

# Optimalizace

## 7. Volné lokální extrémymy

---

Tom Kroupa, Tom Werner

FEL ČVUT

# **Analytické podmínky na volné lokální extrémy**

---

## Podmínka prvního řádu

### Věta

Nechť

- $\mathbf{x} \in X$  je vnitřní bod množiny  $X \subseteq \mathbb{R}^n$ ,
- funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je diferencovatelná v  $\mathbf{x}$ ,
- $\mathbf{x}$  lokální extrém funkce  $f$  na  $X$ .

Pak  $f'(\mathbf{x}) = \mathbf{0}$ .

Bod  $\mathbf{x} \in \mathbb{R}^n$  je **stacionární bod** funkce  $f$ , jestliže  $f'(\mathbf{x}) = \mathbf{0}$ .

## Podmínky druhého řádu

### Věta

Nechť

- $\mathbf{x} \in X$  je vnitřní bod množiny  $X \subseteq \mathbb{R}^n$ ,
- funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je dvakrát diferencovatelná v  $\mathbf{x}$ ,
- $f'(\mathbf{x}) = \mathbf{0}$ .

Pak platí:

- Jestliže  $\mathbf{x}$  je lokální minimum  $f$  na  $X$ , pak je  $f''(\mathbf{x})$  pozitivně semidefinitní.
- Jestliže  $f''(\mathbf{x})$  je pozitivně definitní, pak je  $\mathbf{x}$  ostré lokální minimum  $f$  na  $X$ .
- Jestliže  $f''(\mathbf{x})$  je indefinitní, pak  $\mathbf{x}$  není lokální extrém  $f$  na  $X$ .

Bod  $\mathbf{x} \in \mathbb{R}^n$  je **sedlový bod** funkce  $f$ , jestliže  $f'(\mathbf{x}) = \mathbf{0}$  a  $f''(\mathbf{x})$  je indefinitní.

# Iterační metody na volné lokální extrémy

---

# Rychlost konvergence iteračních algoritmů

Nechť posloupnost bodů  $\mathbf{x}_k \in \mathbb{R}^n$  konverguje k bodu  $\mathbf{x}^*$ .

Pak posloupnost čísel  $r_k = \|\mathbf{x}_k - \mathbf{x}^*\| \geq 0$  konverguje k nule.

## Definice

Pokud existuje limita

$$\lim_{k \rightarrow \infty} \frac{r_{k+1}}{r_k} = \rho$$

řekneme, že posloupnost  $\mathbf{x}_k$  (příp.  $r_k$ ) konverguje

- **sublineárně**, pokud  $\rho = 1$ ,
- **lineárně**, pokud  $0 < \rho < 1$ ,
- **superlineárně**, pokud  $\rho = 0$ .

## Příklady:

- Posloupnost  $r_k = \frac{1}{k} = (1, \frac{1}{2}, \frac{1}{3}, \frac{1}{4}, \dots)$  konverguje sublineárně.
- Posloupnost  $r_k = 2^{-k} = (\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \dots)$  konverguje lineárně.
- Posloupnost  $r_k = 2^{-2^k} = (\frac{1}{4}, \frac{1}{16}, \frac{1}{256}, \dots)$  konverguje superlineárně.

# Sestupné metody, názvosloví

Hledáme lokální minimum diferencovatelné funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ .

- Zvolíme **počáteční odhad**  $\mathbf{x}_0 \in \mathbb{R}^n$
- Tvoříme posloupnost  $\mathbf{x}_1, \mathbf{x}_2, \dots$  pomocí iterace

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$$

kde  $\mathbf{v}_k$  je **směr hledání** a  $\alpha_k > 0$  **délka kroku** v  $k$ -té iteraci

Volba směrů  $\mathbf{v}_k$  odlišuje různé metody:

- Uvažujeme jen **sestupné metody**, splňující  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$  pro každé  $k$ .
- $\mathbf{v}_k$  je **sestupný směr** jestliže

$$f'(\mathbf{x}_k) \mathbf{v}_k = \nabla f(\mathbf{x}_k)^T \mathbf{v}_k < 0$$

**Tvrzení:** Je-li  $\mathbf{v}_k$  sestupný, pak existuje  $\alpha_k > 0$  takové, že  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$ .

