

Formularea problemei
Iterații simple
Newton

Metode care aproximează Jacobianul
Metode robuste de tip Newton
Metode de descompunere

Rezolvarea sistemelor de ecuații algebrice neliniare

Prof.dr.ing. Gabriela Ciuprina

Universitatea "Politehnica" București, Facultatea de Inginerie Electrică

Suport didactic pentru disciplina *Algoritmi Numerici*, 2017-2018

Cuprins

1 Formularea problemei

- Enunț
- Dificultăți

2 Iterații simple

- Problemă de punct fix
- Convergență

● Jacobian

3 Newton

- Algoritm
- Convergență
- Efort de calcul

4 Metode care aproximează Jacobianul

5 Metode robuste de tip Newton

- *Damped Newton*
- *Trust region*

6 Metode de descompunere

Formularea problemei

Se dau $f_k : \mathbb{R}^n \rightarrow \mathbb{R}$, continue, $k = 1, \dots, n$.

Se cer x_k pentru care

$$f_1(x_1, x_2, \dots, x_n) = 0$$

$$f_2(x_1, x_2, \dots, x_n) = 0$$

⋮

$$f_n(x_1, x_2, \dots, x_n) = 0$$

Formularea problemei

Se dă $\mathbf{F} : \mathbb{R}^n \rightarrow \mathbb{R}^n$, continuă.

Se cere $\mathbf{x} \in \mathbb{R}^n$ pentru care

$$\mathbf{F}(\mathbf{x}) = \mathbf{0} \quad (1)$$

unde

$$\mathbf{F} = [f_1, f_2, \dots, f_n]^T \in \mathbb{R}^n$$

$$\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^n$$

Exemplu care conduce la un astfel de sistem: analiza circuitelor rezistive neliniare.

Dificultăți

- Nu există o metodă simplă de a încadra soluția astfel încât să obținem o metodă garantat convergentă ca în cazul 1D.
Metodele de încadrare nu se pot generaliza.
- Efortul de calcul crește rapid odată cu dimensiunea sistemului.

Formularea problemei

Iterații simple

Newton

Metode care aproximează Jacobianul

Metode robuste de tip Newton

Metode de descompunere

Problemă de punct fix

Convergență

Jacobian

Iterații simple

Formularea problemei ca o problemă de punct fix

$$\mathbf{F}(\mathbf{x}) = \mathbf{0} \Leftrightarrow \mathbf{x} = \mathbf{G}(\mathbf{x}) \quad (2)$$

unde

$$\mathbf{G}(\mathbf{x}) = \mathbf{x} + \mathbf{C}\mathbf{F}(\mathbf{x}) \quad (3)$$

și $\mathbf{C} \in \mathbb{R}^{n \times n}$

Iterații de punct fix

$$\mathbf{x}^{(k+1)} = \mathbf{G}(\mathbf{x}^{(k)}) \quad (4)$$

Iterații simple

O condiție suficientă de convergență este:

- În 1D $|g'(x^*)| < 1$ unde x^* este soluția.
- În nD

$$\rho(\mathbf{G}'(\mathbf{x}^*)) < 1$$

unde \mathbf{G}' este matricea Jacobian.

și inițializarea este suficient de apropiată de soluție

Deoarece $\rho(\mathbf{A}) \leq \|\mathbf{A}\| \Rightarrow$ condiție suficientă de convergență:

$$\|\mathbf{G}'(\mathbf{x}^*)\| < 1 \Leftrightarrow \|\mathbf{I} + \mathbf{C}\mathbf{F}'(\mathbf{x})\| < 1$$

unde \mathbf{F}' este matricea Jacobian.

Iterații simple

Matricea Jacobian

$$\mathbf{F}'(\mathbf{x}) = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \cdots & \frac{\partial f_2}{\partial x_n} \\ \vdots & & & \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \cdots & \frac{\partial f_n}{\partial x_n} \end{bmatrix} \stackrel{\text{not}}{=} \mathbf{J}_F(\mathbf{x}) \quad (5)$$

Formularea problemei
Iterații simple
Newton

Metode care aproximează Jacobianul
Metode robuste de tip Newton
Metode de descompunere

Algoritm
Convergență
Efort de calcul

Newton - ideea

Convergența este cu atât mai rapid convergentă cu cât $\|\mathbf{I} + \mathbf{C}\mathbf{F}'(\mathbf{x})\|$ este mai mică.



