

# Appunti di Algebra Lineare Numerica

Mario Putti

Dipartimento di Metodi e Modelli Matematici  
per le Scienze Applicate

25 ottobre 2012

# Indice

<b>1</b>	<b>Introduzione</b>	<b>3</b>
<b>2</b>	<b>Riassunto di Algebra Lineare</b>	<b>3</b>
2.1	Spazi vettoriali, vettori linearmente dipendenti, basi . . . . .	7
2.1.1	Ortogonalità tra vettori e sottospazi . . . . .	9
2.2	Autovalori ed autovettori . . . . .	10
2.3	Norme di vettori e di matrici . . . . .	13
<b>3</b>	<b>Metodi del Gradiente per la soluzione di sistemi lineari</b>	<b>16</b>
3.1	Forme quadratiche . . . . .	17
3.2	Caso simmetrico $A = A^T$ . . . . .	20
3.2.1	Metodo del gradiente (o della discesa più ripida o dello <i>steepest descent</i> ) .	22
3.2.2	Convergenza di SD . . . . .	27
3.2.3	Il metodo del gradiente coniugato . . . . .	30
3.2.4	Convergenza di CG . . . . .	37
3.2.5	Precondizionamento di CG: Metodo PCG . . . . .	39
3.2.6	Implementazione all'elaboratore del PCG . . . . .	41
3.2.7	Metodo delle correzioni residue . . . . .	42
3.2.8	Esempi di applicazione . . . . .	43
3.2.9	Implementazione pratica del metodo PCG . . . . .	45
3.2.10	Calcolo del preconditionatore . . . . .	50

# 1 Introduzione

## 2 Riassunto di Algebra Lineare

Un numero (scalare) intero, reale o complesso sarà in genere indicato da una lettera minuscola dell'alfabeto greco, per esempio:

$$\alpha \in \mathbb{I} \quad \beta \in \mathbb{R} \quad \alpha \in \mathbb{C}.$$

Un vettore, definito come una  $n$ -upla ordinata di numeri (e.g. reali), sarà indicato con una lettera minuscola dell'alfabeto inglese, usando le seguenti notazioni del tutto equivalenti:

$$x \in \mathbb{R}^n \quad x = \begin{bmatrix} x_1 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{bmatrix} \quad x = \{x_i\}.$$

Il numero  $x_i \in \mathbb{R}$  è chiamato la componente  $i$ -esima del vettore  $x$ .

Una matrice, definita da una tabella di numeri (e.g. reali) caratterizzata da  $n$  righe e  $m$  colonne, sarà indicata da una lettera maiuscola dell'alfabeto inglese, usando le seguenti notazioni del tutto equivalenti:

$$A_{[n \times m]} \quad A = \begin{bmatrix} a_{11} & \dots & a_{1m} \\ \cdot & \dots & \\ \cdot & \dots & \\ \cdot & \dots & \\ a_{n1} & \dots & a_{nm} \end{bmatrix} \quad A = \{a_{ij}\}.$$

Il numero  $a_{ij} \in \mathbb{R}$  è chiamato l'elemento  $ij$ -esimo della matrice  $A$ . In realtà noi utilizzeremo quasi esclusivamente matrici quadrate, per cui in genere si avrà  $m = n$ . Si noti che un vettore può essere considerato come una matrice avente una colonna e cioè  $m = 1$ . Per convenzione (nostra) un vettore è quindi sempre un vettore colonna. Tuttavia, quando si parlerà di matrici o di vettori si farà sempre riferimento alle notazioni precedentemente definite. Tutte le proprietà che seguono sono ovviamente valide per vettori e matrici.

**Somma di matrici.** La matrice somma di due matrici della stessa dimensione è definita come la matrice che si ottiene sommando ordinatamente le componenti, o in formula, date  $A, B, C \in \mathbb{R}^{n \times m}$ :

$$C = A \pm B := \{a_{ij} \pm b_{ij}\}.$$

**Prodotto di una matrice per uno scalare.** Il prodotto tra uno scalare e una matrice o un vettore è definito per componenti:

$$\alpha A = \{\alpha a_{ij}\}.$$

**Matrice trasposta.** La matrice  $A^T$  si chiama la matrice trasposta di  $A$  e si ottiene scambiando le righe con le colonne:

$$A = \{a_{ij}\} \quad A^T = \{a_{ji}\}.$$

**Matrice nulla.** La matrice nulla è quella matrice che ha tutte le componenti uguali a zero, ed è l'elemento neutro della somma:

$$A = 0 \iff a_{ij} = 0 \quad i, j = 1, \dots, n.$$

**Matrice identità.** La matrice identità  $I$  è quella matrice quadrata che ha le componenti diagonali uguali a uno e tutte le altre nulle:

$$I_{[n \times n]} \quad I := \begin{bmatrix} 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \cdot & \cdot & \dots & \cdot & \cdot \\ 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & \dots & 0 & 1 \end{bmatrix}.$$

**Matrice positiva o non negativa.** Una matrice è detta positiva (o non negativa)<sup>1</sup> se tutti i suoi elementi sono positivi o nulli con almeno un elemento positivo:

$$A > 0 \Rightarrow a_{ij} \geq 0.$$

**Prodotto scalare tra due vettori.** Si definisce prodotto scalare tra due vettori la somma dei prodotti delle componenti omonime:

$$x^T y = \langle x, y \rangle = x \cdot y := \sum_{i=1}^n x_i y_i.$$

Altre notazioni che useremo per il prodotto scalare sono:

$$\langle x, y \rangle \quad \text{oppure} \quad x \cdot y.$$

---

<sup>1</sup>La proprietà di una matrice di essere *positiva* non va confusa con la proprietà di essere *definita positiva* che verrà definita più avanti.

In modo più formale, dato uno spazio vettoriale  $V \subset \mathbb{C}^n$  (o  $\mathbb{R}^n$ ), il prodotto scalare (o interno) tra due elementi  $x, y \in V$ , indicato con  $\langle x, y \rangle$ , è la mappa:

$$\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{C} \text{ (o } \mathbb{R})$$

che soddisfa alle seguenti proprietà definenti:

- (Simmetria Hermitiana)  $\langle x, y \rangle = \overline{\langle y, x \rangle}$  dove  $\overline{(\cdot)}$  indica l'operazione di coniugazione complessa;
- (linearità)  $\langle \alpha x + \beta y, z \rangle = \alpha \langle x, z \rangle + \beta \langle y, z \rangle$ ;
- (positività)  $\langle x, x \rangle > 0$  per ogni  $x \in \mathbb{C}^n$  (o  $\mathbb{R}^n$ ) e  $\langle x, x \rangle = 0$  solo per  $x = 0$ .

**Prodotto tra matrici.** Il prodotto tra due matrici, detto anche prodotto righe-colonne, è dato da quella matrice che ha per componenti i prodotti scalari tra le righe della prima matrice e le colonne della seconda matrice pensate come vettore:

$$A_{[n \times p]} = \{a_{ij}\} \quad B_{[p \times m]} = \{b_{ij}\} \quad C_{[n \times m]} = \{c_{ij}\}$$

$$C = AB \quad c_{ij} := \sum_{k=1, p} a_{ik} b_{kj}, \quad i = 1, \dots, n \quad j = 1, \dots, m.$$

Il prodotto matrice vettore è un caso particolare del prodotto tra matrice, considerando il vettore come una matrice  $n \times 1$ . E' facile quindi verificare che il prodotto scalare gode della seguente proprietà<sup>2</sup>:

$$\langle x, Ay \rangle = \langle A^T x, y \rangle \quad \langle Ax, y \rangle = \langle x, A^T y \rangle.$$

**Determinante di una matrice.** Data una matrice quadrata  $A$ , il suo determinante determinante,  $\det A$ , è definito come lo scalare dato dalla somma di tutti prodotti ottenuti prendendo come fattore un elemento di ciascuna riga ed uno di ciascuna colonna:

$$\det A := \sum \pm a_{1, i_1} a_{2, i_2} \cdots a_{n, i_n},$$

dove  $i_1, i_2, \dots, i_n$  sono permutazioni distinte dei primi  $n$  numeri interi e il segno è dato dall'ordine della permutazione.

**Inversa di una matrice quadrata.** Data una matrice quadrata  $A_{[n \times n]}$  se  $\det A \neq 0$ , si definisce matrice inversa  $A^{-1}$ , se esiste, la matrice tale che:

$$A^{-1}A = AA^{-1} = I.$$

---

<sup>2</sup>Ovviamente il prodotto scalare è commutativo e cioè:  $\langle x, Ay \rangle = \langle Ay, x \rangle$  ovvero  $x^T Ay = (Ay)^T x$

**Matrice singolare.** Una matrice è singolare se la sua inversa non esiste. Una matrice singolare ha determinante nullo e viceversa.

**Matrice unitaria o ortogonale.** Una matrice si dice unitaria o ortogonale se:

$$U^T = U^{-1}.$$

**Proprietà delle operazioni tra matrici quadrate.**

1.  $AB \neq BA$  (Le matrici per le quali la proprietà commutativa vale sono dette *commutative*.)
2.  $A + B = B + A$
3.  $(A + B) + C = A + (B + C)$
4.  $(AB)C = A(BC)$
5.  $A(B + C) = AB + AC$ ;  $(A + B)C = AC + BC$
6.  $(AB)^T = B^T A^T$
7.  $(AB)^{-1} = B^{-1} A^{-1}$
8.  $(A^T)^{-1} = (A^{-1})^T$ .

**Matrice simmetrica.** Una matrice si dice simmetrica se è uguale alla sua trasposta:

$$A = A^T;$$

si dice antisimmetrica se è opposta alla sua trasposta:

$$A = -A^T.$$

Ogni matrice può essere decomposta secondo la somma della sua parte simmetrica e della sua parte antisimmetrica:

$$A = \frac{1}{2}(A + A^T) + \frac{1}{2}(A - A^T).$$

**Matrice definita positiva.** Una matrice  $A_{[n \times n]}$  si dice definita positiva (semi definita positiva) se:

$$x^T A x = \langle x, Ax \rangle > 0 \quad (\langle x, Ax \rangle \geq 0).$$

**Matrice di tipo M o M-matrice.** Una matrice è detta di tipo M se gode delle seguenti proprietà:

1. è non singolare;
2. tutti gli elementi della diagonale sono positivi;
3. gli elementi extra diagonali sono negativi o nulli.

Una M-matrice ha la proprietà che la sua inversa è positiva.

## 2.1 Spazi vettoriali, vettori linearmente dipendenti, basi

**Spazio vettoriale.** Uno *spazio vettoriale*  $V$  (sul campo scalare  $\mathbb{R}$ ) è un insieme di vettori dove sono definite l'operazione di addizione tra due vettori e di moltiplicazione tra uno scalare (reale) e un vettore. Tali operazioni devono soddisfare le seguenti proprietà definenti<sup>3</sup> per ogni  $x, y \in V$  e per ogni  $\alpha, \alpha_1, \alpha_2 \in \mathbb{R}$ :

1.  $x + y = y + x$ ;
2.  $x + (y + z) = (x + y) + z$ ;
3. esiste un unico elemento nullo dell'addizione (il vettore "zero") tale che  $x + 0 = 0 + x = x$ ;
4. per ogni  $x$  esiste un unico vettore  $-x$  tale che  $x + (-x) = 0$ ;
5.  $1x = x$ ;
6.  $(\alpha_1\alpha_2)x = \alpha_1(\alpha_2x)$ ;
7.  $\alpha(x + y) = \alpha x + \alpha y$ ;
8.  $(\alpha_1 + \alpha_2)x = \alpha_1x + \alpha_2x$ .

Per esempio, sono spazi vettoriali:

- $\mathbb{R}^k$ , l'insieme di tutti i vettori a  $k$  componenti con le classiche operazioni di somma e prodotto per uno scalare;
- $\mathbb{R}^\infty$  l'insieme dei vettori a infinite componenti (di nuovo con le stesse operazioni di prima);
- lo spazio delle matrici  $m \times n$ ; in questo caso i vettori sono matrici e le operazioni sono quelle definite nei paragrafi precedenti<sup>4</sup>;

---

<sup>3</sup>Si noti che tali proprietà agiscono in modo tale che la maggior parte delle operazioni elementari che generalmente facciamo sul campo degli scalari possano essere fatte anche su tale spazio

<sup>4</sup>questo spazio è in qualche modo simile a  $\mathbb{R}^{mn}$

- lo spazio delle funzioni continue  $f(x)$  definite nell'intervallo  $0 \leq x \leq 1$  (ad esempio appartengono a tale spazio  $f(x) = x^2$  e  $g(x) = \sin(x)$  per le quali si ha che  $(f + g)(x) = x^2 + \sin(x)$  e ogni multiplo tipo  $3x^2$  oppure  $-\sin(x)$  sono ancora nello spazio). I vettori in questo caso sono funzioni quindi con “dimensione” infinita.

**Sottospazio vettoriale.** Un sottospazio  $S \subset V$  dello spazio vettoriale  $V$  è un sottoinsieme di  $V$  che soddisfa alle relazioni:

1. per ogni  $x, y \in S$  la loro somma  $z = x + y$  è ancora un elemento di  $S$ ;
2. il prodotto di ogni  $x \in S$  per uno scalare  $\alpha \in \mathbb{R}$  è un elemento di  $S$ :  $z = \alpha x, z \in S$ .

Si dice anche che il sottospazio  $S$  è un sottoinsieme di  $V$  “chiuso” rispetto alle operazioni di addizione e moltiplicazione per uno scalare. Un esempio di un sottospazio vettoriale è un piano, che è affine allo spazio vettoriale  $\mathbb{R}^2$  se pensato isolato ma che è contenuto in  $\mathbb{R}^3$ .

**Indipendenza lineare.** Si dice che  $k$  vettori  $v_k$  sono *linearmente indipendenti* se tutte le loro combinazioni lineari (eccetto quella triviale a coefficienti nulli) sono non-nulle:

$$\alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_k v_k \neq 0 \quad \text{escludendo il caso} \quad \alpha_1 = \alpha_2 = \dots = \alpha_k = 0.$$

In caso contrario, i vettori si dicono linearmente dipendenti.

Si ha la seguente proprietà: un insieme di  $k$  vettori appartenenti a  $\mathbb{R}^m$  devono necessariamente essere linearmente dipendenti se  $k > m$ .

**Span.** Se uno spazio vettoriale  $V$  è formato da tutte le combinazioni lineari dei vettori  $v_1, v_2, \dots, v_n$ , si dice che questi vettori “generano” lo spazio  $V$  e si scrive:

$$V = \text{span}\{v_1, v_2, \dots, v_n\}.$$

In altre parole ogni altro vettore di  $V$  può essere scritto come combinazione lineare dei vettori generatori:

$$w \in V \Rightarrow w = \alpha_1 v_1 + \dots + \alpha_n v_n = \sum_{i=1}^n \alpha_i v_i.$$

**Base.** Una *base* dello spazio vettoriale  $V$  è l'insieme (minimale) dei vettori che:

1. sono linearmente indipendenti;
2. generano lo spazio  $V$ .

