

Sestupné metody

Vojtěch Franc

Centrum strojového vnímání, ČVUT FEL Praha



Optimalizace ZS 2011

Volný a vázaný extrém, stacionární a kritický bod

Lokální minimum/maximum funkce na množině X se nabývá buď

- ◆ ve vnitřním bodě X , pak se jedná o **volný extrém**
- ◆ v hraničním bodě X , pak se jedná o **vázaný extrém**


Volný a vázaný extrém, stacionární a kritický bod

Lokální minimum/maximum funkce na množině X se nabývá buď


- ◆ ve vnitřním bodě X , pak se jedná o **volný extrém**
- ◆ v hraničním bodě X , pak se jedná o **vázaný extrém**

Bod \mathbf{x} z definičního oboru funkce f nazveme

- ◆ **stacionární**, pokud v něm je funkce f diferencovatelná a má všechny parciální derivace nulové, tj. $f'(\mathbf{x}) = \mathbf{0}^T$.
- ◆ **kritický**, pokud je buď stacionární nebo v něm funkce není diferencovatelná.



Podmínky na volné lokální extrémy



Věta: Necht' x je vnitřní bod množiny $X \subseteq \mathbb{R}^n$. Necht' x je lokální extrém funkce $f: X \rightarrow \mathbb{R}$ na množině X . Pak x je kritický bod funkce f .

Podmínky na volné lokální extrémy

Věta: Necht' x je vnitřní bod množiny $X \subseteq \mathbb{R}^n$. Necht' x je lokální extrém funkce $f: X \rightarrow \mathbb{R}$ na množině X . Pak x je kritický bod funkce f .

Poznámka: Věta říká, že kritické body jsou podezřelé z volného lokálního extrému. Kritický bod nemusí být nutně lokální extrém (např. $f(x) = x^3$).

Podmínky na volné lokální extrémy

Věta: Nechť x je vnitřní bod množiny $X \subseteq \mathbb{R}^n$. Nechť x je lokální extrém funkce $f: X \rightarrow \mathbb{R}$ na množině X . Pak x je kritický bod funkce f .

Poznámka: Věta říká, že kritické body jsou podezřelé z volného lokálního extrému. Kritický bod nemusí být nutně lokální extrém (např. $f(x) = x^3$).

Věta: Nechť x je vnitřní bod množiny $X \subseteq \mathbb{R}^n$. Nechť je funkce $f: X \rightarrow \mathbb{R}$ v bodě x dvakrát diferencovatelná a nechť x je stacionární bod.

- ◆ f má v bodě x ostré lokální minimum (maximum) na X právě tehdy, když Hessova matice druhých derivací $f''(\mathbf{x})$ je pozitivně (negativně) definitní.
- ◆ Je-li $f''(\mathbf{x})$ indefinitní, nemá f v x lokální minimum ani lokální maximum X (x se nazývá **sedlový bod**).

Podmínky na volné lokální extrémy

Věta: Nechť x je vnitřní bod množiny $X \subseteq \mathbb{R}^n$. Nechť x je lokální extrém funkce $f: X \rightarrow \mathbb{R}$ na množině X . Pak x je kritický bod funkce f .

Poznámka: Věta říká, že kritické body jsou podezřelé z volného lokálního extrému. Kritický bod nemusí být nutně lokální extrém (např. $f(x) = x^3$).

Věta: Nechť x je vnitřní bod množiny $X \subseteq \mathbb{R}^n$. Nechť je funkce $f: X \rightarrow \mathbb{R}$ v bodě x dvakrát diferencovatelná a nechť x je stacionární bod.

- ◆ f má v bodě x ostré lokální minimum (maximum) na X právě tehdy, když Hessova matice druhých derivací $f''(\mathbf{x})$ je pozitivně (negativně) definitní.
- ◆ Je-li $f''(\mathbf{x})$ indefinitní, nemá f v x lokální minimum ani lokální maximum X (x se nazývá **sedlový bod**).

Poznámka: Věta nic neříká o případě, kdy je $f''(\mathbf{x})$ pozitivně nebo negativně semidefinitní. V tomto případě x může nebo nemusí být lokální extrém (např. $f(x) = x^3$ a $f(x) = x^4$).

Sestupné metody

- ◆ Iterační algoritmy na hledání lokálního minima funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ začínají z odhadu řešení $\mathbf{x}_1 \in \mathbb{R}^n$, které postupně vylepšují aplikací pravidla

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

vektor $\mathbf{s}_k \in \mathbb{R}^n$ je **směr hledání** a skalár $\alpha_k > 0$ je **délka kroku**.

Sestupné metody

- ◆ Iterační algoritmy na hledání lokálního minima funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ začínají z odhadu řešení $\mathbf{x}_1 \in \mathbb{R}^n$, které postupně vylepšují aplikací pravidla

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

vektor $\mathbf{s}_k \in \mathbb{R}^n$ je **směr hledání** a skalár $\alpha_k > 0$ je **délka kroku**.

- ◆ Směr \mathbf{s}_k se nazývá **sestupný**, jestliže


$$f'(\mathbf{x}_k) \mathbf{s}_k < 0$$

směrová derivace ve směru \mathbf{s}_k je záporná.

- ◆ Délku kroku α_k můžeme nalézt minimalizací jednorozměrné funkce

$$\min_{\alpha \geq 0} f(\mathbf{x}_k + \alpha \mathbf{s}_k)$$

Tuto úlohu stačí často řešit přibližně.



Gredientní metoda

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

Gredientní metoda

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Směr hledání se zvolí jako záporný gradient funkce f v bodě \mathbf{x}_k :

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

takže iterační pravidlo má tvar

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

Gredientní metoda

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Směr hledání se zvolí jako záporný gradient funkce f v bodě \mathbf{x}_k :

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

takže iterační pravidlo má tvar

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

- ◆ Směr hledání je sestupný

$$f'(\mathbf{x})\mathbf{s}_k = -f'(\mathbf{x})f'(\mathbf{x})^T = -\|f'(\mathbf{x})\|^2 < 0$$

Gredientní metoda

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Směr hledání se zvolí jako záporný gradient funkce f v bodě \mathbf{x}_k :

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

takže iterační pravidlo má tvar

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

- ◆ Směr hledání je sestupný

$$f'(\mathbf{x})\mathbf{s}_k = -f'(\mathbf{x})f'(\mathbf{x})^T = -\|f'(\mathbf{x})\|^2 < 0$$

- ◆ Gradientní metoda je jednoduchá, ale často konverguje pomalu blízko optima.

Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$

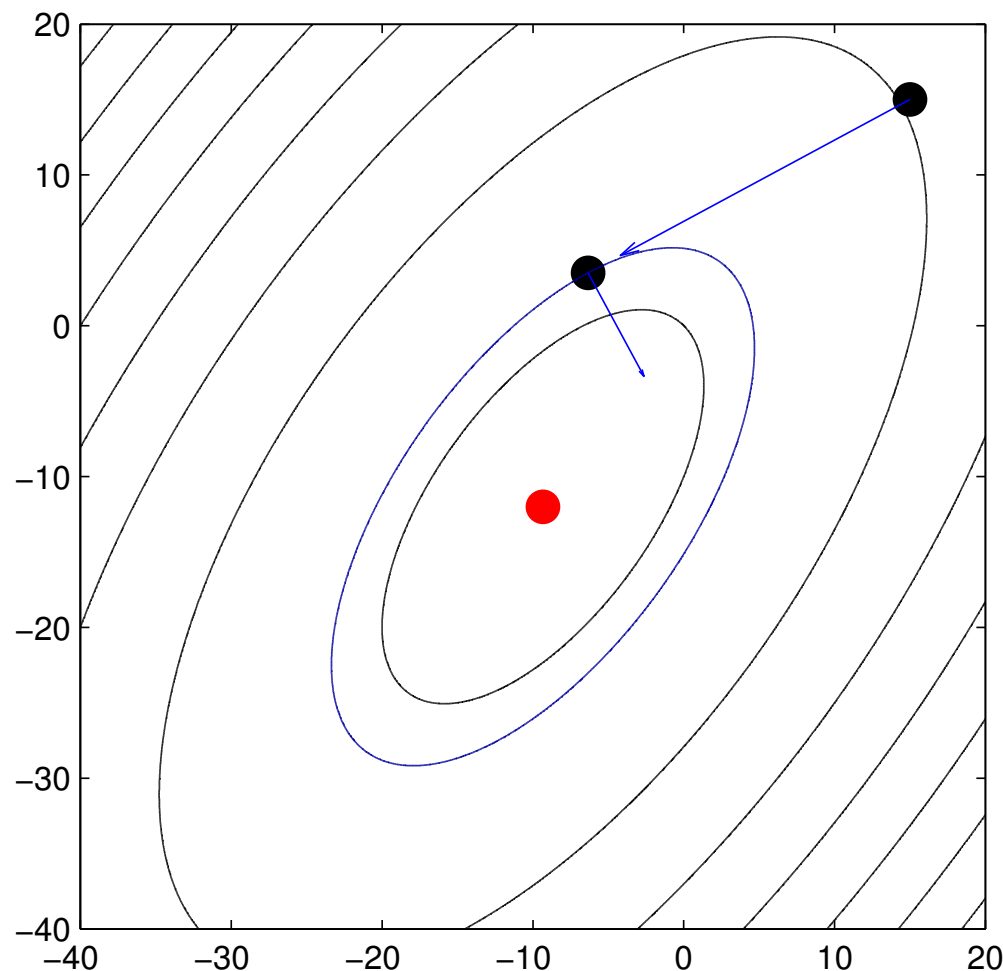
repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Gredientní metoda

