

Metoda potencija

1 Uvod

Problem svojstvenih vrijednosti je kompleksan numerički problem o čemu postoji brojna literatura (vidi primjerice [1], [2], [3], [6], [7]). U primjenama je posebno važno znati najveću i najmanju po modulu svojstvenu vrijednost i odgovarajuće svojstvene vektore. Primjerice, problem izbora rješava se među ostalim i tzv. analitičkim hierarhijskim procesom, pri čemu je potrebno odrediti maksimalnu svojstvenu vrijednost jedne kvadratne matrice (vidi [10]). S druge strane, preko najmanje svojstvene vrijednosti i odgovarajućeg svojstvenog vektora jedne pozitivno definitne simetrične matrice rješava se tzv. potpuni linearni problem najmanjih kvadrata s različitim primjenama (vidi [4], [9]).

2 Metoda potencija

Najprije ćemo pokazati poznatu **metodu potencija** (Power Method) za traženje po modulu najveće svojstvene vrijednosti i pripadnog svojstvenog vektora. Postoje različite varijante u pristupu (vidi primjerice [1], [2] ili [7]). Mi ćemo se uglavnom držati pristupa iz [2]. Za danu kvadratnu matricu $\mathbf{A} \in \mathbb{R}^{n \times n}$ prepostavljamo:

- (i) postoji jedinstvena po modulu najveća svojstvena vrijednost λ_1 :

$$|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \cdots \geq |\lambda_n|,$$

- (ii) postoji linearno nezavisni skup svojstvenih vektora $\{\mathbf{u}^{(1)}, \dots, \mathbf{u}^{(n)}\}$,

$$\mathbf{A} \mathbf{u}^{(i)} = \lambda_i \mathbf{u}^{(i)}, \quad i = 1, \dots, n. \quad (1)$$

Izaberimo vektor $\mathbf{x}^{(0)} \in \mathbb{C}^n$, tako da kada ga prikažemo u bazi $\{\mathbf{u}^{(1)}, \dots, \mathbf{u}^{(n)}\}$, koeficijent koji stoji uz svojstveni vektor $\mathbf{u}^{(1)}$ bude različit od nule:

$$\mathbf{x}^{(0)} = a_1 \mathbf{u}^{(1)} + \cdots + a_n \mathbf{u}^{(n)}, \quad a_1 \neq 0, \quad (2)$$

i formirajmo niz

$$\mathbf{x}^{(1)} = \mathbf{A} \mathbf{x}^{(0)}, \quad \mathbf{x}^{(2)} = \mathbf{A} \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(k)} = \mathbf{A} \mathbf{x}^{(k-1)}, \dots, \quad \text{tj.,}$$

$$\mathbf{x}^{(k)} = \mathbf{A}^k \mathbf{x}^{(0)}, \quad k = 1, 2, \dots \quad (3)$$

Bez smanjenja općenitosti umjesto (1) možemo pisati (koeficijente a_1, \dots, a_n "uvučemo" u vektore $\{\mathbf{u}^{(1)}, \dots, \mathbf{u}^{(n)}\}$)

$$\mathbf{x}^{(0)} = \mathbf{u}^{(1)} + \cdots + \mathbf{u}^{(n)},$$

odakle, koristeći (3), dobivamo

$$\begin{aligned}\mathbf{x}^{(k)} &= \mathbf{A}^k \mathbf{u}^{(1)} + \cdots + \mathbf{A}^k \mathbf{u}^{(n)} = (\text{prema}(1)) = \lambda_1^k \mathbf{u}^{(1)} + \cdots + \lambda_n^k \mathbf{u}^{(n)} = \\ &= \lambda_1^k \left[\mathbf{u}^{(1)} + \left(\frac{\lambda_2}{\lambda_1} \right)^k \mathbf{u}^{(2)} + \cdots + \left(\frac{\lambda_n}{\lambda_1} \right)^k \mathbf{u}^{(n)} \right] = \lambda_1^k [u^{(1)} + \varepsilon^{(k)}],\end{aligned}$$

gdje zbog $|\lambda_i| < |\lambda_1|$, $\varepsilon^{(k)} \rightarrow 0$ za $k \rightarrow \infty$.