**Dimensione di uno spazio vettoriale.** Le basi di uno spazio vettoriale sono infinite. Ciascuna base contiene lo stesso numero di vettori. Tale numero è chiamato *dimensione* dello spazio  $V$ .

Ad esempio, una base dello spazio tri-dimensionale  $\mathbb{R}^3$  è costituita dall'insieme dei vettori coordinate  $e_1, e_2, e_3$ , dove  $e_1 = (1, 0, 0)^T$ ,  $e_2 = (0, 1, 0)^T$ ,  $e_3 = (0, 0, 1)^T$ , con ovvia estensione alla generica dimensione  $n$  e si scrive:

$$n = \dim(V).$$

Ogni insieme di vettori di  $V$  linearmente dipendenti può essere esteso ad una base (se necessario aggiungendo opportuni vettori). Viceversa, ogni insieme di vettori generatori di  $V$  può essere ridotto ad una base (se necessario eliminando dei vettori).

### 2.1.1 Ortogonalità tra vettori e sottospazi

Introduciamo il concetto di lunghezza di un vettore  $x$  che indichiamo con  $\|x\|$  (si veda più avanti il paragrafo sulle norme di vettori). Visivamente, in  $\mathbb{R}^2$ , scomponendo il vettore nelle sue componenti lungo gli assi principali,  $x = (x_1, x_2)$ , si può definire la lunghezza usando il teorema di Pitagora, da cui si ha immediatamente:

$$\|x\|^2 = x_1^2 + x_2^2,$$

e per estensione diretta a  $\mathbb{R}^n$ :

$$\|x\|^2 = x_1^2 + x_2^2 + \dots + x_n^2.$$

**Vettori ortogonali.** Sempre in  $\mathbb{R}^2$ , è intuitivo dire che due vettori  $x$  e  $y$  sono ortogonali se formano un tra loro un angolo rettangolo, ovvero usando il teorema di Pitagora, se (si veda Figura 1):

$$\|x\|^2 + \|y\|^2 = \|x - y\|^2. \tag{1}$$

Dalla precedente, scritta per componenti, si verifica immediatamente che dovranno essere nulli i prodotti incrociati (somma dei doppi prodotti), da cui si ottiene la definizione generale di ortogonalità tra vettori di  $\mathbb{R}^n$ :

$$x^T y = \langle x, y \rangle = 0. \tag{2}$$

Tale quantità, il prodotto scalare, è anche chiamato prodotto interno. Si dimostra immediatamente che se  $n$  vettori sono mutuamente ortogonali, allora essi sono linearmente indipendenti.

**Spazi ortogonali.** due sottospazi  $V$  e  $W$  di  $\mathbb{R}^n$  sono ortogonali se ogni vettore  $v \in V$  è ortogonale a ogni vettore  $w \in W$ .




Figura 1: **A sinistra:** vettori ortogonali:  $x$  e  $y$  sono ortogonali. Applicando il Teorema di Pitagora alla coppia di vettori  $x$  e  $-y$  che formano i cateti di un triangolo rettangolo e scrivendo l'uguaglianza (1) si ricava immediatamente che deve essere valida la (2). **A destra:** proiezione ortogonale del sottospazio  $V$  (formato da un solo vettore) nel sottospazio  $W$  (formato dal piano).

**Complemento ortogonale.** Dato un sottospazio  $V \in \mathbb{R}^n$ , lo spazio di tutti i vettori ortogonali a tutti i vettori di  $V$  si dice complemento ortogonale di  $V$  e si denota con  $V^\perp$ .

**Proiezione ortogonale.** Se  $V$  e  $W$  sono sottospazi di  $\mathbb{R}^n$ , una qualsiasi delle seguenti proprietà li caratterizza come ortogonali:

1.  $W = V^\perp$  ( $W$  consiste di tutti i vettori ortogonali a  $V$ );
2.  $V = W^\perp$  ( $V$  consiste di tutti i vettori ortogonali a  $W$ );
3.  $V$  e  $W$  sono ortogonali e  $\dim V + \dim W = n$ .

La proiezione ortogonale di un vettore  $x \in V_1$  lungo la direzione del vettore  $y \in V_2$  è data dal vettore:

$$y = \langle x, y \rangle y = yy^T v = Pv$$

La matrice  $P$  è detta matrice di proiezione.

Ogni vettore  $x \in \mathbb{R}^n$  può essere scritto come la somma di due vettori  $v \in V$  e  $w \in W$ . Queste componenti  $v$  e  $w$  sono ortogonali e si chiamano le proiezioni ortogonali di  $x$  in  $V$  e  $W$ .

## 2.2 Autovalori ed autovettori

Uno scalare  $\lambda$  ed un vettore  $u \neq 0$  si dicono rispettivamente autovalore ed autovettore di una matrice quadrata  $A$  se soddisfano alla seguente relazione:

$$Au = \lambda u.$$

Si ricava facilmente che

$$(A - \lambda I)u = 0 \quad \Rightarrow \quad P(\lambda) = \det(A - \lambda I) = 0.$$

Dalla prima delle precedenti si vede immediatamente che gli autovettori sono definiti a meno di una costante moltiplicativa. Dalla seconda invece si vede che gli autovalori sono le radici di un polinomio di grado  $n$  a coefficienti reali (se gli elementi di  $A$  sono reali). Da quest'ultima osservazione e usando le proprietà delle radici di un polinomio si ricavano le seguenti proprietà degli autovalori:

$$\lambda \in \mathbb{C} \quad \sum_{i=1}^n \lambda_i = \sum_{i=1}^n a_{ii} = \text{Tr } A \quad \prod_{i=1}^n \lambda_i = \det A \quad A^m u = \lambda^m u.$$

Se esiste  $\lambda = 0$ , allora la matrice è singolare ( $\det A = 0$ ). Secondo una comune notazione, tutti gli autovalori di una matrice  $A$  si indicano con  $\lambda(A)$ . Si dice anche che  $\lambda(A)$  è lo spettro di  $A$ . Molto spesso si ordinano gli autovalori in maniera tale che

$$|\lambda_1| \geq |\lambda_2| \geq \dots \geq |\lambda_n|,$$

per cui in generale la notazione  $\lambda_1(A)$  indica l'autovalore di  $A$  massimo in modulo, mentre  $\lambda_n(A)$  indica l'autovalore minimo (in modulo). Il modulo di  $\lambda_1(A)$  è anche detto raggio spettrale di  $A$  e si indica con  $\rho(A) = |\lambda_1(A)|$ .

**Trasformazioni di similitudine.** Si dice che una matrice  $B$  è ottenuta da  $A$  tramite una trasformazione di similitudine se esiste una matrice non singolare  $S$  tale che:

$$B = S^{-1}AS.$$

Si vede che  $B$  e  $A$  hanno gli stessi autovalori mentre gli autovettori sono scalati dalla matrice  $S$ . Infatti:

$$\det(B - \lambda I) = \det(S^{-1}AS - \lambda S^{-1}S) = \det S^{-1} \det(A - \lambda I) \det S = \det(A - \lambda I),$$

e quindi

$$\begin{aligned} Bu &= \lambda u & \Rightarrow & \quad S^{-1}ASu = \lambda u \\ Av &= \lambda v & \Rightarrow & \quad ASu = \lambda Su & \Rightarrow v = Su. \end{aligned}$$

E' facile verificare che

$$\lambda(A) = \lambda(A^T) \quad \lambda(AB) = \lambda(A^{-1}ABA) = \lambda(BA).$$

E' facile anche verificare che se  $A$  è definita positiva, allora  $\lambda_i > 0$   $i = 1, \dots, n$ .

Se si indica con  $D$  la matrice (diagonale) formata dagli elementi di  $A$  sulla diagonale e con tutti gli elementi extradiagonali nulli:

$$D = \{d_{ij}\} \quad d_{ij} = \begin{cases} a_{ii}, & \text{se } i = j, \\ 0, & \text{se } i \neq j. \end{cases} ;$$

si ha allora:

$$\lambda(D^{-1}A) = (\text{ponendo } S = D^{-\frac{1}{2}}) = \lambda(D^{\frac{1}{2}}D^{-1}AD^{-\frac{1}{2}}) = \lambda(D^{-\frac{1}{2}}AD^{-\frac{1}{2}}).$$

Inoltre, la matrice  $B = D^{-\frac{1}{2}}AD^{-\frac{1}{2}}$  è definita positiva se lo è  $A$ . Infatti:

$$\langle x, Bx \rangle = \langle x, D^{-\frac{1}{2}}AD^{-\frac{1}{2}}x \rangle = \langle D^{-\frac{1}{2}}x, AD^{-\frac{1}{2}}x \rangle > 0.$$

### Proprietà delle matrici simmetriche e diagonalizzazione.

- Gli autovalori ed autovettori di una matrice  $A$  simmetrica sono tutti reali.
- Gli autovalori ed autovettori di una matrice  $A$  antisimmetrica sono immaginari.
- Se  $A$  è definita positiva,  $\lambda_i > 0$  per ogni  $i = 1, \dots, n$ .
- Una matrice  $A$  si dice diagonalizzabile se esiste una matrice  $U$  non singolare tale che

$$\Lambda = U^{-1}AU$$

è una matrice diagonale. In questo caso è facile vedere che  $\lambda_{ii} = \lambda_i$  sono gli autovalori di  $A$  e le colonne di  $U$  sono gli autovettori.

- Se  $A$  è simmetrica e definita positiva, è diagonalizzabile e la matrice  $U$  è unitaria (o ortogonale) ( $U^{-1} = U^T$ ). Una matrice unitaria ha le colonne ortogonali tra di loro, per cui

$$\langle u_i, u_j \rangle = \begin{cases} \neq 0, & \text{se } i = j, \\ = 0, & \text{se } i \neq j. \end{cases} ;$$

e poichè in questo caso gli  $u_i$  sono autovettori di  $A$ , e sono definiti a meno di una costante moltiplicativa, si ha:

$$\langle u_i, u_j \rangle \begin{cases} = 1, & \text{se } i = j, \\ = 0, & \text{se } i \neq j. \end{cases} .$$

Si può concludere gli autovettori di matrici diagonalizzabili formano una base eventualmente ortonormale per lo spazio vettoriale  $\mathbb{R}^n$ . Questo significa che tutti i vettori di  $\mathbb{R}^n$  possono essere espressi come combinazione lineare degli autovettori di  $A$ .

## 2.3 Norme di vettori e di matrici

**Norme di vettori.** Si definisce norma di un vettore  $x$  uno scalare reale che soddisfa alle seguenti relazioni:

1.  $\|x\| > 0$ ,  $\|x\| = 0$  se e solo se  $x = 0$ ;
2. dato  $\alpha \in \mathbb{R}$ ,  $\|\alpha x\| = |\alpha| \|x\|$ ;
3.  $\|x + y\| \leq \|x\| + \|y\|$ ;

Un esempio di norma di vettori generica è dato dalla norma- $p$ :

$$\|x\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{1/p};$$

per  $p = 2$  si ha la classica norma euclidea  $\|x\|_2 = \sqrt{\langle x, x \rangle}$ ; per  $p = \infty$  si ha la norma massima  $\|x\|_\infty = \max_i |x_i|$ , per  $p = 1$  si ha la norma assoluta  $\|x\|_1 = \sum_{i=1}^n |x_i|$ . Per  $p = 2$  vale la disuguaglianza di Schwarz:

$$\langle x, y \rangle \leq \|x\|_2 \|y\|_2.$$

Un'altra norma molto usata è la norma "energia", definita come il prodotto scalare tra il vettore  $x$  e il vettore  $Ax$ , dove la matrice  $A$  è una matrice simmetrica e definita positiva (se non lo fosse la proprietà 1 sopra non sarebbe soddisfatta):

$$\|x\|_A = \sqrt{\langle x, Ax \rangle}.$$

**Norme di matrici.** Si definisce norma di una matrice  $A$  uno scalare reale che soddisfa alle seguenti relazioni:

1.  $\|A\| > 0$ ,  $\|A\| = 0$  se e solo se  $A = 0$ ;
2. dato  $\alpha \in \mathbb{R}$ ,  $\|\alpha A\| = |\alpha| \|A\|$ ;
3.  $\|A + B\| \leq \|A\| + \|B\|$ ;
4.  $\|AB\| \leq \|A\| \|B\|$ ;

Esempi di norme di matrici:

- norma di Frobenius:  $\|A\|_2 = \sqrt{\text{Tr}(A^T A)} = \sqrt{\sum_{ij} |a_{ij}|^2}$ ;
- norma di Hilbert o norma spettrale:  $\|A\| = \sqrt{\rho A^T A} = \sqrt{|\lambda_1(A^T A)|}$ .

**Norme compatibili o indotte.** Si dice che la norma di matrice  $\|A\|$  è compatibile (o indotta da) con la norma di vettore  $\|x\|$  se:

$$\|A\| = \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|}.$$

Dimostriamo che la norma spettrale di matrice è compatibile con (indotta da) la norma euclidea di vettore. Infatti, data una matrice non singolare  $A \in \mathbb{R}^{n \times n}$ , si costruisce la matrice simmetrica e definita positiva  $H = A^T A$ . Essendo  $H$  diagonalizzabile, un generico vettore  $x \in \mathbb{R}^n$  può essere pensato come combinazione lineare degli autovettori  $u_i$  di  $H$ :

$$x = c_1 u_1 + c_2 u_2 + \dots + c_n u_n.$$

Poichè gli  $u_i$  sono ortonormali, si ottiene facilmente:

$$\begin{aligned} \langle x, Hx \rangle &= x^T Hx = (c_1 u_1 + c_2 u_2 + \dots + c_n u_n)^T H (c_1 u_1 + c_2 u_2 + \dots + c_n u_n) \\ &= \lambda_1 |c_1|^2 + \dots + \lambda_n |c_n|^2 \\ &\leq \lambda_1 (|c_1|^2 + \dots + |c_n|^2) = \lambda_1 \|x\|_2^2, \end{aligned}$$

e da questa:

$$\lambda_1(A^T A) \geq \frac{\langle Ax, Ax \rangle}{\|x\|_2^2} = \frac{\|Ax\|_2^2}{\|x\|_2^2}.$$

La dimostrazione si completa prendendo la radice quadrata della precedente espressione.