Příklad: Minimalizace kvadratické funkce $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{H}\mathbf{x} + \mathbf{h}^T \mathbf{x}$

kde $\mathbf{H} = \begin{bmatrix} 0.3 & -0.15 \\ -0.14 & 0.2 \end{bmatrix}$ a $\mathbf{h} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Initial solution $\mathbf{x}_1 \in \mathbb{R}^n$


repeat

$$f'(\mathbf{x}_k) = \mathbf{H}\mathbf{x}_k + \mathbf{h}$$

$$\alpha_k = \min_{\alpha \geq 0} f(\mathbf{x}_k - \alpha f'(\mathbf{x}_k))$$

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

until



Lineární transformace souřadnic

- ◆ Transformujme souřadnice x lineární transformací $\tilde{x} = Ax$ kde A je regulární.

Lineární transformace souřadnic

- ◆ Transformujme souřadnice \mathbf{x} lineární transformací $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ kde \mathbf{A} je regulární.
- ◆ Minimalizační úloha v nové soustavě bude mít stejné optimum

$$\min_{\mathbf{x}} f(\mathbf{x}) = \min_{\tilde{\mathbf{x}}} \tilde{f}(\tilde{\mathbf{x}}) \quad \text{kde} \quad f(\mathbf{x}) = f(\mathbf{A}^{-1}\tilde{\mathbf{x}}) = \tilde{f}(\tilde{\mathbf{x}})$$

Lineární transformace souřadnic

- ◆ Transformujme souřadnice \mathbf{x} lineární transformací $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ kde \mathbf{A} je regulární.
- ◆ Minimalizační úloha v nové soustavě bude mít stejné optimum

$$\min_{\mathbf{x}} f(\mathbf{x}) = \min_{\tilde{\mathbf{x}}} \tilde{f}(\tilde{\mathbf{x}}) \quad \text{kde} \quad f(\mathbf{x}) = f(\mathbf{A}^{-1}\tilde{\mathbf{x}}) = \tilde{f}(\tilde{\mathbf{x}})$$

- ◆ Gradientní metoda v nové soustavě má tvar

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

Lineární transformace souřadnic

- ◆ Transformujme souřadnice \mathbf{x} lineární transformací $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ kde \mathbf{A} je regulární.
- ◆ Minimalizační úloha v nové soustavě bude mít stejné optimum

$$\min_{\mathbf{x}} f(\mathbf{x}) = \min_{\tilde{\mathbf{x}}} \tilde{f}(\tilde{\mathbf{x}}) \quad \text{kde} \quad f(\mathbf{x}) = f(\mathbf{A}^{-1}\tilde{\mathbf{x}}) = \tilde{f}(\tilde{\mathbf{x}})$$

- ◆ Gradientní metoda v nové soustavě má tvar

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

Po dosazení $\tilde{f}'(\tilde{\mathbf{x}}) = f'(\mathbf{x})\mathbf{A}^{-1}$ a $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ dostaneme iteraci v původních souřadnicích

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

Lineární transformace souřadnic

- ◆ Transformujme souřadnice \mathbf{x} lineární transformací $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ kde \mathbf{A} je regulární.
- ◆ Minimalizační úloha v nové soustavě bude mít stejné optimum

$$\min_{\mathbf{x}} f(\mathbf{x}) = \min_{\tilde{\mathbf{x}}} \tilde{f}(\tilde{\mathbf{x}}) \quad \text{kde} \quad f(\mathbf{x}) = f(\mathbf{A}^{-1}\tilde{\mathbf{x}}) = \tilde{f}(\tilde{\mathbf{x}})$$

- ◆ Gradientní metoda v nové soustavě má tvar

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

Po dosazení $\tilde{f}'(\tilde{\mathbf{x}}) = f'(\mathbf{x})\mathbf{A}^{-1}$ a $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ dostaneme iteraci v původních souřadnicích

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

Směr $\mathbf{s}_k = -(\mathbf{A}^T \mathbf{A})^{-1} f'(\mathbf{x}_k)^T$ je sestupný, protože $-f'(\mathbf{x}_k)(\mathbf{A}^T \mathbf{A})^{-1} f'(\mathbf{x}_k)^T < 0$

Lineární transformace souřadnic

- ◆ Transformujme souřadnice \mathbf{x} lineární transformací $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ kde \mathbf{A} je regulární.
- ◆ Minimalizační úloha v nové soustavě bude mít stejné optimum

$$\min_{\mathbf{x}} f(\mathbf{x}) = \min_{\tilde{\mathbf{x}}} \tilde{f}(\tilde{\mathbf{x}}) \quad \text{kde} \quad f(\mathbf{x}) = f(\mathbf{A}^{-1}\tilde{\mathbf{x}}) = \tilde{f}(\tilde{\mathbf{x}})$$

- ◆ Gradientní metoda v nové soustavě má tvar

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

Po dosazení $\tilde{f}'(\tilde{\mathbf{x}}) = f'(\mathbf{x})\mathbf{A}^{-1}$ a $\tilde{\mathbf{x}} = \mathbf{A}\mathbf{x}$ dostaneme iteraci v původních souřadnicích


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

Směr $\mathbf{s}_k = -(\mathbf{A}^T \mathbf{A})^{-1} f'(\mathbf{x}_k)^T$ je sestupný, protože $-f'(\mathbf{x}_k)(\mathbf{A}^T \mathbf{A})^{-1} f'(\mathbf{x}_k)^T < 0$

- ◆ Zobecnění: každá sestupná metoda lze zapsat

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

Newtonova metoda pro řešení soustavy nelineárních rovnic



- ◆ Cíl: pro zadané diferencovatelné zobrazení $g: \mathbb{R}^n \rightarrow \mathbb{R}^n$ chceme vyřešit rovnici

$$g(\mathbf{x}) = \mathbf{0}$$

Tj. řešíme soustavu n rovnic (mohou být nelineární) s n neznámými.

Newtonova metoda pro řešení soustavy nelineárních rovnic

- ◆ Cíl: pro zadané diferencovatelné zobrazení $g: \mathbb{R}^n \rightarrow \mathbb{R}^n$ chceme vyřešit rovnici

$$g(\mathbf{x}) = \mathbf{0}$$

Tj. řešíme soustavu n rovnic (mohou být nelineární) s n neznámými.

- ◆ Aproximujeme zobrazení g v okolí \mathbf{x}_k Taylorovým polynomem prvního řádu

$$g(\mathbf{x}) \approx \tilde{g}(\mathbf{x}) = g(\mathbf{x}_k) + g'(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k)$$

Newtonova metoda pro řešení soustavy nelineárních rovnic

- ◆ Cíl: pro zadané diferencovatelné zobrazení $g: \mathbb{R}^n \rightarrow \mathbb{R}^n$ chceme vyřešit rovnici

$$g(\mathbf{x}) = \mathbf{0}$$

Tj. řešíme soustavu n rovnic (mohou být nelineární) s n neznámými.

- ◆ Aproximujeme zobrazení g v okolí \mathbf{x}_k Taylorovým polynomem prvního řádu

$$g(\mathbf{x}) \approx \tilde{g}(\mathbf{x}) = g(\mathbf{x}_k) + g'(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k)$$

- ◆ Začneme z odhadu \mathbf{x}_1 a další iteraci najdeme řešením lineární soustavy

$$\tilde{g}(\mathbf{x}_{k+1}) = \mathbf{0}$$

Newtonova metoda pro řešení soustavy nelineárních rovnic

- ◆ Cíl: pro zadané diferencovatelné zobrazení $g: \mathbb{R}^n \rightarrow \mathbb{R}^n$ chceme vyřešit rovnici

$$g(\mathbf{x}) = \mathbf{0}$$

Tj. řešíme soustavu n rovnic (mohou být nelineární) s n neznámými.