Definirajmo sada linearni funkcional $\phi : \mathbb{C}^n \mapsto \mathbb{R}$, takav da je $\phi(\mathbf{u}^{(1)}) \neq 0$. Možemo primjerice uzeti $\phi(\mathbf{x}) = x_i$, gdje je x_i i -ta komponenta vektora \mathbf{x} . Kako je

$$\phi(\mathbf{x}^{(k)}) = \lambda_1^k [\phi(u^{(1)}) + \phi(\varepsilon^{(k)})],$$

niz definiran s

$$r_k = \frac{\phi(\mathbf{x}^{(k+1)})}{\phi(\mathbf{x}^{(k)})} = \lambda_1 \left[\frac{\phi(u^{(1)}) + \phi(\varepsilon^{(k+1)})}{\phi(u^{(1)}) + \phi(\varepsilon^{(k)})} \right]$$

konvergira prema λ_1 .

Kako bi izbjegli eventualne mogućnosti da niz $(\mathbf{x}^{(k)})$ konvergira prema $\mathbf{0}$ ili da bude neograničen, vektore $\mathbf{x}^{(k)}$ ćemo normirati.

Algoritam: Power Method

Korak 0 Učitamo: matricu \mathbf{A} , vektor $\mathbf{x}^{(0)}$, maksimalni broj iteracija , funkcional ϕ i stavimo $k = 1$

Korak 1 Definiramo vektor $\mathbf{y} = \mathbf{A} \mathbf{x}^{(0)}$

Korak 2 izračunamo $\lambda = \phi(\mathbf{y})/\phi(\mathbf{x}^{(0)})$ i $\mathbf{x} = \mathbf{y}/\|\mathbf{y}\|$

Korak 3 Ispisimo rezultate: k , λ , x

Korak 4 Stavimo $\mathbf{x}^{(0)} = \mathbf{x}$, $k = k + 1$ i ako je $k < it$, prijeđemo na Korak 1; Inače zaustavimo iterativni proces.

Primjer 1 Pozivom Mathemayica - naredbe Eigensystem za matricu

$$\mathbf{A} = \begin{bmatrix} 6 & 5 & -5 \\ 2 & 6 & -2 \\ 2 & 5 & -1 \end{bmatrix},$$

dobivamo svojstvene vrijednosti: $\lambda_1 = 6$, $\lambda_2 = 4$, $\lambda_3 = 1$ i odgovarajuće svojstvene vektore: $\mathbf{u}^{(1)} = (1, 1, 1)^T$, $\mathbf{u}^{(2)} = (0, 1, 1)^T$, $\mathbf{u}^{(3)} = (1, 0, 1)^T$. Navedenim algoritmom Power Method izračunat ćemo najveću svojstvenu vrijednost i odgovarajući svojstveni vektor. Uz izbor $\mathbf{x}^{(0)} = (-1, 1, 2)^T$, nakon 10 iteracija dobivamo

$$\lambda_1 = 6.08121, \quad \mathbf{u}^{(1)} = (-1., -0.973988, -0.973988)^T.$$

Međutim, ako izaberemo $\mathbf{x}^{(0)} = (1, 2, 3)^T$, nećemo dobiti najveću svojstvenu vrijednost. Zašto?

Na osnovi napisanog algoritma sagradit ćemo odgovarajući Mathematica – modul. Kako bi izbjegli mogućnost lošeg izbora početnog vektora $\mathbf{x}^{(0)}$, njegove komponente definirat ćemo kao slučajne brojeve.

```
In[1]:= PowerMethod[a_, it_] := Module[{lam, x, x0, y, phi}, n = Length[a[[1]]];
x0 = Table[Random[], {i, n}]; phi[x_] := x[[3]];
Do[y = a.x0; lam = phi[y]/phi[x0];
x = y/Max[Abs[y]]; x0 = x, {i, it}];
{lam, x}
]
```

3 Inverzna metoda potencija

Inverzna metoda potencija (Inverse Power Method) služi za brzo računanje po modulu najmanje svojstvene vrijednosti i pripadnog svojstvenog vektora. Može se pokazati da vrijedi (vidi primjerice [7])

Teorem 1 *Neka je $\mathbf{A} \in \mathbb{R}^{n \times n}$ regularna matrica. Ako je $\lambda \in \sigma(\mathbf{A})$, tada je $\lambda^{-1} \in \sigma(\mathbf{A}^{-1})$.*

