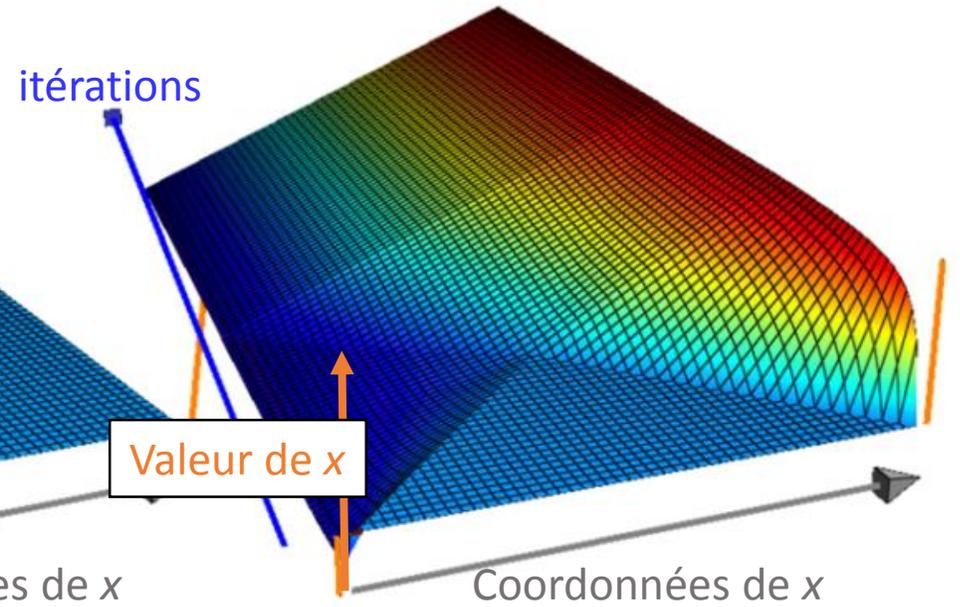
Gradient



Conjugaison

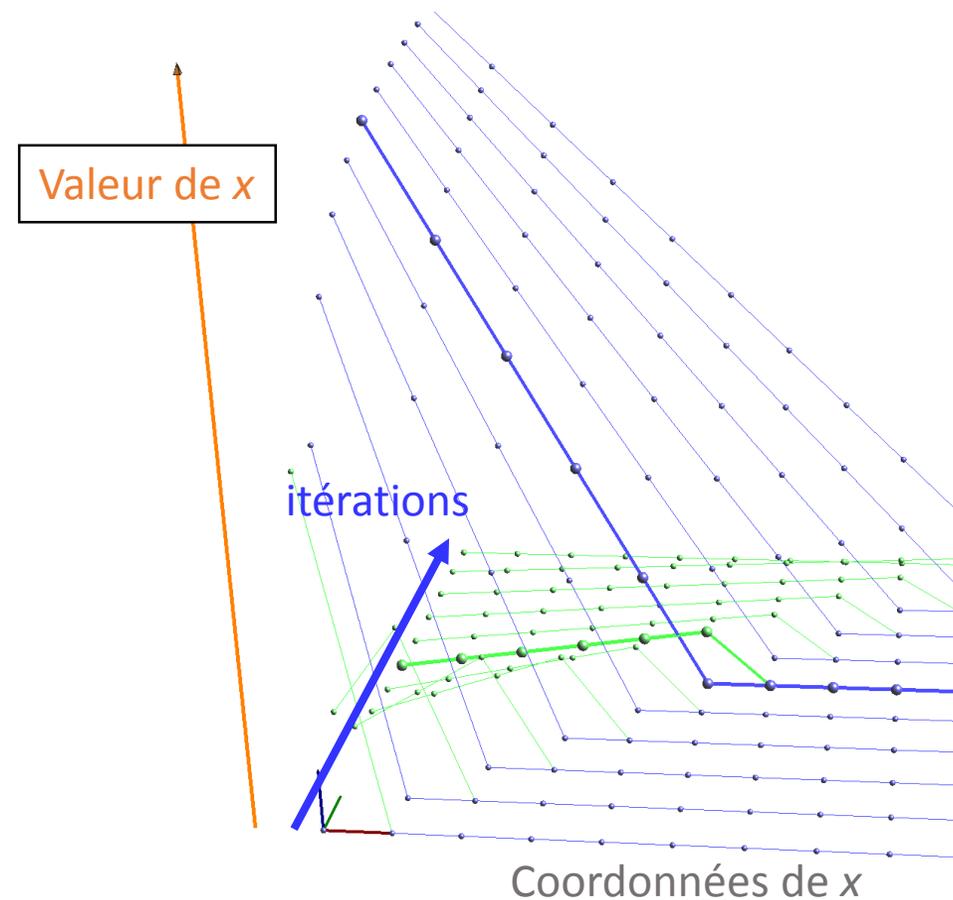