- ◆ Aproximujeme zobrazení g v okolí \mathbf{x}_k Taylorovým polynomem prvního řádu

$$g(\mathbf{x}) \approx \tilde{g}(\mathbf{x}) = g(\mathbf{x}_k) + g'(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k)$$


- ◆ Začneme z odhadu \mathbf{x}_1 a další iteraci najdeme řešením lineární soustavy

$$\tilde{g}(\mathbf{x}_{k+1}) = \mathbf{0}$$

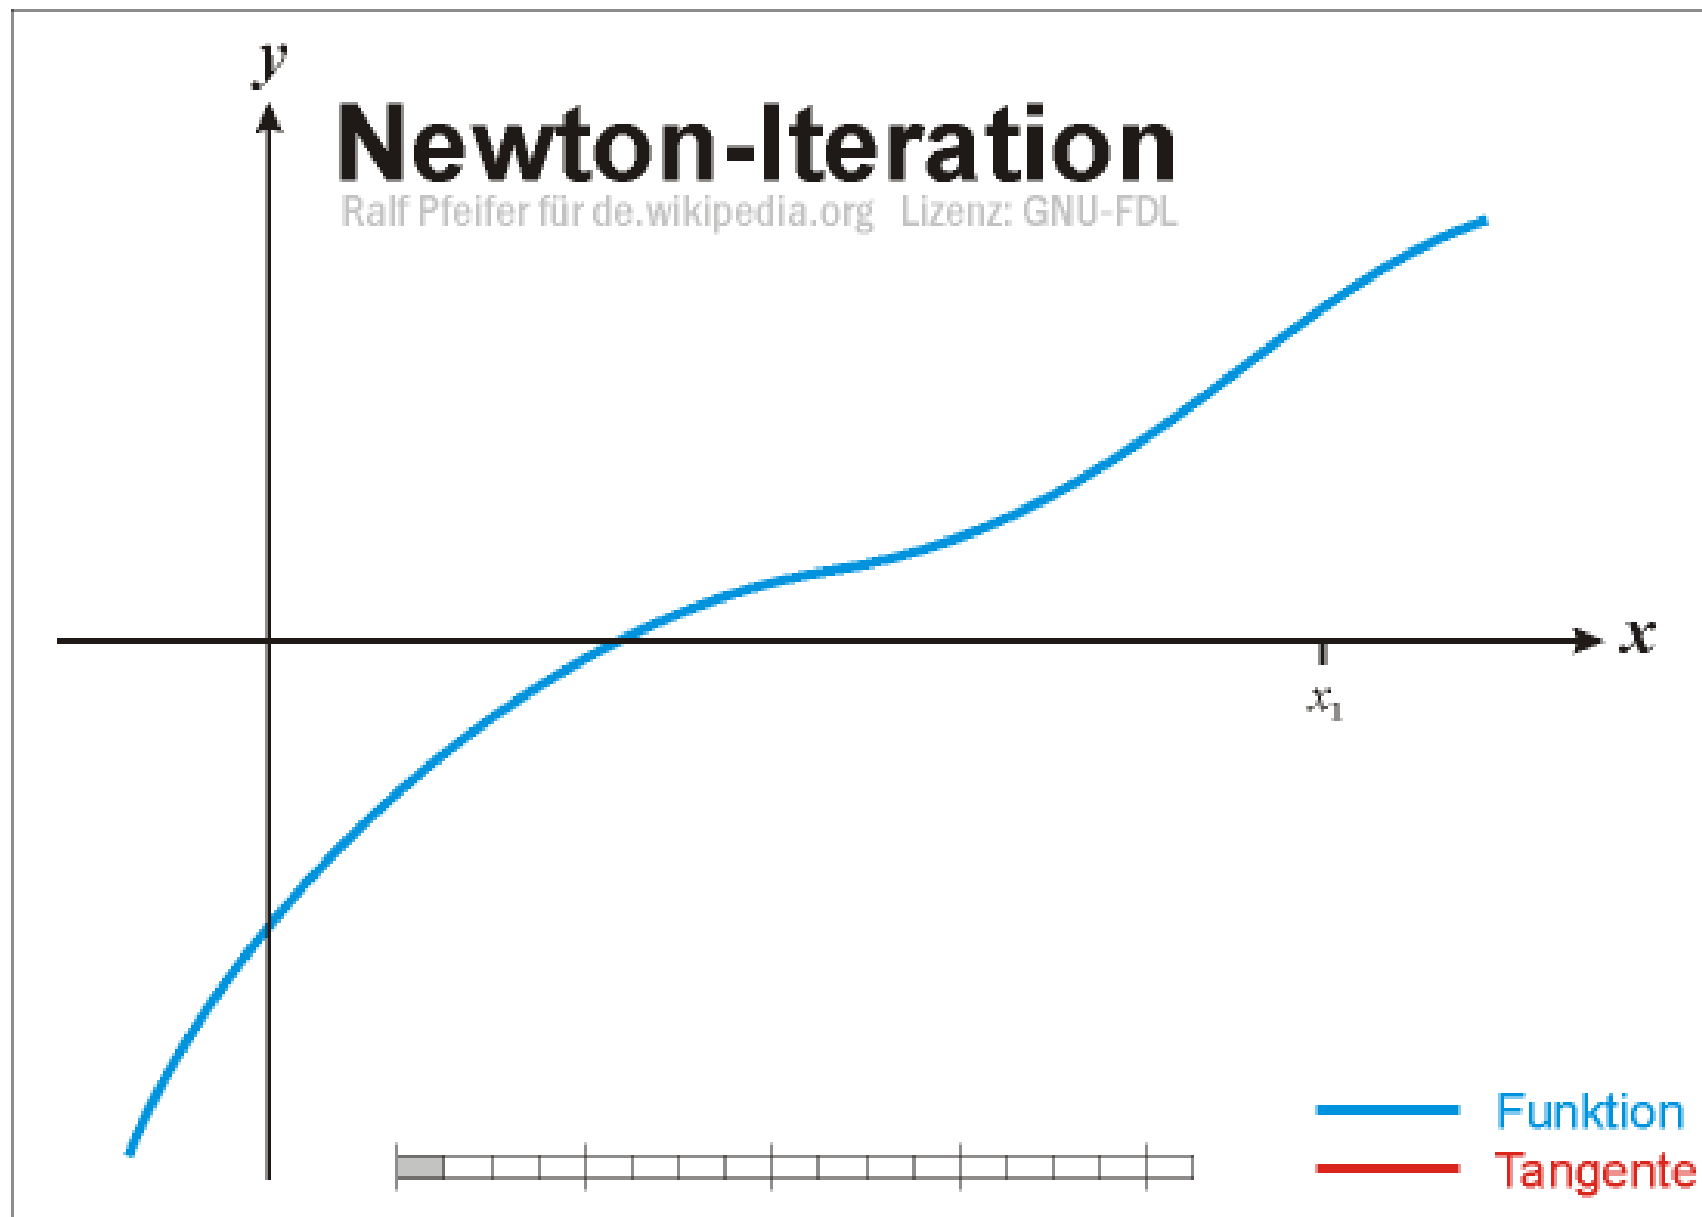
- ◆ Pokud je Jacobiho matice $g'(\mathbf{x}_k) \in \mathbb{R}^{n \times n}$ regulární iterujeme