- **Line search:** Délku kroku  $\alpha_k$  hledáme (přibližnou) minimalizací funkce

$$\varphi(\alpha_k) = f(\mathbf{x}_k + \alpha_k \mathbf{v}_k)$$

přes  $\alpha_k \geq 0$

# Gradientní metoda

---



Iterace:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f'(\mathbf{x}_k)^T$$

- Směr  $\mathbf{v}_k = -f'(\mathbf{x}_k)^T = -\nabla f(\mathbf{x}_k)$  je sestupný právě když  $f'(\mathbf{x}_k) \neq \mathbf{0}$ :

$$f'(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)f'(\mathbf{x}_k)^T = -\|\nabla f(\mathbf{x}_k)\|^2 > 0$$

- Robustní: za velmi obecných předpokladů konverguje
- Obvykle konverguje **lineárně** (což může být velmi pomalu)

# Newtonova metoda

---

# Newtonova metoda na řešení soustavy rovnic


Pro dané diferencovatelné zobrazení  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^n$  řešíme soustavu rovnic  $\mathbf{g}(\mathbf{x}) = \mathbf{0}$ .

**Iterace:** Pro známé  $\mathbf{x}_k$  hledáme  $\mathbf{x}_{k+1}$  splňující

$$\mathbf{T}_1(\mathbf{x}_{k+1}) = \mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k) = \mathbf{0}$$

To je lineární soustava s řešením

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1} \mathbf{g}(\mathbf{x}_k)$$



- Pro konvergenci je třeba, aby poč. odhad  $\mathbf{x}_0$  byl blízko nějakého kořene.
- Obvykle konverguje **superlineárně**.

# Superlineární konvergence Newtonovy metody

## Věta

Nechť  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^n$ ,  $\mathbf{x}^* \in \mathbb{R}^n$ ,  $\mathbf{g}(\mathbf{x}^*) = \mathbf{0}$  a  $\mathbf{g}'(\mathbf{x}^*)$  je regulární.

Nechť posloupnost  $\mathbf{x}_k$  splňující  $\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1}\mathbf{g}(\mathbf{x}_k)$  konverguje k  $\mathbf{x}^*$ . Pak

$$\lim_{k \rightarrow \infty} \frac{\|\mathbf{x}_{k+1} - \mathbf{x}^*\|}{\|\mathbf{x}_k - \mathbf{x}^*\|} = 0.$$

**Důkaz:** Chceme dokázat

$$\lim_{k \rightarrow \infty} \frac{\mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1}\mathbf{g}(\mathbf{x}_k) - \mathbf{x}^*}{\|\mathbf{x}_k - \mathbf{x}^*\|} = \lim_{k \rightarrow \infty} \frac{\mathbf{x}_{k+1} - \mathbf{x}^*}{\|\mathbf{x}_k - \mathbf{x}^*\|} = 0.$$

To plyne z následujícího:

$$\begin{aligned} \lim_{x \rightarrow x^*} \frac{x - \mathbf{g}'(x)^{-1}\mathbf{g}(x) - \mathbf{x}^*}{\|x - \mathbf{x}^*\|} &= \lim_{x \rightarrow x^*} \mathbf{g}'(x)^{-1} \frac{\mathbf{g}'(x)(x - \mathbf{x}^*) - \mathbf{g}(x)}{\|x - \mathbf{x}^*\|} \\ &= \mathbf{g}'(\mathbf{x}^*)^{-1} \lim_{x \rightarrow x^*} \frac{\mathbf{g}'(x)(x - \mathbf{x}^*) - \mathbf{g}(x)}{\|x - \mathbf{x}^*\|} \\ &= \mathbf{g}'(\mathbf{x}^*)^{-1} \lim_{x \rightarrow x^*} \frac{\mathbf{g}(\mathbf{x}^*) - \mathbf{g}(x) - \mathbf{g}'(x)(\mathbf{x}^* - x)}{\|\mathbf{x}^* - x\|} \\ &= 0 \end{aligned}$$

kde poslední limita je nulová z definice derivace (protože  $\mathbf{g}(\mathbf{x}^*) = \mathbf{0}$ ).