**Sistemi Lineari.** Data una matrice  $A$ , di dimensioni  $n \times n$  e non singolare, e un vettore  $b \in \mathbb{R}^n$ , si cerca il vettore  $x \in \mathbb{R}^n$  che soddisfa:

$$Ax = b.$$

La soluzione formale di tale sistema è data da:

$$x^* = A^{-1}b.$$

Non è ragionevole trovare tale vettore, o un'approssimazione di esso, utilizzando la formula precedente, essendo il calcolo dell'inversa  $A^{-1}$  molto oneroso<sup>5</sup>

In queste note si farà riferimento esclusivamente a metodi iterativi per la soluzione di sistemi lineari. In tali metodi si cerca di definire una successione di iterate (vettori)  $x_k$   $k > 0$  in maniera tale che

$$\lim_{k \rightarrow \infty} x_k = x^*. \tag{3}$$

---

<sup>5</sup>Il modo più semplice per calcolare l'inversa è quella di risolvere  $n$  sistemi lineari, con un costo computazionale molto elevato. Ci sono altri metodi per calcolare l'inversa, ma sempre con costo molto alto rispetto alla soluzione di un sistema lineare.

Uno schema iterativo verrà terminato in pratica molto prima che la condizione precedente sia verificata. In effetti, non conoscendo  $x^*$ , sarà impossibile calcolare tale limite. Di solito si definisce il residuo come:

$$r_k = b - Ax_k,$$

per cui la condizione di convergenza (3) si traduce immediatamente dicendo che il residuo deve tendere a zero. L'iterazione verrà quindi terminata non appena la norma (qualsiasi) del residuo non diventi minore di una soglia predeterminata, chiamata tolleranza. In molti casi è meglio sostituire questa condizione con una relativa; l'iterazione termina quando il residuo iniziale è diminuito di un fattore  $\tau$ :

$$\frac{\|r_k\|}{\|r_0\|} < \tau.$$

Definendo il vettore errore come la differenza tra la soluzione approssimata e la soluzione vera  $e_k = x_k - x^*$  si può ricavare una relazione tra residuo ed errore:

$$\frac{\|e_k\|}{\|e_0\|} \leq \kappa(A) \frac{\|r_k\|}{\|r_0\|}.$$

dove il numero  $\kappa(A) = \|A\| \|A^{-1}\|$  è chiamato il numero di condizionamento della matrice  $A$ . Infatti:

$$r_k = b - Ax_k = -Ae_k.$$

da cui, utilizzando norme matriciali compatibili:

$$\|e_k\| = \|A^{-1}Ae_k\| \leq \|A^{-1}\| \|Ae_k\| = \|A^{-1}\| \|r_k\|,$$

e:

$$\|r_0\| = \|Ae_0\| \leq \|A\| \|e_0\|,$$

quindi:

$$\frac{\|e_k\|}{\|e_0\|} \leq \|A^{-1}\| \|A\| \frac{\|r_k\|}{\|r_0\|} = \kappa(A) \frac{\|r_k\|}{\|r_0\|}. \quad (4)$$

La condizione di terminazione sul residuo relativo così definito è scomoda perchè dipende fortemente dalla soluzione iniziale  $x_0$ . Si preferisce quindi rapportare la norma del residuo corrente alla norma del termine noto  $b$ , e cioè utilizzare la condizione:

$$\frac{\|r_k\|}{\|b\|} < \tau.$$




Figura 2: Interpretazione geometrica di un sistema lineare in  $\mathbb{R}^2$ . La soluzione del sistema è il punto di intersezione delle due rette e cioè il vettore  $x^* = [2, -2]^T$ .

Le due condizioni sono equivalenti qualora si scelga come soluzione iniziale  $x_0 = 0$  (e quindi  $r_0 = b$ ), una scelta molto diffusa.

Nel seguito faremo spesso riferimento al seguente esempio:

$$Ax = b \quad \text{ove} \quad A = \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \quad x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad b = \begin{bmatrix} 2 \\ -8 \end{bmatrix} \quad (5)$$

che ha soluzione

$$x^* = \begin{bmatrix} 2 \\ -2 \end{bmatrix}.$$

In  $\mathbb{R}^2$  l'interpretazione geometrica è facile: la soluzione del sistema è il punto di intersezione delle due rette le cui equazioni formano il sistema lineare, situazione che è disegnata in Fig. 2.

### 3 Metodi del Gradiente per la soluzione di sistemi lineari

Queste note sono un'elaborazione di un articolo di Jonathan Shewchuk, dal titolo esemplificativo *An Introduction to the Conjugate Gradient Method Without the Agonizing Pain* [4], mediate con l'illuminante interpretazione geometrica riportata nel libro del Prof. Gambolati [1]. Per approfondimenti si rimanda il lettore al libro di C.T. Kelley [2] o meglio ancora al libro di Y. Saad [3].

### 3.1 Forme quadratiche

Data una matrice  $A$  di dimensione  $n \times n$ , un vettore  $b \in \mathbb{R}^n$  e uno scalare  $c \in \mathbb{R}$ , una forma quadratica è una funzione quadratica di tutte le componenti  $x_1, x_2, \dots, x_n$ :

$$f(x) : \mathbb{R}^n \rightarrow \mathbb{R}$$

definita da

$$f(x) = \frac{1}{2}x^T Ax - b^T x + c = \frac{1}{2} \langle x, Ax \rangle - \langle b, x \rangle + c. \quad (6)$$

Siamo interessati a trovare il minimo di  $f(x)$ . Si dice che  $f(x)$  ha un minimo in  $x^*$  se  $f(x^*) < f(x)$  per tutti gli  $x$  nel dominio di  $f$ . Se tutte le derivate parziali di  $f$  sono nulle in  $x^*$ , allora  $x^*$  può essere un punto di minimo, un punto di massimo, oppure nessuno dei due. Ad esempio in  $\mathbb{R}^2$ , la funzione  $z = f(x, y) = x^2 + y^2$  ha un punto di minimo assoluto in  $(0, 0)$ . D'altro canto, le derivate parziali della funzione  $z = f(x, y) = xy$  si annullano entrambe nel punto  $(0, 0)$ , ma tale punto non è di minimo, (si chiama punto di stazionarietà). Infatti, come si vede facilmente, in tutti i punti  $(x, y)$  del primo e terzo quadrante (dove  $x$  e  $y$  hanno lo stesso segno) si ha  $f(x, y) > 0 = f(0, 0)$ , mentre per tutti i punti del secondo e quarto quadrante (dove  $x$  e  $y$  sono di segno opposto) si ha  $f(x, y) < 0 = f(0, 0)$ .

Prendiamo ora un vettore qualsiasi  $v \in \mathbb{R}^n$  e uno scalare  $\epsilon \in \mathbb{R}$  e formiamo un nuovo vettore  $x^* + \epsilon v \in \mathbb{R}^n$ . Perchè  $x^*$  sia punto di minimo assoluto dovrà essere:

$$f(x^* + \epsilon v) > f(x^*) \quad \text{per ogni } \epsilon \text{ e ogni } v.$$

In particolare dovrà esserlo per  $\epsilon$  piccolo e che tende a zero. Possiamo pensare ora la  $f$  come variabile di  $\epsilon$  soltanto, per cui la condizione di stazionarietà per la  $f(x)$  sarà quindi data da:

$$\frac{d}{d\epsilon} [f(x + \epsilon v)] \Big|_{\epsilon=0} = 0,$$

che deve essere valida per ogni  $v$ . Utilizzando la regola di derivazione della funzione composta si può calcolare la precedente derivata ragionando componente per componente:

$$\frac{d}{d\epsilon} f(x_1, x_2, \dots, x_n) = \frac{\partial f}{\partial x_1} \frac{dx_1}{d\epsilon} + \frac{\partial f}{\partial x_2} \frac{dx_2}{d\epsilon} + \dots + \frac{\partial f}{\partial x_n} \frac{dx_n}{d\epsilon} = \frac{\partial f}{\partial x_1} v_1 + \frac{\partial f}{\partial x_2} v_2 + \dots + \frac{\partial f}{\partial x_n} v_n.$$

Definendo il gradiente della funzione  $f(x)$  come il vettore delle derivate parziali (si vedano le Figure 3 e 4):

$$\nabla f(x) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix},$$




Figura 3: Forma quadratica corrispondente al sistema lineare (5). A sinistra in alto è rappresentato il grafico in  $\mathbb{R}^2$ ; a destra in alto sono rappresentate le linee di livello; in basso il campo dei gradienti.




Figura 4: Grafico della funzione  $f(x, y) = -(\cos^2 x + \cos^2 y)^2$  e del campo vettoriale  $\nabla f(x, y) = (\partial f/\partial x, \partial f/\partial y)^T$




Figura 5: Grafico delle forme quadratiche (in  $\mathbb{R}^2$ ) rappresentative di a) una matrice definita positiva, b) una matrice definita negativa, c) una matrice semidefinita positiva (in realtà è singolare e si nota la linea lungo la quale  $f(x)$  è minima e che corrisponde alle infinite soluzioni del sistema lineare corrispondente), d) una matrice indefinita (punto sella).

si ottiene immediatamente la condizione di minimizzazione di  $f(x)$ :

$$\frac{d}{d\epsilon} [f(x + \epsilon v)] |_{\epsilon=0} = \nabla f(x) \cdot v = \langle \nabla f(x), v \rangle = \nabla f(x)^T v = 0. \quad (7)$$

Si noti che se  $\|v\| = 1$   $\langle \nabla f(x), v \rangle = D_v f(x)$  è la derivata direzionale di  $f$  in  $x$  lungo la direzione  $v$ . D'altro canto, nel caso della nostra forma quadratica (6), possiamo scrivere:

$$\begin{aligned} f(x + \epsilon v) &= \frac{1}{2} \langle (x + \epsilon v), A(x + \epsilon v) \rangle - \langle b, (x + \epsilon v) \rangle + c \\ &= \frac{1}{2} [\langle x, Ax \rangle + \epsilon \langle v, Ax \rangle + \epsilon \langle x, Av \rangle + \epsilon^2 \langle v, Av \rangle] - \langle b, x \rangle - \epsilon \langle b, v \rangle + c, \end{aligned}$$

da cui:

$$\begin{aligned} \frac{d}{d\epsilon} [f(x + \epsilon v)] |_{\epsilon=0} &= \frac{1}{2} [\langle v, Ax \rangle + \langle x, Av \rangle] - \langle b, v \rangle \\ &= \left\langle \frac{A + A^T}{2} x, v \right\rangle - \langle b, v \rangle = 0. \end{aligned}$$

Di conseguenza:

$$\begin{aligned} \nabla f(x) &= \frac{A + A^T}{2} x - b \\ \left( \frac{A + A^T}{2} x - b \right) &\perp v, \end{aligned} \quad (8)$$

e quest'ultima è valida per ogni  $v \in \mathbb{R}^n$ , da cui immediatamente

$$\frac{A + A^T}{2} x = b,$$

e se  $A = A^T$  si ottiene che la condizione di minimo (7) si può scrivere come:

$$\begin{aligned} \nabla f(x) &= Ax - b \\ Ax &= b. \end{aligned} \quad (9)$$

Questo ci dice che la forma quadratica  $f(x)$  ha un minimo in corrispondenza della soluzione del sistema lineare  $Ax = b$ , se  $A$  è simmetrica, del sistema  $\frac{1}{2}(A + A^T)x = b$  se  $A$  non è simmetrica.

### 3.2 Caso simmetrico $A = A^T$

Si può notare che il minimo della  $f(x)$  definito sopra è globale se e solo se  $A$  è simmetrica e definita positiva. Infatti, perchè  $x^*$  sia minimo globale è necessario che  $f(x^* + e) > f(x^*)$  per

ogni vettore  $e \in \mathbb{R}^n$ . Quindi:

$$\begin{aligned}
 f(x^* + e) &= \frac{1}{2} \langle A(x^* + e), (x^* + e) \rangle - \langle b, (x^* + e) \rangle + c \\
 &= \frac{1}{2} [\langle Ax^*, x^* \rangle + \langle Ax^*, e \rangle + \langle Ae, x^* \rangle + \langle Ae, e \rangle] - \langle b, x^* \rangle - \langle b, e \rangle + c \\
 &= \frac{1}{2} \langle Ax^*, x^* \rangle - \langle b, x^* \rangle + c + \langle Ax^*, e \rangle + \frac{1}{2} \langle Ae, e \rangle - \langle b, e \rangle \\
 &= f(x^*) + \frac{1}{2} \langle Ae, e \rangle,
 \end{aligned}$$

dove abbiamo usato il fatto che se  $A = A^T$  si ha  $\langle Az, w \rangle = \langle z, Aw \rangle$ . Se  $A$  è definita positiva,  $\langle Ae, e \rangle > 0$  da cui si ricava che  $f(x^*)$  è minimo assoluto.

Nella Figura 3 viene rappresentato il grafico della  $f(x)$  e il campo dei gradienti  $\nabla f(x)$  nel caso particolare del sistema lineare dato dalla (5), con  $A$  matrice simmetrica. Si noti che le linee di livello che rappresentano la  $f(x)$  (Figura 3 in alto a destra) sono delle ellissi i cui assi principali sono gli autovettori della matrice  $A$ . In  $\mathbb{R}^n$  gli ellissi saranno degli iper-ellissoidi, e le linee di livello si trasformeranno in superfici di livello (o isosuperfici), l'interpretazione geometrica, seppur non rappresentabile graficamente, rimane la stessa. In altre parole, l'equazione  $f(x) = C$  rappresenta un iper-ellissoide in  $\mathbb{R}^n$  il cui centro coincide con il minimo di  $f(x)$  e quindi con la soluzione del sistema lineare <sup>6</sup>.

Per vedere questo si deve lavorare su un nuovo sistema di riferimento ottenuto come segue. Si noti che data una soluzione approssimata  $x_k \neq x^*$ , l'errore associato è rappresentato da:

$$e_k = x_k - x^* \tag{10}$$

Effettuiamo ora un cambio di variabili e poniamoci in un sistema di riferimento  $z$  dato da:

$$e_k = Uz, \tag{11}$$

dove  $z$  è la nuova variabile e  $U$  è la matrice le cui colonne sono gli autovettori  $u_i$  di  $A$  ordinati secondo gli autovalori di  $A$  (sempre positivi) decrescenti. La matrice  $U$  è unitaria (o ortogonale)<sup>7</sup> e cioè  $U^{-1} = U^T$ . Il nuovo sistema di riferimento ha l'origine coincidente con il centro dell'iper-ellissoide e gli assi coordinati coincidenti con gli autovettori di  $A$ , per cui si può scrivere la forma quadratica seguente:

$$\Phi(e_k) = \langle e_k, Ae_k \rangle = \langle Uz, AUz \rangle = z^T \Lambda z = \langle z, \Lambda z \rangle,$$

le cui superfici di livello sono rappresentate dalla seguente equazione:

$$\lambda_1 z_1^2 + \lambda_2 z_2^2 + \dots + \lambda_n z_n^2 = \text{cost},$$

---

<sup>6</sup>Si noti che il grafico  $z = f(x)$  è rappresentabile in  $\mathbb{R}^{n+1}$ .