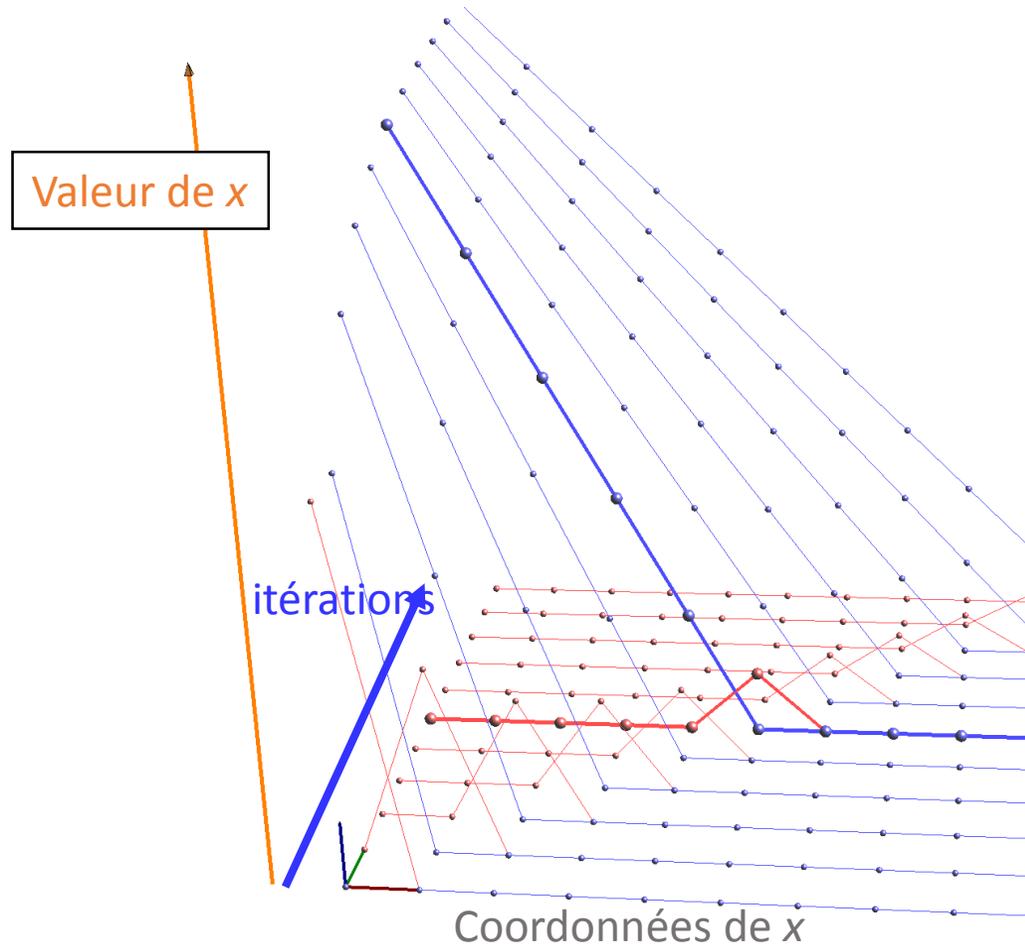


CG



Gradient conjugué: Laplacien 1D

- Final trick ?