# Příklad: Babylónská metoda na výpočet druhé odmocniny

Řešíme

$$g(x) = x^2 - a = 0$$

Iterace:

$$x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)} = x_k - \frac{x_k^2 - a}{2x_k} = \frac{1}{2} \left( x_k + \frac{a}{x_k} \right)$$

Matlab:

```
a = 4;  
x = a;  
for i=1:5  
    x = (x+a/x)/2;  
    fprintf('x=%0.12g  g=%0.12g\n',x,x^2-a);  
end
```

x=2.5 g=2.25

x=2.05 g=0.2025

x=2.0006097561 g=0.00243939619274

x=2.00000009292 g=3.71689187872e-07

x=2 g=8.881784197e-15

# Příklad: Průsečík dvou rovinných křivek

Najdi řešení soustavy dvou rovnic o dvou neznámých:

$$(x - 1)^2 + y^2 = 1$$

$$x^4 + y^4 = 1$$

Je

$$\mathbf{g}(x, y) = \begin{bmatrix} (x - 1)^2 + y^2 - 1 \\ x^4 + y^4 - 1 \end{bmatrix} \quad \mathbf{g}'(x, y) = \begin{bmatrix} 2(x - 1) & 2y \\ 4x^3 & 4y^3 \end{bmatrix}$$

Iterace:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \end{bmatrix} - \begin{bmatrix} 2(x_k - 1) & 2y_k \\ 4x_k^3 & 4y_k^3 \end{bmatrix}^{-1} \begin{bmatrix} (x_k - 1)^2 + y_k^2 - 1 \\ x_k^4 + y_k^4 - 1 \end{bmatrix}$$

Matlab:

```
x = [1;1];  
for iter = 1:5  
    g = [(x(1)-1)^2+x(2)^2-1; x(1)^4+x(2)^4-1];  
    x = x - [2*(x(1)-1) 2*x(2); 4*x.^3] \ g;  
    fprintf('x=(%.12g,%.12g) g=(%.12g,%.12g)\n', x, g);  
end
```

```
x=(0.75,1) g=(0.0625,0.31640625)  
x=(0.678779069767,0.950944767442) g=(0.00747883674452,0.0300334591266)  
x=(0.671937746776,0.944701508411) g=(8.57819836066e-05,0.000339082408219)  
x=(0.671859761262,0.944629025098) g=(1.13355711484e-08,4.46057650816e-08)  
x=(0.671859751039,0.944629015546) g=(0,8.881784197e-16)
```

## Použití Newtonovy metody na minimalizaci funkce


Hledáme lokální minimum dvakrát diferencovatelné funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ .

**Iterace:** Řešíme stacionární podmínku  $\mathbf{g}(\mathbf{x}) = f'(\mathbf{x})^T = \mathbf{0}$  Newtonovou metodou:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T$$

**Jiné odvození:** Minimalizujeme Taylorův polynom funkce  $f$  stupně 2 v okolí  $\mathbf{x}_k$

$$T_2(\mathbf{x}_{k+1}) = f(\mathbf{x}_k) + f'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k) + \frac{1}{2}(\mathbf{x}_{k+1} - \mathbf{x}_k)^T f''(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k)$$



Pro lepší konvergenci můžeme přidat délku kroku:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T$$

(Pro  $\alpha_k = 1$  se nazývá **čistá** Newtonova metoda.)

- **Newtonův směr**  $\mathbf{v}_k = -f''(\mathbf{x}_k)^{-1}f'(\mathbf{x}_k)^T$  je sestupný, tj.

$$f'(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)f''(\mathbf{x}_k)^{-1}f'(\mathbf{x}_k)^T < 0,$$

když Hessián  $f''(\mathbf{x}_k)$  je pozitivně definitní (za předpokladu  $f'(\mathbf{x}_k) \neq \mathbf{0}$ ).

- Soustava

$$f''(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)^T$$

má symetrickou matici: můžeme ji řešit Choleského rozkladem.



# **Nelineární metody nejmenších čtverců**

---

## Nelineární úloha nejmenších čtverců

Pro dané diferencovatelné zobrazení  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^m$  minimalizujeme funkci

$$f(\mathbf{x}) = \|\mathbf{g}(\mathbf{x})\|^2 = \mathbf{g}(\mathbf{x})^T \mathbf{g}(\mathbf{x}) = \sum_{i=1}^m g_i(\mathbf{x})^2$$

- Tedy minimalizujeme součet čtverců daných funkcí.
- Úloha lineárních nejmenších čtverců je speciálním případem, kdy

$$\mathbf{g}(\mathbf{x}) = \mathbf{Ax} - \mathbf{b}$$

je afinní.

