

1 Generátor náhodných kvadratických funkcií

1.1 Kladne definitná matica. Matica G je kladne definitná, ak pre ľubovoľné x platí $x^T G x \geq 0$, pričom rovnosť nastáva len pre $x = 0$. Ukážte, že pre ľubovoľnú maticu A a ľubovoľné $\varepsilon > 0$ je

$$G = AA^T + \varepsilon I,$$

kde I je identická matica, kladne definitná matica.

1.2 Generátor. Naprogramujte generátor náhodných kvadratických funkcií tvaru

$$Q(x) = \frac{1}{2}x^T G x + h^T x,$$

kde $x \in \mathbb{R}^n$ je vektor premenných, G je náhodne generovaná celočíselná symetrická kladne definitná matica rozmeru $n \times n$ a h je n -rozmerný vektor. Náhodne vygenerujte bod optima x_{opt} tak, aby jeho zložky boli celé čísla medzi -5 a 5. Vektor h dopočítajte tak, aby x_{opt} bol skutočne minimom funkcie $Q(x)$. Ako vyzerá $\nabla Q(x)$ a čo musí platiť v optim?

Funkciu v matlabe definujte ako *anonymous function* príkazom

```
Q = @(x) 1/2*x'*G*x + h'*x;
```

1.3 Dvojrozmerný prípad.

- (a) Pre $n = 2$ vykreslite vygenerovanú funkciu Q na ploche $(x_1, x_2) \in [-10, 10]^2$ pomocou funkcie `surf`.

Poznámky

- Miesto `surf(X, Y, Z)` môžete použiť `surf(X, Y, Z, 'EdgeColor', 'none')`, aby vám to nevykreslovalo hrany.
- Mrežu bodov z danej oblasti môžete vytvoriť pomocou `[X, Y] = meshgrid(linspace(-10, 10, 100))`.

- (b) Do nového obrázku vykreslite vrstevnice funkcie Q pomocou funkcie `contour`. V obrázku vyznačte bod minima x_{opt} .

- (c) Najdite minimum vygenerovanej funkcie Q pomocou `fminsearch`, porovnajte to so skutočným minimom x_{opt} a odmerajte, ako dlho výpočet trval pomocou `tic` a `toc`. Ako štartovací bod pre `fminsearch` môžete použiť nulu (`zeros(n, 1)`).

- (d) Funkcia `fminsearch` v sebe zahŕňa iteráčny algoritmus. Vyhľadajte túto funkciu v helpe a pokúste sa pomocou príkazu `options` vykresliť správanie sa funkčnej hodnoty účelovej funkcie v jednotlivých iteráciách tohto algoritmu.

Pravidlá vektorového derivovania

Vektorovému derivovaniu je venovaný Dodatok B v knihe (strana 273). Tu uvádzame len vybrané pravidlá derivovania.

Nech $f : \mathbb{R}^n \rightarrow \mathbb{R}$. Symbolom $\frac{df(x)}{dx}$ označujeme **riadkový** vektor

$$\frac{df(x)}{dx} = \left(\frac{\partial f(x)}{\partial x_1}, \frac{\partial f(x)}{\partial x_2}, \dots, \frac{\partial f(x)}{\partial x_n} \right)$$

a symbolom $\nabla f(x) = \left(\frac{df(x)}{dx} \right)^T$ označujeme **stĺpcový** vektor gradientu funkcie f .

Derivácia skalárneho súčinu

Nech

$$u : \mathbb{R}^n \rightarrow \mathbb{R}^m, \quad v : \mathbb{R}^n \rightarrow \mathbb{R}^m, \quad f : \mathbb{R}^n \rightarrow \mathbb{R},$$

pričom $f(x) = u(x)^T v(x)$. Potom

$$\frac{df(x)}{dx} = \frac{d}{dx} [u(x)^T v(x)] = u(x)^T \frac{dv(x)}{dx} + v(x)^T \frac{du(x)}{dx},$$

$$\nabla f(x) = \left(\frac{df(x)}{dx} \right)^T = \nabla v(x) \ u(x) + \nabla u(x) \ v(x).$$