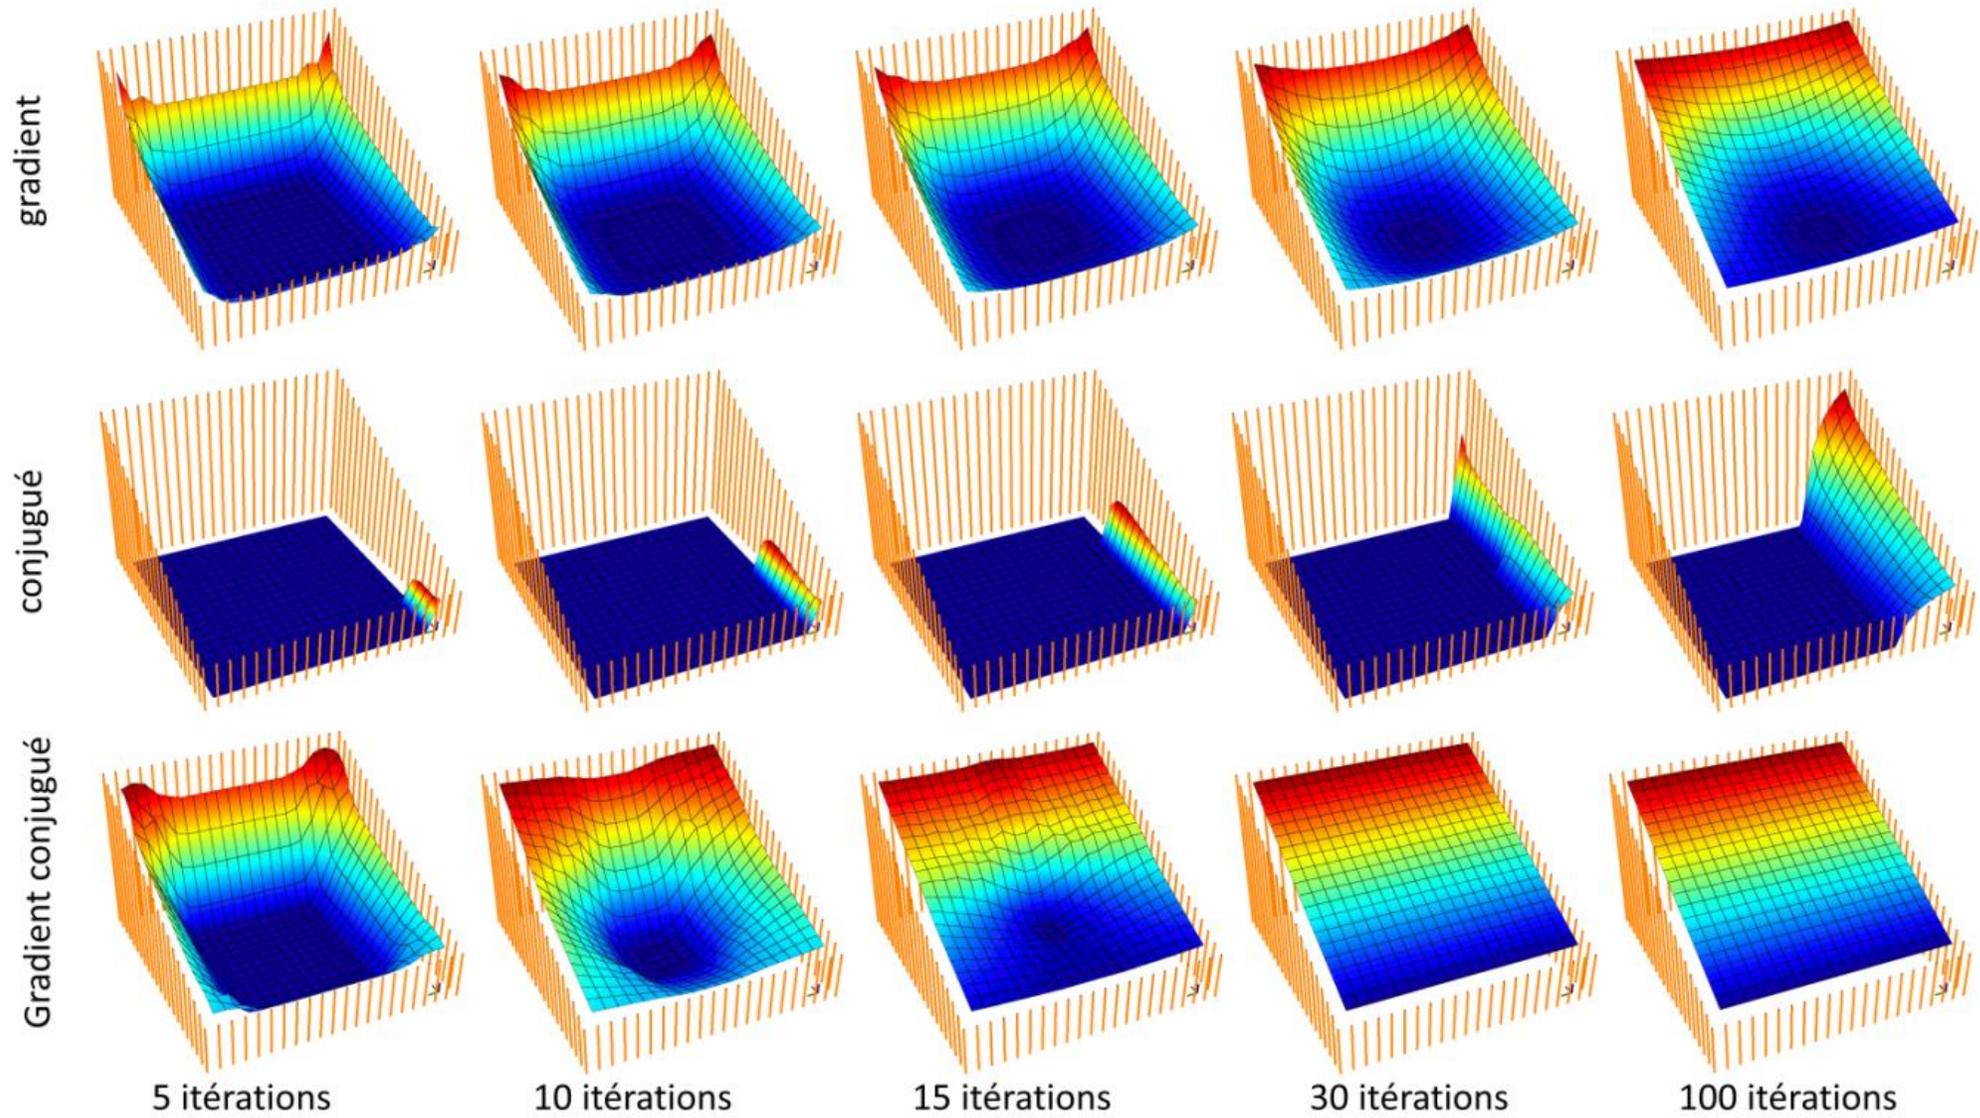
Gradient conjugué: Laplacien 2D

- Problème du Laplacien 2D:

- $x_k = f(i,j)$ avec $i,j = k \text{ mod } n, k / n$
- La $k^{\text{ème}}$ ligne de A est $f(i,j) - 1/4 (f(i-1,j)+ f(i+1,j)+ f(i,j-1)+ f(i,j+1))$
- b représente des contraintes (au bord)

$$\begin{bmatrix}
 4 & -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 -1 & 4 & -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & -1 & 4 & -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & -1 & 4 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 -1 & 0 & 0 & 0 & 4 & -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & -1 & 0 & 0 & -1 & 4 & -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & -1 & 0 & 0 & -1 & 4 & -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & -1 & 0 & 0 & -1 & 4 & 0 & 0 & 0 & -1 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & 4 & -1 & 0 & 0 & -1 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & 4 & -1 & 0 & 0 & -1 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & 4 & -1 & 0 & 0 & -1 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & 4 & 0 & 0 & -1 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & 4 & -1 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & 4 & -1 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & 4 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 4
 \end{bmatrix}$$

Laplacien 2D



Conclusion

- A retenir --- culture générale:
 - CG est extrêmement simple à implémenter
 - Utilisé comme brique de base de l'optimisation numérique (FEM, LS, pbs non linéaires, A non sym. def. +, CG pré-conditionné, etc.)
- A retenir --- techniquement:
 - On peut séparer le « gradient » du « conjugué »
 - On sait calculer des produits scalaires dans $M = \sqrt{A}$
 - Le gradient est déjà orthogonal avec les précédents
- En pratique:
 - Pour des problèmes discrétisés, chaque itération découvre un peu plus de domaine.
 - le nombre d'itérations doit permettre aux contraintes de « se voir ».