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


Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$




Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$

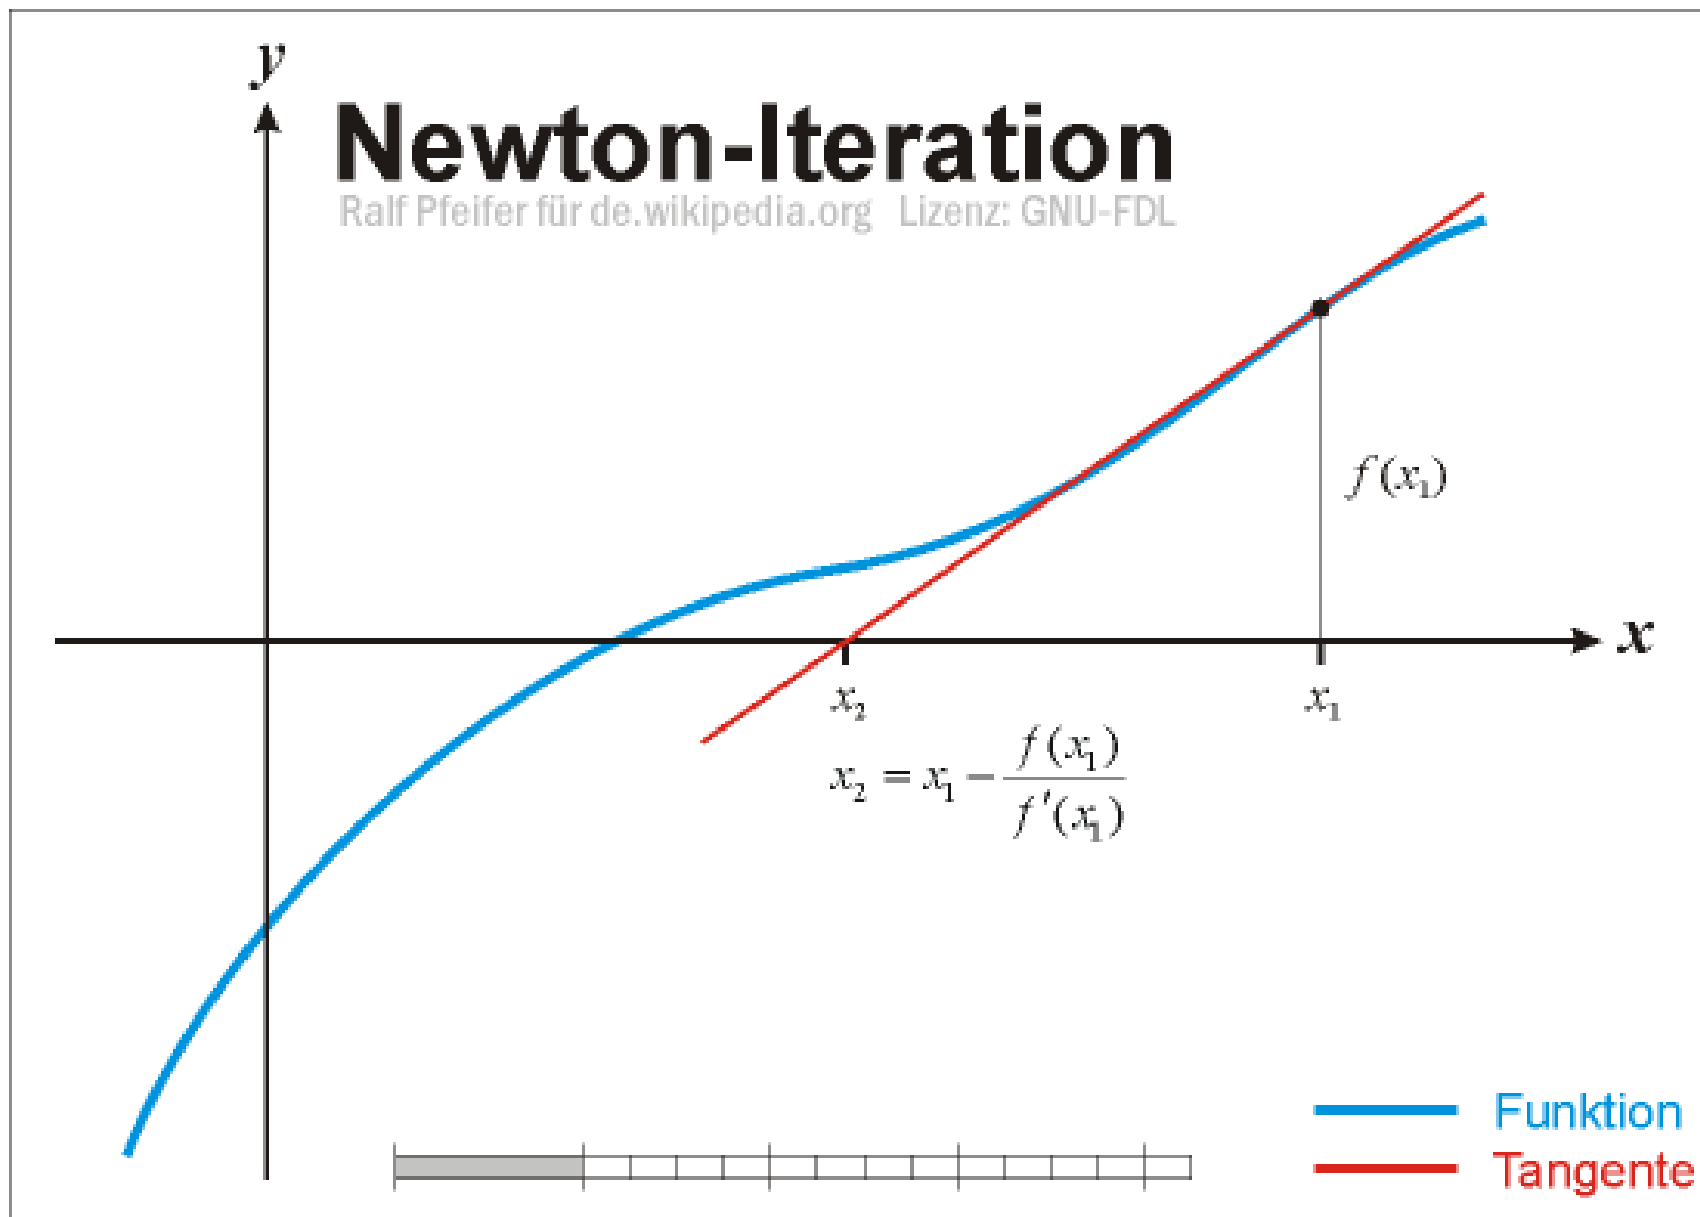


Newtonova metoda pro řešení soustavy nelineárních rovnic


Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



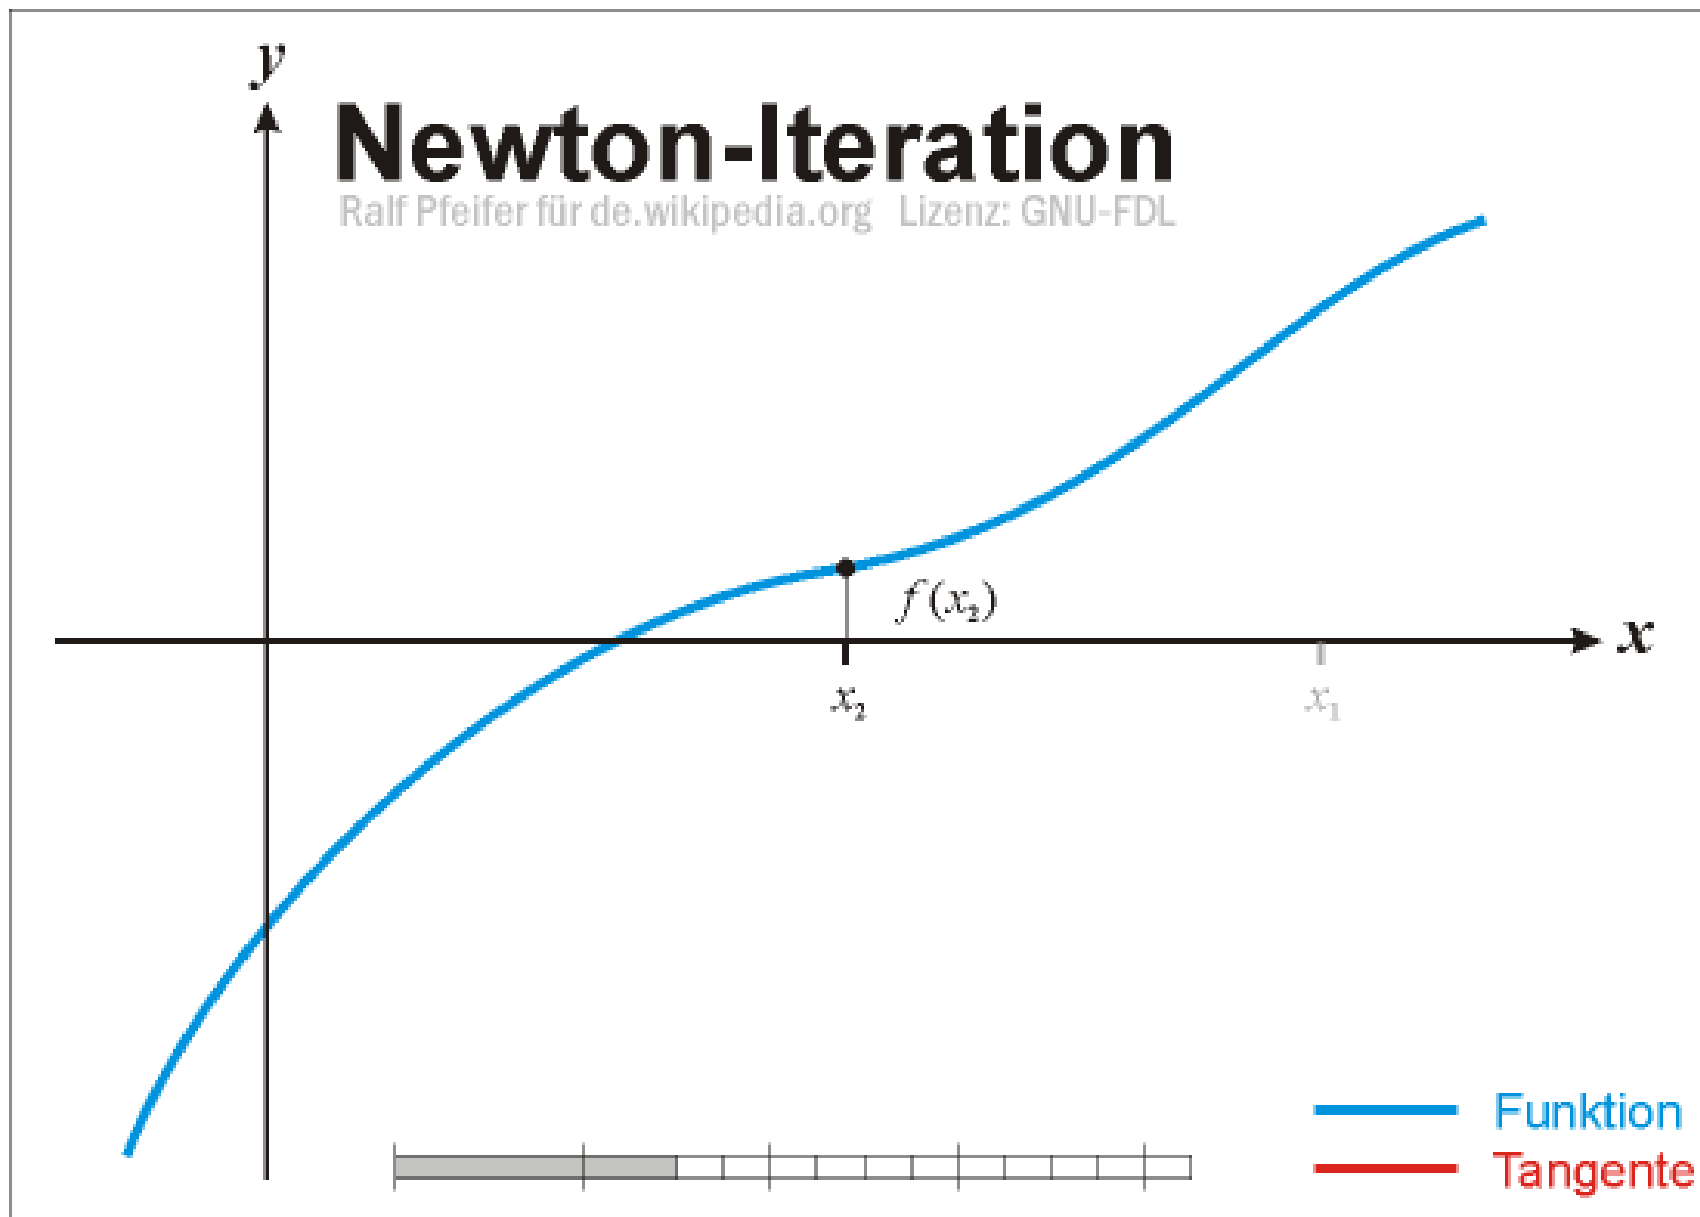
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