<sup>7</sup>Si ricordi che  $A$  è simmetrica e definita positiva, e quindi diagonalizzabile, da cui deriva che i suoi autovettori formano una base per lo spazio vettoriale  $\mathbb{R}^n$ .

ovvero:

$$\frac{z_1^2}{\frac{\text{cost}}{\lambda_1}} + \frac{z_2^2}{\frac{\text{cost}}{\lambda_2}} + \dots + \frac{z_n^2}{\frac{\text{cost}}{\lambda_n}} = 1, \quad (12)$$

che è l'equazione in forma canonica dell'iper-ellissoide avente come lunghezza dei semi-assi:

$$a_1 = \sqrt{\frac{\text{cost}}{\lambda_1}}, \quad a_2 = \sqrt{\frac{\text{cost}}{\lambda_2}}, \dots, a_n = \sqrt{\frac{\text{cost}}{\lambda_n}}$$

Notiamo che la forma quadratica  $\Phi(\cdot)$  ha come punto di minimo il vettore nullo, cioè  $e_k = x_k - x^* = 0$ , corrispondente proprio al minimo della  $f(\cdot)$ , ovvero la soluzione del sistema lineare. Infatti:

$$f(x_k) = f(x^* + e_k) = f(x^*) + \frac{1}{2} \langle e_k, Ae_k \rangle = \frac{1}{2} \Phi(e_k)$$

Inoltre, la  $\Phi(\cdot)$  coincide con la  $\Phi_3(x) = e^T Ae$  descritta sul libro di Gambolati [1] a meno di una costante moltiplicativa positiva.

Abbiamo quindi dimostrato che trovare la soluzione del sistema lineare  $Ax = b$  è equivalente a trovare il punto di minimo della forma quadratica  $f(x)$  ed è equivalente ad imporre l'ortogonalità del residuo a tutti i vettori di  $\mathbb{R}^n$ . In altre parole, per matrici simmetriche, i seguenti problemi sono equivalenti:

**Problema 3.1** (sistema lineare).

Trovare  $x \in \mathbb{R}^n$  tale che:

$$Ax = b. \quad (S)$$

**Problema 3.2** (di minimizzazione).

Trovare  $x \in \mathbb{R}^n$  tale che:

$$F(x) \leq F(v) \quad \forall v \in \mathbb{R}^n. \quad (M)$$

**Problema 3.3** (variazionale).

Trovare  $x \in \mathbb{R}^n$  tale che:

$$\langle b - Ax, v \rangle = 0 \quad \forall v \in \mathbb{R}^n. \quad (V)$$

### 3.2.1 Metodo del gradiente (o della discesa più ripida o dello *steepest descent*)

Poichè il gradiente di  $f$  è interpretabile come la direzione di massimo aumento della funzione  $f$ , dalla (8) si vede immediatamente che il residuo del sistema lineare coincide con la direzione di discesa più ripida (Steepest Descent):

$$r = b - Ax = -\nabla f(x).$$

E' quindi intuitivo costruire un algoritmo basato sul calcolo di tale gradiente. Questo metodo, detto appunto metodo del gradiente o metodo della ricerca più ripida o dello Steepest Descent (SD), cerca di percorrere in ogni punto la direzione di discesa più ripida per arrivare al minimo assoluto. E' intuitivo pensare che tale algoritmo funzionerà solo se non esistono minimi relativi: in un minimo relativo, non è più necessariamente definita una direzione di discesa, e il metodo potrebbe trovarsi in condizioni di stallo.

Costruiamo allora un algoritmo iterativo basato su:

$$x_{k+1} = x_k + \alpha_k r_k,$$

dove l'indice  $k$  indica l'iterazione. Il valore di  $\alpha_k$  viene determinato imponendo che lungo la direzione  $r_k$  il funzionale sia minimo (procedimento di line search, si veda la sua interpretazione geometrica riportata in Fig. 7(a,b)). Il vettore  $r_k$  individua la direzione di ricerca.

Per fare il conto dell'espressione di  $\alpha_k$ , annulliamo semplicemente la derivata prima della forma quadratica pensata come funzione di  $\alpha_k$ . Imponiamo cioè:

$$\frac{d}{d\alpha_k} f(x_k + \alpha_k r_k) = \langle \nabla f(x_k + \alpha_k r_k), r_k \rangle = \langle \nabla f(x_{k+1}), r_k \rangle = 0,$$

ma visto che  $\nabla f(x_{k+1}) = -r_{k+1}$ , si impone:

$$\langle r_{k+1}, r_k \rangle \Rightarrow \langle (b - Ax_{k+1}), r_k \rangle = 0,$$

e siccome  $A = A^T$ :

$$\langle b, r_k \rangle - \langle Ax_k, r_k \rangle - \alpha_k \langle Ar_k, r_k \rangle = \langle r_k, r_k \rangle - \alpha_k \langle Ar_k, r_k \rangle = 0,$$

da cui si ricava immediatamente:

$$\alpha_k = \frac{\langle r_k, r_k \rangle}{\langle Ar_k, r_k \rangle}. \tag{13}$$

L'algoritmo può quindi essere scritto nel modo seguente.

ALGORITHM SD  
 Input:  $x_0, n_{imax}, toll; k = 0;$   
 $r_0 = b - Ax_0.$   
 FOR  $k = 0, 1, \dots$  fino a convergenza:

1.  $\alpha_k = \frac{\langle r_k, r_k \rangle}{\langle Ar_k, r_k \rangle}$  (14)
2.  $x_{k+1} = x_k + \alpha_k r_k$  (15)
3.  $r_{k+1} = r_k - \alpha_k Ar_k$  (16)

END FOR




Figura 6: Interpretazione in  $\mathbb{R}^2$  delle varie fasi dello schema dello steepest descent per la soluzione del sistema (5): a) la direzione di ricerca  $r_0$  e l'errore iniziale  $e_0$ ; b) la forma quadratica e il piano ortogonale a  $x_1$  e  $x_2$  passante per la direzione  $r_0$ ; c) la funzione  $f(\alpha_0)$  nella direzione  $r_0$ ; d) la nuova iterata  $x_1$  e la nuova direzione del gradiente.




Figura 7: Interpretazione in  $\mathbb{R}^2$  delle varie fasi dello schema dello steepest descent per la soluzione del sistema (5). A sinistra sono disegnati i vettori  $\nabla f(x_k + \alpha_k r_k)$  lungo la direzione  $r_k$ ; la  $f(x_{k+1})$  è minima nel punto in cui  $r_k \perp \nabla f(x_k + \alpha_k r_k)$ . A destra sono rappresentate alcune iterazioni del metodo a partire dal punto iniziale  $(-2, -2)^T$ . Lo schema converge alla soluzione  $(2, -2)^T$ .




Figura 8: Il metodo dello steepest descent converge in una sola iterazione se la direzione del residuo iniziale coincide con quella di un autovettore.

In Fig. 7 a destra vengono rappresentate le prime 6 iterazioni del metodo per la soluzione del sistema (2).

**Osservazione 3.4.** Come caso “molto” particolare, supponiamo che alla iterazione  $k$ -esima l'errore  $e_k$  coincida con un autovettore della matrice  $A$  e chiamiamo  $\lambda_k$  il corrispondente autovalore, per cui:

$$r_k = -Ae_k = -\lambda_k e_k,$$

da cui si vede che il residuo è anch'esso un autovettore. Sostituendo nella (15) dell'ALGORITHM SD si ottiene immediatamente:

$$e_{k+1} = e_k + \frac{\langle r_k, r_k \rangle}{\langle r_k, Ar_k \rangle} r_k = e_k + \frac{\lambda_k^2 \langle e_k, e_k \rangle}{\lambda_k^3 \langle e_k, e_k \rangle} (-\lambda_k e_k) = 0.$$

In altre parole, come si può vedere nell'interpretazione geometrica di Fig. 8,  $r_k$  è la direzione dell'autovettore  $e_k$  di  $A$  e coincide quindi con uno degli assi principali dell'iper-ellissoide e quindi passa per il centro (punto di minimo).

E' chiaro che per vedere il comportamento dell'errore nello schema SD si può sfruttare la relazione precedente utilizzando una rappresentazione dell'errore tramite la base data dagli autovettori di  $A$ . Per fare questo scriviamo:

$$\begin{aligned} e_k &= \sum_{j=1}^n \gamma_j u_j \\ r_k &= -Ae_k = -\sum_{j=1}^n \gamma_j \lambda_j u_j, \end{aligned} \tag{17}$$

ma poichè:

$$\|e_k\|^2 = \langle e_k, e_k \rangle = \sum_{j=1}^n \gamma_j^2 \quad e \quad \|e_k\|_A^2 = \langle e_k, Ae_k \rangle = \sum_{j=1}^n \gamma_j^2 \lambda_j,$$

e analogamente:

$$\|r_k\|^2 = \langle r_k, r_k \rangle = \sum_{j=1}^n \gamma_j^2 \lambda_j^2 \quad e \quad \|r_k\|_A^2 = \langle r_k, Ar_k \rangle = \sum_{j=1}^n \gamma_j^2 \lambda_j^3,$$

abbiamo immediatamente:

$$\begin{aligned} e_{k+1} &= e_k + \frac{\langle r_k, r_k \rangle}{\langle r_k, Ar_k \rangle} r_k \\ &= e_k + \frac{\sum_{j=1}^n \gamma_j^2 \lambda_j^2}{\sum_{j=1}^n \gamma_j^2 \lambda_j^3} r_k. \end{aligned}$$

Come visto prima, se  $e_k$  è tale che solo uno degli  $\alpha_j \neq 0$  basta scegliere  $\alpha_j = 1/\lambda_j$  e si ha convergenza immediata. Se d'altra parte tutti gli autovalori sono uguali, si ricava ancora che  $e_{k+1} = 0$ . In questo caso, infatti, gli iper-ellissoidi sono in realtà delle iper-sfere, per cui le direzioni del residuo puntano direttamente verso il centro. Si noti da ultimo che il termine

$$\frac{\langle r_k, r_k \rangle}{\langle r_k, Ar_k \rangle} = \frac{\sum_{j=1}^n \gamma_j^2 \lambda_j^2}{\sum_{j=1}^n \gamma_j^2 \lambda_j^3}$$

può essere intuitivamente visto come una media pesata degli inversi degli autovalori e i pesi  $\gamma_j^2$  fanno sì che le componenti (intese come i vettori  $u_j$  di (17)) più “lunghe” di  $e_k$  vengano “accorciate” prima delle altre. Come risultato si ha che alcune delle componenti più “corte” potrebbero anche aumentare, da cui segue che la convergenza dello schema non è monotona, ma in genere non per molto.

### 3.2.2 Convergenza di SD

Per studiare formalmente la convergenza di SD abbiamo bisogno di utilizzare quella che viene chiamata la norma energia del vettore  $x$ , definita come:

$$\|x\|_A = \sqrt{\langle Ax, x \rangle} = \sqrt{\langle x, Ax \rangle} = \sqrt{x^T Ax}.$$

Per prima cosa vediamo che il minimo della forma quadratica  $f(x_k)$  implica minimizzare la norma energia dell'errore  $\|e_k\|_A$ . Infatti, dalla definizione di errore  $e_k$  e usando il fatto che  $A^T = A$ , si ha immediatamente:

$$f(x_k) = f(x + e_k) = f(x) + \frac{1}{2} \langle Ae_k, e_k \rangle,$$

da cui, siccome  $\frac{1}{2} \langle Ae_k, e_k \rangle \geq 0$  e  $f(x)$  è il minimo assoluto della forma quadratica, segue l'affermazione. Quindi:

$$\begin{aligned} \|e_{k+1}\|_A^2 &= \langle Ae_{k+1}, e_{k+1} \rangle = \langle A(e_k + \alpha_k r_k), (e_k + \alpha_k r_k) \rangle \\ &= \langle Ae_k, e_k \rangle + 2\alpha_k \langle Ae_k, r_k \rangle + \alpha_k^2 \langle Ar_k, r_k \rangle \\ &\quad (\text{ricordando che } Ae_k = -r_k) \\ &= \|e_k\|_A^2 - \frac{(\langle r_k, r_k \rangle)^2}{\langle Ar_k, r_k \rangle} \\ &= \|e_k\|_A^2 \left( 1 - \frac{(\langle r_k, r_k \rangle)^2}{\langle Ar_k, r_k \rangle \langle Ae_k, e_k \rangle} \right) \\ &= \|e_k\|_A^2 \left( 1 - \frac{(\sum_j \gamma_j^2 \lambda_j^2)^2}{(\sum_j \gamma_j^2 \lambda_j^3)(\sum_j \gamma_j^2 \lambda_j)} \right) \\ &= \omega^2 \|e_k\|_A^2, \end{aligned}$$

con evidentemente  $\omega^2$  che deve essere minore di 1 per avere convergenza. In  $\mathbb{R}^2$  è ragionevolmente facile trovare un significato per il numero  $\omega^2$ . Infatti, se  $\lambda_1 \geq \lambda_2$ , definiamo il numero di condizionamento spettrale della matrice  $A$  come  $\kappa(A) = \lambda_1/\lambda_2$  (in generale per una matrice  $A$  di dimensioni  $n \times n$  sarà  $\kappa(A) = \lambda_1/\lambda_n$ ), e definiamo  $\mu = \gamma_2/\gamma_1$ . Si noti che  $\kappa(A)$  è chiamato il numero di condizionamento della matrice. Valori di  $\kappa(A)$  relativamente grandi corrispondono a matrici relativamente malcondizionate. Allora:

$$\omega^2 = 1 - \frac{(\kappa(A)^2 + \mu^2)^2}{(\kappa(A) + \mu^2)(\kappa(A)^3 + \mu^2)}.$$

Analizzando questa relazione, si vede che il caso peggiore si ha quando  $\kappa(A)^2 = \mu^2$ , e cioè:

$$\omega^2 \leq 1 - \frac{4\kappa(A)^4}{(\kappa(A)^3 + \kappa(A)^2)(\kappa(A)^2 + \kappa(A))} = \left( \frac{\kappa(A) - 1}{\kappa(A) + 1} \right)^2.$$

In questo caso  $\omega$  può essere visto come un'approssimazione della costante asintotica dell'errore:

$$\|e_{k+1}\|_A \leq \frac{\kappa(A) - 1}{\kappa(A) + 1} \|e_k\|_A,$$

e cioè:

$$\|e_k\|_A \leq \left( \frac{\kappa(A) - 1}{\kappa(A) + 1} \right)^k \|e_0\|_A,$$

e l'errore relativo sulla forma quadratica diventa:

$$\frac{f(x_k) - f(x)}{f(x_0) - f(x)} = \frac{\frac{1}{2} \langle e_k, Ae_k \rangle}{\frac{1}{2} \langle e_0, Ae_0 \rangle} \leq \left( \frac{\kappa(A) - 1}{\kappa(A) + 1} \right)^{2k}. \quad (18)$$

Si può dimostrare che l'espressione precedentemente scritta per l'errore è valida anche in  $\mathbb{R}^n$ .

