

ESERCITAZIONI DI ANALISI NUMERICA *

A. SOMMARIVA [†] E M.R. RUSSO [‡]

1. Alcuni problemi della teoria dell'approssimazione.

1.1. Costanti di Lebesgue. Dato un set di punti distinti $X = \{x_0, \dots, x_n\}$ nell'intervallo chiuso e limitato $[a, b]$ si definisce *costante di Lebesgue* la quantità

$$\Lambda_n := \max_{x \in [a, b]} \sum_{i=0}^n |L_i(x)|$$

con al solito L_i i -simo polinomio di Lagrange (relativamente al set $x_0, \dots, x_n$). Sia ora $\phi_0, \dots, \phi_n$ una base per lo spazio $\mathbb{P}_n$ dei polinomi di grado n . Sia $V_n(X)$ la matrice di Vandermonde del set di punti X rispetto alla base $\phi_0, \dots, \phi_n$. Sia $Y \subset [a, b]$ un sottoinsieme di discreto con cardinalità finita. Se VX e VY sono rispettivamente $V_n(X)$ e $V_n(Y)$ allora, se l'insieme Y è sufficientemente *fitto*, una buona stima della costante di Lebesgue è data da

```
leb_const=norm(VX'\VY',1);
```

D'altra parte un esempio di base è

```
function V = chebvand(deg, mymesh, intv)

% computes the Chebyshev-Vandermonde matrix at a 1d mesh
% in Chebyshev basis of a rectangle containing
% the mesh points

% INPUT:

% deg = polynomial degree;
% mymesh = 1-columns array of mesh points coordinates;
% intv = interval that contains the mesh.

%OUTPUT:

% V = Chebyshev-Vandermonde matrix

%FUNCTION BODY

if nargin < 3
    intv=[-1 1];
end

% CHEBYSHEV BASIS. SCALED.
a=intv(1); b=intv(2);
xx=(2*mymesh-a-b)/(b-a); % SCALING.
```

*Ultima revisione: 14 marzo 2011

[†]DIPARTIMENTO DI MATEMATICA PURA ED APPLICATA, UNIVERSITÀ DEGLI STUDI DI PADOVA,
VIA TRIESTE 63, 35121 PADOVA, ITALIA (ALVISE@MATH.UNIPD.IT)

[‡]DIPARTIMENTO DI MATEMATICA PURA ED APPLICATA, UNIVERSITÀ DEGLI STUDI DI PADOVA,
VIA TRIESTE 63, 35121 PADOVA, ITALIA (MRRUSSO@MATH.UNIPD.IT)

```

for index = 1:(deg+1)
    V(:,index)=cos((index-1)*acos(xx)); % VANDERMONDE.
end

```

Si domanda:

1. definiti per $m = n + 1$ i nodi equispaziati nell'intervallo $[-1, 1]$ che determinano l'insieme X e i nodi test

$$Y = \{-1 + hk\}, \quad k = 0, \dots, 1000, h = 1/500$$

calcolare approssimativamente la costante di Lebesgue per $n = 3, 4, 5, \dots, 10$.

2. definiti per $m = n + 1$ i nodi di Chebyshev

$$X = \left\{ \cos \frac{(2k+1)\pi}{2m} \right\}, \quad k = 0, \dots, m-1$$

e i nodi test

$$Y = \{-1 + hk\}, \quad k = 0, \dots, 1000, h = 1/500$$

calcolare approssimativamente la costante di Lebesgue per $n = 3, 4, 5, \dots, 10$.

1.2. Miglior approssimante polinomiale e interpolante polinomiale nei nodi di Chebyshev. Il metodo di Remez permette di calcolare il polinomio di miglior approssimazione di grado n di una funzione continua f in un intervallo chiuso e limitato $[a, b]$. Esistono varie implementazioni di tale algoritmo. Utilizzando la versione descritta in

R. Pachon e L.N. Trefethen,
 "Barycentric-Remez algorithms for best polynomial approximation
 in the chebfun system",
 BIT Numer Math (2009) 49, p. 721741,

è possibile calcolare, fissato un grado n il polinomio di miglior approssimazione $p^* \in \mathbb{P}_n$.

Vediamo alcuni esempi. Si consideri la funzione $f(x) = \sin(\exp(x))$, $x \in [-1, 1]$ citata in tale pubblicazione a pagina 734. Se il sistema **chebfun** è stato installato nella versione Matlab (per il download si veda la homepage degli autori), il codice

```

% CHEBFUN DI UNA FUNZIONE.
f=chebfun('sin(exp(x))');

% POLINOMIO DI MIGLIOR APPROSSIMAZIONE p (DI GRADO 10)
% ED ERRORE COMPIUTO err.
[p,err]=remez(f,10);

% POLINOMIO p DESCRITTO NELLA BASE MONOMIALE
% pp(1)*x^N + pp(2) * x^{N-1} + ...
pp=poly(p);

% PUNTI TEST.
xx=(-1:0.001:1)';

% VALUTAZIONE DEL POLINOMIO NEI PUNTI TEST.
pxx=polyval(pp,xx);

```

```
% VALUTAZIONE DELLA FUNZIONE NEI PUNTI TEST.
fxx=feval(f,xx);
```

```
% ERRORE COMPIUTO.
err2=norm(fxx-pxx,inf);
```

```
pp'
err2
```

Si vede che l'errore ottenuto (nella norma 2 nel continuo, cioè $\int_a^b |f(x)|^2 dx$) è approssimativamente $1.7862e - 06$ e che il polinomio p_{10}^* di miglior approssimazione ha coefficienti rispetto alla base monomiale (il primo è quello di grado massimo!)

```
0.003196437149154
0.017324847917382
0.033716160802325
0.027736791074028
-0.020560308792805
-0.139174865843104
-0.321930004523161
-0.420608521955273
-0.150685513280442
0.540295397586175
0.841472656602631
```

Si desidera

1. usando i comandi `polyfit` e `polyval`, valutare nei punti definiti dalla mesh $x = -1 : 0.001 : 1$ il polinomio di grado 10 che interpola la funzione

$$f(x) = \sin(\exp(x))$$

nei nodi di Chebyshev

$$\cos \frac{(2k+1)\pi}{2m}, \quad k = 0, \dots, m-1.$$

Se vogliamo calcolare il polinomio interpolante di grado 10, che valore deve assumere m ?

2. calcolare una stima dell'errore in norma infinito compiuto da p nell'approssimare f , come

$$\max_{x=-1:0.001:1} |f(x) - p(x)|$$

3. plottare il polinomio di miglior approssimazione p_{10}^* nei punti definiti dalla mesh $x = -1 : 0.001 : 1$;
4. plottare in scala semilogaritmica, nei punti della mesh $x = -1 : 0.001 : 1$, la funzione $|f - p_{10}^*|$;

2. Quadratura numerica.

2.1. Alcune formule di quadratura.

2.1.1. Esempi formule composte: trapezi e Cavalieri-Simpson. Tra i metodi comunemente utilizzati per approssimare una funzione continua f in un intervallo chiuso e limitato $[a, b]$, uno dei più semplici è la formula composta dei trapezi e di Cavalieri-Simpson. Si suddivide l'intervallo (chiuso e limitato) $[a, b]$ in N subintervalli $T_j = [x_j, x_{j+1}]$ tali che $x_j = a + jh$ con $h = (b - a)/N$. Dalle proprietà dell'integrale

$$\int_a^b f(x) dx = \sum_{j=0}^{N-1} \int_{x_j}^{x_{j+1}} f(x) dx \approx \sum_{j=0}^{N-1} S(f, x_j, x_{j+1}) \quad (2.1)$$

dove S è una delle regole di quadratura finora esposte (ad esempio $S_3(f)$). Le formule descritte in (2.1) sono dette *composte*. Due casi particolari sono

1. *formula composta dei trapezi*

$$S_1^{(c)} := h \left[\frac{f(x_0)}{2} + f(x_1) + \dots + f(x_{N-1}) + \frac{f(x_N)}{2} \right] \quad (2.2)$$

il cui errore è

$$E_1^{(c)}(f) := I(f) - S_1^{(c)}(f) = \frac{-(b-a)}{12} h^2 f^{(2)}(\xi), \quad h = \frac{(b-a)}{N} \quad (2.3)$$

per qualche $\xi \in (a, b)$;

2. *formula composta di Cavalieri-Simpson* fissati il numero N di subintervalli e i punti $x_k = a + kh/2$ dove $h = \frac{b-a}{N}$ sia

$$I(f) \approx S_3^{(c)}(f) := \frac{h}{6} \left[f(x_0) + 2 \sum_{r=1}^{N-1} f(x_{2r}) + 4 \sum_{s=0}^{N-1} f(x_{2s+1}) + f(x_{2N}) \right]; \quad (2.4)$$

il cui errore è

$$E_3^{(c)}(f) := I(f) - S_3^{(c)}(f) = \frac{-(b-a)}{180} \left(\frac{h}{2} \right)^4 f^{(4)}(\xi) \quad (2.5)$$

per qualche $\xi \in (a, b)$.

2.1.2. Formule gaussiane. Ricordiamo ora che una formula

$$\int_a^b f(x) w(x) dx \approx \sum_{i=1}^M w_i f(x_i)$$

ha grado di precisione *almeno* N se e solo se è esatta per tutti i polinomi f di grado inferiore o uguale a N . Ha inoltre grado di precisione N se e solo se è esatta per ogni polinomio di grado N ed esiste un polinomio di grado $N + 1$ per cui non lo sia. Nelle formule interpolatorie di Newton-Cotes (come ad esempio la regola del Trapezio o di Cavalieri-Simpson che sono alla base delle formule composte precedentemente citate) i nodi $x_1, \dots, x_n$ sono equispaziati e il grado di precisione δ è generalmente uguale almeno a $n - 1$ ma in alcuni casi, come per la regola di Cavalieri-Simpson, uguale al numero di nodi n . Vediamo ora formule che a parità di nodi hanno grado di precisione maggiore di n .

Sia $w : (a, b) \rightarrow \mathbb{R}$ (non necessariamente limitato) è una funzione peso, cioè tale che

1. w è nonnegativa in (a, b) ;
2. w è integrabile in $[a, b]$;
3. esista e sia finito

$$\int_a^b |x|^n w(x) dx$$

per ogni $n \in \mathbb{N}$;

4. se

$$\int_a^b g(x) w(x) dx = 0$$

per una qualche funzione nonnegativa g allora $g \equiv 0$ in (a, b) .

Tra gli esempi più noti ricordiamo

1. *Legendre*: $w(x) \equiv 1$ in $[a, b]$ limitato;
2. *Jacobi*: $w(x) = (1-x)^\alpha (1+x)^\beta$ in $(-1, 1)$ per $\alpha, \beta \geq -1$;
3. *Chebyshev*: $w(x) = \frac{1}{\sqrt{1-x^2}}$ in $(-1, 1)$;
4. *Laguerre*: $w(x) = \exp(-x)$ in $[0, \infty)$;
5. *Hermite*: $w(x) = \exp(-x^2)$ in $(-\infty, \infty)$;

Si dimostra che

TEOREMA 2.1. *Per ogni $n \geq 1$ esistono e sono unici dei nodi $x_1, \dots, x_n$ e pesi $w_1, \dots, w_n$ per cui il grado di precisione della formula di quadratura*

$$\int_a^b g(x) w(x) dx \approx \sum_{i=1}^n w_i g(x_i)$$

sia almeno $2n - 1$. I nodi sono gli zeri del polinomio ortogonale di grado n ,

$$\phi_n(x) = A_n \cdot (x - x_1) \cdot \dots \cdot (x - x_n)$$

e i corrispettivi pesi sono

$$w_i = \int_a^b L_i(x) w(x) dx, \quad i = 1, \dots, n.$$

In generale il calcolo dei nodi e dei pesi non è cosa banale e rimandiamo questo dettaglio alla sezione successiva.

2.2. Implementazione delle formule di quadratura. Per quanto riguarda la formula dei trapezi, una sua implementazione in Matlab/Octave è data da

```
function [x,w]=trapezi_composta(N,a,b)
```

```
% FORMULA DEI TRAPEZI COMPOSTA.
```

```
% INPUT:
```

```
% N: NUMERO SUBINTERVALLI.
```

```
% a, b: ESTREMI DI INTEGRAZIONE.
```

```
% OUTPUT:
% x: NODI INTEGRAZIONE.
% w: PESI INTEGRAZIONE (INCLUDE IL PASSO!).

h=(b-a)/N;           % PASSO INTEGRAZIONE.
x=a:h:b; x=x';       % NODI INTEGRAZIONE.
w=ones(N+1,1);       % PESI INTEGRAZIONE.
w(1)=0.5; w(N+1)=0.5;
w=w*h;
```

che fornisce i nodi di quadratura x e i corrispondenti pesi w come due vettori colonna.

Similmente, per quanto riguarda la formula di Cavalieri-Simpson composta, i nodi di quadratura x e i corrispondenti pesi w si ottengono dalla routine

```
function [x,w]=simpson_composta(N,a,b)

% FORMULA DI SIMPSON COMPOSTA.

% INPUT:
% N: NUMERO SUBINTERVALLI.
% a, b: ESTREMI DI INTEGRAZIONE.

% OUTPUT:
% x: INTEGRAZIONE.
% w: PESI INTEGRAZIONE (INCLUDE IL PASSO!).

h=(b-a)/N;           % AMPIEZZA INTERVALLO.
x=a:(h/2):b; x=x';   % NODI INTEGRAZIONE.

w=ones(2*N+1,1);     % PESI INTEGRAZIONE.
w(3:2:2*N-1,1)=2*ones(length(3:2:2*N-1),1);
w(2:2:2*N,1)=4*ones(length(2:2:2*N),1);
w=w*h/6;
```

Osserviamo che

- in Matlab si può definire una funzione (matematica) f come *inline* e che può essere valutata con il comando *feval* (se necessario aiutarsi con l'help di Matlab/Octave), ad esempio

```
>> f=inline('sin(x)'); % DEFINIZIONE COME INLINE DI UNA FUNZIONE.
>> feval(f,0)           % VALUTAZIONE DELLA FUNZIONE.
ans =
    0
>>
```

(si noti che la funzione è passata come stringa, visti gli apici);

- una volta noti il vettore (colonna) x dei nodi e w dei pesi di integrazione, se la funzione f è richiamata da un m-file $f.m$, basta

```
fx=feval(f,x);         % VALUT. FUNZIONE.
I=w'*fx;               % VALORE INTEGRALE.
```

per calcolare il risultato fornito dalla formula di quadratura composta.

Per quanto concerne le formule gaussiane, esponiamo di seguito una routine eseguita da D. Laurie e W. Gautschi, che fissato un numero naturale positivo N calcola una formula gaussiana rispetto alla funzione peso di Jacobi

$$w(x) = (1-x)^\alpha(1+x)^\beta, \quad x \in (-1, 1).$$

Osserviamo che per $\alpha = \beta = 0$, la funzione peso coincide con $w \equiv 1$.

```
function [x,w]=gauss_jacobi(N,alpha,beta)

% GAUSS-JACOBI RULE ON [-1,1] (OR (-1,1) DEPENDING ON alpha, beta).
% N: FOR GAUSSIAN RULES IT IS THE NUMBER OF QUAD. POINTS.
% alpha, beta ARE THE GAUSS-JACOBI EXPONENTS.
% x, w ARE COLUMN VECTORS OF NODES AND WEIGHTS.
% THE LENGTH OF x AND w IS "N" IF gl=0, "N+2" IF "gl=1".

if nargin < 2
    alpha=0; beta=0;
end

ab=r_jacobi(N,alpha,beta);
xw=gauss(N,ab);

x=xw(:,1);
w=xw(:,2);

%-----
% ADDITIONAL FUNCTIONS BY D.LAURIE AND W.GAUTSCHI.
%-----

function ab=r_jacobi(N,a,b)

nu=(b-a)/(a+b+2);
mu=2^(a+b+1)*gamma(a+1)*gamma(b+1)/gamma(a+b+2);
if N==1
    ab=[nu mu]; return
end

N=N-1;
n=1:N;
nab=2*n+a+b;
nuadd=(b^2-a^2)*ones(1,N)./(nab.*(nab+2));
A=[nu nuadd];
n=2:N;
nab=nab(n);
B1=4*(a+1)*(b+1)/((a+b+2)^2*(a+b+3));
B=4*(n+a).*(n+b).*n.*(n+a+b)./((nab.^2).*(nab+1).*(nab-1));
abadd=[mu; B1; B'];
ab=[A' abadd];

function xw=gauss(N,ab)
N0=size(ab,1); if N0<N, error('input array ab too short'), end
```

```

J=zeros(N);
for n=1:N, J(n,n)=ab(n,1); end
for n=2:N
    J(n,n-1)=sqrt(ab(n,2));
    J(n-1,n)=J(n,n-1);
end
[V,D]=eig(J);
[D,I]=sort(diag(D));
V=V(:,I);
xw=[D ab(1,2)*V(1,:).^2];

```

2.3. Esempio. Vediamo di seguito un esempio su come calcolare con i codici visti un integrale di una funzione (che scegliamo regolare).

Dapprima vediamo qual'è il risultato corretto

```

>> % CALCOLO SIMBOLICO IN MATLAB.
>> f=inline('1/(1+x.^2)'); % DEF. FUNZIONE.
>> syms x
>> int(1./(1+x.^2),-1,1) % INTEGRALE DEF. DA -1 A 1.

ans =

pi/2

```

e di seguito eseguiamo alcuni test numerici

```

>> f=inline('1/(1+x.^2)'); % DEF. FUNZIONE.
>> % CALCOLO INTEGRALE FORMULA TRAPEZI COMPOSTA
>> [x,w]=trapezi_composta(5,-1,1);
>> length(x)

ans =

6

>> fx=feval(f,x);
>> I_tpz=w'*fx

I_tpz =

1.557466063348416e+00

>> err_tpz=abs(I_tpz-pi/2)

err_tpz =

1.333026344648047e-02

>> % CALCOLO INTEGRALE FORMULA COMPOSTA SIMPSON.
>> [x,w]=simpson_composta(5,-1,1);
>> fx=feval(f,x);
>> I_simpson=w'*fx;
>> format long e

```



```

>> pi/2

ans =

    1.570796326794897e+00

>> I_simpson

    1.570795388091188e+00

>> err_simpson=abs(I_simpson-pi/2)

err_simpson =

    9.387037087638106e-07

>> length(x) % PUNTI FORMULA COMPOSTA

ans =

    11

>> % FORMULE GAUSSIANE.
>> [x,w]=gauss_jacobi(5,0,0); % NODI [-1,1]!!!
>> fx=feval(f,x);
>> length(x)

ans =

    5

>> I_gauss=w'*fx

I_gauss =

    1.571171171171171e+00

>> err_gauss=abs(I_gauss-pi/2)

err_gauss =

    3.748443762745524e-04

>> % A PARITA' DI NODI TRAPEZI COMPOSTA OFFRIVA
>> % UN ERRORE DI 1.333026344648047e-02.
>>
>> [x,w]=gauss_jacobi(11,0,0); % NODI [-1,1]!!!
>> fx=feval(f,x);
>> I_gauss=w'*fx

I_gauss =

    1.570796336515167e+00

```

```
>> err_gauss=abs(I_gauss-pi/2)

err_gauss =

    9.720270366386785e-09

>> % A PARITA' DI NODI SIMPSON COMPOSTA OFFRIVA
>> % UN ERRORE DI 9.387037087638106e-07.
```

Si noti che in effetti il prodotto scalare $w' * fX$ equivale alla valutazione della formula di quadratura

```
>> [x,w]=trapezi_composta(5, -1,1);
>> fx=feval(f,x);
>> format long e
>> I=w'*fx
```

```
I =

    1.557466063348416e+00
```

```
>> II=sum(w.*fx)
```

```
II =

    1.557466063348416e+00
```

```
>>
```

2.4. Esercizi. Quale esercizio, ricordato di scrivere le funzioni matematiche come *inline* in forma vettoriale, si approssimino (dopo averli calcolati esplicitamente o via calcolo simbolico) con le formule composte dei trapezi e di Cavalieri-Simpson come pure con le formule gaussiane (scegliere tramite α e β la funzione peso più opportuna), per $N = 5, 10, 15, 20, 25, 30$ i seguenti integrali

1. del polinomio

$$\int_{-1}^1 x^{20} dx;$$

ricordando le funzioni peso di Jacobi, qual'è la funzione peso più appropriata? Il fatto che la funzione integranda sia un polinomio, spiega alcuni risultati ottenuti dalla formula gaussiana utilizzata?

2. della funzione periodica

$$\int_{-1}^1 \sin(\pi(x+1)) dx;$$

ricordando le funzioni peso di Jacobi, qual'è la funzione peso più appropriata? (Facoltativo e richiede pazienza) Il fatto che la funzione integranda sia un polinomio, spiega i risultati ottenuti dalla formula composta dei trapezi? A tale scopo aiutarsi con il teorema di Eulero Mac-Laurin (cercare online, via motore di ricerca).

3. della funzione regolare

$$\int_{-1}^1 \exp(x) dx;$$

ricordando le funzioni peso di Jacobi, qual'è la funzione peso più appropriata? Sono buone le stime dell'errore fornite dalle formule composte (2.3), (2.5)?

4. della funzione *holderiana* e poco regolare

$$\int_{-1}^1 (1-x^2)^{3/2} dx;$$

ricordando le funzioni peso di Jacobi, qual'è la funzione peso più appropriata? Sono scadenti i risultati delle formule composte rispetto a quelle gaussiane? Qual'è la distribuzione dei nodi gaussiani prescelti nell'intervallo $[-1, 1]$? Suggerimento: Nel caso delle formule gaussiane, si osservi che se $f = g \cdot w$ allora

$$\int_a^b f(x) dx = \int_a^b g(x)w(x) dx \approx \sum_i w_i g(x_i).$$

3. Metodi iterativi. Sia A una matrice reale avente n righe ed n colonne, b un vettore colonna avente n righe e si supponga di voler risolvere il sistema lineare $Ax = b$. Come noto, se il determinante della matrice è diverso da 0 (cioè la matrice A è non singolare) allora il problema $Ax = b$ ha una ed una sola soluzione.