Viteza maximă de convergență pentru

$$\|\mathbf{I} + \mathbf{C}\mathbf{F}'(\mathbf{x})\| = 0$$

$$\mathbf{C} = -(\mathbf{F}'(\mathbf{x}))^{-1} \quad (6)$$

Iterații Newton:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - (\mathbf{F}'(\mathbf{x}^{(k)}))^{-1} \mathbf{F}(\mathbf{x}^{(k)}) \quad (7)$$

Eșec dacă se întâlnește o matrice Jacobian singulară.

Algoritm

Nu se implementează formula

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - (\mathbf{F}'(\mathbf{x}^{(k)}))^{-1} \mathbf{F}(\mathbf{x}^{(k)}) \quad (8)$$

Dacă notăm \mathbf{z} corecția:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{z} \quad (9)$$

atunci

$$\mathbf{z} = -(\mathbf{F}'(\mathbf{x}^{(k)}))^{-1} \mathbf{F}(\mathbf{x}^{(k)})$$

$$(\mathbf{F}'(\mathbf{x}^{(k)}))\mathbf{z} = -\mathbf{F}(\mathbf{x}^{(k)}) \quad (10)$$

La fiecare iterare neliniară

- 1 se calculează corecția prin rezolvarea sist. algebric liniar (10);
- 2 se actualizează soluția cu (9).

Convergență

Pătratică

Funcția de iterare $\mathbf{G}(\mathbf{x}) = \mathbf{x} - \mathbf{J}_F^{-1}(x)\mathbf{F}(\mathbf{x})$

$$\mathbf{J}_G(x^*) = \mathbf{0}$$

Taylor:

$$\mathbf{G}(\mathbf{x}) = \mathbf{G}(\mathbf{x}^*) + (\mathbf{x} - \mathbf{x}^*)^T \mathbf{J}_G(\mathbf{x}^*) + (\mathbf{x} - \mathbf{x}^*)^T \mathbf{H}_G(\mathbf{x}^*)(\mathbf{x} - \mathbf{x}^*)/2$$

O demonstrație riguroasă găsiți [aici](#)

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq M \|(\mathbf{x}^{(k-1)} - \mathbf{x}^*)\|^2 \quad (11)$$

Convergență

Matricea Hessian

$$\mathbf{F}''(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f_1}{\partial x_1^2} & \frac{\partial^2 f_1}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f_1}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f_2}{\partial x_2 \partial x_1} & \frac{\partial^2 f_2}{\partial x_2^2} & \cdots & \frac{\partial^2 f_2}{\partial x_2 \partial x_n} \\ \vdots & & & \\ \frac{\partial^2 f_n}{\partial x_n \partial x_1} & \frac{\partial^2 f_n}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f_n}{\partial x_n^2} \end{bmatrix} \stackrel{\text{not}}{=} \mathbf{H}_F(\mathbf{x}) \quad (12)$$

Formularea problemei

Iterații simple

Newton

Metode care aproximează Jacobianul

Metode robuste de tip Newton

Metode de descompunere

Algoritm

Convergență

Efort de calcul

Efort de calcul

La fiecare iterație:

- Evaluarea Jacobianului - n^2 evaluări de funcții scalare dacă problema este densă (fiecare componentă a funcției depinde de toate componentele variabilei);
- Rezolvarea unui sistem de ecuații algebrice liniare - n^3 dacă matricea este plină.

Foarte costisitor!

Variante inspirate din metodele 1D

Scop: reducerea efortului de calcul pe iterație.

Dar: convergență nu va mai fi pătratică \Rightarrow compromis.

- Newton-Kantorovich (tangente paralele)

$$(\mathbf{F}'(\mathbf{x}^{(0)})\mathbf{z} = -\mathbf{F}(\mathbf{x}^{(k)})) \quad (13)$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{z} \quad (14)$$

Sistemul de rezolvat are întotdeauna aceeași matrice a coeficienților \Rightarrow este eficientă folosirea factorizării.

- Secante - derivatele parțiale din formula Jacobianului se calculează numeric.

$$\frac{\partial f_i}{\partial x_j} = \frac{f_i(x_1^{(k-1)}, x_2^{(k-1)}, \dots, x_j^{(k)}, \dots, x_n^{(k-1)}) - f_i(x_1^{(k-1)}, x_2^{(k-1)}, \dots, x_j^{(k-1)}, \dots, x_n^{(k-1)})}{x_j^{(k)} - x_j^{(k-1)}}$$

Convergență locală/globală

Metodă locală

O metoda iterativă este **locală** - dacă ea converge doar dacă inițializarea este suficient de aproape de soluție (*în interiorul razei de convergență*.)

- Metoda Newton și variantele ei sunt locale.
- Dacă inițializarea este foarte proastă, atunci metodele locale pot fi modificate pentru a îmbunătăți convergența lor globală [Martinez]. Exemple de astfel de metode:
 - Newton cu amortizare;
 - quasi-Newton (Broyden);
 - regiuni de încredere;
 - descompunere (separare/decuplare/segregare).