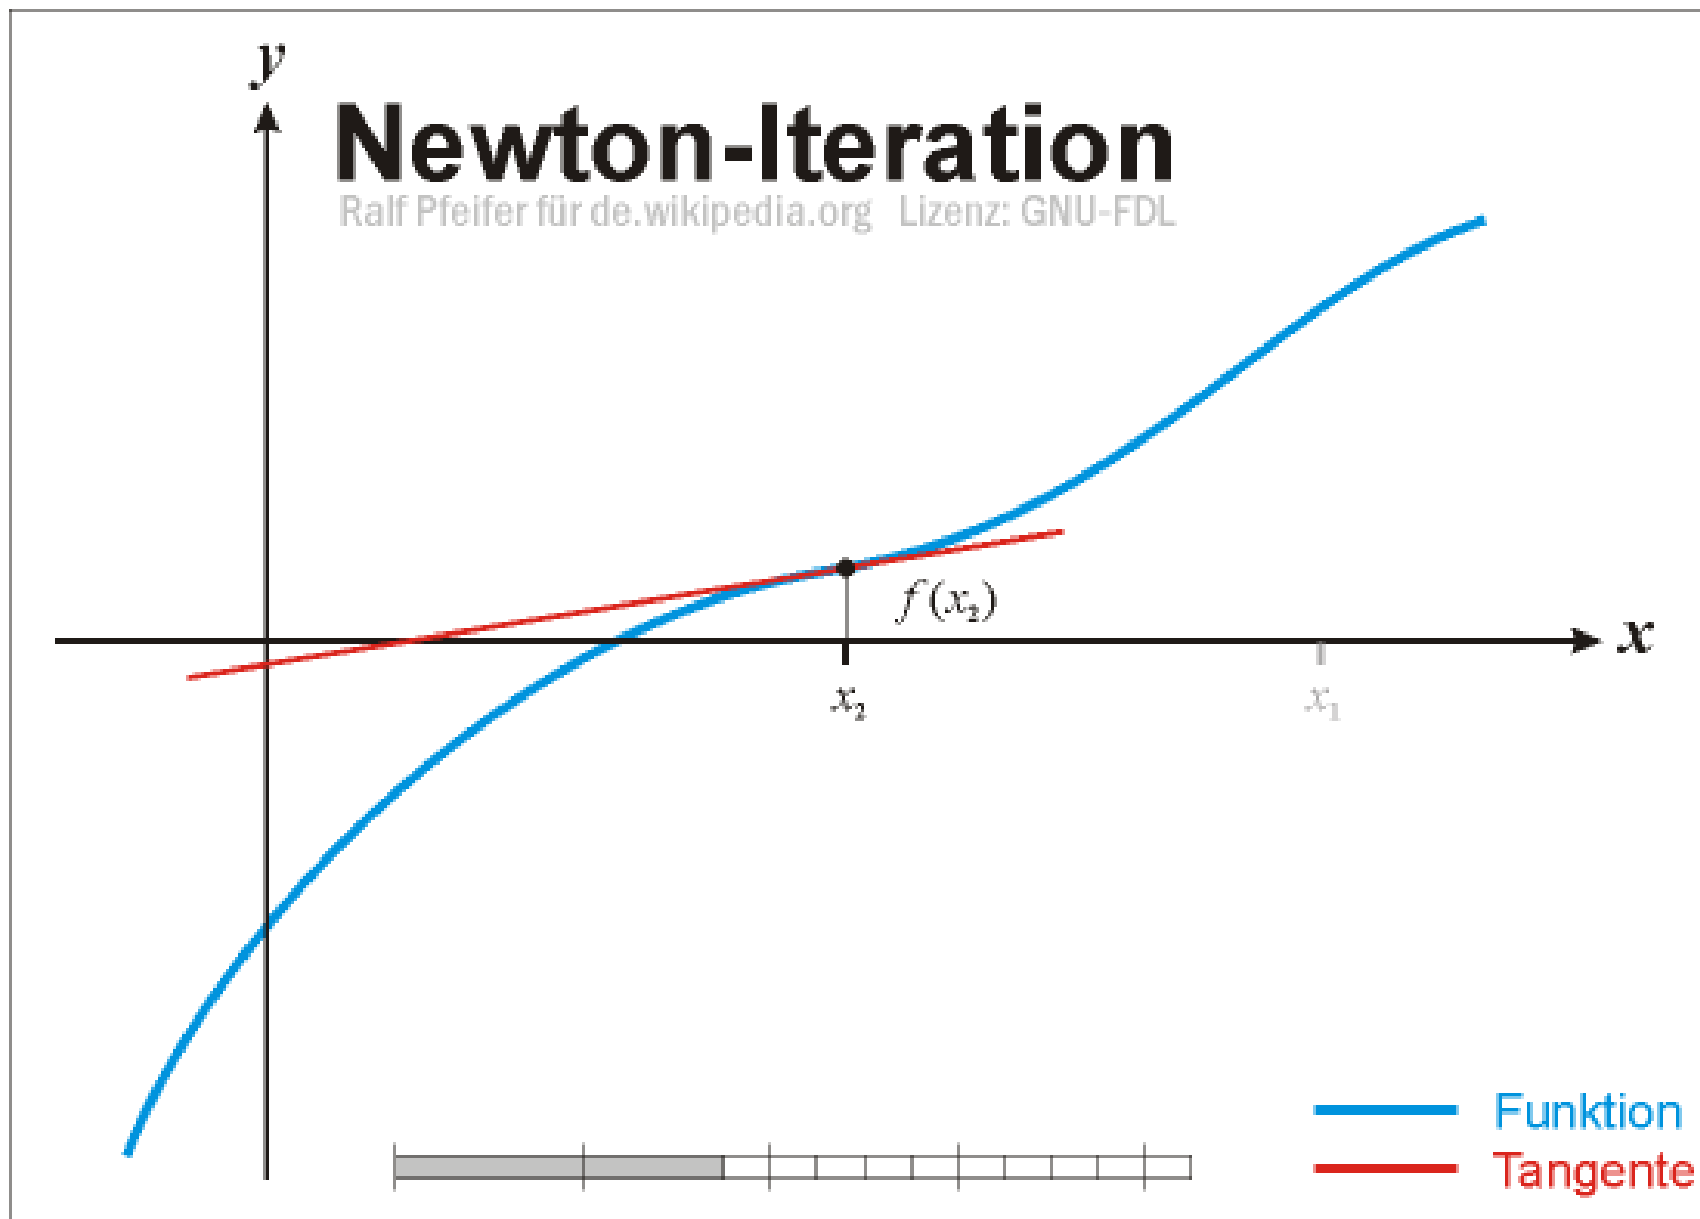
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