Ricordiamo che in Matlab/Octave la soluzione può essere calcolata con il metodo LU, utilizzando il comando `\` e il comando `lu`. Un esempio:

```
>> A=[1 2 4; 2 4 16; 3 9 81];
>> b=ones(3,1);
>> x=A\b
x =
   -2.9167
    2.2083
   -0.1250
>> norm(A*x-b)
ans = 9.9301e-16
>> det(A)
ans = -24.000
>> [L,U]=lu(A);
x=(U\(L\b))
x =
   -2.9167
    2.2083
   -0.1250
```

Uno dei principali problemi del metodo LU è legato all'alto costo computazionale. Se A è una generica matrice quadrata di ordine n infatti necessitano circa

$$O\left(\frac{n^3}{3} + \frac{n^2}{2}\right)$$

operazioni moltiplicative, che possono risultare eccessive nel caso di matrici di grandi dimensioni. Inoltre se calcoliamo la fattorizzazione LU di una matrice A sparsa cioè con un numero

elevato di elementi nulli, otteniamo che i fattori L ed U sono molto più 'pieni', ovvero si perde la proprietà di sparsità iniziale di A , e questo è un inconveniente soprattutto per matrici di grandi dimensioni. Si verifica il cosiddetto fenomeno del *fill-in*, per cui a partire da una matrice sparsa, la U rimane triangolare superiore ma piena, risultando quindi più complicata della matrice di partenza.

Per ovviare a questo problema si usano ad esempio metodi iterativi stazionari del tipo

$$x^{(k+1)} = P x^{(k)} + c, \quad k = 0, 1, \dots$$

con P dipendente da A e c dipendente da A e b (ma non da k). A differenza dei metodi diretti (come ad esempio il metodo LU), in genere un metodo iterativo stazionario convergente calcola usualmente solo un'approssimazione della soluzione x (a meno di una tolleranza prefissata). Se m è il numero di iterazioni necessarie, visto che ogni iterazione ha un costo $O(n^2)$ dovuto al prodotto matrice-vettore $P x^{(k)}$, ci si augura che il costo computazionale $O(m n^2)$ del metodo iterativo sia di gran lunga inferiore a $O(\frac{n^3}{3} + \frac{n^2}{2})$ di un metodo diretto quale LU.

3.1. I metodi stazionari. Sia $A = M - N$ con M invertibile. Di conseguenza, da $Ax = b$ abbiamo facilmente $Mx = Nx + b$ ed essendo M invertibile necessariamente $x = M^{-1}Nx + M^{-1}b$. In modo naturale, da quest'ultima uguaglianza, si definisce un *metodo iterativo stazionario* come

$$x^{(k+1)} = M^{-1}Nx^{(k)} + M^{-1}b. \quad (3.1)$$

La matrice $P = M^{-1}N$ è usualmente chiamata *matrice di iterazione* del metodo iterativo stazionario definito da M, N . Osserviamo che posto $c = M^{-1}b$, il metodo sopracitato è ovviamente stazionario essendo

$$x^{(k+1)} = P x^{(k)} + c \quad (3.2)$$

con P e c indipendenti da k .

3.2. Il metodo di Jacobi. Tale metodo è definito ponendo

$$M = D, \quad N = E + F \quad (3.3)$$

e quindi

$$P = M^{-1}N = D^{-1}(E + F) = D^{-1}(D - D + E + F) = D^{-1}(D - A) = I - D^{-1}A \quad (3.4)$$

Si osservi che se D è non singolare allora il metodo di Jacobi, almeno in questa versione di base, non può essere utilizzato visto che in (3.4) non ha senso la scrittura D^{-1} .

Qualora sia $a_{ii} \neq 0$ per ogni $i = 1, \dots, n$, il metodo di Jacobi può essere descritto come

$$x_i^{(k+1)} = (b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(k)} - \sum_{j=i+1}^n a_{ij}x_j^{(k)})/a_{ii}, \quad i = 1, \dots, n. \quad (3.5)$$

3.3. Il metodo di Gauss-Seidel. Il metodo di Gauss-Seidel è definito quale metodo stazionario in cui

$$M = D - E, \quad N = F \quad (3.6)$$

e quindi

$$P = M^{-1}N = (D - E)^{-1}F \quad (3.7)$$

Similmente al metodo di Jacobi, possiamo riscrivere più semplicemente anche Gauss-Seidel come

$$x_i^{(k+1)} = \left(b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij}x_j^{(k)} \right) / a_{ii}. \quad (3.8)$$

3.4. Generalizzazioni del metodo di Jacobi e Gauss-Seidel. Quali generalizzazioni del metodo di Jacobi e Gauss-Seidel si introducono, per un opportuno parametro ω , la versione *rilassata del metodo di Jacobi*

$$x^{(k+1)} = (I - \omega D^{-1}A)x^{(k)} + \omega D^{-1}b \quad (3.9)$$

la versione *rilassata del metodo di Gauss-Seidel*

$$x^{(k+1)} = \left(\frac{D}{\omega} - E \right)^{-1} \left(\left(\frac{1}{\omega} - 1 \right) D + F \right) x^{(k)} + \left(\frac{D}{\omega} - E \right)^{-1} b. \quad (3.10)$$

L'idea di fondo di questi metodi rilassati è l'introduzione del parametro ω per accelerarne la convergenza. Si osservi che i metodi di Jacobi e Gauss-Seidel si ottengono rispettivamente da (3.9) e (3.10) per la scelta $\omega = 1$.

3.5. Convergenza dei metodi iterativi. Sia $\rho(P)$ il massimo degli autovalori in modulo della matrice di iterazione $P = M^{-1}N$ (il cosiddetto *raggio spettrale*).

TEOREMA 3.1. *Un metodo iterativo stazionario consistente $x^{(k+1)} = Px^{(k)} + c$ converge per ogni vettore iniziale x_0 se e solo se $\rho(P) < 1$.*

Questo teorema permette di mostrare alcuni casi in cui i metodi di Jacobi e Gauss-Seidel risultano convergenti.

3.5.1. Convergenza Jacobi.

1. A è a predominanza diagonale (per righe) se per ogni $i = 1, \dots, n$ risulta

$$|a_{i,i}| \geq \sum_{j=1, j \neq i}^n |a_{i,j}|$$

e per almeno un indice s si abbia

$$|a_{s,s}| > \sum_{j=1, j \neq s}^n |a_{s,j}|.$$

Ad esempio la matrice

$$A = \begin{pmatrix} 4 & -4 & 0 \\ -1 & 4 & -1 \\ 0 & -4 & 4 \end{pmatrix}$$

è a predominanza diagonale (per righe).

2. A è a predominanza diagonale in senso stretto (per righe) se per ogni $i = 1, \dots, n$ risulta

$$|a_{i,i}| > \sum_{j=1, j \neq i}^n |a_{i,j}|.$$

Ad esempio la matrice

$$A = \begin{pmatrix} 4 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 4 \end{pmatrix}$$

è a predominanza diagonale in senso stretto (per righe).

3. A è a predominanza diagonale per colonne (in senso stretto) se A^T è a predominanza diagonale per righe (in senso stretto).
4. A è tridiagonale se $a_{i,j} = 0$ per $|i - j| > 1$. Ad esempio la matrice

$$A = \begin{pmatrix} 4 & -1 & 0 & \dots & 0 \\ -1 & 4 & -1 & \dots & 0 \\ 0 & -1 & 4 & \dots & \dots \\ 0 & \dots & \dots & \dots & -1 \\ 0 & 0 & \dots & -1 & 4 \end{pmatrix}$$

è tridiagonale.

5. A è definita positiva se e solo se i suoi autovalori sono positivi.
6. A di ordine $n \geq 2$ è riducibile se esiste una matrice di permutazione Π e un intero k con $0 < k < n$, tale che

$$B = \Pi A \Pi^T = \begin{pmatrix} A_{1,1} & A_{1,2} \\ 0 & A_{2,2} \end{pmatrix}$$

in cui $A_{1,1} \in C^{k \times k}$, $A_{2,2} \in C^{(n-k) \times (n-k)}$. Se A non è riducibile si dice che A è irriducibile.

Il metodo di Jacobi risulta convergente in uno dei seguenti casi:

1. A è a predominanza diagonale in senso stretto;
2. A è a predominanza diagonale ed è irriducibile;
3. A è a predominanza diagonale in senso stretto per colonne;
4. A è a predominanza diagonale per colonne ed è irriducibile.

3.5.2. Convergenza di Gauss-Seidel. Il metodo di Gauss-Seidel risulta convergente in uno dei seguenti casi:

1. A è a predominanza diagonale in senso stretto.
2. Sia A una matrice simmetrica definita positiva, non singolare con elementi principali $a_{i,i} \neq 0$, allora Gauss-Seidel è convergente.

TEOREMA 3.2. *Per matrici tridiagonali (a blocchi) $A = (a_{i,j})$ con componenti diagonali non nulle, i metodi di Jacobi e Gauss-Seidel sono o entrambi convergenti o divergenti e il tasso di convergenza del metodo di Gauss-Seidel è il doppio di quello del metodo di Jacobi (il che vuol dire che asintoticamente sono necessarie metà iterazioni del metodo di Gauss-Seidel per ottenere la stessa precisione del metodo di Jacobi). Si può infatti dimostrare che $\rho(P_{Gs}) = \rho(P_J)^2$*

3.6. Metodi di discesa. Ad ogni sistema lineare $Ax = b$, con A matrice simmetrica definita positiva si può associare il funzionale (forma quadratica)

$$\phi(x) = \frac{1}{2}x^T Ax - b^T x, \quad x \in \mathbb{R}^n$$

il cui punto di minimo x^* è l'unica soluzione del sistema lineare, cioè $Ax^* = b$ (che esprime la condizione $\Delta\phi = 0$).

E' possibile quindi costruire dei metodi iterativi che, ad ogni passo, procedano verso il minimo della forma quadratica secondo il seguente schema:

$$x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}, \quad k \geq 0, \alpha_k \neq 0 \quad (3.11)$$

dove $p^{(k)}$ è una direzione di discesa fissata secondo qualche criterio e α_k è un parametro di accelerazione. I metodi iterativi scritti nella forma (3.11) prendono il nome di *metodi di Richardson*. Il metodo si definisce *stazionario* nel caso in cui $\alpha_k = \alpha$ con α costante assegnata, *dinamico* nel caso in cui α_k possa cambiare ad ogni iterazione. Vediamo di seguito alcuni di questi metodi.

3.7. Il metodo del gradiente classico. Si dimostra che il parametro α_k ottimale cosicché $\phi(x^{(k+1)})$ sia minimo una volta scelta $p^{(k)}$ è

$$\alpha_k = \frac{(r^{(k)})^T p^{(k)}}{(p^{(k)})^T A p^{(k)}}$$

Nel metodo del gradiente si sceglie quale direzione $p^{(k)} = \text{grad}(\phi(x))|_{x=x^{(k)}}$. Ma se $r^{(k)} = b - Ax^{(k)}$, allora

$$\begin{aligned} \text{grad}(\phi(x))|_{x=x^{(k)}} &= \frac{1}{2} \text{grad}(x^T Ax)|_{x=x^{(k)}} - \text{grad}(b^T x)|_{x=x^{(k)}} \\ &= Ax^{(k)} - b = -r^{(k)} \end{aligned} \quad (3.12)$$

e quindi $p^{(k)} = r^{(k)}$ (è essenziale la direzione ma non il segno e per convincersene si calcoli la successione anche con segno opposto $p^{(k)} = -r^{(k)}$ per parametro α_k ottimale). Di conseguenza il metodo del gradiente è definito dalla successione tipica dei metodi di Richardson non stazionari

$$x^{(k+1)} = x^{(k)} + \alpha_k r^{(k)}$$

dove

$$\alpha_k = \frac{(r^{(k)})^T p^{(k)}}{(p^{(k)})^T A p^{(k)}} = \frac{\|r^{(k)}\|_2^2}{(r^{(k)})^T A r^{(k)}}.$$

Si può dimostrare che le direzioni utilizzate dal metodo del gradiente sono ortogonali, ovvero tali che $(p^{(k+1)})^T p^{(k)} = 0$. Questa proprietà in generale non è valida per due direzioni non

consecutive (cioè , ad esempio, $(p^{(6)})^T p^{(1)} \neq 0$), e quindi il metodo del gradiente non è ancora ottimale. Nel caso del metodo del gradiente, vale la stima

$$\|e^{(k)}\|_A \leq \left(\frac{K_2(A) - 1}{K_2(A) + 1} \right)^k \|e^{(0)}\|_A$$

con

$$K_2(A) := \|A\|_2 \|A^{-1}\|_2 = \frac{\lambda_{\max}(A)}{\lambda_{\min}(A)}$$

che mostra che più grande è il numero di condizionamento $K_2(A)$ più è vicino a 1 la quantità $\frac{K_2(A)-1}{K_2(A)+1}$ il che giustifica una *possibile* convergenza lenta del metodo.

3.7.1. Facoltativo: Il metodo del gradiente coniugato. La successione delle iterazioni del gradiente coniugato è quella propria dei metodi di discesa,

$$x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}, \quad \alpha_k = \frac{(r^{(k)})^T r^{(k)}}{(p^{(k)})^T A p^{(k)}}$$

dove $p^{(0)} = r^{(0)}$ e

$$p^{(k)} = r^{(k)} + \beta_k p^{(k-1)}, \quad \beta_k = \frac{(r^{(k)})^T r^{(k)}}{(r^{(k-1)})^T r^{(k-1)}}.$$

Con questa scelta si prova che

$$(p^{(k)})^T A p^{(k-1)} = 0,$$

cioè i vettori $p^{(k)}$ e $p^{(k-1)}$ sono *A-coniugati*.

Questa proprietà è decisiva, in quanto si può dimostrare che il gradiente coniugato converge alla soluzione esatta in al più n passi, se A è di ordine n ed ammesso di riuscire a lavorare in aritmetica esatta.

3.7.2. Convergenza del gradiente coniugato. Il metodo del gradiente coniugato ha molte proprietà particolari. Ne citiamo alcune.

TEOREMA 3.3. *Se A è una matrice simmetrica e definita positiva di ordine n e $p^{(0)} = r^{(0)}$, il metodo del gradiente coniugato è convergente e fornisce in aritmetica esatta la soluzione del sistema $Ax = b$ in al massimo n iterazioni.*

Questo teorema tradisce un pò le attese, sia perchè in generale i calcoli non sono compiuti in aritmetica esatta, sia perchè in molti casi della modellistica matematica n risulta essere molto alto.

TEOREMA 3.4. *Se A è simmetrica e definita positiva,*

$$\|x\|_A = \sqrt{x^T A x}$$

e

$$e_k = x^* - x^{(k)}$$

allora

$$\|e_k\|_A \leq \left(\frac{\sqrt{K_2(A)} - 1}{\sqrt{K_2(A)} + 1} \right)^{2k} \|e_0\|_A. \quad (3.13)$$

Questo risultato stabilisce che la convergenza del gradiente coniugato è lenta qualora si abbiano alti numeri di condizionamento

$$K_2(A) := \|A\|_2 \|A^{-1}\|_2$$

TEOREMA 3.5. *Sia A simmetrica e definita positiva. Si supponga che ci siano esattamente $k \leq n$ autovalori distinti di A . Allora il metodo del gradiente coniugato in cui si è posto $p^{(0)} = r^{(0)} = b - Ax^{(0)}$ converge in al più k iterazioni.*

TEOREMA 3.6. *Sia A simmetrica e definita positiva. Si supponga b sia combinazione lineare di $k \leq n$ autovettori distinti di A . Allora il metodo del gradiente coniugato con la scelta $x^{(0)} = 0$ converge in al più k iterazioni.*

3.8. Precondizionamento. La maggiorazione 3.13 mette in evidenza l'importanza del numero di condizionamento per quanto concerne la rapidità di convergenza dei metodi di discesa. L'idea del precondizionamento consiste nel sostituire la risoluzione dellequazione $Ax = b$ con quella del sistema equivalente $P^{-1}Ax = P^{-1}b$, ove la matrice P simmetrica, definita positiva e invertibile, è scelta con l'obiettivo di avere $K_2(P^{-1}A) \ll K_2(A)$. Naturalmente, la scelta migliore sarebbe $P^{-1} = A^{-1}$, perchè in questo caso si avrebbe $K_2(P^{-1}A) = 1$; nella pratica, si tratta, al solito, di trovare un opportuno compromesso con il costo del calcolo di $(P^{-1}A)$.

Assumendo P^{-1} simmetrica definita positiva, osserviamo che la matrice $P^{-1}A$ non è, in generale, simmetrica e quindi non possiamo applicare l'algoritmo del gradiente coniugato direttamente a $P^{-1}A$. Tuttavia, si può definire una matrice $P^{1/2}$ simmetrica e definita positiva tale che $P^{1/2}P^{1/2} = P$ (si può dimostrare che una tale matrice, detta 'radice quadrata' di P , esiste) di conseguenza, la matrice

$$P^{1/2}(P^{-1}A)P^{-1/2} = P^{-1/2}(A)P^{-1/2}$$

è simmetrica definita positiva e si può applicare il metodo del gradiente coniugato alla nuova matrice $(\tilde{A}) = P^{-1/2}(A)P^{-1/2}$, ovvero si risolve il sistema

$$P^{-1/2}(A)P^{-1/2}y = P^{-1/2}b, \quad \text{con} \quad y = P^{1/2}x$$

In pratica, non occorre disporre della matrice $P^{1/2}$ o della sua inversa. Infatti l'algoritmo che realizza il metodo del gradiente coniugato precondizionato ad ogni passo risolve un sistema lineare nella matrice P .

Esistono in letteratura diversi tipi di precondizionatore, ma la loro individuazione è basata più sull'empirismo che su argomentazioni teoriche, spesso è sufficiente prendere $P = \text{diag}(A)$.

3.9. Metodi iterativi in Matlab. Vediamo di seguito tre routines Matlab che implementano i metodi sopra descritti di Jacobi, Gauss-Seidel e del gradiente coniugato.

3.9.1. Implementazione del metodo di Jacobi. In questa sottosezione suggeriamo un codice Matlab che implementa il metodo di Jacobi. In input, la matrice A e il vettore b sono relativi al sistema $Ax = b$ da risolvere, x è il vettore colonna iniziale da cui far partire le iterazioni, `max_it` il numero massimo di iterazioni da compiere e `tol` la tolleranza richiesta da un certo criterio di arresto. Delle variabili in output, x è l'approssimazione della soluzione, `error` l'errore in norma 2 compiuto, `iter` il numero di iterazioni compiute, `flag` una variabile che a seconda sia 0 o 1 l'algoritmo è uscito correttamente oppure per il numero massimo di iterazioni richieste.

```

function [x, error, iter, flag] = jacobi(A, x, b, max_it, tol)

% -- Iterative template routine --
%   Univ. of Tennessee and Oak Ridge National Laboratory
%   October 1, 1993
%   Details of this algorithm are described in "Templates for the
%   Solution of Linear Systems: Building Blocks for Iterative
%   Methods", Barrett, Berry, Chan, Demmel, Donato, Dongarra,
%   Eijkhout, Pozo, Romine, and van der Vorst, SIAM Publications,
%   1993. (ftp netlib2.cs.utk.edu; cd linalg; get templates.ps).
%
% [x, error, iter, flag] = jacobi(A, x, b, max_it, tol)
%
% jacobi.m solves the linear system Ax=b using the Jacobi Method.
%
% input   A          REAL matrix
%         x          REAL initial guess vector
%         b          REAL right hand side vector
%         max_it     INTEGER maximum number of iterations
%         tol        REAL error tolerance
%
% output  x          REAL solution vector
%         error      REAL error norm
%         iter       INTEGER number of iterations performed
%         flag       INTEGER: 0 = solution found to tolerance
%                        1 = no convergence given max_it

iter = 0;                                % initialization
flag = 0;

bnrm2 = norm( b );
if ( bnrm2 == 0.0 ), bnrm2 = 1.0; end

r = b - A*x;
error = norm( r ) / bnrm2;
if ( error < tol ) return, end

[m,n]=size(A);
[ M, N ] = split( A , b, 1.0, 1 );      % matrix splitting

for iter = 1:max_it,                    % begin iteration

    x_1 = x;
    x    = M \ (N*x + b);                % update approximation

    error = norm( x - x_1 ) / norm( x ); % compute error
    if ( error <= tol ), break, end      % check convergence

end

if ( error > tol ) flag = 1; end          % no convergence

```

Il codice di `jacobi` utilizza una funzione `split` che serve per calcolare le matrici M , N che definiscono l'iterazione del metodo di Jacobi:

```
function [ M, N, b ] = split( A, b, w, flag )
%
% function [ M, N, b ] = split_matrix( A, b, w, flag )
%
% split.m sets up the matrix splitting for the stationary
% iterative methods: jacobi and sor (gauss-seidel when w = 1.0 )
%
% input   A          DOUBLE PRECISION matrix
%         b          DOUBLE PRECISION right hand side vector (for SOR)
%         w          DOUBLE PRECISION relaxation scalar
%         flag       INTEGER flag for method: 1 = jacobi
%                                     2 = sor
%
% output  M          DOUBLE PRECISION matrix
%         N          DOUBLE PRECISION matrix such that A = M - N
%         b          DOUBLE PRECISION rhs vector ( altered for SOR )

[m,n] = size( A );

if ( flag == 1 ),                % jacobi splitting

    M = diag(diag(A));
    N = diag(diag(A)) - A;

elseif ( flag == 2 ),           % sor/gauss-seidel splitting

    b = w * b;
    M = w * tril( A, -1 ) + diag(diag( A ));
    N = -w * triu( A, 1 ) + ( 1.0 - w ) * diag(diag( A ));

end;

% END split.m
```

La routine `jacobi` è scritta da esperti di algebra lineare e si interrompe quando la norma 2 dello step relativo

$$\frac{\|x^{(k+1)} - x^{(k)}\|_2}{\|x^{(k+1)}\|_2}$$

è inferiore ad una tolleranza `tol` prefissata oppure un numero massimo di iterazioni `max_it` è raggiunto. Ricordiamo che se $v = (v_i)_{i=1,\dots,n}$ è un elemento di $\mathbb{R}^n$ allora

$$\|v\|_2 = \sqrt{\sum_{i=1}^n v_i^2}.$$

3.9.2. Implementazione del metodo di Gauss-Seidel. In questa sottosezione suggeriamo un codice Matlab che implementa una generalizzazione del metodo di Gauss-Seidel nota come SOR. Il metodo di Gauss-Seidel corrisponde alla scelta di $w = 1$. In input, la matrice A e il vettore b sono relativi al sistema $Ax = b$ da risolvere, x è il vettore colonna iniziale da cui

far partire le iterazioni, `max_it` il numero massimo di iterazioni da compiere e `tol` la tolleranza richiesta da un certo criterio di arresto. Delle variabili in output, `x` è l'approssimazione della soluzione, `error` l'errore in norma 2 compiuto, `iter` il numero di iterazioni compiute, `flag` una variabile che a seconda sia 0 o 1 l'algoritmo è uscito correttamente oppure per il numero massimo di iterazioni richieste.

```
function [x, error, iter, flag] = sor(A, x, b, w, max_it, tol)

% -- Iterative template routine --
%   Univ. of Tennessee and Oak Ridge National Laboratory
%   October 1, 1993
%   Details of this algorithm are described in "Templates for the
%   Solution of Linear Systems: Building Blocks for Iterative
%   Methods", Barrett, Berry, Chan, Demmel, Donato, Dongarra,
%   Eijkhout, Pozo, Romine, and van der Vorst, SIAM Publications,
%   1993. (ftp netlib2.cs.utk.edu; cd linalg; get templates.ps).
%
% [x, error, iter, flag] = sor(A, x, b, w, max_it, tol)
%
% sor.m solves the linear system Ax=b using the
% Successive Over-Relaxation Method (Gauss-Seidel method when omega = 1 ).
%
% input   A          REAL matrix
%         x          REAL initial guess vector
%         b          REAL right hand side vector
%         w          REAL relaxation scalar
%         max_it     INTEGER maximum number of iterations
%         tol        REAL error tolerance
%
% output  x          REAL solution vector
%         error      REAL error norm
%         iter       INTEGER number of iterations performed
%         flag       INTEGER: 0 = solution found to tolerance
%                        1 = no convergence given max_it

flag = 0;                                % initialization
iter = 0;

bnrm2 = norm( b );
if ( bnrm2 == 0.0 ), bnrm2 = 1.0; end

r = b - A*x;
error = norm( r ) / bnrm2;
if ( error < tol ) return, end

[ M, N, b ] = split( A, b, w, 2 );      % matrix splitting

for iter = 1:max_it                      % begin iteration

    x_1 = x;
    x = M \ ( N*x + b );                % update approximation

    error = norm( x - x_1 ) / norm( x ); % compute error
```

```

        if ( error <= tol ), break, end           % check convergence

    end
    b = b / w;                                   % restore rhs

    if ( error > tol ) flag = 1; end;            % no convergence

```

Come per il metodo di Jacobi, il processo si interrompe quando la norma 2 dello step relativo

$$\frac{\|x^{(k+1)} - x^{(k)}\|_2}{\|x^{(k+1)}\|_2}$$

è inferiore ad una tolleranza `tol` prefissata oppure un numero massimo di iterazioni `max_it` è raggiunto.