Pretpostavimo da postoji jedinstvena po modulu najmanja ne-nula svojstvena vrijednost λ_n ,

$$|\lambda_1| \geq |\lambda_2| \geq \cdots \geq |\lambda_{n-1}| > |\lambda_n| > 0.$$

što možemo zapisati kao

$$|\lambda_1^{-1}| \leq |\lambda_2^{-1}| \leq \cdots \leq |\lambda_{n-1}^{-1}| < |\lambda_n^{-1}|.$$

Kako je λ_n^{-1} po modulu jedinstvena najveća svojstvena vrijednost matrice \mathbf{A}^{-1} , možemo je izračunati primjenom Power Method.

Primjer 2 *Potražimo najmanju svojstvenu vrijednost i odgovarajući svojstveni vektor matrice iz Primjera 1.*

Primjenom modula PowerMethod na matricu \mathbf{A}^{-1} nakon 10 iteracija dobivamo:

$$\lambda_3 = 1, \quad \mathbf{u}^{(1)} = (1., 0, 1)^T.$$

Međutim, ako bi za funkcional φ izabrali $\varphi(\mathbf{x}) = x_2$, iterativni postupak nebi konvergirao rješenju. Zašto?

Budući da je izračunavanje inveržne matrice numerički nestabilan posao, u Koraku 1 umjesto izračunavanja vektora $\mathbf{y} = \mathbf{A}^{-1} \mathbf{x}^{(0)}$ možemo rješavati sustav linearnih jednažbi

$$\mathbf{A} \mathbf{y} = \mathbf{x}^{(0)}. \quad (4)$$

Budući da susatv oblika (4) u algoritmu rješavamo u svakoj iteraciji s istom matricom sustava \mathbf{A} , korisno je primijeniti LU-dekompoziciju matrice \mathbf{A} .

Uz pretpostavku da su dostupni moduli **FS** za rješavanje donjeg trokutastog i **BS** za rješavanje gornjeg trokutastog sustava, modifikaciom modula **PowerMethod** sagradit ćemo modul **InversePowerMethod** za izračunavanje po modulu najmanje svojstvene vrijednosti matrice \mathbf{A} i odgovarajućeg svojstvenog vektora.

```
In[1]:= InversePowerMethod[a_, it_] := Module[{lam, x, x0, y, phi}, n = Length[a[[1]]];
    LU[a, n];
    x0 = Table[Random[], {i, n}]; phi[x_] := x[[3]];
    Do[xx = FS[n, L, x0]; y = BS[n, U, xx]; lam = phi[y]/phi[x0];
        x = y/Max[Abs[y]]; x0 = x, {i, it}];
    {lam, x}
]
```

Literatura

- [1] J. W. DEMMEL, *Applied Numerical Linear Algebra*, SIAM, Philadelphia, 1997.
- [2] D. KINCAID, W. CHENEY, *Numerical Analysis*, Brooks/Cole Publishing Company, New York, 1996.
- [3] S. KUREPA, *Uvod u linearnu algebru*, Školska knjiga, Zagreb, 1985.
- [4] Y. NEIVERGELT, *Total least squares: state-of-the-art regression in numerical analysis*, SIAM Review **36**(1994) 258–264.
- [5] W. H. PRESS, B. P. FLANNERY, S. A. TEUKOLSKY, W. T. VETTERLING, *Numerical Recipes*, Cambridge University Press, Cambridge, 1989.
- [6] J. STOER, *Numerische Mathematik 1, 2*, 2nd Ed., Springer Verlag, New York, 1993.
- [7] J. STOER, R. BULIRSCH, *Introduction to Numerical Analysis*, 2nd Ed., Springer Verlag, New York, 1993.

- [8] R. SCITOVSKI, *Numerička matematika*, Odjel za matematiku, Sveučilište u Osijeku, Osijek, 2000
- [9] R. SCITOVSKI, Š. Ungar, D. Jukić, *Approximating surfaces by moving total least squares method*, Applied Mathematics and Computation **93**(1998) 219-232
- [10] T. L. SAATY, How to make a decision: The analytic hierarchy process, European Journal of Operational Research **48**(1990) 9-26