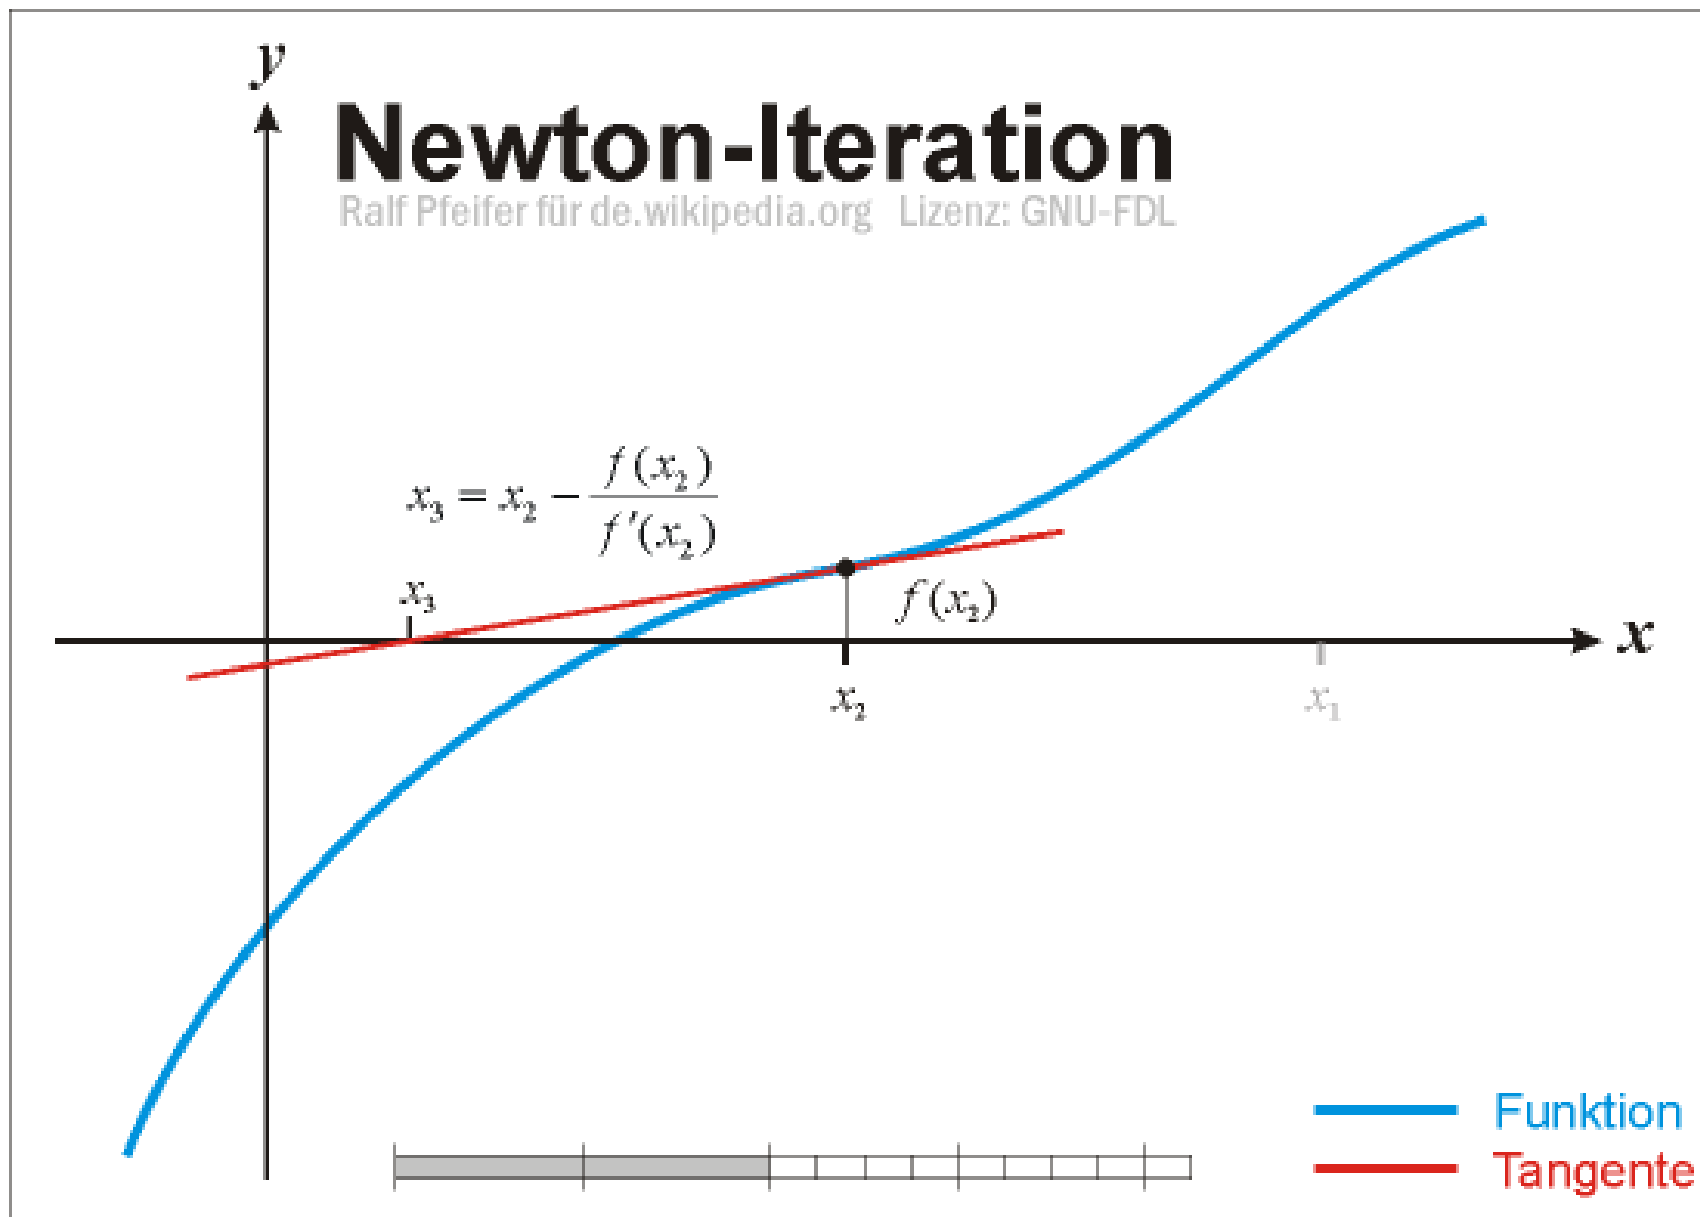
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$




Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



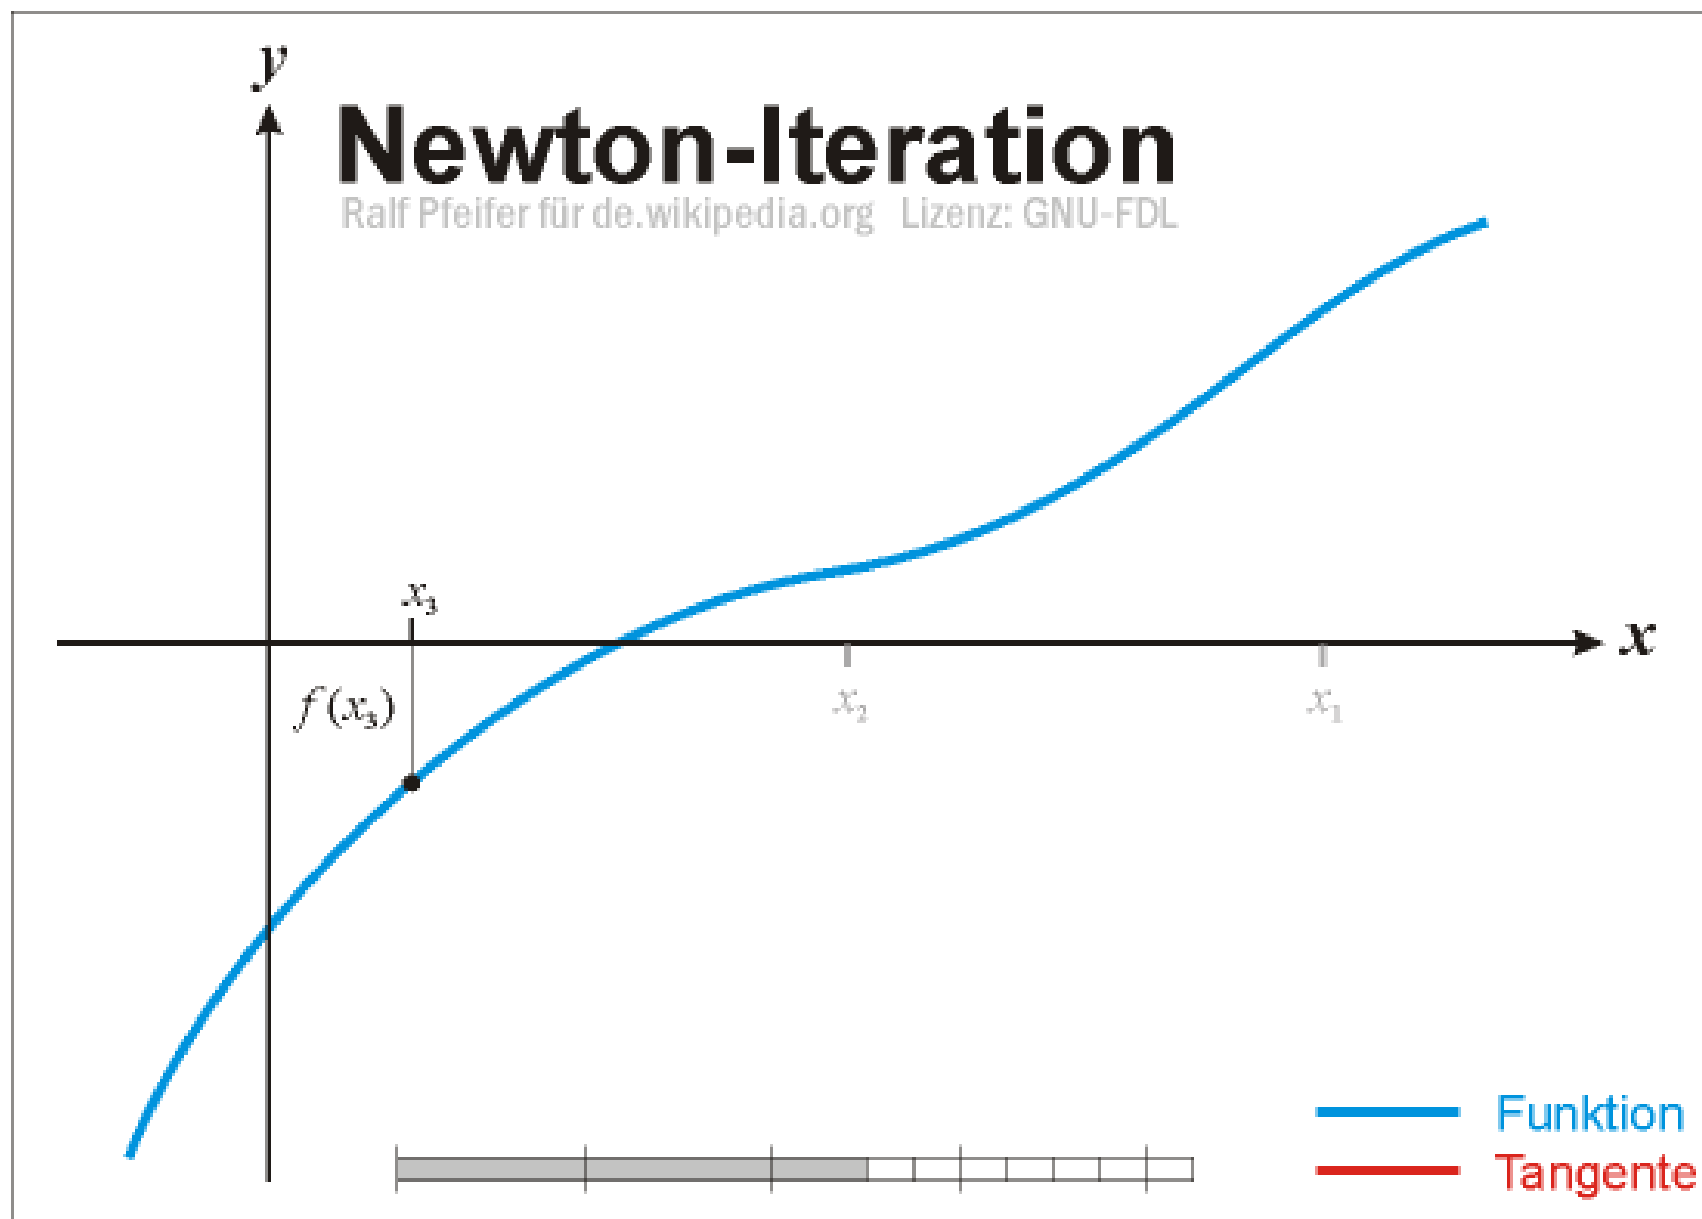
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



Newtonova metoda pro řešení soustavy nelineárních rovnic



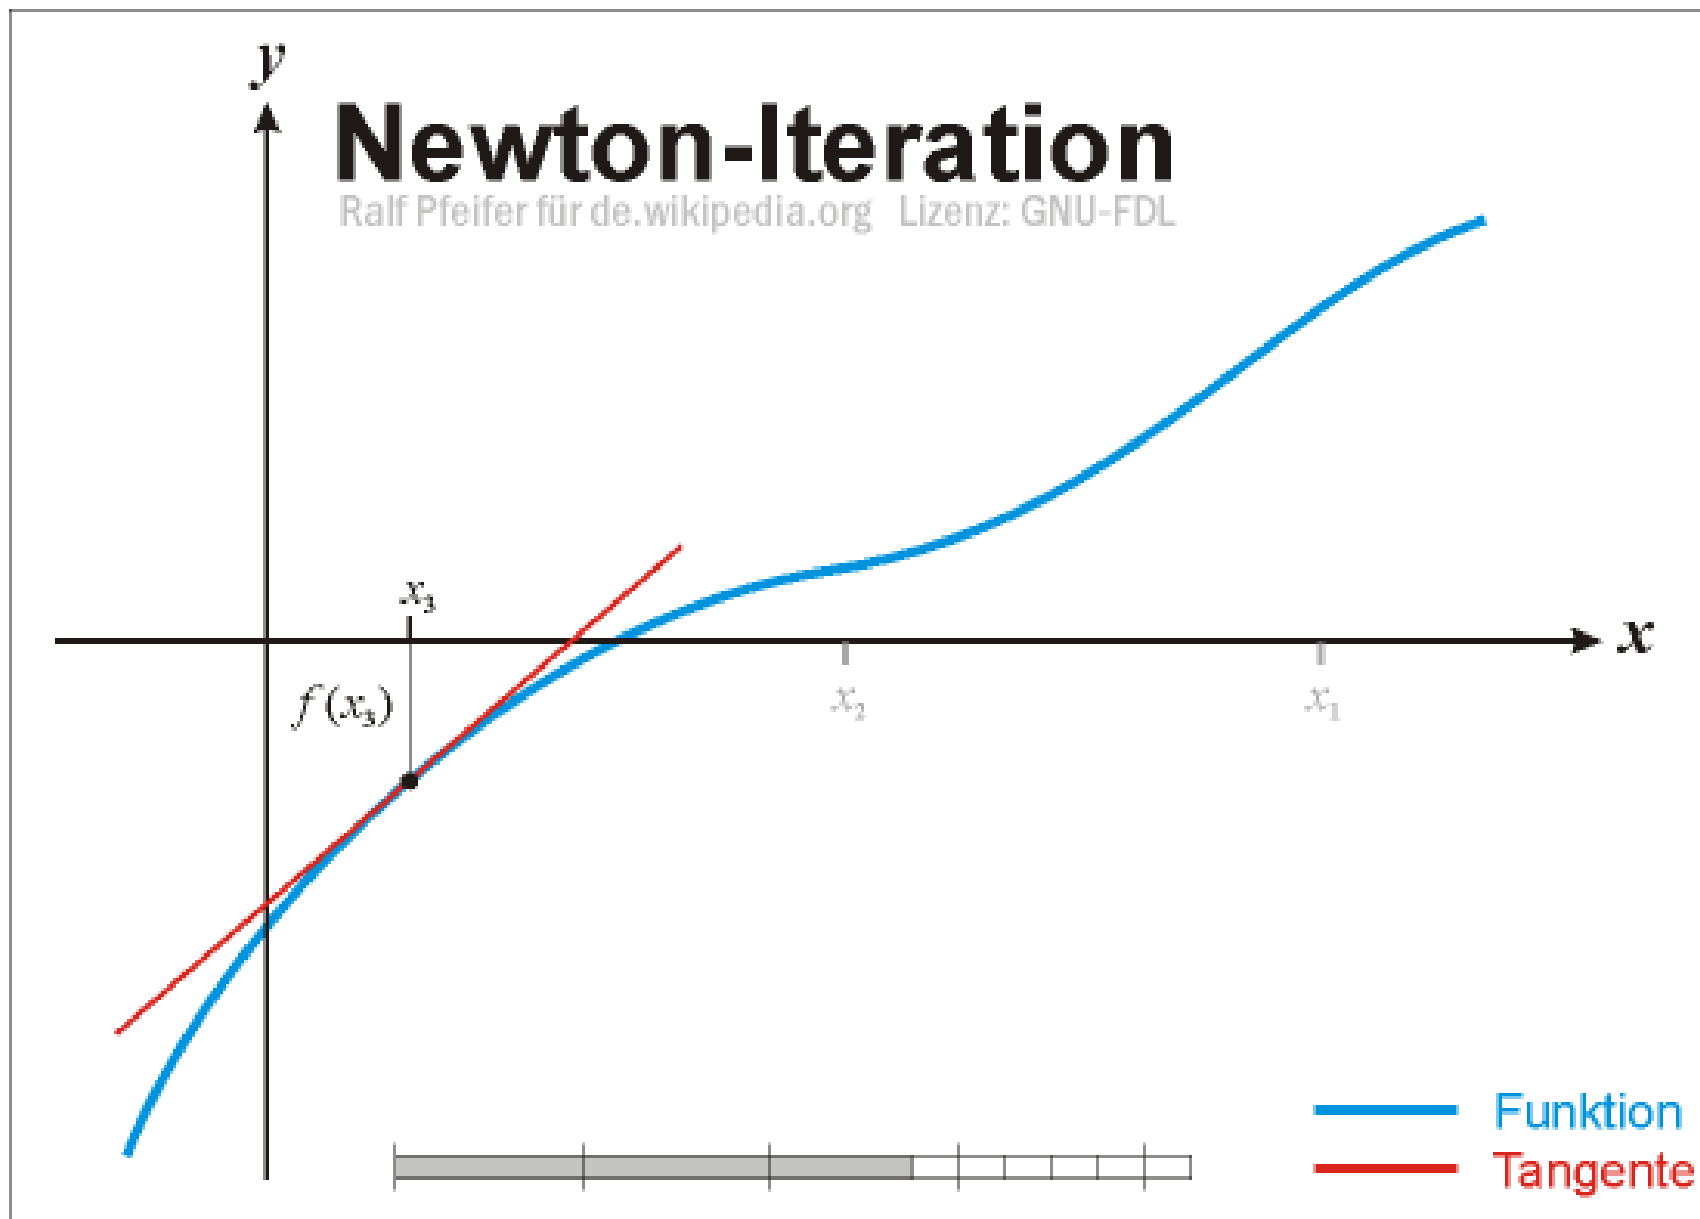
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