3.9.3. Implementazione del metodo del gradiente coniugato. Per quanto riguarda il codice del Gradiente Coniugato, un esempio è il file `cg.m` tratto dal sito di Netlib.

In input, la matrice A e il vettore b sono relativi al sistema $Ax = b$ da risolvere, x è il vettore colonna iniziale da cui far partire le iterazioni, `max_it` il numero massimo di iterazioni da compiere e `tol` la tolleranza richiesta da un certo criterio di arresto. Infine M è un possibile preconditionatore. Se non si sa bene cosa scegliere quale preconditionatore, si ponga $M = \text{eye}(\text{size}(A))$. Delle variabili in output, x è l'approssimazione della soluzione, `error` l'errore in norma 2 compiuto, `iter` il numero di iterazioni compiute, `flag` una variabile che a seconda sia 0 o 1 l'algoritmo è uscito correttamente oppure per il numero massimo di iterazioni richieste.

```

function [x, error, iter, flag] = cg(A, x, b, M, max_it, tol)

% -- Iterative template routine --
%   Univ. of Tennessee and Oak Ridge National Laboratory
%   October 1, 1993
%   Details of this algorithm are described in "Templates for the
%   Solution of Linear Systems: Building Blocks for Iterative
%   Methods", Barrett, Berry, Chan, Demmel, Donato, Dongarra,
%   Eijkhout, Pozo, Romine, and van der Vorst, SIAM Publications,
%   1993. (ftp netlib2.cs.utk.edu; cd linalg; get templates.ps).
%
% [x, error, iter, flag] = cg(A, x, b, M, max_it, tol)
%
% cg.m solves the symmetric positive definite linear system Ax=b
% using the Conjugate Gradient method with preconditioning.
%
% input   A          REAL symmetric positive definite matrix
%         x          REAL initial guess vector
%         b          REAL right hand side vector
%         M          REAL preconditioner matrix
%         max_it     INTEGER maximum number of iterations
%         tol        REAL error tolerance
%
% output  x          REAL solution vector
%         error      REAL error norm
%         iter       INTEGER number of iterations performed
%         flag       INTEGER: 0 = solution found to tolerance

```

```

%                                     1 = no convergence given max_it

flag = 0;                               % initialization
iter = 0;

bnrm2 = norm( b );
if ( bnrm2 == 0.0 ), bnrm2 = 1.0; end

r = b - A*x;
error = norm( r ) / bnrm2;
if ( error < tol ) return, end

for iter = 1:max_it                       % begin iteration

    z = M \ r;
    rho = (r'*z);

    if ( iter > 1 ),                       % direction vector
        beta = rho / rho_1;
        p = z + beta*p;
    else
        p = z;
    end

    q = A*p;
    alpha = rho / (p'*q );
    x = x + alpha * p;                     % update approximation vector

    r = r - alpha*q;                       % compute residual
    error = norm( r ) / bnrm2;             % check convergence
    if ( error <= tol ), break, end

    rho_1 = rho;

end

if ( error > tol ) flag = 1; end           % no convergence

% END cg.m

```

Osserviamo che il procedimento itera finchè un numero massimo di iterazioni è raggiunto oppure la norma 2 del residuo (relativo)

$$\frac{\|b - Ax^{(k)}\|_2}{\|b\|_2}$$

immagazzinata nella variabile `error` risulta inferiore ad una tolleranza prefissata `tol`. In questo caso il criterio d'arresto del metodo del gradiente coniugato è diverso da quello dello step relativo utilizzato nelle precedenti versioni di `Jacobi` ed `SOR`.

3.9.4. Un esempio. Prendiamo quale esempio una matrice di Toeplitz, simmetrica e definita positiva, dalla `gallery` di Matlab.

```
>> % MATRICE DI TOEPLITZ, SIMMETRICA E DEFINITA POSITIVA.
```

```

>> A=gallery('toeppd',5)
A =
    3.3932    1.8817    0.8909    1.3019    0.9454
    1.8817    3.3932    1.8817    0.8909    1.3019
    0.8909    1.8817    3.3932    1.8817    0.8909
    1.3019    0.8909    1.8817    3.3932    1.8817
    0.9454    1.3019    0.8909    1.8817    3.3932
>> % CONTROLLO SIMMETRIA.
>> A-A'
ans =
     0     0     0     0     0
     0     0     0     0     0
     0     0     0     0     0
     0     0     0     0     0
     0     0     0     0     0
>> % CONTROLLO DEF. POSITIVA.
>> eig(A)
ans =
    0.5499
    1.8948
    2.5502
    3.0555
    8.9159
>> % TERMINE NOTO.
>> b=[1; 1; 1; 1; 1]
b =
     1
     1
     1
     1
     1
>> % SOLUZIONE COL METODO LU.
>> format long e
>> x=A\b
x =
    1.743211621943181e-01
    2.855210174362449e-02
    1.715052207727628e-01
    2.855210174362447e-02
    1.743211621943181e-01
>> %-----
>> % JACOBI (NON E' DETTO CONVERGA PER MATRICI SIMMETRICHE!!!)
>> %-----
>> x0=b; max_it=1000; tol=10^(-12);
>> t0=cputime; [x1,error,iter,flag]=jacobi(A,x0,b,max_it,tol); t1=cputime;
>> x1
x2 =
    2.812150840584267e+211
    3.182477056364826e+211
    3.075904398497104e+211
    3.182477056364826e+211
    2.812150840584267e+211
>> t1-t0
ans =

```

```

3.0000000000000114e-02
>> flag
flag =
1
>> % ANALISI: JACOBI NON CONVERGE.
>> %-----
>> % GAUSS-SEIDEL (CONVERGE!). "sor" CON "w=1".
>> %-----
>> w=1;
>> t0=cputime; [x2,error,iter,flag]=sor(A,x0,b,w,max_it,tol);; t1=cputime;
>> x2
x2 =
1.743211621945437e-01
2.855210174332565e-02
1.715052207730155e-01
2.855210174338184e-02
1.743211621944382e-01
>> error
error =
7.271979844164592e-13
>> iter
iter =
76
>> flag
flag =
0
>> t1-t0 % CPUTIME: SCRIVE 0 PERCHE' MOLTO PICCOLO.
ans =
0
>> %-----
>> % GRADIENTE CONIUGATO.
>> %-----
>> M=eye(size(A)); % NESSUN PRECONDIZIONATORE.
>> t0=cputime; [x3,error,iter,flag]=cg(A,x0,b,M,max_it,tol); t1=cputime;
>> x3
x3 =
1.743211621943214e-01
2.855210174363323e-02
1.715052207727673e-01
2.855210174363175e-02
1.743211621943232e-01
>> error
error =
5.198603009807900e-14
>> iter
iter =
3
>> % ANALISI: NUMERO DI ITERAZIONI INFERIORE O UGUALE
>> % ALLA DIMENSIONE DELLA MATRICE.
>> flag
flag =
0
>> t1-t0
ans =

```


9.9999999999998010e-03

>>

3.10. Esercizio svolto 1. Si consideri la seguente matrice pentadiagonale $A \in \mathbb{R}^{100 \times 100}$:

$$A = \begin{bmatrix} 4+\beta & -1 & -1 & & & & \\ -1 & 4+\beta & -1 & -1 & & & \\ -1 & -1 & 4+\beta & -1 & -1 & & \\ & \ddots & \ddots & \ddots & \ddots & \ddots & \\ & & -1 & -1 & 4+\beta & -1 & -1 \\ & & & -1 & -1 & 4+\beta & -1 \\ & & & & -1 & -1 & 4+\beta \end{bmatrix}$$

1. Creare la matrice in Matlab utilizzando il comando `diag`, dopo aver posto $\beta = 0.1$. Determinare il numero di elementi non nulli tramite il comando `nnz` e visualizzare il pattern di sparsità della matrice con il comando `spy`. Convertire la matrice in formato sparso utilizzando il comando `sparse` e verificare la differente occupazione di memoria nei due casi (in caso di matrici con struttura a banda come quella nellesempio, è possibile creare direttamente la matrice in formato sparso con il comando `spdiags`)
2. Si costruiscano esplicitamente le matrici di iterazione P_J e P_{GS} associate rispettivamente ai metodi di Jacobi e Gauss-Seidel, a partire dallo splitting della matrice A (si usino i comandi `diag`, `tril`, `inv`). Si calcolino i relativi raggi spettrali $\rho(P_J)$ e $\rho(P_{GS})$, utilizzando il comando `eig`. La condizione necessaria e sufficiente per la convergenza del metodo iterativo è soddisfatta in entrambi i casi? Commentare, alla luce della teoria, i risultati ottenuti.
3. Utilizzare la funzione `jacobi` che implementa il metodo di Jacobi per un generico sistema lineare $Ax = b$ per calcolare la soluzione del sistema lineare con A matrice di partenza e $b = [1, 1, \dots, 1]^T$. Si ponga come vettore iniziale $x = [0, 0, \dots, 0]^T$ tolleranza pari a $1e^{-10}$ e come numero massimo di iterazioni 1000.
4. Utilizzare la funzione `sor` che implementa il metodo di Gauss-Seidel ($\omega = 1$) per un generico sistema lineare $Ax = b$ per risolvere il sistema precedente.
5. Si confrontino i risultati ottenuti tramite i due metodi e si commentino i risultati ottenuti considerando i raggi spettrali delle matrici di iterazione.
6. Si ponga ora $\beta = -0.1$ nella matrice A . Si utilizzino nuovamente i metodi di Jacobi e Gauss-Seidel per risolvere il sistema lineare con i medesimi parametri scelti al punto 3. Si calcolino i raggi spettrali delle matrici di iterazione associate ai due metodi. Commentare, alla luce della teoria, i risultati ottenuti.

Soluzione

1. La matrice può essere costruita tramite i seguenti comandi:

```
>>n = 100;
>>UNIT = ones(n,1);
>>beta = 0.1;
>>A = (4+beta)*diag(UNIT) - diag(UNIT(1:n-1),-1) ...
- diag(UNIT(1:n-1),1) - diag(UNIT(1:n-2),-2) - diag(UNIT(1:n-2),2);
```

Il comando `nnz` restituisce il numero di elementi non nulli della matrice data in ingresso; l'output in questo caso è :

```
>>nnz(A)
ans =
    494
```

Si può convertire la matrice in formato sparso tramite il comando `sparse` e verificare la diversa occupazione di memoria con il comando `whos`:

```
>>Asp = sparse(A);
>>whos A Asp
```

Name	Size	Bytes	Class
A	100x100	80000	double array
Asp	100x100	6332	double array (sparse)

Si può vedere come il formato sparso riduca la memoria richiesta per memorizzare una stessa matrice rispetto al formato pieno.

2. Le matrici di iterazione dei due metodi si calcolano a partire dalla definizione:

```
>>D = diag(diag(A)); % D diagonale estratta da A
>>PJ = inv(D) * (D-A); % matrice di iterazione di Jacobi
>>E = -tril(A,-1); % E matrice tr. inferiore di A
>>F = -triu(A,1); % F matrice tr. superiore di A
>>PGs = inv(D-E)*F % matrice di iterazione di Gauss-Seidel

>>rho_j = max(abs(eig(PJ)))
>>rho_gs = max(abs(eig(PGs)))

rho_j =
    0.9744
rho_gs =
    0.9496
```

Dal calcolo del raggio spettrale delle matrici si può concludere che sia il metodo di Jacobi che il metodo di GaussSeidel convergono, in quanto entrambi gli autovalori massimi risultano in modulo strettamente minore di 1.

3. Per risolvere il sistema è sufficiente richiamare la funzione, dopo aver definito tutti i parametri di ingresso che richiede:

```
>>x0 = zeros(n,1); b = ones(n,1); max_it = 1000;tol = 1e-10;
>>[xJ,errorJ,iterJ,flagJ] = jacobi(A, x0, b, max_it, tol)
xJ =

    1.8133
    2.7016
    3.7329
    4.5302
    5.2599
    5.8795
    6.4229
```

```

        6.8929
        7.3017
        .....
        1.8133

errorJ =
    9.8528e-011
iterJ =
    748
flagJ =
    0

```

Il metodo di Jacobi converge in 748 iterazioni.

4. Per risolvere il sistema è sufficiente richiamare la funzione, utilizzando gli stessi parametri di ingresso del caso precedente:

```

>>w=1;
>>[xGs,errorGs,iterGs,flagGs] = sor(A, x0, b, w, max_it, tol)
xGs =

    1.8133
    2.7016
    3.7329
    .....
    2.7016
    1.8133

errorGs =
    9.7019e-011
iterGs =
    391
flagGs =
    0

```

Il metodo di GaussSeidel converge in 391 iterazioni.

5. Grazie alla teoria, dato che i due metodi risultano convergenti, il metodo di Gauss-Seidel risulta più veloce del metodo di Jacobi. Infatti, in questo esempio, il numero di iterazioni del metodo di Jacobi è circa il doppio del numero di iterazioni del metodo di GaussSeidel.
6. Con il nuovo parametro β si crea la nuova matrice e si richiamano le funzioni

```

beta = -0.1;
>>A2 = (4+beta)*diag(UNIT) - diag(UNIT(1:n-1),-1)...
-diaG(UNIT(1:n-1),1) - diaG(UNIT(1:n-2),-2) - diaG(UNIT(1:n-2),2);

>>[xJ,errorJ,iterJ,flagJ] = jacobi(A2, x0, b, max_it, tol)
>>[xGs,errorGs,iterGS,flagGs] = sor(A2, x0, b, w, max_it, tol)

```

In uscita si avranno flagJ e flagGs uguali a 1, ovvero i metodi non convergono. In effetti i raggi spettrali delle matrici di iterazione sono entrambi maggiori di 1 quindi per entrambi i metodi la condizione necessaria per la convergenza non è soddisfatta.

```

>>D = diag(diag(A2));
>>Pj = inv(D) * (D-A2);

```

```

>>E = -tril(A2,-1);
>>F = -triu(A2,1);
>>Pgs = inv(D-E)*F

>>rho_j = max(abs(eig(Pj)))
>>rho_gs = max(abs(eig(Pgs)))

rho_j =
    1.0244
rho_gs =
    1.0495

```

Se volessimo rappresentare graficamente l'andamento dell'errore al variare delle iterazioni, basterà modificare le function in modo che venga memorizzati ad ogni iterazione.

```

function [x, E, iter, flag] = jacobiE(A, x, b, max_it, tol)
    .
    .
    .
    .
    iter = 0; % initialization
    flag = 0;

    bnorm2 = norm( b );
    if ( bnorm2 == 0.0 ), bnorm2 = 1.0; end

    r = b - A*x;
    error = norm( r ) / bnorm2;
    E = [error]; %----> Inizialization error vector
    if ( error < tol ) return, end

    [m,n]=size(A);
    [ M, N ] = split( A , b, 1.0, 1 ); % matrix splitting

    for iter = 1:max_it, % begin iteration

        x_1 = x;
        x = M \ (N*x + b); % update approximation

        error = norm( x - x_1 ) / norm( x ); % compute error
        E = [E; error]; %----> collect error vector

        if ( error <= tol ), break, end % check convergence
    end

    if ( error > tol ) flag = 1; end % no convergence

```

Si richiama la funzione sempre con gli stessi parametri e poi si ottiene il grafico in scala semilogaritmica dell'andamento dell'errore memorizzato nel vettore EJ:

```

[xJ,EJ,iterJ, flagJ] = jacobiE(A, x0, b, max_it, tol);
semilogy([0:iterJ],EJ,'b');

```

```
legend('jacobi')
grid
```




FIGURA 3.1. Andamento dell'errore nel metodo di Jacobi

Coerentemente con il criterio d'arresto utilizzato, il metodo si arresta quando l'errore raggiunge la tolleranza fissata di $1e^{-10}$

3.11. Esercizi proposti.

1. Si modifichino le function `sor` e `cg` in modo che diano in uscita il vettore degli errori e le si utilizzino per graficare l'andamento dell'errore dei tre metodi come visto nell'esercizio svolto relativamente al sistema precedente (si usi il comando `hold on` per trattenere l'ambiente grafico e plottare i tre grafici sulla stessa finestra.)
2. Si considerino le matrici $T \in \mathbb{R}^{N \times N}$ ed $F \in \mathbb{R}^{N \times N}$ $N = 47$, definite attraverso i seguenti comandi Matlab,

```
N=47;
T=2*diag(ones(N,1),0) - diag(ones(N-1,1),1) - diag(ones(N-1,1),-1);
F=6*diag(ones(N,1),0) - 4*diag(ones(N-1,1),1) - 4*diag(ones(N-1,1),-1) ...
+ diag(ones(N-2,1),2) + diag(ones(N-2,1),-2);
```

Sia fissato $h = 1/(N + 3) = 1/50$, definire la matrice $A \in \mathbb{R}^{N \times N}$ e il termine noto $f \in \mathbb{R}^N$ tali che

$$A = \frac{T}{h^2} + \frac{F}{h^4}, \quad f = -[1, 1, \dots, 1]^T$$

dove T ed F sono le matrici definite sopra. il sistema lineare $Au = f$ deriva dall'approssimazione numerica dello spostamento verticale di una trave di lunghezza unitaria incastrata agli estremi e flessa da una forzante uniforme di intensità unitaria diretta verso il basso.

- (a) Verificare che A è simmetrica e definita positiva e calcolare il numero di condizionamento $K_2(A)$ (si usi il comando `cond` aiutandosi eventualmente con l'Help di Matlab).
- (b) Risolvere il sistema lineare $Au = f$ con i metodi di Gauss Seidel, Jacobi e metodo del gradiente coniugato non preconditionato con una tolleranza $tol = 10^{-10}$ e un numero massimo di iterazioni $nmax = 1000$. Riportare il numero

di iterazioni effettuate e visualizzare il grafico della funzione discreta u_i per $i = 1, \dots, N$ rispetto a vettore $x_i = (i + 1)h$, $i = 1, \dots, N$.

- (c) Si risolva lo stesso sistema usando il metodo del gradiente coniugato preconditionato. Come preconditionatori si confrontino le seguenti scelte per il preconditionatore:
- il preconditionatore P_1 uguale alla matrice diagonale estratta da A .
 - il preconditionatore P_2 uguale alla matrice T/h^2 .
- Si commentino i risultati ottenuti relativamente al numero di iterazioni richieste per la convergenza in relazione al numero di condizionamento della matrice A e della matrice $P^{-1}A$. Quale preconditionatore risulta più efficace?

3.12. Esercizi facoltativi.

1. Si consideri la seguente matrice $A \in \mathbb{R}^{N \times N}$:

$$A = \begin{bmatrix} 1 & -1 & 1 & 1 & \cdots & 1 \\ R_1 & R_2 & 0 & 0 & \cdots & 0 \\ 0 & R_1 & R_2 & 0 & \cdots & 0 \\ \vdots & 0 & \ddots & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & R_1 & R_2 \end{bmatrix}$$

Si ponga $n = 100$, $R_1 = 1$, $R_2 = 3$.

- Memorizzare la matrice in formato pieno, e determinare il numero di elementi non nulli tramite il comando `nnz` e visualizzare il pattern di sparsità della matrice con il comando `spy`.
- Si costruiscano esplicitamente le matrici di iterazione P_J e P_{GS} associate rispettivamente ai metodi di Jacobi e Gauss-Seidel, a partire dallo splitting della matrice A . Si calcolino i relativi raggi spettrali $\rho(P_J)$ e $\rho(P_{GS})$, utilizzando il comando `eig`. La condizione necessaria e sufficiente per la convergenza del metodo iterativo è soddisfatta in entrambi i casi? Commentare, alla luce della teoria, i risultati ottenuti.
- Si determini la soluzione del sistema lineare $Ax = b$ con b vettore di dimensione n :

$$b = [2, 1, \dots, 1]^T$$

con il metodo di Jacobi e Gauss-Seidel.

Si ponga $x_0 = [1, 1, \dots, 1]^T$ tolleranza $tol = 10^{-6}$ e numero massimo di iterazioni $nmax = 1000$.

- Si confrontino i risultati ottenuti tramite i due metodi e si commentino i risultati ottenuti alla luce del numero di condizionamento per la matrice A .
- Si calcoli la fattorizzazione LU della matrice A ; cosa si può osservare confrontando il pattern di sparsità delle matrici L e U con quello di A ? Che fenomeno si è verificato? Commentare i risultati ottenuti confrontando il metodo LU con i metodi iterativi visti.