**Osservazione 3.5.** Il gradiente della forma quadratica è pari a  $\nabla f(z) = \Lambda z$ . La relazione di aggiornamento della soluzione approssimata  $x_{k+1}$  nel nuovo riferimento diventa quindi:

$$z_{k+1} = z_k - \alpha_k U^T U \Lambda z_k,$$

per cui se la soluzione iniziale  $z_0$  (che coincide con l'errore iniziale) ha la componente  $i$ -esima nulla, anche  $z_1$  avrà la componente  $i$ -esima nulla, e quindi  $x_{1,i}$  sarà esatta. Se le componenti esatte sono molte, si avrà una notevole accelerazione della convergenza.

L'andamento di  $\omega$  in funzione di  $\kappa(A)$  e  $\mu$  è graficato in Fig. 9. Si vede che se l'errore iniziale coincide con un autovettore, e quindi  $\mu = 0$  (o  $\infty$ ),  $\omega = 0$  e la convergenza è istantanea. Lo stesso avviene per  $\kappa(A) = 1$  e cioè se gli autovalori sono tutti uguali.




Figura 9: Andamento del fattore di convergenza  $\omega$ .




Figura 10: Esempi di convergenza del metodo di Steepest Descent in corrispondenza a valori estremi di  $\kappa(A)$  e  $\mu$  relativi alla figura 9. Le due figure in alto si riferiscono al caso di  $\kappa(A)$  grande, mentre quelle in basso sono caratterizzate da un valore di  $\kappa(A)$  vicino a 1.




Figura 11: I punti iniziali peggiori per la convergenza di SD sono localizzati sulle linee continue nere. Le linee tratteggiate rappresentano il percorso delle iterate e formano un angolo di  $45^\circ$  rispetto agli assi dell'iper-ellissoide visualizzati con le frecce grigie. Per questo caso  $\kappa(A) = 3.5$ .

In Fig. 10 è invece illustrato il “cammino” di SD per vari valori di  $\kappa(A)$  e  $\mu$  nel sistema di riferimento definito dagli autovettori di  $A$ . Come si verifica da (18), la convergenza peggiora per valori di  $\kappa(A)$  grandi, in corrispondenza al fatto che la matrice risulta malcondizionata. I primi due grafici in alto di Fig. 10 rappresentano degli esempi caratterizzati da  $\kappa(A)$  grande; SD può convergere velocemente se il punto iniziale è fortunato (Fig. 10 alto a sinistra) ma in generale la convergenza è molto lenta (Fig. 10 alto a destra). Nei due grafici in basso, invece, l'iper-ellissoide è quasi “sferico” (infatti  $\kappa(A) \approx 1$ ) e la convergenza è veloce indipendentemente dalla soluzione iniziale.

Nella Fig. 11, corrispondente al solito sistema (5) per il quale  $\kappa(A) = 3.5$ , sono riportate le linee dei punti iniziali “peggiori”. Le equazioni delle linee sono date da  $\gamma_2/\gamma_1 = \pm\kappa(A)$ .

### 3.2.3 Il metodo del gradiente coniugato

Si è visto in precedenza che il metodo SD può convergere lentamente. In particolare, si è visto che due direzioni di ricerca (gradienti) successive sono ortogonali tra di loro (cfr. Fig. 11). Di conseguenza, solo due direzioni di discesa vengono utilizzate nell'intero processo, essendo  $r_k$  ortogonale a  $r_{k-1}$  e parallelo a  $r_{k-2}$ . Ovviamente, se le due direzioni di ricerca non passano per il punto di minimo del funzionale, il numero di iterazioni di SD per arrivare alla soluzione esatta è infinito. Per migliorare la convergenza è quindi necessario utilizzare direzioni di ricerca che non si ripetano.




Figura 12: Utilizzando due direzioni ortogonali si arriva a convergenza in due iterazioni usando la direzione dell'errore  $e_k$

Cerchiamo quindi di costruire uno schema che ad ogni iterazione generi una nuova direzione di ricerca diversa (ortogonale) da tutte le precedenti (e di conseguenza linearmente indipendente da tutte le altre). Lungo ogni direzione eseguiamo un passo di lunghezza tale da “allinearsi” al punto di minimo (il centro dell'iperelissoide) in quella direzione. Come conseguenza, nel caso peggiore la  $n$ -esima direzione di ricerca passa per il punto di minimo di  $f(x)$  e lo schema in teoria converge con al massimo  $n$  iterazioni. Si dice allora che lo schema iterativo ha terminazione finita, intendendo cioè che lo schema ha un impianto simile ad uno schema iterativo (formule ricorsive per l'aggiornamento delle variabili) ma raggiunge la soluzione esatta in un numero predefinito di iterazioni. Per esempio, in  $\mathbb{R}^2$ , data una prima direzione (chiamiamola  $p_0$ ) ad esempio parallela all'asse  $x$ , si esegue lungo essa un passo di lunghezza tale da fermarsi sul punto di intersezione tra la direzione  $p_0$  e la normale ad essa passante per il centro. La direzione successiva ( $p_1$ ) è parallela all'asse  $y$  e ci porta direttamente alla soluzione (si veda la Fig. 12). Notiamo anche che questa direzione è coincidente con la direzione dell'errore  $e_{k+1} = x - x_{k+1}$ . Possiamo scrivere questo come:

$$x_{k+1} = x_k + \alpha_k p_k, \tag{19}$$

e calcoliamo  $\alpha_k$  in modo che  $e_{k+1}$  sia ortogonale a  $p_k$ :

$$\begin{aligned} \langle p_k, e_{k+1} \rangle &= 0 \\ \langle p_k, e_k + \alpha_k p_k \rangle &= 0 \quad \text{dal'eq. (19)} \\ \alpha_k &= -\frac{\langle p_k, e_k \rangle}{\langle p_k, p_k \rangle}. \end{aligned}$$




Figura 13: Sinistra: coppie di vettori  $A$ -coniugati; destra: gli stessi vettori in un piano deformato con la matrice  $A$ .

Prima di procedere alla costruzione dello schema, vediamo alcune definizioni utili. Diciamo che due vettori  $x$  e  $y$  sono  $A$ -coniugati o  $A$ -ortogonali se:

$$\langle x, Ay \rangle = 0.$$

Si noti che se  $A$  è simmetrica e definita positiva, la formula precedente può essere usata come definizione di un nuovo prodotto scalare:

$$\langle x, y \rangle_A = \langle x, Ay \rangle = \langle Ax, y \rangle,$$

che genera la norma (chiamata norma energia):

$$\|x\|_A = \sqrt{\langle x, x \rangle_A}.$$

Siano  $p_i$ ,  $i = 1, \dots, n$ ,  $n$  vettori (direzioni)  $A$ -ortogonali, e cioè tali che

$$\langle p_i, Ap_j \rangle = \begin{cases} \neq 0, & \text{if } i = j, \\ 0, & \text{if } i \neq j. \end{cases} \quad (20)$$

Tali vettori sono linearmente indipendenti e quindi formano una base per  $\mathbb{R}^n$ . Infatti, se supponiamo che esistano delle costanti  $\alpha_i$  tali per cui:

$$0 = \alpha_1 p_1 + \dots + \alpha_n p_n;$$

moltiplicando per la matrice  $A$  (simmetrica e definita positiva) e poi scalarmente per  $p_i$ ,  $i = 1, \dots, n$ , si ottiene:

$$0 = \alpha_1 \langle p_i, Ap_1 \rangle + \dots + \alpha_n \langle p_i, Ap_n \rangle, \quad i = 1, \dots, n.$$

Dalla (20) si ottiene subito  $\alpha_i = 0$ .

Da quello che abbiamo visto in precedenza è facile arguire che se le isosuperfici (linee di livello del paraboloido identificato dalla forma quadratica) fossero sferiche il metodo SD convergerebbe in 1 iterazione. In questo caso, infatti, le direzioni del gradiente sono tutte ortogonali alle isosuperfici, per cui le direzioni calcolate da SD devono necessariamente passare per il centro. Guardando all'equazione (12), si nota che le isosuperfici sono sferiche se tutti gli autovalori  $\lambda_i$  sono uguali. E' possibile usare un cambiamento di variabili (cambiamento del sistema di riferimento) per trasformare gli iperellissoidi in ipersuperfici sferiche. Per fare ciò usiamo il fatto che  $A$  è simmetrica e definita positiva per cui  $A = U\Lambda U^T$ . Quindi:

$$\frac{1}{2} \langle x, Ax \rangle = \frac{1}{2} \langle y, y \rangle,$$

dove

$$y = \Lambda^{\frac{1}{2}} U^T x.$$

Nelle nuove coordinate  $y$  le isosuperfici diventano quindi sferiche (basta sostituire opportunamente in (12)). L'idea è quindi di trovare delle direzioni  $q_i$  mutuamente ortogonali nel caso sferico e che quindi garantiscono la convergenza in al massimo  $n$  iterazioni. Tali direzioni dovranno quindi soddisfare:

$$\langle q_i, q_j \rangle = 0$$

per ogni indice  $i$  e  $j$  (diversi) compresi tra 1 e  $n$ . Possiamo ora tornare al caso "ellittico" notando che le direzioni  $q_i$  nel sistema "sferico" sono legate alle direzioni  $p_i$  nel sistema "ellittico" dalla relazione:

$$q_i = \Lambda^{\frac{1}{2}} U^T p_i;$$

la relazione di ortogonalità tra  $q_i$  e  $q_j$  in termini di  $p_i$  e  $p_j$  diventa:

$$\left\langle \Lambda^{\frac{1}{2}} U^T p_i, \Lambda^{\frac{1}{2}} U^T p_j \right\rangle = p_i^T U \Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} U^T p_j = p_i^T A p_j = \langle p_i, p_j \rangle_A = 0,$$

ovvero,  $p_i$  e  $p_j$  devono essere  $A$ -coniugati. Fig. 13 mostra la relazione che esiste tra due vettori  $A$ -coniugati rappresentati nel piano  $\mathbb{R}^2$  oppure nel piano deformato utilizzando la matrice  $A = U\Lambda U^T$ . Si noti che la relazione di  $A$ -ortogonalità nello spazio vettoriale avente prodotto scalare standard ( $\langle \cdot, \cdot \rangle$ ) si trasforma in una relazione di ortogonalità in uno spazio indotto dal prodotto scalare  $\langle \cdot, \cdot \rangle_A$ .




Figura 14: Interpretazione geometrica del metodo CG in  $\mathbb{R}^2$ : le due direzioni di ricerca sono  $A$ -coniugate, per cui la seconda necessariamente passa per il centro dell'ellissoide, e quindi per il punto soluzione  $x^*$ .

In sintesi, vogliamo calcolare  $n$  direzioni  $p_0, \dots, p_n$  che siano mutuamente  $A$ -coniugate, sulle quali andremo a cercare ogni volta il minimo della  $f(x)$  utilizzando ancora la formula (13). Per fare questo, ovviamente, non possiamo servirci degli autovalori di  $A$  perchè sarebbe troppo costoso. L'interpretazione geometrica del metodo CG in  $\mathbb{R}^2$  è mostrata in Fig. 14.

Andiamo a costruire quindi il seguente algoritmo del gradiente coniugato (CG):

```

ALGORITHM CG
Input:  $x_0, n_{imax}, toll; k = 0;$ 
 $r_0 = b - Ax_0 = p_0$ 
FOR  $k = 0, 1, \dots$  fino a convergenza:

    1.  $\alpha_k = \frac{\langle p_k, r_k \rangle}{\langle p_k, Ap_k \rangle}$  (21)
    2.  $x_{k+1} = x_k + \alpha_k p_k$  (22)
    3.  $r_{k+1} = r_k - \alpha_k Ap_k$  (23)
    4.  $\beta_k = -\frac{\langle r_{k+1}, Ap_k \rangle}{\langle p_k, Ap_k \rangle}$  (24)
    5.  $p_{k+1} = r_{k+1} + \beta_k p_k$  (25)

END FOR

```

Il coefficiente  $\beta_k$  è calcolato in modo da imporre la relazione di  $A$ -ortogonalità tra la direzione  $p_k$  e la nuova direzione  $p_{k+1}$ , cioè:

$$\langle p_{k+1}, Ap_k \rangle = \langle r_{k+1} + \beta_k p_k, Ap_k \rangle = 0,$$

da cui si ricava immediatamente la (24). Si può dimostrare per induzione che  $p_{k+1}$  è  $A$ -ortogonale anche alle precedenti direzioni e che i residui sono tra loro ortogonali:

$$\langle p_{k+1}, Ap_i \rangle = 0 \quad i = 0, 1, \dots, k \quad (26)$$

$$\langle r_{k+1}, r_i \rangle = 0 \quad i = 0, 1, \dots, k \quad (27)$$

Infatti, poniamo  $p_0 = r_0$   $x_0 = p_0$ . Quindi:

$$\boxed{k = 0}$$

$$\begin{aligned} x_1 &= x_0 + \alpha_0 p_0 \\ r_1 &= r_0 - \alpha_0 A p_0 \end{aligned}$$

imponiamo  $\langle p_0, r_1 \rangle = 0$  ottenendo:

$$\langle p_0, r_0 - \alpha_0 A p_0 \rangle = 0 \quad \Rightarrow \quad \alpha_0 = \frac{\langle p_0, r_0 \rangle}{\langle p_0, A p_0 \rangle}$$

scriviamo:

$$p_1 = r_1 + \beta_0 p_0$$

imponiamo  $\langle p_0, A p_1 \rangle = 0$  ottenendo:

$$\langle p_0, A(r_1 + \beta_0 p_0) \rangle = 0 \quad \Rightarrow \quad \beta_0 = -\frac{\langle p_0, A r_0 \rangle}{\langle p_0, A p_0 \rangle}$$

Si noti che  $\langle r_0, r_1 \rangle = 0$ .

$$\boxed{k = 1}$$

$$\begin{aligned} x_2 &= x_1 + \alpha_1 p_1 \\ r_2 &= r_1 - \alpha_1 A p_1 \end{aligned}$$

imponiamo  $\langle p_1, r_2 \rangle = 0$  ottenendo:

$$\langle p_1, r_1 - \alpha_1 A p_1 \rangle = 0 \quad \Rightarrow \quad \alpha_1 = \frac{\langle p_1, r_1 \rangle}{\langle p_1, A p_1 \rangle}$$

scriviamo:

$$p_2 = r_2 + \beta_1 p_1$$

imponiamo  $\langle p_1, Ap_2 \rangle = 0$  ottenendo:

$$\langle p_1, A(r_2 + \beta_1 p_1) \rangle = 0 \quad \Rightarrow \quad \beta_1 = -\frac{\langle p_1, Ar_1 \rangle}{\langle p_1, Ap_1 \rangle}$$

Quindi si hanno i seguenti risultati:

$$\begin{aligned} \langle r_0, r_2 \rangle &= \langle p_0, r_2 \rangle = \langle p_0, r_1 - \alpha_1 Ap_1 \rangle = 0 \\ \langle r_1, r_2 \rangle &= \langle r_2, p_1 - \beta_0 p_0 \rangle = 0 \\ \langle r_2, Ap_0 \rangle &= \frac{\langle r_2, r_0 - r_1 \rangle}{\alpha_0} = 0 \\ \langle p_0, Ap_2 \rangle &= \langle p_0, A(r_2 + \beta_1 p_1) \rangle = \langle r_2, Ap_0 \rangle + \beta_1 \langle p_0, Ap_1 \rangle = 0 \end{aligned}$$

$$\boxed{k = \dots}$$

Alla fine del processo di induzione si vede chiaramente che:

$$\begin{aligned} \langle p_j, r_i \rangle &= 0 \quad i > j \\ \langle r_i, r_j \rangle &= 0 \quad i \neq j \\ \langle p_i, Ap_j \rangle &= 0 \quad i \neq j. \end{aligned}$$

Si osservi che

$$\begin{aligned} x_2 &= x_0 + \alpha_0 r_0 + \alpha_1 p_1 \\ &= x_0 + (\alpha_0 + \alpha_1 \beta_0) r_0 + \alpha_1 r_1 \\ &= x_0 + \gamma'_1 r_0 + \gamma'_2 Ar_0 \\ &\dots \\ x_k &= x_0 + \sum_{i=0}^{k-1} \gamma_i A^i r_0 \end{aligned}$$

da cui si vede che la soluzione è data da una combinazione lineare dei vettori  $A^i r_i$ . Si dimostra che tali vettori sono linearmente indipendenti e generano uno spazio affine a  $\mathbb{R}^k$   $\mathcal{K}_k \approx \mathbb{R}^k$ , chiamato spazio di Krylov, per cui si può scrivere:

$$x_k \in x_o + \mathcal{K}_k,$$

dove

$$\mathcal{K}_k = \text{span} \{r_0, Ar_0, A^2 r_0, \dots, A^{k-1} r_0\}$$

Per questo il metodo del gradiente coniugato e i metodi derivati da esso si chiamano metodi di Krylov.