Metoda Newton cu amortizare

Se calculează corecția \mathbf{z} la fiecare iterație, dar aproximarea nouă se calculează ca

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

α_k este un parametru scalar care se alege a.î. aproximarea $\mathbf{x}^{(k+1)}$ să fie mai bună decât aproximarea $\mathbf{x}^{(k)}$.

Metoda Newton cu amortizare

Exemplu:

α_k se alege a.î. $\|\mathbf{f}(\mathbf{x}^{(k)})\|_2$ să scadă suficient de mult la fiecare iterație.

sau

α_k se alege a.î. $h(\alpha) = \|\mathbf{f}(\mathbf{x}^{(k)}) + \alpha \mathbf{z}\|_2$ să fie minimă

- Există o legătură între rezolvarea sistemelor neliniare și tehniciile de minimizare (optimizare).
- Când aproximările au devenit suficient de aproape de soluție, coeficientul de amortizare trebuie să devină 1.

Metoda regiunii de încredere

Este o metodă mai complicată dar care face metoda de tip Newton să fie mai robustă.

Ideeă:

- Se estimează razei unei "regiuni de încredere" în care aproximarea seriei Taylor pe care se bazează metoda Newton să fie suficient de precisă.
- Corecția soluției se ajustează în funcție de raza acestei regiuni de încredere.
- În apropierea soluției, regiunile de încredere sunt suficient de mari astfel încât sunt permise corecții totale Newton.

Și această metodă folosește **tehnici de optimizare**¹

¹ Detalii ale acestor algoritmi vor fi prezentate în capitolul de optimizare.

Metoda regiunii de încredere

Exemple de algoritmi din această categorie:

- Levenberg - Marquardt;
- *double dogleg*;
- etc.

Astfel de algoritmi sunt folosiți de exemplu în:

- funcția matlab `fsoolve`;
- COMSOL
- etc

Formularea problemei
Iterații simple

Newton


Metode care aproximează Jacobianul

Metode robuste de tip Newton

Metode de descompunere

Damped Newton
Trust region


Fiți atenți la astfel de informații (capturi din COMSOL)



Formularea problemei
Iterații simple
Newton
Metode care aproximează Jacobianul
Metode robuste de tip Newton
Metode de descompunere

Damped Newton
Trust region

Fiți atenți la astfel de informații (capturi din COMSOL)



Fiți atenți la astfel de informații (capturi din COMSOL)

The screenshot shows the COMSOL Multiphysics interface for a 2D static model named "sw_Qian_2D_static.mph".

- Model Builder:** Shows the project structure with "sw_Qian_2D_static.mph (root)" containing "Global Definitions", "Parameters", "Materials", "Model 1 (mod)", "Step 1: Stationary", "Solver 1 (sol1)", and "Results".
- Settings Window:** Set to "Fully Coupled" mode. Under "General", "Linear solver" is set to "Direct". Under "Method and Termination", "Nonlinear method" is "Automatic". Other settings include "Initial damping factor" (1E-4), "Minimum damping factor" (1E-8), "Restriction for step-size update" (10), and "Use recovery damping factor" (Automatic). Recovery damping factor is set to 0.75.
- Graphics Window:** Displays a 2D plot titled "U(33)=30.358 Surface: Electric potential (V)". The plot shows a color gradient from 0 to 30 V across a domain from -150 to 250 μm on the x-axis and 0 to 3 μm on the y-axis.
- Convergence Plot 1:** A table showing the convergence history for the nonlinear iterations. The continuation parameter U starts at 30.3023 and increases to 30.907. The table includes columns for Iter, SolEst, ResEst, Damping, StepSize, #Res, #Jac, #Sol, LinErr, and LinRes.

Ideea

Până acum componentele Jacobianului au fost evaluate în același punct.

$$\begin{aligned} f_1(x_1, x_2) &= 0, \\ f_2(x_1, x_2) &= 0 \end{aligned}$$

Newton - aplicat întregului sistem

$$\begin{bmatrix} x_1^{(k+1)} \\ x_2^{(k+1)} \end{bmatrix} = \begin{bmatrix} x_1^{(k)} \\ x_2^{(k)} \end{bmatrix} - \begin{bmatrix} \frac{\partial f_1}{\partial x_1}(x_1^{(k)}, x_2^{(k)}) & \frac{\partial f_1}{\partial x_2}(x_1^{(k)}, x_2^{(k)}) \\ \frac{\partial f_2}{\partial x_1}(x_1^{(k)}, x_2^{(k)}) & \frac{\partial f_2}{\partial x_2}(x_1^{(k)}, x_2^{(k)}) \end{bmatrix}^{-1} \begin{bmatrix} f_1(x_1^{(k)}, x_2^{(k)}) \\ f_2(x_1^{(k)}, x_2^{(k)}) \end{bmatrix} \quad (15)$$

Ideea: Jacobi-Newton

Iterații - ca la Jacobi; Newton - aplicat pe grupuri de ecuații.