2. Sia data la matrice $A \in \mathbb{R}^{10 \times 10}$ seguente,

$$A = \begin{bmatrix} 3 & -1 & 0 & 0 \\ -1 & 3 & -1 & 0 \\ 0 & -1 & 3 & -1 \\ & \ddots & \ddots & \ddots \\ & 0 & 0 & -1 & 3 \end{bmatrix}$$

e il sistema lineare associato $Ax = b$, ove b è scelto in modo tale che la soluzione esatta del sistema sia $x = [1, 1, \dots, 1]^T$

- (a) Verificare che la matrice A è simmetrica, definita positiva e a dominanza diagonale stretta. Stabilire inoltre se i metodi iterativi di Jacobi, Gauss-Seidel sono convergenti. Si consideri inoltre il metodo SOR, con matrice di iterazione

$$P_{SOR} = (D - \omega E)^{-1}(\omega F + (1 - \omega)D)$$

utilizzando il programma `sor` applicato al sistema lineare $Ax = b$ con tolleranza $\text{tol} = 10^{-6}$, numero massimo di iterazioni $N_{max} = 1000$, e per 50 valori di ω equidistribuiti su $[-3, 3]$ si traccino in funzione di ω i grafici sovrapposti di

- raggio spettrale $\rho(P_{SOR(\omega)})$
 - rapporto k/N_{max} , dove k è il numero di iterazioni del metodo SOR eseguite.
- Commentare i risultati ottenuti per fornire una stima sperimentale dell'intervallo di valori di ω per i quali il metodo SOR converge, e per fornire il valore ottimale ω_{opt} del parametro di rilassamento che massimizza la velocità di convergenza.
- (b) Verificare numericamente che $\rho(P_{Gs}) = \rho(P_J)^2$. Determinare quindi la relazione tra le velocità di convergenza dei due metodi e verificarla sperimentalmente usando i programmi `jacobi` e `sor`.

4. Autovalori. Il problema del calcolo degli autovalori di una matrice quadrata A di ordine n consiste nel trovare gli n numeri (possibilmente complessi) λ tali che

$$Ax = \lambda x, \quad x \neq 0 \quad (4.1)$$

A seconda delle esigenze talvolta è richiesto solamente il calcolo di alcuni autovalori (ad esempio quelli di massimo modulo, per determinare lo spettro della matrice) mentre in altri casi si vogliono determinare tutti gli n autovalori in $\mathbb{C}$.

4.1. Il metodo delle potenze. Il metodo delle potenze è particolarmente indicato per il calcolo dell'autovalore di massimo modulo di una matrice.

Sia A una matrice quadrata di ordine n con n autovettori $x_1, \dots, x_n$ linearmente indipendenti e autovalori $\lambda_1, \dots, \lambda_n$ tali che

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|. \quad (4.2)$$

Ricordiamo i seguenti risultati.

1. Una matrice A è diagonalizzabile se e solo se possiede n autovettori linearmente indipendenti.
2. Se tutti gli autovalori di A sono distinti la matrice è diagonalizzabile; l'opposto è ovviamente falso (si pensi alla matrice identica).

3. Una matrice simmetrica (hermitiana) è diagonalizzabile. L'opposto è ovviamente falso, visto che la matrice

$$A = \begin{pmatrix} 15 & 0 \\ 1 & 10 \end{pmatrix} \quad (4.3)$$

è diagonalizzabile visto che ha tutti gli autovalori distinti ma non è simmetrica.

Il metodo delle potenze è definito come segue. Sia $t_0 \in \mathcal{R}^n$ definito da

$$t_0 = \sum_{i=1}^n \alpha_i x_i, \quad \alpha_1 \neq 0,$$

e si generi la successione

$$y_0 = t_0 \quad (4.4)$$

$$y_k = Ay_{k-1}, \quad k = 1, 2, \dots \quad (4.5)$$

TEOREMA 4.1. *Sia A è una matrice quadrata diagonalizzabile avente autovalori λ_k tali che*

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|.$$

Siano $u_k \neq 0$ autovettori relativi all'autovalore λ_k , cioè

$$Au_k = \lambda_k u_k.$$

Sia

$$y_0 = \sum_k \alpha_k u_k, \quad \alpha_1 \neq 0.$$

La successione $\{y_s\}$ definita da $y_{s+1} = Ay_s$ converge ad un vettore parallelo a x_1 e che il coefficiente di Rayleigh (relativo al prodotto scalare euclideo)

$$\rho(y_s, A) := \frac{(y_s, Ay_s)}{(y_s, y_s)} \quad (4.6)$$

converge a λ_1 .

NOTA 4.2. *Il metodo converge anche nel caso in cui*

$$\lambda_1 = \dots = \lambda_r$$

per $r > 1$, tuttavia non è da applicarsi quando l'autovalore di modulo massimo non è unico.

NOTA 4.3. *In virtù di alcune possibili problemi di underflow e underflow si preferisce normalizzare passo passo il vettore y_k definito in (4.4). Conseguentemente l'algoritmo del metodo delle potenze risulta*

$$u_k = At_{k-1} \quad (4.7)$$

$$t_k = \frac{u_k}{\beta_k}, \quad \beta_k = \|u_k\|_2 \quad (4.8)$$

$$l_k = \rho(t_k, A) \quad (4.9)$$

dove $\rho(t_k, A)$ è il coefficiente di Rayleigh definito in (4.6).

4.2. Il metodo delle potenze inverse. Una variante particolarmente interessante del metodo delle potenze è particolarmente utile nel caso in cui A sia una matrice quadrata con n autovettori linearmente indipendenti,

$$|\lambda_1| \geq |\lambda_2| \geq \dots > |\lambda_n| > 0. \quad (4.10)$$

e si desidera calcolare il più piccolo autovalore in modulo, cioè λ_n , applicando il metodo delle potenze ad A^{-1} . Si ottiene così la successione $\{t_k\}$ definita da

$$Au_k = t_{k-1} \quad (4.11)$$

$$t_k = \frac{u_k}{\beta_k}, \quad \beta_k = \|u_k\|_2 \quad (4.12)$$

e convergente ad un vettore parallelo a x_n . La successione di coefficienti di Rayleigh

$$\rho(t_k, A^{-1}) := \frac{(t_k, A^{-1}t_k)}{(t_k, t_k)} = \frac{(t_k, u_{k+1})}{(t_k, t_k)} \rightarrow 1/\lambda_n. \quad (4.13)$$

da cui è immediato calcolare λ_n .

Vediamo in dettaglio questo punto. Se $\{\xi_i\}$ sono gli autovalori di A^{-1} con

$$|\xi_1| > |\xi_2| \geq |\xi_3| \geq \dots \geq |\xi_n|$$

allora il metodo delle potenze inverse calcola un'approssimazione di ξ_1 e di un suo autovettore x . Si osserva subito che se $A^{-1}x = \xi_i x$ (con $\xi_i \neq 0$) allora moltiplicando ambo membri per $\xi_i^{-1}A$ si ottiene leggendo da destra a sinistra $Ax = \xi_i^{-1}x$ cioè ξ_i^{-1} è un autovalore di A e x è non solo autovettore di A^{-1} relativo all'autovalore ξ_i , ma pure autovettore di A relativo all'autovalore ξ_i^{-1} . Conseguentemente se ξ_1 è l'autovalore di massimo modulo di A^{-1} e λ_n è l'autovalore di minimo modulo di A si ha $\lambda_n = \xi_1^{-1}$ e che

$$A^{-1}x = \xi_1 x \Rightarrow Ax = \xi_1^{-1}x = \lambda_n x$$

Notiamo che il metodo delle potenze inverse, calcola $\xi_1 = \lambda_n^{-1}$ e il relativo autovettore x . Per ottenere λ_n viene naturale calcolare ξ_1^{-1} , ma usualmente essendo x autovettore di A relativo a λ_n si preferisce per questioni numeriche calcolare λ_n via coefficiente di Rayleigh

$$\rho(x, A) := \frac{(x, Ax)}{(x, x)}.$$

In generale, fissato $\mu \in \mathbb{C}$ è possibile calcolare, se esiste unico, l'autovalore λ più vicino a μ considerando il seguente pseudocodice:

$$(A - \mu I)z_k = q_{k-1} \quad (4.14)$$

$$q_k = z_k / \|z_k\|_2 \quad (4.15)$$

$$\sigma_k = (q_k)^H A q_k \quad (4.16)$$

Ricordiamo che se λ è autovalore di A allora

$$Ax = \lambda x \Rightarrow (A - \mu I)x = \lambda x - \mu x = (\lambda - \mu)x$$

e quindi $\lambda - \mu$ è autovalore di $A - \mu I$. Il metodo delle potenze inverse applicato a $A - \mu I$ calcola il minimo autovalore $\sigma = \lambda - \mu$ in modulo di $A - \mu I$ cioè il σ che rende minimo il valore di $|\sigma| = |\lambda_i - \mu|$, dove λ_i sono gli autovalori di A . Quindi essendo $\lambda_i = \sigma_i - \mu$ si ottiene pure il λ_i più vicino a μ .

4.3. Il metodo QR. Sia A una matrice quadrata di ordine n . Utilizzando il metodo di Householder è possibile fattorizzare la matrice A come prodotto di due matrici Q ed R con Q unitaria (cioè $Q^T * Q = Q * Q^T = I$) ed R triangolare superiore. Citiamo alcune cose:

1. La matrice A ha quale sola particolarità di essere quadrata. Nel caso generale però la sua fattorizzazione QR in generale non è unica bensì determinata a meno di una matrice di fase.
2. Tale fattorizzazione non è unica (i segni delle componenti sulla diagonale della matrice A possono essere scelti arbitrariamente). Nel caso sia non singolare, allora tale fattorizzazione è unica qualora si chieda che i coefficienti diagonali di R siano positivi.
3. La routine Matlab `qr` effettua tale fattorizzazione.
4. Se la matrice H è simile a K (cioè esiste una matrice non singolare S tale che $H = S^{-1}KS$) allora H e K hanno gli stessi autovalori. Si può vedere facilmente che la relazione di similitudine è transitiva, cioè se H_1 è simile ad H_2 e H_2 è simile ad H_3 allora H_1 è simile ad H_3 .

Il metodo QR venne pubblicato indipendentemente nel 1961 da Francis e da Kublanovskaya e successivamente implementato in EISPACK. Ci limiteremo a considerare versioni di base del metodo.

Sia

$$A_0 = A = Q_0 R_0$$

e si ponga

$$A_1 := R_0 Q_0.$$

Poichè

$$Q_0 A_1 Q_0^T = Q_0 A_1 Q_0^T = Q_0 R_0 Q_0 Q_0^T = A_0$$

la matrice A_1 è simile ad A_0 (si ponga $S = Q_0^{-1} = Q_0^T$) e quindi ha gli stessi autovalori. Sia quindi in generale

$$A_k = Q_k R_k$$

$$A_{k+1} = R_k Q_k.$$

Per le stesse motivazioni A_{k+1} è simile ad A_k , e per transitività ad A_0 . Quindi A_{k+1} ha gli stessi autovalori di A_0 .

Per la convergenza del metodo esistono vari risultati. Ricordiamo principalmente

TEOREMA 4.4. *Se la matrice $A \in \mathbb{R}^{n \times n}$ è regolare e con autovalori tutti distinti in modulo, con*

$$|\lambda_1| > \dots > |\lambda_n| \quad (4.17)$$

allora l'algoritmo QR converge ad una matrice A_∞ triangolare superiore. Se la matrice è simmetrica, allora

$$A_\infty = \text{diag}(\lambda_1, \dots, \lambda_n).$$

Inoltre se A è una matrice Hessenberg superiore allora l'algoritmo QR converge ad una matrice A_∞ triangolare a blocchi, simile ad A e con gli autovalori di ogni blocco diagonale tutti uguali in modulo.

Alcuni dettagli.

1. Nelle implementazioni si calcola con un metodo scoperto da Householder (ma esiste un metodo alternativo dovuto a Givens) una matrice di Hessenberg T

$$T = \begin{pmatrix} a_{1,1} & a_{1,2} & a_{1,3} & \dots & a_{1,n} \\ a_{2,1} & a_{2,2} & a_{2,3} & \dots & a_{2,n} \\ 0 & a_{3,2} & a_{3,3} & \dots & a_{3,n} \\ 0 & 0 & a_{4,3} & \dots & a_{4,n} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & a_{n,n-1} & a_{n,n} \end{pmatrix}$$

simile ad A ed in seguito si applica il metodo QR relativamente alla matrice T . Se A è simmetrica la matrice T risulta tridiagonale simmetrica. In entrambi i casi le iterazioni mantengono la struttura, cioè se $A_0 = T$ è di Hessenberg, allora A_k è di Hessenberg, se $A_0 = T$ è tridiagonale allora A_k è tridiagonale.

2. Per inciso, si può dimostrare che la velocità di convergenza dipende dal rapporto

$$\rho := \max_{1 \leq i \leq n-1} \max \frac{|\lambda_{i+1}|}{|\lambda_i|}. \quad (4.18)$$

Il numero di moltiplicazioni necessarie all'algoritmo di Givens per calcolare tale matrice T a partire da A è approssimativamente $10n^3/3$ mentre per quanto riguarda l'algoritmo di Householder è $5n^3/3$. Il metodo QR applicato ad una matrice A in forma di Hessenberg superiore ha ad ogni passo un costo di $2n^2$ operazioni moltiplicative.

3. Se la condizione (4.17) non è verificata si può dimostrare che la successione $\{A_k\}$ tende a una forma triangolare a blocchi.

4.4. Implementazione Matlab di alcuni metodi per il calcolo degli autovalori. Partiamo con una versione semplice `power_basic` del metodo delle potenze

```
function [lambda1, x1, niter, err]=power_basic(A,z0,toll,nmax)

% INPUT:
% A    : MATRICE DI CUI VOGLIAMO CALCOLARE L'AUTOVALORE DI MASSIMO MODULO.
% z0   : VETTORE INIZIALE (NON NULLO).
% toll : TOLLERANZA.
% nmax : NUMERO MASSIMO DI ITERAZIONI.
%
% OUTPUT:
% lambda1 : VETTORE DELLE APPROSSIMAZIONI DELL'AUTOVALORE DI MASSIMO MODULO.
% x1      : AUTOVETTORE RELATIVO ALL'AUTOVALORE DI MASSIMO MODULO.
% niter   : NUMERO DI ITERAZIONI.
% err     : VETTORE DEI RESIDUI PESATI RELATIVI A "lambda1".
%
% TRATTO DA QUARTERONI-SALERI, "MATEMATICA NUMERICA", p. 184.
%
```

```

q=z0/norm(z0); q2=q; err=[]; lambda1=[];
res=toll+1; niter=0; z=A*q;
while (res >= toll & niter <= nmax)
    q=z/norm(z); z=A*q; lam=q'*z; x1=q;
    z2=q2'*A; q2=z2/norm(z2); q2=q2'; y1=q2; costheta=abs(y1'*x1);
    niter=niter+1; res=norm(z-lam*q)/costheta;
    err=[err; res]; lambda1=[lambda1; lam];
end

```

Qualche nota

1. il vettore iniziale z_0 e' normalizzato ed in `err`, `lambda1` vengono memorizzati rispettivamente i valori dell'errore compiuto e dell'autovalore di massimo modulo $\lambda_{\max}$;
2. l'assegnazione `res=toll+1`; forza l'algoritmo ad entrare nel ciclo `while`, mentre `z=A*q`; è una quantità da utilizzarsi per il calcolo dell'autovalore $\lambda_{\max}$;
3. nel ciclo `while`, `q` è un'approssimazione di un autovettore relativo a $\lambda_{\max}$, mentre `lam` di $\lambda_{\max}$;
4. il ciclo si interrompe se un numero massimo di iterazioni `niter` è raggiunto oppure

$$\frac{\|Aq^k - \lambda^k\|_2}{|\cos(\theta_{\lambda_k})|} < \text{tol}$$

dove θ_{λ_k} è l'angolo formato tra (un'approssimazione del)l'autovalore destro x_1 e sinistro y_1 associati a `lam`

4.4.1. Esempio 1. Testiamo il codice relativamente al calcolo dell'autovalore di massimo modulo di

$$\begin{aligned}
 A &= \begin{pmatrix} -15.5 & 7.5 & 1.5 \\ -51 & 25 & 3 \\ -25.5 & 7.5 & 11.5 \end{pmatrix} \\
 &= \begin{pmatrix} 1 & 2 & 3 \\ 2 & 5 & 6 \\ 7 & 9 & 3 \end{pmatrix} \cdot \begin{pmatrix} 10 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} 1 & 2 & 3 \\ 2 & 5 & 6 \\ 7 & 9 & 3 \end{pmatrix}^{-1} \quad (4.19)
 \end{aligned}$$

La matrice A è diagonalizzabile e ha autovalori 10, 10, 1. Si può vedere che una base di autovettori relativa agli autovalori 10, 10, 1 è composta da (1, 2, 7), (2, 5, 9), (3, 6, 3). Quale vettore iniziale del metodo delle potenze consideriamo

$$z_0 = (1, 1, 1) = (7/6) \cdot (1, 2, 7) - 1 \cdot (2, 5, 9) + (11/18) \cdot (3, 6, 3)$$

e quindi il metodo delle potenze applicato ad A , e avente quale punto iniziale z_0 può essere utilizzato per il calcolo dell'autovalore di massimo modulo di A , poichè $\alpha_1 = 7/6 \neq 0$. Dalla shell di Matlab/Octave:

```

>> S=[1 2 3; 2 5 6; 7 9 3];
>> D=diag([10 10 1]);
>> A=S*D*inv(S)
A =
   -15.5000    7.5000    1.5000

```

```

-51.0000    25.0000     3.0000
-25.5000     7.5000    11.5000
>> z0=[1 1 1]';
>> toll=10^(-8);
>> nmax=10;
>> format short e;
>> [lambda1, x1, niter, err]=power_basic(A,z0,toll,nmax)
lambda1 =
  1.1587e+001
  1.0138e+001
  1.0014e+001
  1.0001e+001
  1.0000e+001
  1.0000e+001
  1.0000e+001
  1.0000e+001
  1.0000e+001
  1.0000e+001
  1.0000e+001
x1 =
 -2.8583e-001
 -9.1466e-001
 -2.8583e-001
niter =
    10
err =
  2.2466e+000
  2.1028e-001
  2.0934e-002
  2.0925e-003
  2.0924e-004
  2.0924e-005
  2.0924e-006
  2.0924e-007
  2.0924e-008
  2.0924e-009
>>

```

La convergenza è abbastanza veloce come si vede dalla quantità `err`, che consiste in un particolare residuo pesato.

Una questione sorge spontanea. Cosa sarebbe successo se avessimo utilizzato l'algoritmo senza normalizzazione come ad esempio `power_method` definito da

```

function [lambda,v]=power_method(A,x0,maxit)

v=x0;

for index=1:maxit
    v_old=v;
    v=A*v_old;
    lambda=(v_old'*v)/(v_old'*v_old);
end

```

Proviamo il test, facendo iterare il metodo prima 5, poi 100 volte e alla fine 1000 volte (si noti il settaggio della variabile `maxit` relativa al numero di iterazioni da compiere):

```
>> x0=[1 1 1]'
x0 =
     1
     1
     1
>> A=[-15.5 7.5 1.5; -51 25 3; -25.5 7.5 11.5]
A =
    -15.5000     7.5000     1.5000
    -51.0000    25.0000     3.0000
    -25.5000     7.5000    11.5000
>> [lambda,v]=power_method(A,x0,5)
lambda =
    10.0014
v =
    1.0e+005 *
    -0.8333
    -2.6666
    -0.8333
>> [lambda,v]=power_method(A,x0,100)
lambda =
    10.0000
v =
    1.0e+100 *
    -0.8333
    -2.6667
    -0.8333
>> [lambda,v]=power_method(A,x0,1000)
lambda =
    NaN
v =
    NaN
    NaN
    NaN
>>
```

La ragione è semplice. Per k relativamente piccolo si ha $A \cdot t_k \approx 10 \cdot t_k$ e quindi per $s \geq k$

$$t_s \approx A^{s-k} \cdot t_k \approx 10 \cdot A^{s-k-1} \cdot t_k \approx \dots \approx 10^{s-k} \cdot t_k$$

da cui

$$\|t_s\|_2 \approx 10^{s-k} \cdot \|t_k\|_2$$

spiegando quindi perchè si possano avere problemi di overflow applicando l'algoritmo di base.

4.4.2. Esempio 2. Proviamo un test diverso, questa volta con la matrice (diagonalizzabile)

$$A = \begin{pmatrix} 1 & 2 \\ 0 & -1 \end{pmatrix},$$

avente autovalori $\lambda_1 = 1$ e $\lambda_2 = -1$ e autovettori linearmente indipendenti $(1, 0)$, $(-1, 1)$.
Quale vettore iniziale poniamo

$$x_0 = (1, 3) = 4 \cdot (1, 0) + 3 \cdot (-1, 1)$$

e quindi il metodo delle potenze applicato ad A, partendo da x_0 può essere sicuramente applicato. D'altra parte dubitiamo converga in quanto $|\lambda_1| = |\lambda_2| = 1$ pur essendo $\lambda_1 \neq \lambda_2$.
Dalla shell di Matlab/Octave:

```
>> A=[1 2; 0 -1]
A =
     1     2
     0    -1
>> [lambda1, x1, niter, err]=power_basic(A,[1; 3],10^(-8),15)
lambda1 =
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
-3.4483e-002
-2.0000e-001
x1 =
 3.1623e-001
 9.4868e-001
niter =
    16
err =
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
 4.4567e-001
 2.4000e+000
```

>>

Dal residuo pesato è chiaro che il metodo non converge, e come anticipato il motivo è la presenza di autovalori distinti aventi modulo massimo.

4.4.3. Esempio 3. Per terminare, vediamo il caso della matrice diagonalizzabile (avendo autovalori distinti)

$$A = \begin{pmatrix} 1 & 2 \\ 0 & 10 \end{pmatrix},$$

in cui il metodo funziona rapidamente, in quanto esiste un solo autovalore di modulo massimo, uguale a 10.

```
>> A=[1 2; 0 10]
A =
     1     2
     0    10
>> [lambda1, x1, niter, err]=power_basic(A,[1; 3],10^(-8),15)
lambda1 =
 9.9779e+000
 9.9979e+000
 9.9998e+000
 1.0000e+001
 1.0000e+001
 1.0000e+001
 1.0000e+001
 1.0000e+001
 1.0000e+001
x1 =
 2.1693e-001
 9.7619e-001
niter =
     8
err =
 9.6726e-002
 9.7529e-003
 9.7610e-004
 9.7618e-005
 9.7619e-006
 9.7619e-007
 9.7619e-008
 9.7619e-009
```

Si osservi che il metodo termina in quanto l'errore pesato `err` è minore della tolleranza $toll = 10^{-8}$.