Si noti che, essendo i residui tra loro ortogonali (si veda la (27)), si verifica immediatamente che  $r_n = 0$  e quindi  $x_n = x^*$ , e cioè il metodo CG in teoria ritorna la soluzione vera dopo  $n$  iterazioni. Si dice anche che CG è un metodo iterativo che ha terminazione finita, e per questo è “paragonabile” ad uno schema diretto, in quanto teoricamente la soluzione vera è raggiunta dopo un numero di operazioni finito e determinabile a priori. Questo fatto però è vero solo in teoria, perchè nella pratica le relazioni di ortogonalità precedentemente viste sono verificate solamente in maniera approssimata per la presenza degli errori di rappresentazione dei numeri all’elaboratore. Quindi lo schema va considerato alla stregua degli schemi iterativi. Inoltre, per questioni di costi computazionali, noi preferiremmo riuscire a raggiungere la tolleranza richiesta nell’errore con un numero di iterazioni molto inferiore a  $n$ . Per questo si ricorre alla tecnica del preconditionamento, che vedremo più avanti.

### 3.2.4 Convergenza di CG

Da quanto discusso prima, si deduce che la  $k$ -esima iterazione del metodo CG è il punto di minimo della forma quadratica  $f(x)$  sul sottospazio  $S = x_0 + \mathcal{K}_k$ . Poichè la matrice  $A$  è simmetrica, minimizzare la  $f(x)$  su  $S$  è equivalente a minimizzare  $\|x - x^*\|_A$  sullo stesso sottospazio. Infatti, con pochi passaggi, si ricava:

$$\|x - x^*\|_A^2 = \|b - Ax\|_{A^{-1}}^2 = 2f(x).$$

Da questo, segue immediatamente che

$$\|x_k - x^*\|_A \leq \|w - x^*\|_A$$

per ogni  $w \in x_0 + \mathcal{K}_k$ . Quindi,  $x_k$  è il vettore più vicino (se misurato in norma energia) alla soluzione  $x_*$  rispetto a tutti gli altri vettori appartenenti allo spazio  $x_0 + \mathcal{K}_k$ . D’altro canto, il vettore  $w$  può essere scritto in generale come:

$$w = x_0 + \sum_{j=0}^{k-1} \gamma_j A^j r_0$$

per opportuni coefficienti  $\gamma_j \in \mathbb{R}$ . Quindi

$$w - x^* = x_0 + \sum_{j=0}^{k-1} \gamma_j A^j r_0 - x^* = x_0 - x^* - \sum_{j=0}^{k-1} \gamma_j A^{j+1} (x_0 - x^*) = p(A)(x_0 - x^*)$$

e il polinomio  $p(z) \in \mathcal{P}_{k,p(0)=1}$ , appartiene cioè all’insieme dei polinomi di grado  $k$  e omogenei ( $p_k(0) = 1$ ), ed è definito da:

$$p(z) = 1 + \sum_{j=0}^{k-1} \gamma_j z^{j+1}.$$

Si vede immediatamente che:

$$\|x_k - x^*\|_A = \min_{p \in \mathcal{P}_{k,p(0)=1}} \|p(A)(x_0 - x^*)\|_A. \quad (28)$$

Usando la decomposizione spettrale della matrice  $A$ , scritta come:

$$A^j = U \Lambda^j U^T,$$

si ottiene:

$$p(A) = U p(\lambda) U^T.$$

Poichè:

$$\|p(A)x\|_A = \|A^{1/2} p(A)x\|_2 \leq \|p(A)\|_2 \|A^{1/2}x\|_2 = \|p(A)\|_2 \|x\|_A,$$

si ottiene dalla (28):

$$\|x_k - x^*\|_A \leq \|x_0 - x^*\|_A \min_{p \in \mathcal{P}_{k,p(0)=1}} \max_{z \in \lambda(A)} |p(z)|,$$

dove  $\lambda(A)$ , chiamato lo spettro di  $A$ , è l'insieme di tutti gli autovalori di  $A$ . Da qui l'importante risultato che fornisce una maggiorazione dell'errore relativo alla  $k$ -esima iterazione di CG:

$$\frac{\|x_k - x^*\|_A}{\|x_0 - x^*\|_A} \leq \max_{z \in \lambda(A)} |p_k(z)|,$$

dove  $p_k(z)$  è un qualsiasi polinomio di grado  $k$  con  $p_k(0) = 1$ .

Utilizzando polinomi scelti opportunamente, si possono ricavare alcune proprietà importanti di CG. Per esempio, è possibile far vedere la proprietà di terminazione finita. Per fare ciò si prenda il polinomio così definito:

$$p^*(z) = \prod_{i=1}^N \frac{\lambda_i - z}{\lambda_i},$$

e osservando che tale polinomio ha radici in corrispondenza agli autovalori di  $A$ , si ottiene immediatamente:

$$\|x_N - x^*\|_A \leq \max_{z \in \lambda(A)} |p_k^*(z)| = 0.$$

Con ragionamento simile, si vede che se  $A$  ha  $m < N$  autovalori distinti, CG converge in al massimo  $m$  iterazioni. Lo stesso accade nel caso in cui il termine noto sia una combinazione

lineare di  $m$  autovettori della matrice  $A$ , e si parta da  $x_0 = 0$ . Dalla simmetria della matrice e dalla compatibilità della norma matriciale di Hilbert con la norma euclidea dei vettori, ricordando la (4), si ottiene immediatamente:

$$\frac{\|r_k\|_2}{\|r_0\|_2} = \frac{\|b - Ax_k\|_2}{\|b - Ax_0\|_2} = \frac{\|A(x_k - x^*)\|_2}{\|A(x_0 - x^*)\|_2} \leq \sqrt{\frac{\lambda_1}{\lambda_N}} \frac{\|x_k - x^*\|_A}{\|x_0 - x^*\|_A},$$

dove  $\lambda_1$  e  $\lambda_N$  sono rispettivamente l'autovalore massimo e quello minimo della matrice  $A$ .

Usando i polinomi di Chebyshev, è possibile dimostrare il seguente risultato di convergenza dello schema CG:

$$\frac{\|x_k - x^*\|_A}{\|x_0 - x^*\|_A} \leq 2 \left( \frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k,$$

dove  $\kappa(A) = \lambda_1/\lambda_N$  è l'indice di condizionamento della matrice  $A$ . Il risultato mostra che il numero di iterazioni che CG impiega per arrivare a convergenza è proporzionale alla radice del numero di condizionamento di  $A$ . Possiamo quindi calcolare il numero  $m$  di iterazioni necessario per ridurre l'errore iniziale di un fattore  $\epsilon$ . Infatti basta imporre che:

$$2 \left( \frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^m < \epsilon,$$

da cui, prendendo i logaritmi e notando che

$$\log \left( \frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right) \sim -\frac{1}{\sqrt{\kappa(A)}}$$

per valori grandi di  $\kappa(A)$ , si ottiene immediatamente:

$$m \geq \frac{1}{2} \sqrt{\kappa(A)} \log \frac{2}{\epsilon}.$$

Si noti che la convergenza di CG risulta più veloce di quella di SD per la presenza della radice del numero di condizionamento di  $A$  (si veda l'eq. (18)). Inoltre, la convergenza è accelerata se  $\kappa(A)$  si avvicina a 1, ovvero se  $\lambda_1 \approx \lambda_N$ . Questa osservazione ci permette di cercare di migliorare la convergenza del metodo tramite la tecnica di “precondizionamento”, secondo la quale si cerca di trasformare il sistema originale in uno equivalente che ha indice di condizionamento il più possibile vicino a 1.

### 3.2.5 Precondizionamento di CG: Metodo PCG

Il precondizionamento del metodo CG serve a ridurre il numero di condizionamento della matrice  $A$ , in modo da accelerare la convergenza dello schema. Lo scopo è quello di arrivare ad una

soluzione accettabile (i.e., con un residuo sufficientemente piccolo) in un numero di iterazioni che generalmente è molto minore della dimensione della matrice. Per fare questo riscriviamo il problema iniziale premoltiplicandolo per una matrice  $P$  simmetrica e definita positiva, che approssimi  $A$  ma sia facile da invertire:

$$P^{-1}Ax = P^{-1}b.$$

In realtà, per migliorare la convergenza di CG applicato a questo sistema bisogna richiedere:

$$1 \leq \kappa(P^{-1}A) \ll \kappa(A) \tag{29}$$

(idealmente  $\kappa(P^{-1}A) \approx 1$ ). Il problema fondamentale con quanto scritto è che la nuova matrice  $B = P^{-1}A$  non è più simmetrica nè positiva definita, per cui non si può applicare il metodo CG.

Si può però procedere ricordandoci dell'esistenza delle trasformazioni di similitudine, discusse nel paragrafo 2.2. E' possibile infatti scrivere la matrice di preconditionamento  $P$  come prodotto di due matrici che risultino facili da invertire. In tal caso otteniamo:

$$\begin{aligned} P &= E^T E & P^{-1} &= E^{-T} E^{-1} \\ B &= E^{-1} A E^{-T} & \lambda(B) &= \lambda(P^{-1}A) \end{aligned}$$

e il nuovo sistema da risolvere si può scrivere quindi:

$$By = c \quad \text{con} \quad B = E^{-1} A E^{-T} \quad y = E^T x \quad c = E^{-1} b. \tag{30}$$

Tale sistema ha le stesse soluzioni di quello originale e  $B$  è simmetrica e definita positiva con un indice di condizionamento minore di quello di  $A$  (vedi la (29)). Dal punto di vista geometrico, possiamo dire che gli iperelissoidi che rappresentano le curve di livello della forma quadratica che andiamo a minimizzare saranno molto più vicine a delle ipersfere nel caso del sistema preconditionato, con evidenti vantaggi in termini di allineamento precoce della direzione di ricerca con il centro di tali iperelissoidi (e quindi il minimo della forma quadratica).

Applicando il metodo di CG al nuovo sistema (30), con qualche passaggio si arriva alle seguenti equazioni del "Preconditioned Conjugate Gradient" (PCG) algoritmo:

```

ALGORITHM PCG
Input:  $x_0, n_{imax}, toll; k = 0;$ 
 $r_0 = b - Ax_0$   $p_0 = P^{-1}r_0$ 
FOR  $k = 0, 1, \dots$  fino a convergenza:
    1.  $\alpha_k = \frac{\langle p_k, r_k \rangle}{\langle p_k, Ap_k \rangle}$  (31)
    2.  $x_{k+1} = x_k + \alpha_k p_k$  (32)
    3.  $r_{k+1} = r_k - \alpha_k Ap_k$  (33)
    4.  $\beta_k = -\frac{\langle P^{-1}r_{k+1}, Ap_k \rangle}{\langle p_k, Ap_k \rangle}$  (34)
    5.  $p_{k+1} = P^{-1}r_{k+1} + \beta_k p_k$  (35)
END FOR

```

Si noti che è sufficiente applicare il preconditionatore solamente una volta al vettore  $r_{k+1}$ , salvando il risultato per utilizzarlo poi sia in (34) che in (35).

La definizione del preconditionatore più efficiente per un dato problema è generalmente difficile e non esistono metodi generali. Per i sistemi che scaturiscono dalla discretizzazione (agli elementi finiti o alle differenze finite) di equazioni differenziali, si usano spesso due tipi di preconditionatori: il semplice preconditionatore diagonale di Jacobi e la decomposta Incompleta di Cholesky (IC(0)).

Il preconditionatore diagonale di Jacobi (Jacobi diagonal scaling) corrisponde alla scelta:

$$P = D \quad p_{ij} = \begin{cases} a_{ij}, & \text{se } i = j, \\ 0, & \text{se } i \neq j. \end{cases}$$

ed è di facilissima applicazione, anche se la sua efficienza non è elevatissima.

Il più usato, perchè spesso più efficiente, è dato dalla decomposta Incompleta di Cholesky senza fill-in. Tale preconditionatore è facilmente definito a partire dalla fattorizzazione di Cholesky della matrice  $A = LL^T$  imponendo a priori lo stesso pattern di sparsità della matrice  $A$ . In altre parole, detti  $l_{ij}$  gli elementi della matrice (triangolare) fattorizzata di Cholesky, il preconditionatore IC(0) è dato da:

$$P = EE^T \quad e_{ij} = \begin{cases} l_{ij}, & \text{se } a_{ij} \neq 0, \\ 0, & \text{se } a_{ij} = 0. \end{cases}$$

### 3.2.6 Implementazione all'elaboratore del PCG

In realtà l'implementazione del metodo PCG si deve fare prendendo in considerazione il fatto che le operazioni più costose sono il prodotto matrice vettore e l'applicazione del preconditionatore ad un vettore, per cui tali operazioni vanno effettuate solo se necessarie. Per questo, si preferisce

salvare i vettori risultanti e riutilizzarli opportunamente. L'algoritmo completo può quindi essere scritto così':

```

ALGORITHM PCG
Input:  $A, P, b, x_0, nimax, toll; k = 1;$ 
 $x = x_0, r = r_0 = b - Ax_0, \rho_0 = \|r\|_2^2$ 
DO WHILE  $\sqrt{\rho_{k-1}} > toll \|b\|_2$  and  $k < nimax$ :

    1.       $z = P^{-1}r$ 
    2.       $\tau_{k-1} = z^T r$ 
    3.      if  $k = 1$  then
                 $\beta = 0$ 
                 $p = z$ 
            else
                 $\beta = \tau_{k-1} / \tau_{k-2}$ 
                 $p = z + \beta p$ 
            end if
    4.       $w = Ap$ 
    5.       $\alpha = \tau_{k-1} / p^T w$ 
    6.       $x = x + \alpha p$ 
    7.       $r = r - \alpha w$ 
    8.       $\rho_k = r^T r$ 
    9.       $k = k + 1$ 

END FOR

```

Questo algoritmo prevede di memorizzare la matrice  $A$ , il preconditionatore  $P$  e 6 vettori:  $b, x, r, z, p$  e  $w$ .