# Gauss-Newtonova metoda

**Iterace:** Pro známé  $\mathbf{x}_k$  najdeme  $\mathbf{x}_{k+1}$  které minimalizuje funkci

$$\|\mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k)\|^2$$

To je lineární úloha nejmenších čtverců s řešením

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^+ \mathbf{g}(\mathbf{x}_k)$$

Můžeme přidat délku kroku:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{g}'(\mathbf{x}_k)^+ \mathbf{g}(\mathbf{x}_k)$$

(Pro  $\alpha_k = 1$  se nazývá **čistá** Gauss-Newtonova metoda.)

- Má-li  $\mathbf{g}'(\mathbf{x}_k)$  lin. nezávislé sloupce, Gauss-Newtonův směr lze psát jako

$$\begin{aligned} \mathbf{v}_k &= -\mathbf{g}'(\mathbf{x}_k)^+ \mathbf{g}(\mathbf{x}_k) \\ &= -(\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} \mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}(\mathbf{x}_k) \\ &= -\frac{1}{2}(\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T \quad (\text{neboť } f'(\mathbf{x}) = 2\mathbf{g}(\mathbf{x})^T \mathbf{g}'(\mathbf{x})) \end{aligned}$$

- Gauss-Newtonův směr je vždy sestupný:

$$f'(\mathbf{x}_k) \mathbf{v}_k = -\frac{1}{2} f'(\mathbf{x}_k) (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T < 0.$$

# Rozdíl oproti Newtonově metodě

Minimalizace funkce  $f(\mathbf{x}) = \|\mathbf{g}(\mathbf{x})\|^2$  Newtonovou vs. Gauss-Newtonovou metodou:

- Gauss-Newtonův směr je

$$\mathbf{v}_k = -\frac{1}{2}(\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T$$

- Newtonův směr je

$$\begin{aligned} \mathbf{v}_k &= -f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T \\ &= -\frac{1}{2} \left( \mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k) + \sum_{i=1}^m g_i(\mathbf{x}_k) g_i''(\mathbf{x}_k) \right)^{-1} f'(\mathbf{x}_k)^T \end{aligned}$$

Gauss-Newtonova metoda zanedbává **členy druhého řádu** v Hessiánu  $f''(\mathbf{x})$ .

- Proto obvykle konverguje o něco pomaleji než Newtonova metoda.
- Výhoda: nemusíme počítat Hessiány  $g_i''(\mathbf{x})$

## Příklad: Přibližný průsečík tří křivek

Najdi přibližné řešení soustavy tří rovnic o dvou neznámých:

$$(x - 1)^2 + y^2 = 1$$

$$x^4 + y^4 = 1$$

$$x^2 + (y - 1)^2 = \frac{1}{2}$$

Minimalizujeme funkci

$$\begin{aligned} f(x, y) &= \mathbf{g}(x, y)^T \mathbf{g}(x, y) \\ &= ((x - 1)^2 + y^2 - 1)^2 + (x^4 + y^4 - 1)^2 + (x^2 + (y - 1)^2 - \frac{1}{2})^2 \end{aligned}$$

Je

$$\mathbf{g}(x, y) = \begin{bmatrix} (x - 1)^2 + y^2 - 1 \\ x^4 + y^4 - 1 \\ x^2 + (y - 1)^2 - \frac{1}{2} \end{bmatrix}, \quad \mathbf{g}'(x, y) = \begin{bmatrix} 2(x - 1) & 2y \\ 4x^3 & 4y^3 \\ 2x & 2(y - 1) \end{bmatrix}$$

Iterace čisté Gauss-Newtonovy metody:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \end{bmatrix} - \begin{bmatrix} 2(x_k - 1) & 2y_k \\ 4x_k^3 & 4y_k^3 \\ 2x_k & 2(y_k - 1) \end{bmatrix}^+ \begin{bmatrix} (x_k - 1)^2 + y_k^2 - 1 \\ x_k^4 + y_k^4 - 1 \\ x_k^2 + (y_k - 1)^2 - \frac{1}{2} \end{bmatrix}$$