4.5. Il metodo delle potenze inverse. Una versione di base `invpower` del metodo delle potenze inverse è

```
function [lambda, x, niter, err]=invpower(A,z0,mu,toll,nmax)

% DATO UN VALORE mu, SI CALCOLA L'AUTOVALORE "lambda_mu" PIU' VICINO A mu.
```



```

% INPUT:
% A : MATRICE DI CUI VOGLIAMO CALCOLARE L'AUTOVALORE "lambda_mu".
% z0 : VETTORE INIZIALE (NON NULLO).
% mu : VALORE DI CUI VOGLIAMO CALCOLARE L'AUTOVALORE PIU' VICINO.
% toll: TOLLERANZA.
% nmax: NUMERO MASSIMO DI ITERAZIONI.
%
% OUTPUT:
% lambda : VETTORE DELLE APPROSSIMAZIONI DELL'AUTOVALORE DI MINIMO MODULO.
% x : AUTOVETTORE RELATIVO ALL'AUTOVALORE DI MINIMO MODULO.
% niter : NUMERO DI ITERAZIONI.
% err : VETTORE DEI RESIDUI PESATI RELATIVI A "lambda".
%
% TRATTO DA QUARTERONI-SALERI, "MATEMATICA NUMERICA", p. 184.
%

n=max(size(A)); M=A-mu*eye(n); [L,U,P]=lu(M);
q=z0/norm(z0); q2=q'; err=[]; lambda=[];
res=toll+1; niter=0;
while (res >= toll & niter <= nmax)
    niter=niter+1; b=P*q; y=L\b; z=U\y;
    q=z/norm(z); z=A*q; lam=q'*z;
    b=q2'; y=U'\b; w=L'\y;
    q2=(P'*w)'; q2=q2/norm(q2); costheta=abs(q2*q);
    if (costheta > 5e-2)
        res=norm(z-lam*q)/costheta; err=[err; res]; lambda=[lambda; lam];
    else
        disp('\n \t [ATTENZIONE]: AUTOVALORE MULTIPLIO'); break;
    end
    x=q;
end

```

Forniamo ora alcune spiegazioni del codice in `invpower`.

1. Per risolvere il sistema lineare in 4.14, si effettua una fattorizzazione $PM = LU$ della matrice $M = A - \mu I$;
2. All'interno del ciclo while, nella prima riga si calcola z_k , mentre nella successiva un suo versore q_k , e σ_k è immagazzinato in `lam`;
3. Similmente al metodo diretto si effettua il prodotto scalare di un'autovalore sinistro con uno destro.

4.5.1. Esempio 1. Applichiamo il metodo delle potenze inverse per il calcolo dell'autovalore più piccolo in modulo della matrice

$$\begin{aligned}
 A &= \begin{pmatrix} -15.5 & 7.5 & 1.5 \\ -51 & 25 & 3 \\ -25.5 & 7.5 & 11.5 \end{pmatrix} \\
 &= \begin{pmatrix} 1 & 2 & 3 \\ 2 & 5 & 6 \\ 7 & 9 & 3 \end{pmatrix} \cdot \begin{pmatrix} 10 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} 1 & 2 & 3 \\ 2 & 5 & 6 \\ 7 & 9 & 3 \end{pmatrix}^{-1} \quad (4.20)
 \end{aligned}$$

Come visto la matrice A è quindi diagonalizzabile, ha autovalori 10, 10, 1 e relativi autovettori $(1, 2, 7)$, $(2, 5, 9)$, $(3, 6, 3)$ formanti una base di $\mathbb{R}^3$. Quale vettore iniziale del metodo delle

potenze consideriamo

$$z_0 = (1, 1, 1) = (7/6) \cdot (1, 2, 7) - 1 \cdot (2, 5, 9) + (11/18) \cdot (3, 6, 3)$$

e quindi il metodo delle potenze inverse applicato ad A , e avente quale punto iniziale z_0 può essere utilizzato per il calcolo dell'autovalore di minimo modulo di A .

```
>> z0=[1;1;1]; mu=0; toll=10^(-8); nmax=10;
>> A=[-15.5 7.5 1.5; -51 25 3; -25.5 7.5 11.5]
A =
-15.500000000000000    7.500000000000000    1.500000000000000
-51.000000000000000   25.000000000000000    3.000000000000000
-25.500000000000000    7.500000000000000   11.500000000000000
>> [lambda, x, niter, err]=invpower(A,z0,mu,toll,nmax)
lambda =
    0.39016115351993
    0.94237563941268
    0.99426922936854
    0.99942723776656
    0.99994272692315
    0.99999427272378
    0.99999942727270
    0.99999994272728
    0.99999999427273
x =
    0.40824829053809
    0.81649658085350
    0.40824829053809
niter =
     9
err =
    0.81535216507377
    0.08358101289062
    0.00838126258396
    0.00083836078891
    0.00008383842712
    0.00000838386620
    0.00000083838685
    0.00000008383868
    0.00000000838387
>>
```

La convergenza è lineare (come si intuisce dalle approssimazioni contenute nel vettore `lambda`).

Per vederlo, dalla shell di Matlab/Octave calcoliamo l'errore assoluto/relativo relativo all'autovalore 1:

```
>> s=1-lambda
s =
    0.60983884648007
    0.05762436058732
    0.00573077063146
    0.00057276223344
    0.00005727307685
    0.00000572727622
```




FIGURA 4.1. Grafico che illustra la convergenza lineare del metodo delle potenze inverse nell'esempio 1.

```
0.00000057272730
0.0000005727272
0.000000572727
>> semilogy(1:length(s),s)
```

generando il grafico in scala semi-logaritmica in figura che evidentemente sottolinea la convergenza lineare.

4.6. Il metodo QR. Una versione di base del metodo QR è la seguente. Si salvi il file `houshess.m` che implementa la trasformazione per similitudine di A in una matrice di Hessenberg

```
function [H,Q]=houshess(A)

% REDUCTION OF A MATRIX TO A SIMILAR HESSENBERG ONE.
% SEE QUARTERONI, SACCO, SALERI P. 192.

n=max(size(A)); Q=eye(n); H=A;

for k=1:(n-2)
    [v,beta]=vhouse(H(k+1:n,k)); I=eye(k); N=zeros(k,n-k);
    m=length(v); R=eye(m)-beta*v*v'; H(k+1:n,k:n)=R*H(k+1:n,k:n);
    H(1:n,k+1:n)=H(1:n,k+1:n)*R; P=[I,N; N',R]; Q=Q*P;
end
```

ove `vhouse.m` è definito da

```
function [v,beta]=vhouse(x)

% BUILDING HOUSEHOLDER VECTOR.
% SEE QUARTERONI, SACCO, SALERI P. 197.

n=length(x); x=x/norm(x); s=x(2:n)'*x(2:n); v=[1; x(2:n)];
if (s==0)
    beta=0;
else
    mu=sqrt(x(1)^2+s);
    if (x(1) <= 0)
        mu=-mu;
    end
    beta=(x(1)+mu)/x(1);
    v=v-beta*x;
```

```

        v(1)=x(1)-mu;
    else
        v(1)=-s/(x(1)+mu);
    end
    beta=2*v(1)^2/(s+v(1)^2);
    v=v/v(1);
end

```

quindi `QRbasicmethod.m` che calcola la matrice triangolare T relativa a QR:

```

function [T,hist]=QRbasicmethod(T_input,maxit)

% QR METHOD FOR A SYMMETRIC TRIDIAGONAL MATRIX "T_input".

T=T_input;
hist=sort(diag(T));

for index=1:maxit
    [Q,R]=qr(T);
    T=R*Q; % NEW SIMILAR MATRIX.
    hist=[hist sort(diag(T))]; % IT STORES THE DIAGONAL ELEMENTS
                                % OF THE "index" ITERATION.
end

```

In questa sezione desideriamo calcolare gli autovalori della matrice (simmetrica e a banda) di Poisson

$$A = \begin{pmatrix} B & -I & 0 & \dots & 0 \\ -I & B & -I & \dots & 0 \\ 0 & -I & B & \dots & \dots \\ 0 & \dots & \dots & \dots & -I \\ 0 & 0 & \dots & -I & B \end{pmatrix}$$

con

$$B = \begin{pmatrix} 4 & -1 & 0 & \dots & 0 \\ -1 & 4 & -1 & \dots & 0 \\ 0 & -1 & 4 & \dots & \dots \\ 0 & \dots & \dots & \dots & -1 \\ 0 & 0 & \dots & -1 & 4 \end{pmatrix}.$$

che si ottiene dal comando `makefish`. Più precisamente in `demoQR.m` scriviamo il seguente codice per il calcolo degli autovalori della matrice di Poisson `makefish(2)`, mostrando come la matrice di partenza A viene trasformata in una matrice di Hessenberg H da cui si calcola la matrice T triangolare superiore prodotta dalle iterazioni di QR:

```

format short

maxit=100;
siz=2;

A = makefish(siz);
eigs=eig(A);

```

```
[H,Q]=houshess(A);

[T,hist]=QRbasicmethod(H,maxit);

A
H
T
eig(A)
```

Otteniamo come risultato

```
>> demoQR
A =

     4     -1     -1     0
    -1     4      0    -1
    -1     0      4    -1
     0     -1     -1     4

H =

    4.0000    1.4142    0.0000   -0.0000
    1.4142    4.0000    1.4142   -0.0000
   -0.0000    1.4142    4.0000   -0.0000
         0   -0.0000   -0.0000    4.0000

T =

    6.0000    0.0000   -0.0000   -0.0000
    0.0000    4.0000    0.0000   -0.0000
   -0.0000   -0.0000    4.0000    0.0000
         0   -0.0000    0.0000    2.0000

ans =

    2.0000
    4.0000
    4.0000
    6.0000

>>
```

In cui si vede che gli autovalori, sono le componenti diagonali della matrice T .

4.7. Esercizio: Calcolo degli zeri di un polinomio, via autovalori della matrice compagna. Si può dimostrare che gli zeri del polinomio monico di grado n

$$p(t) = c_0 + c_1 t + \cdots + c_{n-1} t^{n-1} + t^n$$

sono gli autovalori della matrice compagna (o equivalentemente della sua trasposta visto che

$$\text{eig}(A) = \text{eig}(A^T)$$

$$C = \begin{bmatrix} 0 & 0 & \dots & 0 & -c_0 \\ 1 & 0 & \dots & 0 & -c_1 \\ 0 & 1 & \dots & 0 & -c_2 \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & \dots & 1 & -c_{n-1} \end{bmatrix}.$$

Sfruttando il comando `eig`, e osservando che

```
>> A=[1 2; 3 4]
```

```
A =
```

```
1    2
3    4
```

```
>> B=[5 6; 7 8]
```

```
B =
```

```
5    6
7    8
```

```
>> C=[A B]
```

```
C =
```

```
1    2    5    6
3    4    7    8
```

```
>> D=[A; B]
```

```
D =
```

```
1    2
3    4
5    6
7    8
```

```
>>
```

scrivere un codice Matlab che risolva un'equazione algebrica calcolando gli autovalori della matrice compagna associata. Effettuare quindi un test su un polinomio di cui si conoscono gli zeri e valutare la bontà del proprio codice. Di seguito si calcolino gli zeri di modulo massimo e minimo usando il metodo delle potenze e la sua variante inversa, come pure il metodo QR (se applicabile).

5. Definizione dei metodi di Eulero implicito ed esplicito. Si consideri il problema di Cauchy

$$\begin{cases} y'(x) = f(x, y(x)), & x \geq x_0 \\ y(x_0) = y_0 \end{cases} \quad (5.1)$$

dove f è a valori in $\mathbb{R}^n$ e definita in un sottoinsieme Ω di $\mathbb{R} \times \mathbb{R}^n$, con $(x_0, y_0) \in \Omega$. Osserviamo che essendo f a valori in $\mathbb{R}^n$ il problema in generale è un sistema di equazioni differenziali

$$\begin{cases} y_1'(x) = f_1(x, y_1(x), \dots, y_n(x)), & x \geq x_0 \\ \dots \\ y_n'(x) = f_n(x, y_1(x), \dots, y_n(x)), & x \geq x_0 \\ y(x_0) = y_0 \end{cases} \quad (5.2)$$

dove per $k = 1, \dots, n$ ogni y_k, f_k è una funzione a valori in $\mathbb{R}$.

6. Alcuni teoremi di esistenza e unicità. Si trovano in letteratura molti teoremi di esistenza ed unicità per la soluzione di problemi ai valori iniziali del tipo (5.2). Ne citiamo in particolare due usualmente citati nei testi di Analisi matematica.

$$\exists \delta, \epsilon, L > 0 : [x_0 - \delta, x_0 + \delta] \times \overline{B}_\epsilon(y_0) \subseteq \Omega, \quad (6.1)$$

$$|f(x, y_1) - f(x, y_2)| \leq L|y_1 - y_2|, \quad \forall x \in [x_0 - \delta, x_0 + \delta], \forall y_1, y_2 \in \overline{B}_\epsilon(y_0) \quad (6.2)$$

si dimostra il seguente teorema di esistenza ed unicità (in piccolo)

TEOREMA 6.1. *Siano Ω un aperto di $\mathbb{R} \times \mathbb{R}^n$, f una funzione di Ω in $\mathbb{R}^n$ e (x_0, y_0) un punto di Ω . Se f è continua e valgono le condizioni in (6.1) allora esiste un intervallo aperto contenente x_0 nel quale è definita una e una sola soluzione del problema di Cauchy (5.2).*

Notiamo che questo teorema non determina l'intervallo contenente la soluzione. A tal proposito ricordiamo un teorema di esistenza ed unicità (in grande)

TEOREMA 6.2. *Sia $f(x, y)$ definita e continua nella striscia*

$$S = \{(x, y) : a \leq x \leq b, -\infty < y < +\infty\}$$

e ivi lipschitziana rispetto a y cioè

$$|f(x, y_1) - f(x, y_2)| \leq L|y_1 - y_2|, \quad \forall (x, y_1), (x, y_2) \in S.$$

Allora esiste ed è unica la soluzione del problema (5.2) di classe $C^1([a, b])$.

Per ulteriori teoremi di esistenza e unicità della soluzione si consultino.

6.1. I metodi di Eulero esplicito ed Eulero implicito. Si supponga che (5.2) abbia una e una sola soluzione. Per semplicità consideriamo il caso in cui y sia a valori in $\mathbb{R}$. Due classici metodi per risolvere il problema differenziale (5.2) sono il metodo di *Eulero esplicito* ed il metodo di *Eulero implicito*.

Sia $\mathcal{I}(s_1, s_2)$ il più piccolo intervallo aperto contenente s_1 e s_2 . Assumendo che la soluzione sia sufficientemente regolare, abbiamo dalla formula di Taylor per $x \approx x_s, c_1 \in \mathcal{I}(x, \overline{x})$ e (5.2)

$$\begin{aligned} y(x) &= y(\overline{x}) + y'(\overline{x})(x - \overline{x}) + \frac{y''(c_1)(x - \overline{x})^2}{2} \\ &\approx y(\overline{x}) + y'(\overline{x})(x - \overline{x}) \\ &= y(\overline{x}) + f(\overline{x}, y(\overline{x}))(x - \overline{x}) \end{aligned} \quad (6.3)$$

Di conseguenza se si desidera calcolare la soluzione nei punti $x_{k+1} = x_0 + kh = x_k + h$ con $k \geq 0$, ponendo $x = x_{k+1}$, $\bar{x} = x_k$ abbiamo

$$y(x_{k+1}) \approx y(x_k) + hf(x_k, y(x_k)). \quad (6.4)$$

Il metodo di Eulero esplicito consiste nell'approssimare $y(x_{k+1})$ con y_{k+1} definito da

$$y_{k+1} = y_k + hf(x_k, y_k), \quad (6.5)$$

ove $y_0 = y(x_0)$.

Similmente al caso precedente, se poniamo in (6.3) che siano $x = x_k$, $\bar{x} = x_{k+1}$ abbiamo

$$y(x_k) \approx y(x_{k+1}) + f(x_{k+1}, y(x_{k+1}))(x_k - x_{k+1}), \quad (6.6)$$

e quindi

$$y(x_{k+1}) \approx y(x_k) + hf(x_{k+1}, y(x_{k+1})). \quad (6.7)$$

Il metodo di Eulero implicito consiste nell'approssimare $y(x_{k+1})$ con y_{k+1} definito da

$$y_{k+1} = y_k + hf(x_{k+1}, y_{k+1}), \quad (6.8)$$

ove $y_0 = y(x_0)$.

Evidentemente ad ogni iterazione si richiede di risolvere un'equazione nonlineare nella variabile z del tipo $z = y_k + hf(x_{k+1}, z)$, la cui soluzione può essere calcolata utilizzando ad esempio col metodo di punto fisso, delle secanti o di Newton.

NOTA 6.3. Si osservi che utilizzando la formula di Taylor multivariata, i due metodi possono essere estesi al caso generale $n \geq 1$. In particolare il metodo di Eulero implicito ad ogni operazione dovrà risolvere un sistema nonlineare, ad esempio con il metodo di punto fisso o di tipo Newton.

7. I metodi di Eulero in Matlab. Utilizzando l'help di Matlab, si nota subito che esistono delle routines predefinite per risolvere equazioni differenziali ordinarie. Infatti

```
>> help funfun
Function functions and ODE solvers.

...

Differential equation solvers.
Initial value problem solvers for ODEs. (If unsure about stiffness,
try ODE45 first, then ODE15S.)
ode45      - Solve non-stiff differential equations, medium order
             method.
ode23      - Solve non-stiff differential equations, low order
             method.
ode113     - Solve non-stiff differential equations, variable order
             method.
ode23t     - Solve moderately stiff ODEs and DAEs Index 1, trape-
             zoidal rule.
ode15s     - Solve stiff ODEs and DAEs Index 1, variable order
```



```

                                method.
ode23s    - Solve stiff differential equations, low order method.
ode23tb   - Solve stiff differential equations, low order method.

...

>>

```

Tra queste non sono incluse le routines dei metodi di Eulero esplicito ed implicito che d'altra parte non sono difficili da programmare. Dei codici in merito si trovano presso il sito web di K. Atkinson, osservando che *forward Euler* e *backward Euler* corrispondono rispettivamente ai metodi di Eulero esplicito ed implicito. Tale software è gentilmente fornito gratuitamente dagli autori. Per quanto detto `euler_for` corrisponde al metodo di Eulero esplicito mentre `euler_back` al metodo di Eulero implicito.

7.1. Codice di Eulero esplicito. Di seguito scriviamo il codice Matlab che implementa il metodo di Eulero esplicito, offerto da K. Atkinson, W. Han e D. Steward. Quali inputs vengono richiesti il punto iniziale `t_0` e il valore `y_0` della soluzione, il punto finale `t_end`, il passo `h` e la funzione `f` via la variabile `fcn`.

```

function [t,y] = euler_for(t0,y0,t_end,h,fcn)
%-----
% MATLAB CODE TAKEN FROM
% K. Atkinson, W. Han e D. Steward,
% Numerical Solution of Ordinary Differential Equations,
% programs for the book, John Wiley and Sons, 2009,
% http://www.math.uiowa.edu/NumericalAnalysisODE/
%-----
% function [t,y]=euler_for(t0,y0,t_end,h,fcn)
%-----
% Solve the initial value problem
%   y' = f(t,y),  t0 <= t <= b,  y(t0)=y0
% Use Euler's method with a stepsize of h.  The user must
% supply a program to define the right side function of the
% differential equation. Use some name, say deriv, and a first
% line of the form
%   function ans=deriv(t,y)
% A sample call would be
%   [t,z]=eulercls(t0,z0,b,delta,'deriv')
%-----
% Output:
% The routine euler_for will return two vectors, t and y.
% The vector t will contain the node points
%   t(1)=t0, t(j)=t0+(j-1)*h, j=1,2,...,n
% with
%   t(n) <= t_end,  t(n)+h > t_end
% The vector y will contain the estimates of the solution Y
% at the node points in t.
%-----

n = fix((t_end-t0)/h)+1;
t = linspace(t0,t0+(n-1)*h,n)';
y = zeros(n,1);

```

```

y(1) = y0;
for i = 2:n
    y(i) = y(i-1) + h*feval(fcn,t(i-1),y(i-1));
end

end % euler_for

```

Consideriamo quale test, il problema di Cauchy

$$\begin{cases} y'(x) = \lambda y(x) + (1 - \lambda)\cos(x) - (1 + \lambda)\sin(x), & x \geq 0 \\ y(0) = 1 \end{cases} \quad (7.1)$$

la cui soluzione è $\overline{y}(x) = \sin(x) + \cos(x)$, indipendentemente da λ . La particolarità di questo problema test è che il metodo di Eulero esplicito per h fissato ha comportamenti molto diversi al variare di λ , nonostante la soluzione sia sempre la stessa.

```

>> % lambda = -1, h= 0.5.
>> fcn=inline('2*cos(x)-0*sin(x)-y');
>> t0=1; y0=1; t_end=10; h=0.5;
>> [t,y] = euler_for(t0,y0,t_end,h,fcn);
>> y_sol=sin(t)+cos(t);

>> [t y y_sol abs(y-y_sol) abs(y-y_sol)./abs(y_sol)]

ans =

```

1.0000	1.0000	1.3818	0.3818	0.2763
1.5000	1.0403	1.0682	0.0279	0.0261
2.0000	0.5909	0.4932	0.0977	0.1982
2.5000	-0.1207	-0.2027	0.0820	0.4044
3.0000	-0.8615	-0.8489	0.0126	0.0149
3.5000	-1.4207	-1.2872	0.1335	0.1037
4.0000	-1.6468	-1.4104	0.2364	0.1676
4.5000	-1.4771	-1.1883	0.2887	0.2430
5.0000	-0.9493	-0.6753	0.2741	0.4059
5.5000	-0.1910	0.0031	0.1941	62.0331
6.0000	0.6132	0.6808	0.0676	0.0993
6.5000	1.2668	1.1917	0.0750	0.0630
7.0000	1.6100	1.4109	0.1991	0.1411
7.5000	1.5589	1.2846	0.2742	0.2135
8.0000	1.1261	0.8439	0.2822	0.3344
8.5000	0.4175	0.1965	0.2211	1.1251
9.0000	-0.3932	-0.4990	0.1058	0.2120
9.5000	-1.1078	-1.0723	0.0354	0.0330
10.0000	-1.5510	-1.3831	0.1680	0.1214

Nelle colonne dei risultati, la prima è l'ascissa in cui viene approssimata la soluzione, la seconda il valore approssimato dal metodo di Eulero esplicito, la terza la soluzione corretta. Infine nelle ultime due colonne vengono forniti gli errori assoluti e relativi compiuti dal metodo di Eulero esplicito.