Usando il preconditionatore IC(0), il punto 1. dell'algoritmo precedente viene svolto risolvendo il sistema lineare  $Pz = (EE^T)z = r$  tramite una sostituzione in avanti ed una indietro:

$$Ey = r$$

$$E^T z = y.$$

### 3.2.7 Metodo delle correzioni residue

Il metodo delle correzioni residue (CR) si utilizza spesso per calcolare una soluzione iniziale per il PCG. In pratica tale metodo è una modifica del metodo iterativo di Richardson che utilizza

come matrice di iterazione la matrice

$$E = (I - P^{-1}A),$$

per cui, partendo dalla soluzione iniziale  $x_0 = 0$  si hanno le seguenti iterate:

$$\begin{aligned} x_0 &= P^{-1}b \\ x_1 &= x_0 + P^{-1}r_0 \\ x_2 &= x_1 + P^{-1}r_1 \\ &\dots \\ x_{k+1} &= x_k + P^{-1}r_k. \end{aligned}$$

Di solito una iterazione è sufficiente per eliminare tutte le componenti dell'errore corrispondenti ad autovettori unitari della matrice  $P^{-1}A$ . Infatti, l'errore dello schema precedente può essere scritto come:

$$e_{k+1} = (I - P^{-1}A)^k e_0.$$

Notando che la matrice  $P^{-1}A$  è diagonalizzabile, si vede immediatamente che l'errore alla  $k$ -esima iterazione è dato da

$$e_k = \sum_{j=1}^n (1 - \lambda_j)^k c_j v_j,$$

essendo  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_N$  gli autovalori di  $P^{-1}A$  ordinati in senso decrescente e i vettori  $v_j$ ,  $j = 1, \dots, N$  i corrispondenti autovettori. Si vede subito che una iterazione del metodo CR azzerava tutte le componenti dell'errore relative agli autovettori associati agli autovalori di  $P^{-1}A$  unitari.

### 3.2.8 Esempi di applicazione

Si riportano qui di seguito due esempi di applicazione del metodo PCG preconditionato con IC(0) (la decomposta incompleta di Cholesky).

Il primo esempio riguarda una matrice di dimensioni  $n = 28600$ , derivante dalla discretizzazione spaziale tramite il metodo agli elementi finiti misti (ibridizzati) di un'equazione ellittica a coefficienti variabili nello spazio. La matrice è simmetrica e definita positiva ed è caratterizzata da un numero di elementi non nulli pari a 201200, circa lo 0.02% degli elementi totali ( $n^2$ ). La soluzione è stata ottenuta con un processore Pentium 4 a 2 GHz in circa 10 secondi. Il pattern degli elementi non nulli è mostrato in Figura 15.

Il secondo esempio è relativo ad una matrice di dimensioni  $n = 80711$ , avente un numero di elementi non nulli pari a 432000, circa lo 0.07% degli elementi totali ( $n^2$ ) (Figura 16). La matrice è relativa ad una discretizzazione di un sistema di equazioni di diffusione tramite un




Figura 15: Pattern spaziali degli elementi non nulli della matrice  $n = 28600$ . A destra è disegnata l'intera matrice, a sinistra si riporta uno zoom del riquadro in alto a sinistra.




Figura 16: Pattern spaziali degli elementi non nulli della matrice  $n = 80711$ . A destra è disegnata l'intera matrice, a sinistra si riporta uno zoom del riquadro in alto a sinistra.




Figura 17: Profili di convergenza del metodo PCG con preconditionatore di Choleky per la matrice  $n = 28600$  (sinistra) e  $n = 80711$  (destra).

metodo misto di elementi finiti alla Galerkin con elementi triangolari e un metodo alle differenze finite. La soluzione ha impiegato circa 5 secondi.

I profili di convergenza del metodo PCG per le due matrici sono riportati in Figura 17, a destra quello relativo alla prima matrice, e a sinistra quello relativo alla seconda. Si noti il comportamento del residuo calcolato tramite la formula ricorrente del PCG, che continua a decrescere, mentre il residuo vero si stabilizza alla precisione di macchina (circa  $10^{-16}$ ).

### 3.2.9 Implementazione pratica del metodo PCG

Per l'applicazione ottimale del PCG è necessario minimizzare i costi del prodotto matrice-vettore e dell'applicazione del preconditionatore. Ciò viene effettuato in general sfruttando la caratteristica di sparsità tipica delle matrici che derivano da discretizzazioni di equazioni differenziali e quindi memorizzando solamente gli elementi non nulli della matrice e effettuando le operazioni solo su di essi.

Il modo in cui viene memorizzata la matrice  $A$  del sistema è detto Compressed Row Storage (CRS).

**Caso non simmetrico.** Data una generica matrice  $A$  quadrata di ordine  $n$ , la tecnica di memorizzazione CRS prevede la generazione di 3 vettori:

1. **SYSMAT**: vettore di numeri reali contenente gli  $nt$  coefficienti non nulli della matrice  $A$  memorizzati in successione per righe;
2. **JA**: vettore di numeri interi contenente gli  $nt$  indici di colonna dei corrispondenti elementi memorizzati in **SYSMAT**;



Si noti che che le componenti di **IA** sono necessariamente ordinate in senso strettamente crescente e che  $\mathbf{IA}(n+1) = nt + 1$ . Ciò si deduce immediatamente dal fatto che per individuare un elemento  $a_{ij}$  dell'ultima riga di  $A$  si deve cercare l'indice  $k$  della componente in **SYSMAT** nell'intervallo  $\mathbf{IA}(n) \leq k \leq \mathbf{IA}(n+1) - 1$ .

**Caso simmetrico** Nel caso in cui la matrice  $A$  sia simmetrica, come accade ad esempio nella soluzione agli elementi finiti dell'equazione differenziale ellittica di Laplace, il risparmio computazionale derivato dal sistema CRS viene incrementato memorizzando la sola parte triangolare alta, inclusa la diagonale principale, di  $A$ . In altri termini, vengono memorizzati solo i coefficienti  $a_{ij} \neq 0$  con  $j \geq i$  e si sfrutta la proprietà  $A$  secondo cui  $a_{ij} = a_{ji}$ .

La memorizzazione di  $A$  viene effettuata sempre mediante i tre vettori **SYSMAT**, **JA** e **IA** definiti nel paragrafo precedente, in cui tuttavia  $nt$  rappresenta il numero di coefficienti non nulli della triangolare alta e **IA** contiene le posizioni in cui si trova in **SYSMAT** l'elemento diagonale di ciascuna riga di  $A$ .

Anche in questo caso facciamo un esempio numerico per rendere più chiaro il concetto. Si consideri la seguente matrice  $A$  di dimensione  $7 \times 7$ , sparsa e simmetrica:

$$A = \begin{bmatrix} 10 & 0 & 0 & 0 & 1 & 0 & 2 \\ 0 & 1 & 0 & 3 & 0 & -1 & 0 \\ 0 & 0 & 4 & 0 & 0 & 0 & 1 \\ 0 & 3 & 0 & 2 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 5 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 & 1 & 0 \\ 2 & 0 & 1 & 0 & 0 & 0 & 20 \end{bmatrix}.$$

Gli elementi non nulli sono 19, mentre se fosse piena ne avremmo 49. Tuttavia i coefficienti da memorizzare sono solamente quelli relativi alla parte superiore di  $A$ , di seguito evidenziati:

$$A' = \begin{bmatrix} \boxed{10} & & & & \boxed{1} & & \boxed{2} \\ & \boxed{1} & & \boxed{3} & & \boxed{-1} & \\ & & \boxed{4} & & & & \boxed{1} \\ & 3 & & \boxed{2} & \boxed{1} & & \\ 1 & & & 1 & \boxed{5} & & \\ & -1 & & & & \boxed{1} & \\ 2 & & 1 & & & & \boxed{20} \end{bmatrix}.$$

Il vettore **SYSMAT** avrà perciò dimensione  $nt = 13$  (7 elementi diagonali più 6 extra-diagonali) anziché 19, con un risparmio di memoria superiore al 30%, e sarà dato da:

$$\overbrace{10 \ 1 \ 2 \ 1 \ 3 \ -1 \ 4 \ 1 \ 2 \ 1 \ 5 \ 1 \ 20}^{nt}.$$

Il vettore **JA** con gli indici di colonna corrispondenti ha la stessa dimensione di **SYSMAT** e risulta:

$$\overbrace{1 \ 5 \ 7 \ 2 \ 4 \ 6 \ 3 \ 7 \ 4 \ 5 \ 5 \ 6 \ 7}^{nt} .$$

Infine, il vettore **IA** possiede sempre dimensione  $n + 1$  ed individua la posizione in **SYSMAT** degli elementi diagonali:

$$\overbrace{1 \ 4 \ 7 \ 9 \ 11 \ 12 \ 13 \ 14}^{n+1} .$$

Ad esempio,  $\mathbf{IA}(3)=7$  significa che  $a_{33}$  è memorizzato in **SYSMAT**(7), come confermato anche dal fatto che  $\mathbf{JA}(7)=3$ .

Come nel caso di matrici non simmetriche, si pone  $\mathbf{IA}(n + 1) = nt + 1$ . Si noti anche che dovrà sempre essere  $\mathbf{IA}(1)=1$  e  $\mathbf{IA}(n) = nt$ , nonché  $\mathbf{JA}(1)=1$  e  $\mathbf{JA}(nt) = n$ .

**Implementazione del prodotto matrice-vettore** Lo schema del GCM necessita dell'operazione del prodotto matrice-vettore. L'implementazione di tale operazione al calcolatore risulta del tutto banale nel caso di memorizzazione tabellare della matrice, mentre è necessaria qualche attenzione qualora si utilizzi il sistema di rappresentazione CRS. Nel seguito distingueremo fra l'implementazione del prodotto matrice-vettore per matrici non simmetriche, più intuitivo, e per matrici simmetriche in cui si memorizza la sola triangolare alta.

**Caso non simmetrico** Si vuole calcolare il prodotto matrice-vettore:

$$Av = w \tag{36}$$

con  $A$  matrice quadrata non simmetrica di ordine  $n$ ,  $v$  e  $w$  vettori in  $\mathbb{R}^n$ . Si ricorda che la componente  $i$ -esima di  $w$  è pari alla somma dei prodotti degli elementi della riga  $i$  di  $A$  per i corrispondenti elementi di  $v$ :

$$w_i = \sum_{j=1}^n a_{ij}v_j \tag{37}$$

Se la matrice è memorizzata in modo compatto, gli elementi  $a_{ij}$  vanno opportunamente ricercati in **SYSMAT** mediante l'uso di **IA**, mentre gli indici  $j$  relativi alle colonne si trovano nel vettore intero **JA**. In particolare, gli elementi di  $A$  appartenenti alla riga  $i$  sono memorizzati in corrispondenza agli indici  $k$  del vettore **SYSMAT** compresi, per definizione di **IA**, nell'intervallo  $\mathbf{IA}(i) \leq k \leq \mathbf{IA}(i + 1) - 1$ . Gli indici di colonna  $j$ , di conseguenza, sono memorizzati in  $\mathbf{JA}(k)$ .

Il prodotto matrice-vettore con  $A$  non simmetrica e memorizzata in forma compatta può quindi essere calcolato implementando il seguente algoritmo:

```

001     Per  $i = 1, n$ 
002         azzero  $w_i$ 
003         Per  $k = \text{IA}(i), \text{IA}(i + 1) - 1$ 
004              $j := \text{JA}(k)$ 
005              $w_i := w_i + \text{SYSMAT}(k) \cdot v_j$ 
006         Fine Per
007     Fine Per

```

Si noti che è sempre utile azzerare il vettore soluzione prima di procedere all'implementazione del ciclo di sommatoria (riga 2), al fine di evitare l'uso improprio di valori precedentemente contenuti in  $w$ .

**Caso simmetrico** Si vuole ora calcolare il prodotto (36) in cui la matrice simmetrica  $A$  è memorizzata in formato CRS come descritto prima (e quindi memorizzando solo la parte triangolare. Poiché gli elementi  $a_{ij}$  con  $j < i$  non sono ora immediatamente disponibili nella sequenza di coefficienti della riga  $i$ , conviene scrivere la definizione (37) come:

$$w_i = \sum_{j=1}^{i-1} a_{ji}v_j + \sum_{j=i}^n a_{ij}v_j \quad (38)$$

avendo sfruttato la condizione per cui  $a_{ij} = a_{ji}$ . Dalla (38) si deduce che il contributo a  $w_i$  relativo agli elementi con  $j \geq i$  può essere implementato in maniera del tutto analoga a quanto fatto nel paragrafo precedente, mentre il contributo relativo agli elementi con  $j < i$  può essere determinato selezionando in **SYSMAT** le componenti  $k$  per cui  $\text{JA}(k) = i$ , cioè appartenenti alla colonna  $i$ -esima. E' del tutto evidente, tuttavia, che questo modo di procedere, seppure intuitivo, risulta inapplicabile da un punto di vista pratico. Sarebbe, infatti, necessario procedere ad una ricerca su  $nt$  componenti per  $n$  volte, con un dispendio che renderebbe inutile il vantaggio fornito dalla memorizzazione compatta della matrice e, in certi casi, dalla convergenza accelerata del GCM.