## Matlab:

```
x = [1;1];
for iter = 1:10
    g = [(x(1)-1)^2+x(2)^2-1; x(1)^4+x(2)^4-1; x(1)^2+(x(2)-1)^2-.5];
    x = x - [2*(x(1)-1) 2*x(2); 4*x'.^3; 2*x(1) 2*(x(2)-1)] \ g;
    fprintf('x=(%.12g,%.12g) g=(%.12g,%.12g,%.12g)\n',x,g);
end

x=(0.75,1) g=(0,1,0.5)
x=(0.696777860013,0.945770115246) g=(0.0625,0.31640625,0.0625)
x=(0.691092552216,0.940578214706) g=(-0.0135752229284,0.0358061117489,-0.0115597333957)
x=(0.691002680826,0.94054818438) g=(-0.0198888107249,0.0107820331379,-0.0188601357041)
x=(0.691002154829,0.940548357781) g=(-0.0198897696029,0.0105634499047,-0.0189807767107)
x=(0.691002152527,0.940548357855) g=(-0.0198891183559,0.0105633328127,-0.0189815242591)
x=(0.691002152516,0.940548357857) g=(-0.0198891167934,0.0105633300224,-0.0189815274491)
x=(0.691002152516,0.940548357857) g=(-0.0198891167821,0.0105633300147,-0.0189815274653)
x=(0.691002152516,0.940548357857) g=(-0.019889116782,0.0105633300146,-0.0189815274654)
x=(0.691002152516,0.940548357857) g=(-0.019889116782,0.0105633300146,-0.0189815274654)
```

# Levenberg-Marquardtova metoda

Široce používané vylepšení Gauss-Newtonovy metody.

**Iterace:** Pro známé  $\mathbf{x}_k$  najdeme  $\mathbf{x}_{k+1}$  které minimalizuje funkci

$$\|\mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k)\|^2 + \mu_k \|\mathbf{x}_{k+1} - \mathbf{x}_k\|^2$$

Řešení je

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k) + \mu_k \mathbf{I})^{-1} \mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}(\mathbf{x}_k)$$

Výhoda: Pro  $\mu_k > 0$  inverze vždy existuje!

- Pro  $\mu_k \approx 0$  se blíží Gauss-Newtonově iteraci
- Pro  $\mu_k \gg 0$  se blíží iteraci gradientní metody:

$$\mathbf{x}_{k+1} \approx \mathbf{x}_k - \frac{1}{\mu_k} \mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}(\mathbf{x}_k) = \mathbf{x}_k - \frac{1}{2\mu_k} f'(\mathbf{x}_k)^T$$

Heuristika pro volbu  $\mu_k$  (také nahrazuje line search):

- Pokud  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$ , iteraci přijmeme a  $\mu_k$  zmenšíme (např. 2 krát).
- Pokud  $f(\mathbf{x}_{k+1}) \geq f(\mathbf{x}_k)$ , iteraci odmítneme a  $\mu_k$  zvětšíme (např. 2 krát).

# Přehled probraných metod

úloha	metoda	iterace
$\min_{\mathbf{x}} f(\mathbf{x})$	gradientní	$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f'(\mathbf{x}_k)^T$
$\mathbf{g}(\mathbf{x}) = \mathbf{0}$	Newton	$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1} \mathbf{g}(\mathbf{x}_k)$
$\min_{\mathbf{x}} f(\mathbf{x})$	Newton	$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T$
$\min_{\mathbf{x}} \underbrace{\ \mathbf{g}(\mathbf{x})\ ^2}_{f(\mathbf{x})}$	Gauss-Newton	$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{g}'(\mathbf{x}_k)^+ \mathbf{g}(\mathbf{x}_k)$ $= \mathbf{x}_k - \alpha_k (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} \underbrace{\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}(\mathbf{x}_k)}_{\frac{1}{2} f'(\mathbf{x}_k)^T}$
$\min_{\mathbf{x}} \ \mathbf{g}(\mathbf{x})\ ^2$	Levenberg-Marquardt	$\mathbf{x}_{k+1} = \mathbf{x}_k - (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k) + \mu_k \mathbf{I})^{-1} \mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}(\mathbf{x}_k)$