7.2. Codice di Eulero implicito. Di seguito scriviamo il codice Matlab che implementa il metodo di Eulero esplicito, offerto da K. Atkinson, W. Han e D. Steward. Quali inputs

vengono richiesti il punto iniziale t_0 e il valore y_0 della soluzione, il punto finale t_{end} , il passo h , la funzione f via la variabile fcn . e tol la tolleranza richiesta dal metodo iterativo che risolve ad ogni iterazione l'equazione nonlineare richiesta dal metodo.

```
function [t,y] = euler_back(t0,y0,t_end,h,fcn,tol)

%-----
% MATLAB CODE TAKEN FROM
% K. Atkinson, W. Han e D. Steward,
% Numerical Solution of Ordinary Differential Equations,
% programs for the book, John Wiley and Sons, 2009,
% http://www.math.uiowa.edu/NumericalAnalysisODE/
%-----
% function [t,y] = euler_back(t0,y0,t_end,h,fcn,tol)
%-----
% Solve the initial value problem
%    $y' = f(t,y)$ ,  $t_0 \leq t \leq b$ ,  $y(t_0)=y_0$ 
% Use the backward Euler method with a stepsize
% of  $h$ .
% The user must supply an m-file to define the
% derivative  $f$ , with some name,
% say 'deriv.m', and a first line of the form
%   function ans=deriv(t,y)
% tol is the user supplied bound on the difference
% between successive values of the backward Euler
% iteration.
% A sample call would be
%   [t,z]=euler_back(t0,z0,b,delta,'deriv',1e-6)
%-----
% Output:
% The routine euler_back will return two vectors,
% t and y.
% The vector t will contain the node points
%    $t(1)=t_0$ ,  $t(j)=t_0+(j-1)*h$ ,  $j=1,2,\dots,N$ 
% with
%    $t(N) \leq t_{\text{end}}$ ,  $t(N)+h > t_{\text{end}}$ 
% The vector y will contain the estimates of the
% solution  $Y$  at the node points in t.
%-----

% Initialize.
n = fix((t_end-t0)/h) + 1;
t = linspace(t0,t0+(n-1)*h,n)';
y = zeros(n,1);
y(1) = y0;
% advancing
for i=2:n
% forward Euler estimate
    yt1 = y(i-1) + h*feval(fcn,t(i-1),y(i-1));
% one-point iteration
    count = 0;
    diff = 1;
    while diff > tol && count < 10
        yt2 = y(i-1) + h*feval(fcn,t(i),yt1);
```

```

        diff = abs(yt2-yt1);
        yt1 = yt2;
        count = count +1;
    end
    if count >= 10
        disp('Not converging after 10 steps at t = ')
        fprintf('%5.2f\n', t(i))
    end
    y(i) = yt2;
end

end % euler_back

```

Come prima, consideriamo quale test il problema di Cauchy precedentemente studiato

$$\begin{cases} y'(x) = \lambda y(x) + (1 - \lambda)\cos(x) - (1 + \lambda)\sin(x), & x \geq 0 \\ y(0) = 1 \end{cases} \quad (7.2)$$

la cui soluzione è $\bar{y}(x) = \sin(x) + \cos(x)$.

```

>> fcn=inline('2*cos(x)-0*sin(x)-y');
>> t0=1; y0=1; t_end=10; h=0.5; tol=10^(-2);
>> [t,y] = euler_back(t0,y0,t_end,h,fcn,tol);
>> [t y y_sol abs(y-y_sol) abs(y-y_sol)./abs(y_sol)]

ans =

1.0000e+00    1.0000e+00    1.3818e+00    3.8177e-01    2.7629e-01
1.5000e+00    7.1127e-01    1.0682e+00    3.5696e-01    3.3416e-01
2.0000e+00    1.9496e-01    4.9315e-01    2.9819e-01    6.0467e-01
2.5000e+00   -4.0679e-01   -2.0267e-01    2.0412e-01    1.0072e+00
3.0000e+00   -9.2890e-01   -8.4887e-01    8.0027e-02    9.4274e-02
3.5000e+00   -1.2469e+00   -1.2872e+00    4.0374e-02    3.1365e-02
4.0000e+00   -1.2647e+00   -1.4104e+00    1.4573e-01    1.0332e-01
4.5000e+00   -9.8131e-01   -1.1883e+00    2.0701e-01    1.7420e-01
5.0000e+00   -4.6325e-01   -6.7526e-01    2.1201e-01    3.1396e-01
5.5000e+00    1.6187e-01    3.1294e-03    1.5874e-01    5.0724e+01
6.0000e+00    7.5062e-01    6.8075e-01    6.9869e-02    1.0263e-01
6.5000e+00    1.1543e+00    1.1917e+00    3.7359e-02    3.1349e-02
7.0000e+00    1.2700e+00    1.4109e+00    1.4092e-01    9.9881e-02
7.5000e+00    1.0753e+00    1.2846e+00    2.0933e-01    1.6295e-01
8.0000e+00    6.1780e-01    8.4386e-01    2.2605e-01    2.6788e-01
8.5000e+00    1.2917e-02    1.9648e-01    1.8356e-01    9.3426e-01
9.0000e+00   -6.0044e-01   -4.9901e-01    1.0143e-01    2.0325e-01
9.5000e+00   -1.0674e+00   -1.0723e+00    4.9650e-03    4.6302e-03
1.0000e+01   -1.2689e+00   -1.3831e+00    1.1417e-01    8.2547e-02

>>

```

Nelle colonne dei risultati, la prima è l'ascissa in cui viene approssimata la soluzione, la seconda il valore approssimato dal metodo di Eulero implicito, la terza la soluzione corretta. Infine nelle ultime due colonne vengono forniti gli errori assoluti e relativi compiuti dal

metodo di Eulero implicito. Il metodo risolve l'equazione

$$z = y_k + hf(x_{k+1}, z)$$

con il *metodo di punto fisso*

$$z^{(s+1)} = y_k + hf(x_{k+1}, z^{(s)})$$

interrompendo il processo con un avviso di cattiva convergenza se dopo 10 iterazioni non si ha avuto

$$|z^{(s+1)} - z^{(s)}| \leq \text{tol}$$

per qualche $s \leq 10$.

In alternativa al metodo di punto fisso, si può risolvere l'equazione nonlineare $g(z) = 0$ proposta da Eulero implicito (in cui $g(z) = z - (y_k + hf(x_{k+1}, z))$) con il metodo delle secanti, la cui successione è

$$z^{(n+1)} = z^{(n)} - \frac{g(z^{(n)})}{d_n}, \quad d_n = \frac{g(z^{(n)}) - g(z^{(n-1)})}{z^{(n)} - z^{(n-1)}}.$$

Osserviamo che questo metodo, la cui velocità di convergenza è localmente superlineare se la soluzione è semplice, non richiede a differenza di quello di Newton il calcolo di derivate, ma di due approssimazioni iniziali della soluzione.

Possiamo quindi scrivere la seguente variante di `euler_back` che utilizza il metodo delle secanti per risolvere l'equazione nonlineare (e non il metodo di punto fisso come in `euler_back`)

```
function [t,y] = euler_back_secants(t0,y0,t_end,h,fcn,maxit,tol)

%-----
% VARIANT OF A MATLAB CODE TAKEN FROM
% K. Atkinson, W. Han e D. Steward,
% Numerical Solution of Ordinary Differential Equations,
% programs for the book, John Wiley and Sons, 2009,
% http://www.math.uiowa.edu/NumericalAnalysisODE/
%-----
% Solve the initial value problem
%   y' = f(t,y),  t0 <= t <= b,  y(t0)=y0
% Use the backward Euler method with a stepsize of h.  The user must
% supply an m-file to define the derivative f, with some name,
% say 'deriv.m', and a first line of the form
%   function ans=deriv(t,y)
% tol is the user supplied bound on the difference between successive
% values of the backward Euler iteration.
% Maxit is the maximum number of iterations performed
% by the secants method.
% A sample call would be
%   [t,z]=euler_back_secants(t0,z0,b,delta,'deriv',maxit,1e-6)
%-----
% Output:
% The routine euler_back will return two vectors, t and y.
% The vector t will contain the node points
```

```

% t(1)=t0, t(j)=t0+(j-1)*h, j=1,2,...,N
% with
% t(N) <= t_end, t(N)+h > t_end
% The vector y will contain the estimates of the solution Y
% at the node points in t.
%-----

% Initialize.
n = fix((t_end-t0)/h) + 1;
t = linspace(t0,t0+(n-1)*h,n)';
y = zeros(n,1);
y(1) = y0;
% advancing
for i=2:n
    % forward Euler estimate
    yt1 = y(i-1) + h*feval(fcn,t(i-1),y(i-1));

    % fixed point iteration
    yt2 = y(i-1) + h*feval(fcn,t(i),yt1);

    % secant iteration
    k=1;
    yy(1)=min(yt1,yt2); yy(2)=max(yt1,yt2);
    step_err(1)=yy(2)-yy(1);

    while (abs(step_err(k)) > tol) & (k < maxit)

        k=k+1;

        fx_old=yy(k-1)-y(i-1)-h*feval(fcn,t(i),yy(k-1));
        fx_new=yy(k)-y(i-1)-h*feval(fcn,t(i),yy(k));
        dfx=(fx_new-fx_old)/(yy(k)-yy(k-1));

        step_err_k=-fx_new/dfx;
        step_err=[step_err; step_err_k];

        yy(k+1)=yy(k)+step_err(end);

    end

    step_err=[];

    if k == maxit
        fprintf('\n \t Results may be not correct. ');
    end

    y(i) = yy(end);
end

```

Applicando tale implementazione di Eulero implicito abbiamo

```

>> fcn=inline('2*cos(x)+0*sin(x)-y');
>> t0=1; y0=1; t_end=10; h=0.5; maxit=100; tol=10^(-4);
>> [t,y] = euler_backn(t0,y0,t_end,h,fcn,maxit,tol);

```

```

>> y_sol=sin(t)+cos(t);
>> [t y y_sol abs(y-y_sol) abs(y-y_sol)./abs(y_sol)]

ans =

    1.0000e+00    1.0000e+00    1.3818e+00    3.8177e-01    2.7629e-01
    1.5000e+00    7.1382e-01    1.0682e+00    3.5441e-01    3.3177e-01
    2.0000e+00    1.9845e-01    4.9315e-01    2.9470e-01    5.9758e-01
    2.5000e+00   -4.0179e-01   -2.0267e-01    1.9912e-01    9.8249e-01
    3.0000e+00   -9.2786e-01   -8.4887e-01    7.8985e-02    9.3047e-02
    3.5000e+00   -1.2429e+00   -1.2872e+00    4.4363e-02    3.4464e-02
    4.0000e+00   -1.2643e+00   -1.4104e+00    1.4610e-01    1.0358e-01
    4.5000e+00   -9.8343e-01   -1.1883e+00    2.0490e-01    1.7243e-01
    5.0000e+00   -4.6651e-01   -6.7526e-01    2.0875e-01    3.0914e-01
    5.5000e+00    1.6144e-01    3.1294e-03    1.5831e-01    5.0587e+01
    6.0000e+00    7.4774e-01    6.8075e-01    6.6985e-02    9.8398e-02
    6.5000e+00    1.1496e+00    1.1917e+00    4.2156e-02    3.5374e-02
    7.0000e+00    1.2690e+00    1.4109e+00    1.4192e-01    1.0059e-01
    7.5000e+00    1.0771e+00    1.2846e+00    2.0757e-01    1.6158e-01
    8.0000e+00    6.2105e-01    8.4386e-01    2.2281e-01    2.6404e-01
    8.5000e+00    1.2690e-02    1.9648e-01    1.8379e-01    9.3541e-01
    9.0000e+00   -5.9896e-01   -4.9901e-01    9.9949e-02    2.0029e-01
    9.5000e+00   -1.0641e+00   -1.0723e+00    8.2349e-03    7.6795e-03
    1.0000e+01   -1.2688e+00   -1.3831e+00    1.1432e-01    8.2655e-02

>>

```

8. Esercizi.

1. Per comprendere meglio la propagazione dell'errore nell'algoritmo di Eulero, risolviamo la classica equazione differenziale del secondo ordine

$$\begin{cases} u''(t) = -u(t) \\ u(0) = 0, \quad u'(0) = 1 \end{cases} \quad (8.1)$$

la cui soluzione è $u(t) = \sin(t)$. Un'equazione differenziale del secondo ordine può essere trasformata in un sistema di 2 equazioni differenziali del primo ordine. Ponendo

$$y_1 = u \quad \text{e} \quad y_2 = u'$$

si ottiene il sistema

$$\begin{cases} y_1' = y_2 \\ y_2' = -y_1 \\ y_1(0) = 0, \quad y_2(0) = 1 \end{cases} \quad (8.2)$$

La risoluzione numerica di un'equazione differenziale di ordine superiore al primo è quindi riconducibile alla risoluzione di un sistema di equazioni del primo ordine. Risolviamo con il metodo di Eulero esplicito

```

function [t,y] = eulersys(t0,y0,t_end,h,fcn)
%
```

```

% function [t,y]=eulersys(t0,y0,t_end,h,fcn)
%
% Solve the initial value problem of a system
% of first order equations
%   y' = f(t,y),   t0 <= t <= b,   y(t0)=y0
% Use Euler's method with a stepsize of h.
% The user must supply a program to compute the
% right hand side function with some name, say
% deriv, and a first line of the form
%   function ans=deriv(t,y)
% A sample call would be
%   [t,z]=eulersys(t0,z0,b,delta,'deriv')
%
% The program automatically determines the
% number of equations from the dimension of
% the initial value vector y0.
%
% Output:
% The routine eulersys will return a vector t
% and matrix y. The vector t will contain the
% node points in [t0,t_end]:
%   t(1)=t0, t(j)=t0+(j-1)*h, j=1,2,...,N
% The matrix y is of size N by m, with m the
% number of equations. The i-th row y(i,:) will
% contain the estimates of the solution Y
% at the node points in t(i).
%
m = length(y0);
n = fix((t_end-t0)/h)+1;
t = linspace(t0,t0+(n-1)*h,n)';
y = zeros(n,m);
y(1,:) = y0;
for i = 2:n
    y(i,:) = y(i-1,:) + h*feval(fcn,t(i-1),y(i-1,:));
end

end %

```

Si richiama il metodo di Eulero esplicito con le seguenti istruzioni:

```

t0=0; y0=[0,1] t_end=50;
h=0.1;
[t,y] = eulersys(t0,y0,t_end,h,'eqsys') ;
plot(t,y(:,1),'-r');

```

dove eqsys.m è la funzione seguente:

```

function f=eqsys(t,y)
%
% Equazioni per il sistema differenziale
% y1' = y2
% y2' = -y1
%

```



```
f(1) = y(2);
f(2) = -y(1);
end
```




FIGURA 8.1. *Grafico della soluzione con Eulero Esplicito*

La figura seguente mostra il grafico nell'intervallo $[0, 50]$. Come si vede, la periodicità è andata perduta: anziché oscillare tra -1 e 1 la soluzione di Eulero ha un'ampiezza crescente, addirittura maggiore di 10 dopo solo 8 periodi.

La soluzione $y(:, 1)$ dovrebbe rappresentare $\sin(t)$ e quindi $y(:, 2)$ la sua derivata $\cos(t)$; risolvere nuovamente il sistema dopo aver imposto $h = 0.01$, graficare le due soluzioni (`plot(y(:, 1), y(:, 2), ...)`) e confrontarle sullo stesso grafico con l'equazione parametrica del cerchio (`x=cos(t), y=sin(t), plot(x, y, ...)`).

2. Risolvere la seguente equazione differenziale (equazione del pendolo senza l'approssimazione delle piccole oscillazioni):

$$\begin{cases} \theta''(t) = -\frac{g}{l} \sin(\theta(t)) & t \in [0, T] \\ \theta'(0) = 0, \theta(0) = \theta_0 \end{cases} \quad (8.3)$$

con il metodo di Eulero esplicito per sistemi, dopo aver trasformato l'equazione in un sistema differenziale. Si utilizzi la seguente funzione che definisce il sistema differenziale del pendolo semplice:

```
function dydt = eqPendolo(t,y)
% EQPENDOLO Equazione diff. pendolo
% SINTASSI
%   dydt = eqPendolo(t,y)
% INPUT
%   t : Valore corrente della variabile indipendente
%   y : Valore corrente della variabile dipendente
% OUTPUT
%   dydt : Valore di f(t,y) in t e y
% costante di gravita'
g = 9.81;
% lunghezza del pendolo
l = 10;
% equazione differenziale
dydt = [y(2); -g/l*sin(y(1))];
```

Produrre il grafico dell'andamento dell'angolo (posizione) del pendolo, quello della velocità angolare e della Mappa di Pointcaré, ovvero posizione-velocità.

3. Facoltativo

Calcolare per ogni $\theta_0 \in [0, \pi]$ il tempo $P(\theta_0)$ impiegato dal pendolo per compiere un'oscillazione (periodo). Disegnare la funzione $P(\theta_0)$ e verificare che se θ_0 è vicino a 0 allora $P(\theta_0)$ vale approssimativamente $2\pi\sqrt{\frac{L}{g}}$ (isocronismo delle piccole oscillazioni, Galileo Galilei, 1583).

Suggerimento: Risolvere numericamente l'equazione del pendolo con il metodo di Eulero, con passo $h = 0.01$ e angolo θ_0 inizialmente piccolo (per esempio $\pi/10$). Per valutare numericamente il tempo impiegato dal pendolo a compiere un'oscillazione occorre individuare nel vettore soluzione della posizione ($y(:, 1)$) i punti in cui l'angolo approssima quello iniziale (θ_0) e controllare i tempi corrispondenti nel vettore di discretizzazione temporale (t). Il periodo si potrà ottenere per differenza di tali valori. Ripetere l'operazione per valori crescenti dell'angolo θ_0 .

4. Facoltativo

Nell'ambito delle equazioni differenziali ordinarie, esistono vari criteri di stabilità. Un classico problema è quello di vedere se un metodo è *assolutamente stabile*. Definito il problema di Cauchy

$$\begin{cases} y'(x) = \lambda y(x), & x \geq 0 \\ y(0) = 1 \end{cases} \quad (8.4)$$

per un certo $\lambda \in \mathbb{C}$ con $\Re(\lambda) < 0$, visto che l'unica soluzione è $y(x) = \exp(\lambda x)$ si cerca di definire il passo h cosicché il metodo numerico per la soluzione del problema di Cauchy (5.2) abbia lo stesso comportamento asintotico di $\exp(\lambda x)$. Ricordiamo a tal proposito che dalla formula di Eulero, se $z = a + ib$ allora

$$\exp(z) = \exp(a) \cdot (\cos(b) + i \sin(b)).$$

Quindi se $\Re(\lambda) < 0$, visto che $|\cos(\Im(\lambda x)) + i \sin(\Im(\lambda x))| = 1$ e $x > 0$ abbiamo

$$|\exp(\lambda x)| = |\Re(\exp(\lambda x))| |\cos(\Im(\lambda x)) + i \sin(\Im(\lambda x))| = |\Re \exp(\lambda x)| \rightarrow 0, \text{ per } x \rightarrow \infty.$$

Visto il comportamento asintotico di $\exp(\lambda x)$, se $y_h(x_n)$ è l'approssimazione della soluzione in x_n fornita da un metodo numerico a passo h , si desidera sia $y_h(x_n) \rightarrow 0$ per $n \rightarrow +\infty$. Nel caso del metodo di Eulero esplicito, si dimostra che ciò accade se $|1 + h\lambda| < 1$, mentre per il metodo di Eulero implicito ciò si realizza se $|1 - h\lambda| > 1$ cioè qualsiasi sia h indipendentemente da λ con $\Re(\lambda) < 0$.

5. Facoltativo

Approssimare per $\lambda = -100$ il valore assunto dalla soluzione $\overline{y}$ del problema di Cauchy

$$\begin{cases} y'(x) = \lambda y(x), & x \geq 0 \\ y(0) = 1 \end{cases} \quad (8.5)$$

nel punto $x = 0.2$. A tal proposito si utilizzano i metodi di Eulero esplicito e Eulero implicito (nella versione con il metodo delle secanti) con passi $h = 0.1, h = 0.05, h = 0.02, h = 0.01, h = 0.001$. Al variare di h verificare quando $|1 + h\lambda| < 1$. Se eseguiti correttamente dovrebbero fornire quali risultati

1.0000e-01	8.1000e+01	8.2645e-03
5.0000e-02	2.5600e+02	7.7160e-04
2.0000e-02	1.0000e+00	1.6933e-05
1.0000e-02	2.0612e-09	9.5161e-07
1.0000e-03	1.3556e-09	3.2046e-09

in cui alla prima colonna si stabilisce il passo h , nella seconda si espongono i risultati ottenuti dal metodo di Eulero esplicito e nella terza quelli di Eulero implicito (nella versione con il metodo delle secanti). Suggestivi.

(a) Se necessario, definire la funzione come

```
>> fcn=inline('0*x-100*y');
```

(b) **Facoltativo**

Visto che vogliamo valutare la funzione in 0.2, ha senso porre t_{end} maggiore o minore di 0.2? Perché?

6. Approssimare per $\lambda = -500$ il valore assunto dalla soluzione $\bar{y}$ del problema di Cauchy

$$\begin{cases} y'(x) = \lambda y(x), & x \geq 0 \\ y(0) = 1 \end{cases} \quad (8.6)$$

nel punto $x = 0.2$. A tal proposito si utilizzano i metodi di Eulero esplicito e Eulero implicito (nella versione con il metodo delle secanti) con passi $h = 0.1, h = 0.05, h = 0.02, h = 0.01, h = 0.001, h = 0.0005$. Al variare di h verificare quando $|1 + h\lambda| < 1$. Il metodo di Eulero implicito per h piccoli può richiedere molto tempo di calcolo.

9. Alcuni cenni sulle equazioni di Laplace e Poisson. Si consideri l'equazione alle derivate parziali *quasi-lineare*

$$A \frac{\partial^2 u}{\partial x^2} + B \frac{\partial^2 u}{\partial x \partial y} + C \frac{\partial^2 u}{\partial y^2} = f(x, y, u, \frac{\partial u}{\partial x}, \frac{\partial u}{\partial y}), \quad (x, y) \in \Omega \subseteq \mathbb{R}^2 \quad (9.1)$$

dove A, B e C sono costanti.