Conviene osservare che gli elementi della triangolare alta della riga  $i$ , oltre a contribuire al calcolo di  $w_i$ , entrano in gioco, in virtù della simmetria di  $A$ , anche nel calcolo di  $w_j$ , con  $j$  pari all'indice di colonna dell'elemento considerato. All'interno del medesimo ciclo sulle righe  $i$  si aggiornerà pertanto non solo  $w_i$  ma anche tutti i  $w_j$  corrispondenti. L'algoritmo descritto nel precedente paragrafo viene quindi modificato nel modo seguente:

```

001     Per  $i = 1, n$ 
002         azzero  $w_i$ 
003     Fine Per
004     Per  $i = 1, n$ 

```

```

005          $k := \text{IA}(i)$ 
006          $w_i := w_i + \text{SYSMAT}(k) \cdot v_i$ 
007         Per  $k = \text{IA}(i) + 1, \text{IA}(i + 1) - 1$ 
008              $j := \text{JA}(k)$ 
009              $w_i := w_i + \text{SYSMAT}(k) \cdot v_j$ 
010              $w_j := w_j + \text{SYSMAT}(k) \cdot v_i$ 
011         Fine Per
012     Fine Per

```

Si noti che, a differenza dell'algoritmo utilizzato per matrici non simmetriche, in questo caso l'azzeramento del vettore prodotto  $w$  va fatto con un ulteriore ciclo (righe 1-3) esterno a quello di calcolo di  $w$ . Inoltre, il contributo a  $w_i$  dato dall'elemento diagonale  $a_{ii}$  viene conteggiato a parte (riga 6) per evitare di considerarlo due volte nel ciclo successivo (corrisponde infatti al caso in cui  $i = j$ ).

### 3.2.10 Calcolo del preconditionatore

Una delle chiavi del successo del GCM nella soluzione efficiente di sistemi lineari sparsi, simmetrici e definiti positivi sta nella possibilità di ottenere formidabili accelerazioni della convergenza mediante l'uso di opportune matrici di preconditionamento. La scelta di  $K^{-1}$  deve soddisfare alle seguenti caratteristiche:

- deve essere tale che il prodotto  $AK^{-1}$  abbia lo spettro, cioè l'insieme degli autovalori, raggruppato attorno all'unità e comunque un numero di condizionamento spettrale inferiore a quello di  $A$ ;
- il calcolo deve essere semplice e poco costoso per non appesantire lo schema;
- l'occupazione di memoria deve essere inferiore o al più paragonabile a quella della matrice del sistema allo scopo di non vanificare lo sforzo computazionale effettuato per la memorizzazione compatta.

Spesso le suddette caratteristiche confliggono fra loro e necessariamente la scelta di  $K^{-1}$  diventa il risultato di un compromesso. Per paradosso, la matrice che soddisfa completamente la prima richiesta è ovviamente  $A^{-1}$ , il cui costo ed occupazione di memoria (si ricordi che l'inversa di una matrice sparsa è generalmente una matrice piena) tuttavia rendono del tutto incalcolabile.

Una discreta accelerazione del metodo del GC è ottenuta scegliendo:

$$K^{-1} = D^{-1} \tag{39}$$

dove  $D$  è la matrice diagonale contenente gli elementi diagonali di  $A$ . In questo caso, il calcolo della matrice di preconditionamento e la sua applicazione nello schema del GCM risultano banali

e vengono lasciati per esercizio al lettore. Il raggruppamento degli autovalori attorno all'unità di  $AD^{-1}$ , tuttavia, può essere limitato, specialmente se  $A$  presenta coefficienti extra-diagonali grandi rispetto agli elementi diagonali.

Risultati assai più significativi sono invece ottenuti assumendo:

$$K^{-1} = (\tilde{L}\tilde{L}^T)^{-1} \quad (40)$$

dove  $\tilde{L}$ , matrice triangolare bassa, è calcolata mediante la fattorizzazione incompleta di  $A$ , cioè la decomposta di Cholesky a cui viene assegnato il medesimo schema di sparsità di  $A$ . L'uso di questa matrice di preconditionamento, proposto negli anni '70 da Kershaw, si rivela generalmente un ottimo compromesso fra le contrapposte esigenze precedentemente discusse. Il calcolo di  $K^{-1}$  secondo la (40) e la sua applicazione nell'algoritmo del GCM verranno esaminati nei due paragrafi seguenti.

**Fattore incompleto di Cholesky secondo Kershaw** Il calcolo del fattore incompleto di Cholesky si basa sulla fattorizzazione triangolare di matrici simmetriche che viene di seguito brevemente richiamata. Poichè con la memorizzazione compatta di  $A$  vengono conservati i soli elementi appartenenti alla triangolare alta, conviene riscrivere la (40) come:

$$K^{-1} = (\tilde{U}^T\tilde{U})^{-1} \quad (41)$$

dove  $\tilde{U} = \tilde{L}^T$ . Supponiamo che  $A$  sia una matrice  $3 \times 3$  piena di cui svolgiamo per esteso la fattorizzazione:

$$\begin{bmatrix} u_{11} & 0 & 0 \\ u_{12} & u_{22} & 0 \\ u_{13} & u_{23} & u_{33} \end{bmatrix} \begin{bmatrix} u_{11} & u_{12} & u_{13} \\ 0 & u_{22} & u_{23} \\ 0 & 0 & u_{33} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{12} & a_{22} & a_{23} \\ a_{13} & a_{23} & a_{33} \end{bmatrix} \quad (42)$$

Si noti che nella (42) si è sfruttata la simmetria di  $A$  ed il fatto che i soli elementi  $a_{ij}$  memorizzati sono quelli per cui  $j \geq i$ .

Sviluppiamo il prodotto (42) procedendo secondo la successione delle righe di  $A$ . Per la prima riga vale:

$$\begin{aligned} a_{11} = u_{11}^2 &\Rightarrow u_{11} = \sqrt{a_{11}} \\ a_{12} = u_{11}u_{12} &\Rightarrow u_{12} = \frac{a_{12}}{u_{11}} \\ a_{13} = u_{11}u_{13} &\Rightarrow u_{13} = \frac{a_{13}}{u_{11}} \end{aligned} \quad (43)$$

Si può osservare che i coefficienti sottodiagonali di  $A$  vengono di volta in volta già utilizzati nel calcolo delle righe superiori a quella corrente. Si procede, pertanto, con le righe 2 e 3

considerando i soli termini relativi alla triangolare alta di  $A$ :

$$\begin{aligned}
a_{22} = u_{12}^2 + u_{22}^2 &\Rightarrow u_{22} = \sqrt{a_{22} - u_{12}^2} \\
a_{23} = u_{12}u_{13} + u_{22}u_{23} &\Rightarrow u_{23} = \frac{1}{u_{22}} (a_{23} - u_{12}u_{13}) \\
a_{33} = u_{13}^2 + u_{23}^2 + u_{33}^2 &\Rightarrow u_{33} = \sqrt{a_{33} - u_{13}^2 - u_{23}^2}
\end{aligned} \tag{44}$$

Dalle (43) e (44) si può facilmente generalizzare l'algoritmo di calcolo del fattore completo di Cholesky per una matrice di ordine  $n$ :

```

001     u11 := √a11
002     Per j = 2, n
003         u1j := a1j/u11
004     Fine Per
005     Per i = 2, n
006         uii := √(aii - ∑l=1i-1 uli2)
007         Per j = i + 1, n
008             uij := (aij - ∑l=1i-1 uli ulj) / uii
009         Fine Per
010     Fine Per

```

Il passaggio concettuale dal fattore completo di Cholesky a quello incompleto secondo Kershaw risulta a questo punto banale, in quanto all'algoritmo precedente è sufficiente aggiungere l'assegnazione:

$$a_{ij} = 0 \Rightarrow u_{ij} := 0 \tag{45}$$

Poiché  $A$  è memorizzata in modo compatto, e così anche  $\tilde{U}$ , si deduce immediatamente che, in virtù dell'assegnazione (45), i vettori IA e JA descrivono anche la topologia di  $\tilde{U}$  per la quale sarà sufficiente adottare un vettore PREC contenente i coefficienti non nulli memorizzati sequenzialmente per righe.

Il nuovo algoritmo di calcolo del fattore incompleto di Cholesky secondo Kershaw con la memorizzazione in formato CRS risulta pertanto:

```

001     PREC(1) := √SYSMAT(1)
002     Per k = IA(1)+1, IA(2)-1
003         PREC(k) := SYSMAT(k)/PREC(1)

```

```

004     Fine Per
005     Per  $i = 2, n$ 
006          $k := \text{IA}(i)$ 
007          $l :=$  ogni  $k < \text{IA}(i)$  per cui  $\text{JA}(k) = i$ 
008          $\text{PREC}(k) := \sqrt{\text{SYSMAT}(k) - \sum_l \text{PREC}(l)^2}$ 
009         Per  $k1 = \text{IA}(i) + 1, \text{IA}(i + 1) - 1$ 
010              $j := \text{JA}(k1)$ 
011              $l1 :=$  ogni  $k < \text{IA}(i)$  per cui  $\text{JA}(k) = i$ 
012              $l2 :=$  ogni  $k < \text{IA}(i)$  per cui  $\text{JA}(k) = j$ 
013              $\text{PREC}(k1) := \left( \text{SYSMAT}(k1) - \sum_{l1, l2} \text{PREC}(l1) \cdot \text{PREC}(l2) \right) / \text{PREC}(k)$ 
014     Fine Per
015     Fine Per

```

Va osservato, tuttavia, che l'implementazione efficiente delle sommatorie in riga 8 e 13 sugli indici  $l, l1$  ed  $l2$  è in realtà non banale e va preferibilmente effettuata calcolando separatamente il contributo del coefficiente relativo al  $k$  corrente in modo da evitare le dispendiose ricerche previste in riga 7, 11 e 12. Tale implementazione è effettuata nella subroutine **KERSH** a disposizione dello studente.

Si deve infine ricordare che l'uso generalizzato delle (43) e (44) comporta l'estrazione di radici quadrate il cui argomento, nel caso di una fattorizzazione incompleta, non è più garantito essere positivo. In questo caso l'elemento diagonale in questione verrà posto pari ad un numero positivo arbitrario (ad esempio, l'ultimo coefficiente diagonale di  $\tilde{U}$  non nullo). Si dimostra comunque teoricamente che se la matrice  $A$  è di tipo M, come ad esempio si verifica nella discretizzazione agli elementi finiti dell'equazione ellittica di Laplace se si utilizzano funzioni di base lineari definite su una triangolazione di Delaunay, tutte le radici da calcolare nel fattore incompleto esistono nel campo reale.

**Applicazione della decomposta incompleta** Mediante l'algoritmo sviluppato nel precedente paragrafo non si calcola esplicitamente la matrice di preconditionamento  $K^{-1}$  ma solamente il fattore incompleto  $\tilde{U}$ . E' quindi necessario sviluppare un algoritmo ad hoc che permetta di calcolare il generico prodotto  $K^{-1}v$  senza generare esplicitamente  $K^{-1}$ . Sia quindi  $w$  il vettore in  $\mathbb{R}^n$  risultato del prodotto  $K^{-1}v$ . Per definizione di  $K^{-1}$  si ha:

$$w = \left( \tilde{U}^T \tilde{U} \right)^{-1} v \quad (46)$$

cioè, premoltiplicando per  $K$  ambo i membri:

$$\left( \tilde{U}^T \tilde{U} \right) w = v \quad (47)$$




Figura 18: Schema della soluzione del sistema con sostituzioni in avanti.

Il calcolo di  $w$  viene quindi ricondotto alla soluzione di un sistema lineare la cui matrice è  $K$ . Poiché  $K$  è fattorizzabile nel prodotto di due matrici triangolari, il sistema (47) è risolvibile tramite sostituzioni in avanti e all'indietro. Posto:

$$\tilde{U}w = z \tag{48}$$

la (47) diventa:

$$\tilde{U}^T z = v \tag{49}$$

che si può facilmente risolvere con sostituzioni in avanti (Figura 18). Iniziando dalla prima componente, ricavata in modo immediato come:

$$z_1 = \frac{v_1}{u_{11}} \tag{50}$$

si ottiene con semplici calcoli la formula ricorrente:

$$z_i = \frac{1}{u_{ii}} \left( v_i - \sum_{j=1}^{i-1} u_{ji} z_j \right) \quad i = 2, \dots, n \tag{51}$$

Come osservato per il prodotto matrice-vettore e per la determinazione del fattore incompleto di Cholesky, la sommatoria contenuta in (51) non è banale da implementare in modo efficiente memorizzando le matrici secondo il sistema CRS. A tal proposito, risulta conveniente definire un vettore di accumulazione  $s$  nelle cui componenti viene aggiornato il prodotto contenuto nella sommatoria dell'equazione (51) procedendo per righe di  $\tilde{U}$ . L'algoritmo per il calcolo del vettore  $z$  può pertanto essere scritto come:

```

001   Per  $j = 1, n$ 
002       azzero  $s_j$ 
003   Fine Per
004        $z_1 := v_1 / \text{PREC}(1)$ 

```




Figura 19: Schema della soluzione del sistema con sostituzioni all'indietro.

```

005   Per  $i = 2, n$ 
006        $k := \text{IA}(i)$ 
006       Per  $k1 = \text{IA}(i - 1) + 1, \text{IA}(i) - 1$ 
007            $j := \text{JA}(k1)$ 
008            $s_j := s_j + \text{PREC}(k1) \cdot z_{i-1}$ 
009       Fine Per
010        $z_i := (v_i - s_i) / \text{PREC}(k)$ 
011   Fine Per

```

Ottenuto il vettore  $z$  si può infine calcolare  $w$  risolvendo il sistema (48) tramite sostituzioni all'indietro (Figura 19). La formula ricorrente si ricava in modo del tutto analogo a quanto fatto nelle equazioni (50) e (51) partendo in questo caso dalla componente  $n$ -esima:

$$w_n = \frac{z_n}{u_{nn}} \quad (52)$$

$$w_i = \frac{1}{u_{ii}} \left( z_i - \sum_{j=i+1}^n u_{ij} w_j \right) \quad i = n - 1, \dots, 1 \quad (53)$$

L'implementazione della (19) risulta stavolta molto semplice anche memorizzando la matrice  $\tilde{U}$  in forma compatta. Sempre utilizzando il vettore di accumulo  $s$ , l'algoritmo corrispondente può essere scritto nel modo seguente:

```

001    $w_n := z_n / \text{PREC}(nt)$ 
002   Per  $i = n - 1, 1$  con passo -1
003       azzero  $s_i$ 
004        $k := \text{IA}(i)$ 
005       Per  $k1 = \text{IA}(i) + 1, \text{IA}(i + 1) - 1$ 
006            $j := \text{JA}(k1)$ 
007            $s_i := s_i + \text{PREC}(k1) \cdot w_j$ 

```

008            **Fine Per**  
009             $w_i := (z_i - s_i) / \text{PREC}(k)$   
010        **Fine Per**

Per un confronto, viene messa a disposizione dello studente la subroutine LSOLVE che implementa gli algoritmi soprariportati.

## Riferimenti bibliografici

- [1] G. Gambolati. *Lezioni di metodi numerici per ingegneria e scienze applicate*. Cortina, Padova, Italy, 2 edition, 2002. 619 pp.
- [2] C. T. Kelley. *Iterative Methods for Linear and Nonlinear Equations*. SIAM, Philadelphia, 1995.
- [3] Y. Saad. *Iterative Methods for Sparse Linear Systems. Second edition*. SIAM, Philadelphia, PA, 2003.
- [4] J. R. Shewchuk. An introduction to the conjugate gradient method without the agonizing pain. Technical report, Pittsburgh, PA, USA, 1994.