- se rezolvă $f_1(x_1, x_2^{(k)}) = 0 \Rightarrow x_1^{(k+1)}$;
- se rezolvă $f_2(x_1^{(k)}, x_2) = 0 \Rightarrow x_2^{(k+1)}$;

Deplasări simultane:

$$x_1^{(j+1)} = x_1^{(j)} - f_1^{-1}(x_1^{(j)}, x_2^{(k)})f_1(x_1^{(j)}, x_2^{(k)}) \rightarrow x_1^{(k+1)}$$

$$x_2^{(j+1)} = x_2^{(j)} - f_2^{-1}(x_1^{(k)}, x_2^{(j)})f_2(x_1^{(k)}, x_2^{(j)}) \rightarrow x_2^{(k+1)}$$

Condiție: să existe inversele.

Ideea: Jacobi-Newton

Aproape echivalent cu

$$\begin{bmatrix} x_1^{(j+1)} \\ x_2^{(j+1)} \end{bmatrix} = \begin{bmatrix} x_1^{(j)} \\ x_2^{(j)} \end{bmatrix} - \begin{bmatrix} \frac{\partial f_1}{\partial x_1}(x_1^{(j)}, x_2^{(k)}) & 0 \\ 0 & \frac{\partial f_2}{\partial x_2}(x_1^{(k)}, x_2^{(j)}) \end{bmatrix}^{-1} \begin{bmatrix} f_1(x_1^{(j)}, x_2^{(k)}) \\ f_2(x_1^{(k)}, x_2^{(j)}) \end{bmatrix} \quad (16)$$

Termenii care indică cuplajul $\partial f_1 / \partial x_2$, $\partial f_2 / \partial x_1$ sunt neglijati.

Ideea: Gauss-Seidel-Newton

Iterații - ca la Gauss-Seidel; Newton - aplicat pe grupuri de ecuații.

- se rezolvă $f_1(x_1, x_2^{(k)}) = 0 \Rightarrow x_1^{(k+1)}$;
- se rezolvă $f_2(x_1^{(k+1)}, x_2) = 0 \Rightarrow x_2^{(k+1)}$.

Deplasări succesive:

$$x_1^{(j+1)} = x_1^{(j)} - f_1^{-1}(x_1^{(j)}, x_2^{(k)})f_1(x_1^{(j)}, x_2^{(k)}) \rightarrow x_1^{(k+1)}$$


$$x_2^{(j+1)} = x_2^{(j)} - f_2^{-1}(x_1^{(k+1)}, x_2^{(j)})f_2(x_1^{(k+1)}, x_2^{(j)}) \rightarrow x_2^{(k+1)}$$

Condiție: să existe inversele.


Aplicații tipice

- Această abordare este mai ales utilă în probleme multifizice, în care separarea sistemului în grupuri de ecuații se face pe considerente fizice.
- Fiecare grup de ecuații provine din formulările matematice ale unor probleme foarte bine definite și cunoscute, cu operatori matematici foarte bine studiați.
- Rezolvarea pe componente (cuplaj slab) poate fi mai robustă decât rezolvarea simultană (cuplaj tare).


Rezolvarea pe componente (cuplaj slab) în COMSOL




Rezolvarea pe componente (cuplaj slab) în COMSOL



Rezolvarea pe componente (cuplaj slab) în COMSOL



Rezolvarea pe componente (cuplaj slab) în COMSOL



Referințe

- [Ioan98] D. Ioan et al., *Metode numerice în ingineria electrică*, Ed. Matrix Rom, Bucuresti, 1998. (Capitolul 16)
- [Cheney] Ward Cheney and David Kincaid, *Numerical Mathematics and Computing*, Brooks/Cole publishing Company, 2000.
- [Heath] Michael Heath, *Scientific computing. An Introductory Survey*, McGraw Hill 2002 (capitolul 5 din carte) și alte resurse de la
disponibilă la <http://heath.cs.illinois.edu/scicomp/>
- [Martinez] Jose Mario Martinez, *Algorithms for Solving Nolinear Systems of Equations*, 1994, disponibil la
<http://www.ime.unicamp.br/martinez/nato.pdf>