Tale equazione è

- *ellittica* se $B^2 - 4AC < 0$;
- *parabolica* se $B^2 - 4AC = 0$;
- *iperbolica* se $B^2 - 4AC > 0$.

Un importante esempio è l'equazione di Poisson.

$$\begin{cases} \Delta u(x, y) := \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} = f, & (x, y) \in \Omega \\ u = g, & (x, y) \in \partial\Omega \end{cases} \quad (9.2)$$

Nel caso particolare $f \equiv 0$, l'equazione alle derivate parziali (14.1), è nota come equazione di Laplace. La particolare condizione al bordo è detta di *Dirichlet*. E' facile osservare che (14.1) è di tipo quasi-lineare con $A = 1, B = 0, C = 1$ e quindi ellittica.

NOTA 9.1 (Facoltativo). Lo studio dell'esistenza e l'unicità della soluzione al problema di Poisson non è banale. Accanto al problema differenziale di Poisson sopracitato, si definisce una formulazione debole. Sia Ω un aperto limitato di $\mathbb{R}^n$ di frontiera $\partial\Omega$ di classe C^1 a tratti. Si dimostra (non facile!), che il problema di Poisson per $f \in L_2(\Omega)$ con condizione di Dirichlet $u = 0$, $(x, y) \in \partial\Omega \subset \mathbb{R}^n$, ha un'unica soluzione debole nello spazio di Sobolev $H_0^1(\Omega)$ (cioè $f \in L_2(\Omega)$, $\frac{\partial f}{\partial x_i} f \in L_2(\Omega)$, $i = 1, \dots, n$ ed f è nulla sul bordo $\partial\Omega$). Per una descrizione più generale, anche nel caso di $f \neq 0$, si consideri dove il problema è risolto con un uso non banale del lemma di Lax-Milgram.

9.1. Discretizzazione del Laplaciano in dimensione uno (calcolo della derivata seconda). Risulta utile per lo studio dell'equazione di Poisson discretizzare il Laplaciano prima in dimensione 1 e poi in dimensione superiore.

TEOREMA 9.2. Supponendo che $s : [a, b] \rightarrow \mathbb{R}$ sia sufficientemente regolare, si ha

$$\begin{aligned} s^{(2)}(x) &= \frac{s(x+h) - 2s(x) + s(x-h)}{h^2} + O(h^2) \\ &\approx \frac{s(x+h) - 2s(x) + s(x-h)}{h^2} \end{aligned} \quad (9.3)$$

DIMOSTRAZIONE. Supponendo che $s : [a, b] \rightarrow \mathbb{R}$ sia sufficientemente regolare, dalla formula di Taylor si ha

$$s(x+h) = s(x) + hs^{(1)}(x) + \frac{h^2 s^{(2)}(x)}{2} + \frac{h^3 s^{(3)}(x)}{6} + \frac{h^4 s^{(4)}(\xi)}{24} \quad (9.4)$$

con $\xi \in \mathcal{I}(x, x+h)$ (dove $\mathcal{I}(a, b)$ è il più piccolo intervallo aperto contenente a, b). Similmente a (10.2) si ha quindi per $\epsilon \in \mathcal{I}(x, x-h)$

$$s(x-h) = s(x) - hs^{(1)}(x) + \frac{h^2 s^{(2)}(x)}{2} - \frac{h^3 s^{(3)}(x)}{6} + \frac{h^4 s^{(4)}(\epsilon)}{24}. \quad (9.5)$$

Sommando membro a membro (10.2), (10.3) abbiamo

$$s^{(2)}(x) = \frac{s(x+h) - 2s(x) + s(x-h)}{h^2} + O(h^2) \quad (9.6)$$

$$\approx \frac{s(x+h) - 2s(x) + s(x-h)}{h^2} \quad (9.7)$$

□

9.1.1. Facoltativo: Un esempio. Consideriamo la funzione

$$s(x) = \cos(x)$$

e valutiamo

$$s^{(2)}(x) = -\cos(x)$$

per $x = \pi$, qualora si usino alcuni valori di $h = 10^{-s}$ con $s = 0, 0.1, 0.2, \dots, 16$. Noto che $s^{(2)}(\pi) = -\cos(\pi) = 1$ valuteremo l'errore assoluto (e al tempo stesso relativo) fornito dalla formula (10.4).

Un possibile codice Matlab `diff2experiments.m` è il seguente




FIGURA 9.1. Grafico che illustra in scala semilogaritmica l'errore assoluto compiuto dalla formula (10.4) per il calcolo della derivata seconda del coseno nel punto $x = \pi$, utilizzando valori di $h = 10^{-s}$ dove s è il valore indicato nelle ascisse.

```
s=0:0.1:16;
x=pi;
exactvalue=1;

for index=1:length(s)
    h_exp=s(index);
    h=10^(-h_exp);
    fxplus=f(x+h);
    fx=f(x);
    fxminus=f(x-h);
    f2approx=(fxplus-2*fx+fxminus)/(h^2);
    abserr(index)=abs(f2approx-exactvalue);
    fprintf('\n \t [h]: %2.2e [ABS. ERR.]: %2.2e',h,abserr(index))
end

semilogy(h_vett,abserr);
```

in cui $f.m$ è data da

```
function fx=f(x)
fx=cos(x);
```

Si ottengono i seguenti risultati

```
[h]: 1.00e+000 [ABS. ERR.]: 8.06e-002
[h]: 7.94e-001 [ABS. ERR.]: 5.15e-002
[h]: 6.31e-001 [ABS. ERR.]: 3.27e-002
[h]: 5.01e-001 [ABS. ERR.]: 2.08e-002
[h]: 3.98e-001 [ABS. ERR.]: 1.31e-002
```

```

[h]: 3.16e-001 [ABS. ERR.]: 8.31e-003
...
[h]: 5.01e-004 [ABS. ERR.]: 2.09e-008
[h]: 3.98e-004 [ABS. ERR.]: 1.27e-008
[h]: 3.16e-004 [ABS. ERR.]: 7.19e-009
[h]: 2.51e-004 [ABS. ERR.]: 5.80e-009
[h]: 2.00e-004 [ABS. ERR.]: 2.77e-009
[h]: 1.58e-004 [ABS. ERR.]: 2.70e-010
[h]: 1.26e-004 [ABS. ERR.]: 1.26e-009
[h]: 1.00e-004 [ABS. ERR.]: 6.08e-009
[h]: 7.94e-005 [ABS. ERR.]: 4.04e-009
[h]: 6.31e-005 [ABS. ERR.]: 3.07e-008
[h]: 5.01e-005 [ABS. ERR.]: 6.21e-008
[h]: 3.98e-005 [ABS. ERR.]: 5.48e-008
[h]: 3.16e-005 [ABS. ERR.]: 8.27e-008
[h]: 2.51e-005 [ABS. ERR.]: 8.39e-008
[h]: 2.00e-005 [ABS. ERR.]: 1.09e-007

```

che dicono che la formula per il calcolo della derivata seconda è da usarsi con cautela, in quanto fornisce risultati accurati per h non eccessivamente piccolo altrimenti errori di arrotondamento *degradano* la convergenza della formula.

9.1.2. Facoltativo: Un esercizio. Si caloli numericamente la derivata seconda nel caso in cui $f(x) = \exp(x)$, $x = 0$ (e quindi $f^{(2)}(0) = 1$). Si faccia attenzione a modificare correttamente la funzione f e le variabili x , `exactvalue`.

9.2. Discretizzazione del Laplaciano in dimensione due. Siamo pronti ad introdurre una *discretizzazione* dell'operatore di Laplace

$$\Delta u := u_{xx} + u_{yy} := \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2}.$$

TEOREMA 9.3. *Supponendo che $s : \Omega \subseteq \mathbb{R}^2 \rightarrow \mathbb{R}$ sia sufficientemente regolare, si ha*

$$\begin{aligned} \Delta u(x, y) &= \frac{u(x, y+h) - 2u(x, y) + u(x, y-h)}{h^2} \\ &+ \frac{u(x+h, y) - 2u(x, y) + u(x-h, y)}{h^2} + O(h^2) \\ &\approx \frac{u(x+h, y) + u(x-h, y) + u(x, y+h) + u(x, y-h) - 4u(x, y)}{h^2}. \end{aligned} \quad (9.8)$$

DIMOSTRAZIONE. Dalla formula unidimensionale abbiamo

$$u_{xx}(x, y) = \frac{u(x+h, y) - 2u(x, y) + u(x-h, y)}{h^2} + O(h^2), \quad (9.9)$$

e

$$u_{yy}(x, y) = \frac{u(x, y+h) - 2u(x, y) + u(x, y-h)}{h^2} + O(h^2), \quad (9.10)$$




FIGURA 9.2. Grafico che illustra in scala semilogaritmica l'errore assoluto compiuto dalla formula (10.9) per il calcolo del laplaciano della funzione $g(x, y)$ nel punto $(0, 0)$, utilizzando valori di $h = 10^{-s}$ dove s è il valore indicato nelle ascisse.

da cui

$$\begin{aligned} \Delta u(x, y) &= \frac{u(x, y+h) - 2u(x, y) + u(x, y-h)}{h^2} \\ &+ \frac{u(x+h, y) - 2u(x, y) + u(x-h, y)}{h^2} + O(h^2) \\ &\approx \frac{u(x+h, y) + u(x-h, y) + u(x, y+h) + u(x, y-h) - 4u(x, y)}{h^2} \end{aligned} \quad (9.11)$$

□

Facciamo una nuova verifica numerica. Sia

$$g(x, y) = \cos(x) \exp(2y)$$

e supponiamo di voler valutare $\Delta g(0, 0)$. E' facile osservare che

$$\Delta g(x, y) = -\cos(x) \exp(2y) + 4 \cos(x) \exp(2y)$$

e che quindi

$$\Delta g(0, 0) = -1 \cdot 1 + 4 \cdot 1 \cdot 1 = 3.$$

Scriviamo quindi le 2 funzioni Matlab/Octave `diff22Dexperiments.m` e `g.m` che ci permettono di sperimentare quanto descritto:

```
s=0:0.1:16;
x=0; y=0;

correct_value=3;
```

```

for index=1:length(s)
    h_exp=s(index);
    h=10^(-h_exp);
    g2approx=( g(x+h,y)+g(x-h,y)+g(x,y+h)+g(x,y-h)-4*g(x,y) )/(h^2);
    abserr(index)=abs(g2approx-correct_value);
    fprintf('\n \t [h]: %2.2e [ABS.ERR.]: %2.2e',h,abserr(index))
end

semilogy(s,abserr);

function gxy=g(x,y)
gxy=cos(x)*exp(2*y);

```

I risultati numerici sono i seguenti

```

[h]: 1.00e+000 [ABS.ERR.]: 1.60e+000
[h]: 7.94e-001 [ABS.ERR.]: 9.67e-001
[h]: 6.31e-001 [ABS.ERR.]: 5.93e-001
[h]: 5.01e-001 [ABS.ERR.]: 3.67e-001
[h]: 3.98e-001 [ABS.ERR.]: 2.29e-001
[h]: 3.16e-001 [ABS.ERR.]: 1.43e-001
...
[h]: 5.01e-004 [ABS.ERR.]: 3.54e-007
[h]: 3.98e-004 [ABS.ERR.]: 2.22e-007
[h]: 3.16e-004 [ABS.ERR.]: 1.42e-007
[h]: 2.51e-004 [ABS.ERR.]: 8.99e-008
[h]: 2.00e-004 [ABS.ERR.]: 4.75e-008
[h]: 1.58e-004 [ABS.ERR.]: 3.62e-008
[h]: 1.26e-004 [ABS.ERR.]: 3.79e-009
[h]: 1.00e-004 [ABS.ERR.]: 7.06e-008
[h]: 7.94e-005 [ABS.ERR.]: 6.49e-008
[h]: 6.31e-005 [ABS.ERR.]: 4.75e-008
[h]: 5.01e-005 [ABS.ERR.]: 3.45e-008
[h]: 3.98e-005 [ABS.ERR.]: 3.96e-007
[h]: 3.16e-005 [ABS.ERR.]: 2.48e-007
...
[h]: 2.51e-008 [ABS.ERR.]: 1.85e-001
[h]: 2.00e-008 [ABS.ERR.]: 7.69e-001
[h]: 1.58e-008 [ABS.ERR.]: 5.36e-001
...

```

che suggerisce nuovamente che l'utilizzo di tale discretizzazione richiede che il *passo* h non sia eccessivamente piccolo.

Consideriamo l'equazione

$$\begin{cases} \Delta u(x, y) = f(x, y), & (x, y) \in \Omega = (0, 1) \times (0, 1) \\ u(x, y) = g(x, y), & (x, y) \in \partial\Omega \end{cases} \quad (9.12)$$

Definita la griglia di punti $\mathcal{G} = \{(x_i, y_j)\}_{i,j=0,\dots,n+1}$

$$x_i = ih, \quad y_j = jh, \quad h = 1/(n+1), \quad i, j = 0, \dots, n+1$$

risulta evidente che per $i = 0$ o $j = 0$, $i = n+1$ o $j = n+1$ abbiamo un punto del bordo e quindi in virtù delle condizioni di Dirichlet in (10.10), il valore di u^* è determinato. Vediamo




FIGURA 10.1. La molecola della citata discretizzazione del Laplaciano avente centro $(0.5, 0.5)$ e $h = 0.25$. Si ricordi di dividere ogni valore nella molecola per h^2 .

cosa succede quando il punto della griglia $\mathcal{G}$ è interno al quadrato $\Omega = (0, 1) \times (0, 1)$, cioè nel caso in cui (x_i, y_j) sia tale che nessuno tra gli indici i, j sia uguale a 0 oppure $n + 1$.

10. Discretizzazione dell'equazione di Poisson-Laplace. Dalla discretizzazione dell'operatore di Laplace Δ , tralasciando i termini $O(h^2)$ abbiamo

$$\Delta u(x, y) \approx \frac{u(x + h, y) + u(x - h, y) + u(x, y + h) + u(x, y - h) - 4u(x, y)}{h^2}$$

e quindi

$$\Delta u(x_i, y_j) = \frac{u(x_{i+1}, y_j) + u(x_{i-1}, y_j) + u(x_i, y_{j+1}) + u(x_i, y_{j-1}) - 4u(x_i, y_j)}{h^2} \quad (10.1)$$

da cui la discretizzazione dell'equazione di Poisson

$$u(x_{i+1}, y_j) + u(x_{i-1}, y_j) + u(x_i, y_{j+1}) + u(x_i, y_{j-1}) - 4u(x_i, y_j) = h^2 f(x_i, y_j), \quad (10.2)$$

per $i, j = 1, \dots, n$ con le condizioni al contorno

$$u(x_i, y_j) = g(x_i, y_j), \quad i = 0, j = 1, \dots, n \quad (10.3)$$

$$u(x_i, y_j) = g(x_i, y_j), \quad i = n + 1, j = 1, \dots, n \quad (10.4)$$

$$u(x_i, y_j) = g(x_i, y_j), \quad i = 1, \dots, n, j = 0, j = n + 1 \quad (10.5)$$

Purtroppo, la descrizione del sistema lineare non è troppo chiara. Vediamola scritta matricialmente. Sia B la matrice $n \times n$

$$B = \begin{pmatrix} -4 & 1 & 0 & \dots & 0 \\ 1 & -4 & 1 & 0 & \dots \\ 0 & 1 & -4 & 1 & \dots \\ \dots & \dots & \dots & \dots & \dots \\ 0 & \dots & 0 & 1 & -4 \end{pmatrix}$$




FIGURA 10.2. Una griglia avente passo $h = 1/3$ relativamente al quadrato $[0, 1] \times [0, 1]$.



FIGURA 10.3. Pierre-Simon Laplace (1749-1827) e Siméon Denis Poisson (1781-1840).

ed I la matrice identica di ordine n del tipo

$$I = \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix}.$$

Allora se b è il vettore ottenuto dai contributi dei termini dovuti a f e g in (10.10) e (11.2), definita la matrice a blocchi

$$A = \begin{pmatrix} B & I & 0 & \dots & 0 \\ I & B & I & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ \dots & 0 & I & B & I \end{pmatrix}$$

si ricava che il sistema da risolvere è $Au = b$.

Per una implementazione della matrice di Poisson A , utilizziamo la funzione `makefish`

```
function mat = makefish(siz);
```

```
% make a Poisson matrix

leng = siz*siz;
dia = zeros(siz,siz);
off = -eye(siz,siz);
for i=1:siz, dia(i,i)=4; end;
for i=1:siz-1, dia(i,i+1)=-1; dia(i+1,i)=-1; end;
mat = zeros(leng,leng);
for ib=1:siz,
    mat(1+(ib-1)*siz:ib*siz,1+(ib-1)*siz:ib*siz) = dia; end;
for ib=1:siz-1,
    mat(1+(ib-1)*siz:ib*siz,1+ib*siz:(ib+1)*siz) = off;
    mat(1+ib*siz:(ib+1)*siz,1+(ib-1)*siz:ib*siz) = off; end;
return;
```

Vediamone un esempio dalla shell di Matlab/Octave:

```
>> makefish(2)
ans =
     4     -1     -1     0
    -1     4     0    -1
    -1     0     4    -1
     0     -1    -1     4
>>
```

Si vede subito dal 4 sulla diagonale che `makefish` non calcola A ma $-A$ e dovremo tener conto di questo dettaglio nell'implementazione.

Osserviamo che non è proprio facile determinare, fissato i, j , quali siano i punti adiacenti a (x_i, y_j) che essendo sul bordo hanno valore della soluzione noto a priori e quindi tali da contribuire attivamente al termine noto.

11. Sull'equazione di Poisson. Esempio del metodo alle differenze con 5 punti. Facciamo un esempio sulla risoluzione dell'equazione di Poisson via metodo alle differenze con 5 punti. Sia $\Omega = [0, 1] \times [0, 1]$, $h = 1/3$ e siano

$$P_{i,j} = (ih, jh), \quad i, j = 0, 1, 2, 3.$$

E' chiaro che per $i = 0$ i punti $P_{0,j}$ sono sull'asse $x = 0$ (cioè l'asse y), per $i = 3$ i punti $P_{3,j}$ sono sull'asse $x = 1$, per $j = 0$ i punti $P_{i,0}$ sono sull'asse $y = 0$ (cioè l'asse x) e per $j = 3$ i punti $P_{i,3}$ sono sull'asse $y = 1$. Date le condizioni al contorno, la soluzione in questi punti è nota ed è uguale a $u_{i,j} = g(x_i, y_j)$.

I rimanenti punti $P_{i,j}$, con $i, j = 1, 2$ sono interni al quadrato Ω (cf. Figura 11). Per quanto visto

$$u(x_{i+1}, y_j) + u(x_{i-1}, y_j) + u(x_i, y_{j+1}) + u(x_i, y_{j-1}) - 4u(x_i, y_j) = h^2 f(x_i, y_j), \quad (11.1)$$

Analizziamo caso per caso queste equazioni:

1. Nel caso $i = 1, j = 1$ si ha

$$u(x_2, y_1) + u(x_0, y_1) + u(x_1, y_2) + u(x_1, y_0) - 4u(x_1, y_1) = h^2 f(x_1, y_1),$$

ed essendo

$$u(x_0, y_1) = g(x_0, y_1), \quad u(x_1, y_0) = g(x_1, y_0)$$

portando questi due termini a secondo membro otteniamo

$$u(x_2, y_1) + u(x_1, y_2) - 4u(x_1, y_1) = h^2 f(x_1, y_1) - g(x_0, y_1) - g(x_1, y_0).$$

2. Nel caso $i = 2, j = 1$ si ha

$$u(x_3, y_1) + u(x_1, y_1) + u(x_2, y_2) + u(x_2, y_0) - 4u(x_2, y_1) = h^2 f(x_2, y_1),$$

ed essendo

$$u(x_3, y_1) = g(x_3, y_1), u(x_2, y_0) = g(x_2, y_0)$$

portando questi due termini a secondo membro otteniamo

$$u(x_1, y_1) + u(x_2, y_2) - 4u(x_2, y_1) = h^2 f(x_1, y_1) - g(x_3, y_1) - g(x_2, y_0).$$

3. Nel caso $i = 1, j = 2$ si ha

$$u(x_2, y_2) + u(x_0, y_2) + u(x_1, y_3) + u(x_1, y_1) - 4u(x_1, y_2) = h^2 f(x_1, y_2),$$

ed essendo

$$u(x_0, y_2) = g(x_0, y_2), u(x_1, y_3) = g(x_1, y_3)$$

portando questi due termini a secondo membro otteniamo

$$u(x_2, y_2) + u(x_1, y_1) - 4u(x_1, y_2) = h^2 f(x_1, y_2) - g(x_0, y_2) - g(x_1, y_3).$$

4. Nel caso $i = 2, j = 2$ si ha

$$u(x_3, y_2) + u(x_1, y_2) + u(x_2, y_3) + u(x_2, y_1) - 4u(x_2, y_2) = h^2 f(x_2, y_2),$$

ed essendo

$$u(x_3, y_2) = g(x_3, y_2), u(x_2, y_3) = g(x_2, y_3)$$

portando questi due termini a secondo membro otteniamo

$$u(x_1, y_2) + u(x_2, y_1) - 4u(x_2, y_2) = h^2 f(x_2, y_2) - g(x_3, y_2) - g(x_2, y_3).$$

Poniamo ora

$$b_1 := h^2 f(x_1, y_1) - g(x_0, y_1) - g(x_1, y_0),$$

$$b_2 := h^2 f(x_1, y_2) - g(x_0, y_2) - g(x_1, y_3),$$

$$b_3 := h^2 f(x_1, y_1) - g(x_3, y_1) - g(x_2, y_0),$$

$$b_4 := h^2 f(x_2, y_2) - g(x_3, y_2) - g(x_2, y_3),$$

ordiniamo i punti da sinistra a destra, e dal basso verso l'alto (ordine lessicografico)

$$P_1 = (x_1, y_1), P_2 = (x_2, y_1), P_3 = (x_1, y_2), P_4 = (x_2, y_2),$$

e infine poniamo

$$u_1 = u(x_1, y_1), u_2 = u(x_2, y_1), u_3 = u(x_1, y_2), u_4 = u(x_2, y_2),$$

ottenendo così

$$u_2 + u_3 - 4u_1 = b_1,$$

$$u_1 + u_4 - 4u_2 = b_2,$$

$$u_4 + u_1 - 4u_3 = b_3,$$

$$u_3 + u_2 - 4u_4 = b_4,$$

da cui posto

$$A = \begin{pmatrix} -4 & 1 & 1 & 0 \\ 1 & -4 & 0 & 1 \\ 1 & 0 & -4 & 1 \\ 0 & 1 & 1 & -4 \end{pmatrix}$$

basta risolvere il sistema $Au = b$ per ottenere $u(x_1, y_1), u(x_2, y_1), u(x_1, y_2), u(x_2, y_2)$.

Notiamo che

```
>> makefish(2)
ans =
     4     -1     -1     0
    -1     4      0    -1
    -1     0      4    -1
     0     -1     -1     4
>>
```

calcola proprio $-A$, mentre il termine noto b può essere facilmente calcolato dopo aver notato che

1. i termini $-g(x_i, y_0)$ sono presenti nelle componenti b_i ;
2. posto $n = 1/h$, per $i = 1, \dots, n-1$, i termini $-g(x_i, y_n)$ sono presenti nelle componenti $b_{(n-1)^2 - (n-1) + i}$;
3. per $j = 1, \dots, n-1$, i termini $-g(x_0, y_j)$ sono presenti nelle componenti b_s con $s \equiv 1 \pmod{n-1}$;
4. per $j = 1, \dots, n-1$, i termini $-g(x_n, y_j)$ sono presenti nelle componenti b_s con $s \equiv 0 \pmod{n-1}$.

12. Sull'equazione di Poisson. Implementazione del metodo alle differenze con 5 punti. Vediamo ora un'implementazione del metodo sopra descritto, detto per ovvi motivi a 5 punti (cf. (11.2)).

Risulta importante ricordare che vale la seguente stima dell'errore

TEOREMA 12.1. *Se u è soluzione dell'equazione di Poisson (10.10) ed è almeno 4 volte differenziabile con continuità nel quadrato $\Omega := [0, 1] \times [0, 1]$ ed u_h l'approssimazione*

ottenuta col metodo alle differenze con 5 punti, utilizzando una griglia $\mathcal{G} = \{(x_i, y_j)\}$ con $x_i = i h, y_j = j h, h = 1/(n+1)$ allora

$$|u(x_i, y_j) - u_h(x_i, y_j)| \leq ch^2$$

con

$$c = (1/24) \left(\max_{(x,y) \in \Omega} \left| \frac{\partial^4 u(x,y)}{\partial x^4} \right| + \max_{(x,y) \in \Omega} \left| \frac{\partial^4 u(x,y)}{\partial y^4} \right| \right)$$

Ci si aspetta quindi dai test numerici che effettueremo un errore dell'ordine di h^2 .

13. Sull'equazione di Poisson. Implementazione in Matlab del metodo alle differenze con 5 punti. Salviamo in `poisson5pts.m` la funzione

```
function u=poisson5pts(n,f,g_left,g_right,g_down,g_up)

% ATKINSON. P. 559.% RICORDARSI CHE LA MATRICE DI
% MAKEFISH HA SEGNO OPPOSTO A QUELLA DA UTILIZZARE!!
A=-makefish(n);

h=1/(n+1);

x=(h:h:1-h)'; y=x;

% SOLUZIONI IN BASSO.
x_loc=x;
y_loc=zeros(size(x_loc));
b_down=feval(g_down,x_loc,y_loc);

% SOLUZIONI IN ALTO.
y_loc=ones(size(x_loc));
b_up=feval(g_up,x_loc,y_loc);

% SOLUZIONI A SINISTRA.
y_loc=x_loc; x_loc=zeros(size(x_loc));
b_left=feval(g_left,x_loc,y_loc);

% SOLUZIONI A DESTRA
x_loc=ones(size(x_loc));
b_right=feval(g_right,x_loc,y_loc);

% COMPOSIZIONE TERMINE NOTO.
b1=b_down;

% PRIMA RIGA IN BASSO.
b1(1)=b1(1)+b_left(1); b1(n)=b1(n)+b_right(1);

% PRIMA RIGA IN ALTO.
bn=b_up; bn(1)=bn(1)+b_left(n); bn(n)=bn(n)+b_right(n);

% RIGHE INTERMEDIE.
bj=[];
```

```

for j=2:(n-1)
    bjloc=zeros(n,1);
    bjloc(1)=bjloc(1)+b_left(j); bjloc(n)=bjloc(n)+b_right(j);
    bj=[bj; bjloc];
end

b=[b1; bj; bn];

% GRIGLIA LESSICOGRAFICA (METODO STANDARD).
lunghezza_x=length(x);

X=[]; Y=[];
for index=1:lunghezza_x
    X=[X; x];
    Y=[Y; y(index)*ones(size(x))];
end

fXY=feval(f,X,Y);

b_f=(h^2)*fXY;
b=b_f-b;

u=A\b;

e in demopoisson5pts.m la demo

% MODIFIED VERSION: MARCH 13, 2008.

demo_example=2;

switch demo_example
case 1
    f=inline('zeros(size(x))','x','y');
    g_down=inline('ones(size(x))','x','y');
    g_up=inline('ones(size(x))','x','y');
    g_left=inline('ones(size(x))','x','y');
    g_right=inline('ones(size(x))','x','y');

    solution=inline('ones(size(x))','x','y');

case 2
    f=inline('zeros(size(x))','x','y');
    g_down=inline('exp(pi*x)','x','y');
    g_up=inline('-exp(pi*x)','x','y');
    g_left=inline('cos(pi*y)','x','y');
    g_right=inline('((exp(1))^pi)*cos(pi*y)','x','y');

    solution=inline('(exp(pi*x)).*cos(pi*y)','x','y');

case 3
    f=inline('(-2*(pi^2))*sin(pi*x).*sin(pi*y)','x','y');
    g_down=inline('zeros(size(x))','x','y');
    g_up=inline('zeros(size(x))','x','y');
    g_left=inline('zeros(size(x))','x','y');

```

```

g_right=inline('zeros(size(x))','x','y');

solution=inline('(sin(pi*x)).*sin(pi*y)','x','y');

otherwise
f=inline('ones(size(x))','x','y');
g_down=inline('zeros(size(x))','x','y');
g_up=inline('zeros(size(x))','x','y');
g_left=inline('zeros(size(x))','x','y');
g_right=inline('zeros(size(x))','x','y');

solution=inline('(sin(pi*x)).*sin(pi*y)','x','y');
end

for index=2:5
n=2^index;

h=1/(n+1); x=(h:h:1-h)'; y=x;
[X,Y]=meshgrid(x,y);
X=X'; Y=Y';

% VETTORE SOLUZIONE NEI PUNTI DELLA GRIGLIA ORDINATI IN LESSICOGRAFICO.
u=poisson5pts(n,f,g_left,g_right,g_down,g_up);

% USO RESHAPE COSI' LA SOLUZIONE HA LE STESSA DIMENSIONI DELLE MATRICI X, Y.
Z=(reshape(u,n,n));

if demo_example <=3

    V=feval(solution,X,Y);

    err(index)=norm(V(:)-Z(:),inf);
    if index == 1
        fprintf('\n \t [n]: %4.0f [ERR]: %2.2e',n,err(index));
    else
        fprintf('\n \t [n]: %4.0f [ERR]: %2.2e [RATIO]: %2.2f',...
            n,err(index),err(index-1)/err(index));
    end

end
end

surf(X,Y,Z);

```

13.0.1. Descrizione del codice. Alcune osservazioni sui codici Matlab/Octave appena esposti.

1. Posto $h = \frac{1}{n+1}$, allora la matrice $B \in \mathbb{R}^{n \times n}$ mentre il termine noto b e il vettore soluzione u apparterranno a $\mathbb{R}^{n^2}$. dobbiamo risolvere un sistema lineare $Au = b$ con

$$A = \begin{pmatrix} B & I & 0 & \dots & 0 \\ I & B & I & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ \dots & 0 & I & B & I \end{pmatrix}$$

e b un vettore i cui contributi dipendono dai valori che hanno sul bordo le funzioni f e g che definiscono l'equazione di Poisson

$$\begin{cases} -\left[\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2}\right] = f(x, y), & (x, y) \in \Omega \\ u(x, y) = g(x, y), & (x, y) \in \partial\Omega \end{cases} \quad (13.1)$$

Dobbiamo tener conto che `makefish` non calcola A ma $\bar{A} = -A$ ed è per questo che scriviamo `A=-makefish(n)`.

2. **(Per i più esperti)** La funzione `meshgrid` crea a partire da due vettori di numeri reali x, y , le ascisse X e le ordinate Y dei punti facenti parte della griglia *generata* da x ed y . In particolare la matrice di punti

$$\begin{pmatrix} (x_1, y_1) & (x_2, y_1) & \dots & (x_n, y_1) \\ \dots & \dots & \dots & \dots \\ (x_1, y_n) & (x_2, y_n) & \dots & (x_n, y_n) \end{pmatrix}$$

viene descritta tramite la griglia di ascisse e ordinate e cioè come

$$X = \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ \dots & \dots & \dots & \dots \\ x_1 & x_2 & \dots & x_n \end{pmatrix}$$

e

$$Y = \begin{pmatrix} y_1 & y_1 & \dots & y_1 \\ y_2 & y_2 & \dots & y_2 \\ y_3 & y_3 & \dots & y_3 \end{pmatrix}$$

Così ad esempio

```
>> h=1/3;
>> x=h:h:1-h;
>> x
x =
    0.3333    0.6667
>> y=x;
>> [X,Y]=meshgrid(x,y)
X =
    0.3333    0.6667
    0.3333    0.6667
Y =
    0.3333    0.3333
    0.6667    0.6667
>>
```

descrivendone le coordinate x , y .

Per ulteriori chiarimenti usiamo l'help di Matlab 6.1 ottenendo

```
>> help meshgrid
```

```
MESHGRID    X and Y arrays for 3-D plots.
[X,Y] = MESHGRID(x,y) transforms the domain specified by vectors
x and y into arrays X and Y that can be used for the evaluation
of functions of two variables and 3-D surface plots.
The rows of the output array X are copies of the vector x and
the columns of the output array Y are copies of the vector y.
```

```
[X,Y] = MESHGRID(x) is an abbreviation for [X,Y] = MESHGRID(x,x).
[X,Y,Z] = MESHGRID(x,y,z) produces 3-D arrays that can be used to
evaluate functions of three variables and 3-D volumetric plots.
```

```
For example, to evaluate the function x*exp(-x^2-y^2) over the
range -2 < x < 2, -2 < y < 2,
```

```
    [X,Y] = meshgrid(-2:.2:2, -2:.2:2);
    Z = X .* exp(-X.^2 - Y.^2);
    mesh(Z)
```

```
... ..
```

```
See also SURF, SLICE, NDGRID.
```

Il comando Matlab `:` mappa invece una matrice A in un vettore $A(:)$ ottenuto incolonnando le colonne di A . Ad esempio

```
>> A=[1 2; 3 4; 5 6]
```

```
A =
```

```
    1    2
    3    4
    5    6
```

```
>> A(:)
```

```
ans =
```

```
    1
    3
    5
    2
    4
    6
```

```
>>
```

Se x è un vettore colonna, la parte di codice

```
lunghezza_x=length(x);
X=[]; Y=[];
for index=1:lunghezza_x
    X=[X;x];
    Y=[Y; y(index)*ones(size(x))];
end
```

è equivalente a

```
[X,Y]=meshgrid(x,y);  
X=X'; Y=Y';  
X=X(:); Y=Y(:);
```

Vediamolo in un'implementazione della griglia lessografica descritta nell'esempio della sezione precedente

```
>> h=1/3;  
>> x=h:h:1-h; x=x'  
x =  
    0.3333  
    0.6667  
>> y=x;  
>> lunghezza_x=length(x);  
X=[]; Y=[];  
for index=1:lunghezza_x  
    X=[X;x];  
    Y=[Y; y(index)*ones(size(x))];  
end  
>> X  
X =  
    0.3333  
    0.6667  
    0.3333  
    0.6667  
>> Y  
Y =  
    0.3333  
    0.3333  
    0.6667  
    0.6667  
>> % METODO COL MESHGRID  
>> [X,Y]=meshgrid(x,y);  
X=X'; Y=Y';  
>> X(:)  
X =  
    0.3333  
    0.6667  
    0.3333  
    0.6667  
>> Y=Y(:)  
Y =  
    0.3333  
    0.3333  
    0.6667  
    0.6667  
>>
```

3. una porzione di codice particolarmente complicata di demopoisson5pts è

```

[X,Y]=meshgrid(x,y);
X=X'; Y=Y';

% VETTORE SOLUZIONE NEI PUNTI DELLA GRIGLIA
% ORDINATI IN LESSICOGRAFICO.
u=poisson5pts(n,f,g_left,g_right,g_down,g_up);

% USO RESHAPE COSI' LA SOLUZIONE HA LE
% STESSE DIMENSIONI DELLE MATRICI X, Y.
Z=(reshape(u,n,n));

```

L'effetto è di costruire la griglia di punti sotto forma di due matrici X , Y , e poi di definire una matrice Z che assegni a ogni punto della griglia il valore della soluzione che precedentemente era immagazzinata nel vettore u . Il comando `reshape` permette il passaggio dal vettore u alla matrice Z .

4. Notiamo l'uso in `demopoison5pts` di `reshape`, affinché la soluzione abbia una struttura uguale a quella fornita da `meshgrid`. Questa scelta è dovuta alla scelta di usare `surf` per plottare la funzione. Si ricorda che `surf` non è implementato in tutte le versioni di Octave. Funziona in Gnu Octave per PC, in versione 2.1.73. Vediamo un esempio di `reshape`.

```

>> u=[1;2;3;4;5;6]
u =
     1
     2
     3
     4
     5
     6
>> reshape(u,2,3)
ans =
     1     3     5
     2     4     6
>>

```

In pratica `reshape(u, m, n)` parte da un vettore u di dimensione $m \cdot n$ (nel nostro caso $6 = 2 \cdot 3$), e costruisce colonna per colonna una matrice $m \times n$. Per ulteriori dettagli seguiamo l'help di `reshape`

```

>> help reshape

RESHAPE Change size.
  RESHAPE(X,M,N) returns the M-by-N matrix whose elements
  are taken columnwise from X.  An error results if X does
  not have M*N elements.
  ... ..

See also SQUEEZE, SHIFTDIM, COLON.

```

Per quanto riguarda `surf` esegue il plot dei valori Z di una griglia strutturata in matrici X , Y come quelle costruite via `meshgrid`,

```
>> help surf
```

SURF 3-D colored surface.

SURF(X,Y,Z,C) plots the colored parametric surface defined by four matrix arguments. The view point is specified by VIEW. The axis labels are determined by the range of X, Y and Z, or by the current setting of AXIS. The color scaling is determined by the range of C, or by the current setting of CAXIS. The scaled color values are used as indices into the current COLORMAP. The shading model is set by SHADING.

SURF(X,Y,Z) uses C = Z, so color is proportional to surface height.

... ..

AXIS, CAXIS, COLORMAP, HOLD, SHADING and VIEW set figure, axes, and surface properties which affect the display of the surface.

See also SURFC, SURFL, MESH, SHADING.

13.1. Problema 1. Consideriamo un semplice esempio che illustra la risoluzione dell'equazione di Poisson con un metodo alle differenze. Consideriamo l'equazione di Poisson nel quadrato unitario $\Omega = [0, 1] \times [0, 1]$

$$\begin{cases} \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} = 0, & (x, y) \in \Omega \\ u(x, y) = 1, & (x, y) \in \partial\Omega \end{cases} \quad (13.2)$$

la cui soluzione è $u(x, y) = 1$.

Non è difficile osservare che

$$\max_{(x,y) \in \Omega} \left| \frac{\partial^4 u(x, y)}{\partial x^4} \right| = 0, \quad \max_{(x,y) \in \Omega} \left| \frac{\partial^4 u(x, y)}{\partial y^4} \right| = 0$$

e quindi ci si aspetta che per qualsiasi h si abbia un errore dell'ordine della precisione di macchina.

Lanciamo da shell il primo esempio della demo, ottenendo

```
>> demopoisson5pts
```

```
[n]:    4 [ERR]: 4.44e-016 [RATIO]: 163181252362740.50
[n]:    8 [ERR]: 1.11e-015 [RATIO]: 0.40
[n]:   16 [ERR]: 1.55e-015 [RATIO]: 0.71
[n]:   32 [ERR]: 6.66e-015 [RATIO]: 0.23
```

```
>>
```

Per *ratio* si intende il rapporto dell'errore tra due iterate successive.

13.2. Problema 2. Consideriamo un semplice esempio che illustra la risoluzione dell'equazione di Laplace nel quadrato unitario $\Omega = [0, 1] \times [0, 1]$ con un metodo alle differenze.




FIGURA 13.1. Soluzione del problema 2.

$$\begin{cases} \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} = 0, & (x, y) \in \Omega \\ u(x, 0) = \exp(\pi x), & x \in [0, 1] \\ u(x, 1) = -\exp(\pi x), & x \in [0, 1] \\ u(0, y) = \cos(\pi y), & y \in [0, 1] \\ u(1, y) = \exp(\pi) \cdot \cos(\pi y), & y \in [0, 1] \end{cases} \quad (13.3)$$

la cui soluzione è $u(x, y) = \exp(\pi x) \cdot \cos(\pi y)$. Si nota subito che per $x, y \in [0, 1]$ si ha

$$\left| \frac{\partial^4 u}{\partial x^4}(x, y) \right| = \pi^4 |\exp(\pi x) \cdot \cos(\pi y)| \leq \pi^4 \exp(\pi) \approx 2254.1$$

$$\left| \frac{\partial^4 u}{\partial y^4}(x, y) \right| = \pi^4 |\exp(\pi x) \cdot \cos(\pi y)| \leq \pi^4 \exp(\pi) \approx 2254.1$$

da cui

$$c \leq (1/24) \cdot 2254.1 \cdot 2 \approx 187.8428.$$

Quindi quale maggiorazione dell'errore assoluto in norma infinito, per $n = 3, 7, 15, 31$, avremo i valori immagazzinati qui sotto nel vettore `err`

```
>> format short e
>> c=187.8428; err=[];
>> for n=2:5, N=2^n-1; h=1/(N+1); h2=h^2; err=[err; c*h2]; end
>> err

err =

    1.1740e+001
    2.9350e+000
    7.3376e-001
    1.8344e-001

>>
```




FIGURA 13.2. Soluzione del problema 3.

Lanciando la demo `demopoisson5pts`, per `demoexample=2`, abbiamo

```
>> demopoisson5pts
```

```
[n]:    4 [ERR]: 9.75e-002 [RATIO]: 0.74
[n]:    8 [ERR]: 3.20e-002 [RATIO]: 3.04
[n]:   16 [ERR]: 9.05e-003 [RATIO]: 3.54
[n]:   32 [ERR]: 2.45e-003 [RATIO]: 3.69
```

```
>>
```

1. Come ci si aspettava la maggiorazione è realizzata, ma purtroppo come stima è abbastanza conservativa.
2. Nella colonna `[RATIO]` abbiamo indicato il rapporto e_{2h}/e_h dove e_h è l'errore assoluto compiuto dal metodo a 5 punti con passo h (ovvero la quantità espone nella colonna `[ERR]` nella stessa riga di h). Il fatto che la *ratio* sia 4 non è sorprendente. Infatti se l'errore decresce come h^2 si può supporre che sia $e_h \approx \hat{c}h^2$ per qualche $\hat{c}$ indipendente da h e quindi

$$\frac{e_{2h}}{e_h} \approx \frac{\hat{c}(2h)^2}{\hat{c}h^2} \approx 4.$$

13.3. Problema 3. Consideriamo un la risoluzione dell'equazione di Poisson nel quadrato unitario $\Omega = [0, 1] \times [0, 1]$ con un metodo alle differenze.

$$\begin{cases} \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} = (-2\pi^2) \sin(\pi x) \sin(\pi y), & (x, y) \in \Omega \\ u(x, 0) = 0, & x \in [0, 1] \\ u(x, 1) = 0, & x \in [0, 1] \\ u(0, y) = 0, & y \in [0, 1] \\ u(1, y) = 0, & y \in [0, 1] \end{cases} \quad (13.4)$$

la cui soluzione è $u(x, y) = \sin(\pi x) \sin(\pi y)$. Ripetendo la stima basata sulle derivate quarte della soluzione u abbiamo facilmente

$$c \leq (1/24) 2\pi^4 \approx 8.1174$$

da cui

```
>> c=8.1174;
>> err=[]; for n=2:5, N=2^n; N=N-1; h=1/(N+1); h2=h^2; err=[err; c*h2]; end
>> format short e
>> err

err =

5.0734e-001
1.2683e-001
3.1709e-002
7.9271e-003

>>
```

Lanciando la demo `demopoisson5pts`, per `demoexample=3`, abbiamo

```
>> demopoisson5pts

[n]:      4 [ERR]: 3.04e-002 [RATIO]: 2.39
[n]:      8 [ERR]: 9.91e-003 [RATIO]: 3.06
[n]:     16 [ERR]: 2.83e-003 [RATIO]: 3.51
[n]:     32 [ERR]: 7.54e-004 [RATIO]: 3.75

>>
```

Rispetto al caso precedente la stima è più precisa, e la ratio di circa 4 ci dice che la convergenza è ancora dell'ordine di h^2 .

14. Facoltativo: Meshgrid e i grafici bidimensionali. Non è infrequente di voler rappresentare graficamente una funzione definita su un quadrato Ω , supponiamo per semplicità $\Omega = [0, 1] \times [0, 1]$. Vediamone un esempio, proponendoci di voler plottare il piano

$$f(x, y) = 3x + y.$$

Si tratta di un piano passante per l'origine $P_1=(0, 0, 0)$, per il punto $P_2=(0, 1, 1)$ e $P_3=(1, 1, 4)$. Descriviamo il quadrato Ω tramite una griglia non troppo fine, diciamo con passo $h_x = h_y = h = 1/10$. Vediamone i dettagli che salviamo in `my_2D_plot`:

```
h=1/10;

f=inline('3*x+y','x','y');

% DEFINIAMO IL QUADRATO [a, b] x [c, d].
a=0; b=1;
c=0; d=1;

x=0:h:1;
y=0:h:1;

[X,Y]=meshgrid(x,y);
Z=feval(f,X,Y);

surf(X,Y,Z);
```

Il risultato è descritto in figura ed è in effetti un piano che passa per P_1, P_2, P_3 .




FIGURA 14.1. Il piano ottenuto con i comandi `meshgrid` e `surf`.