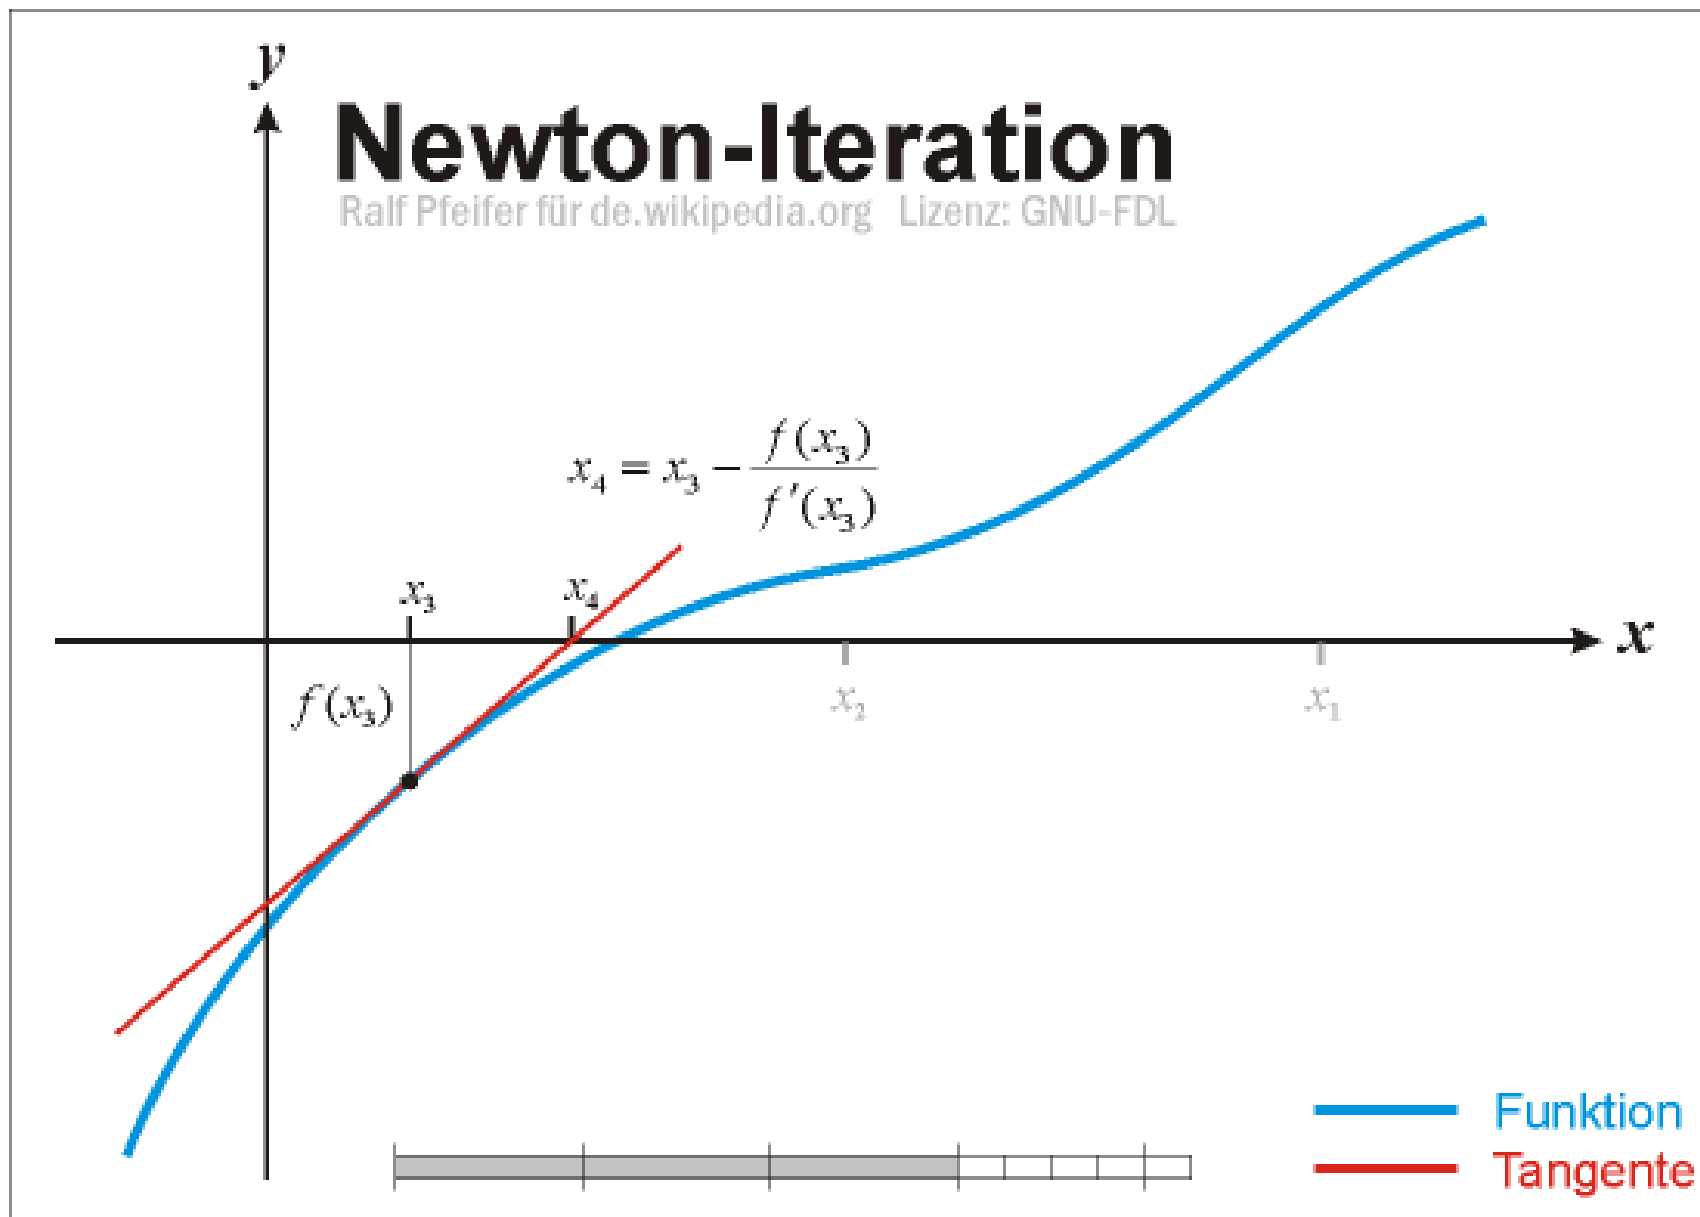
Newtonova metoda pro řešení soustavy nelineárních rovnic



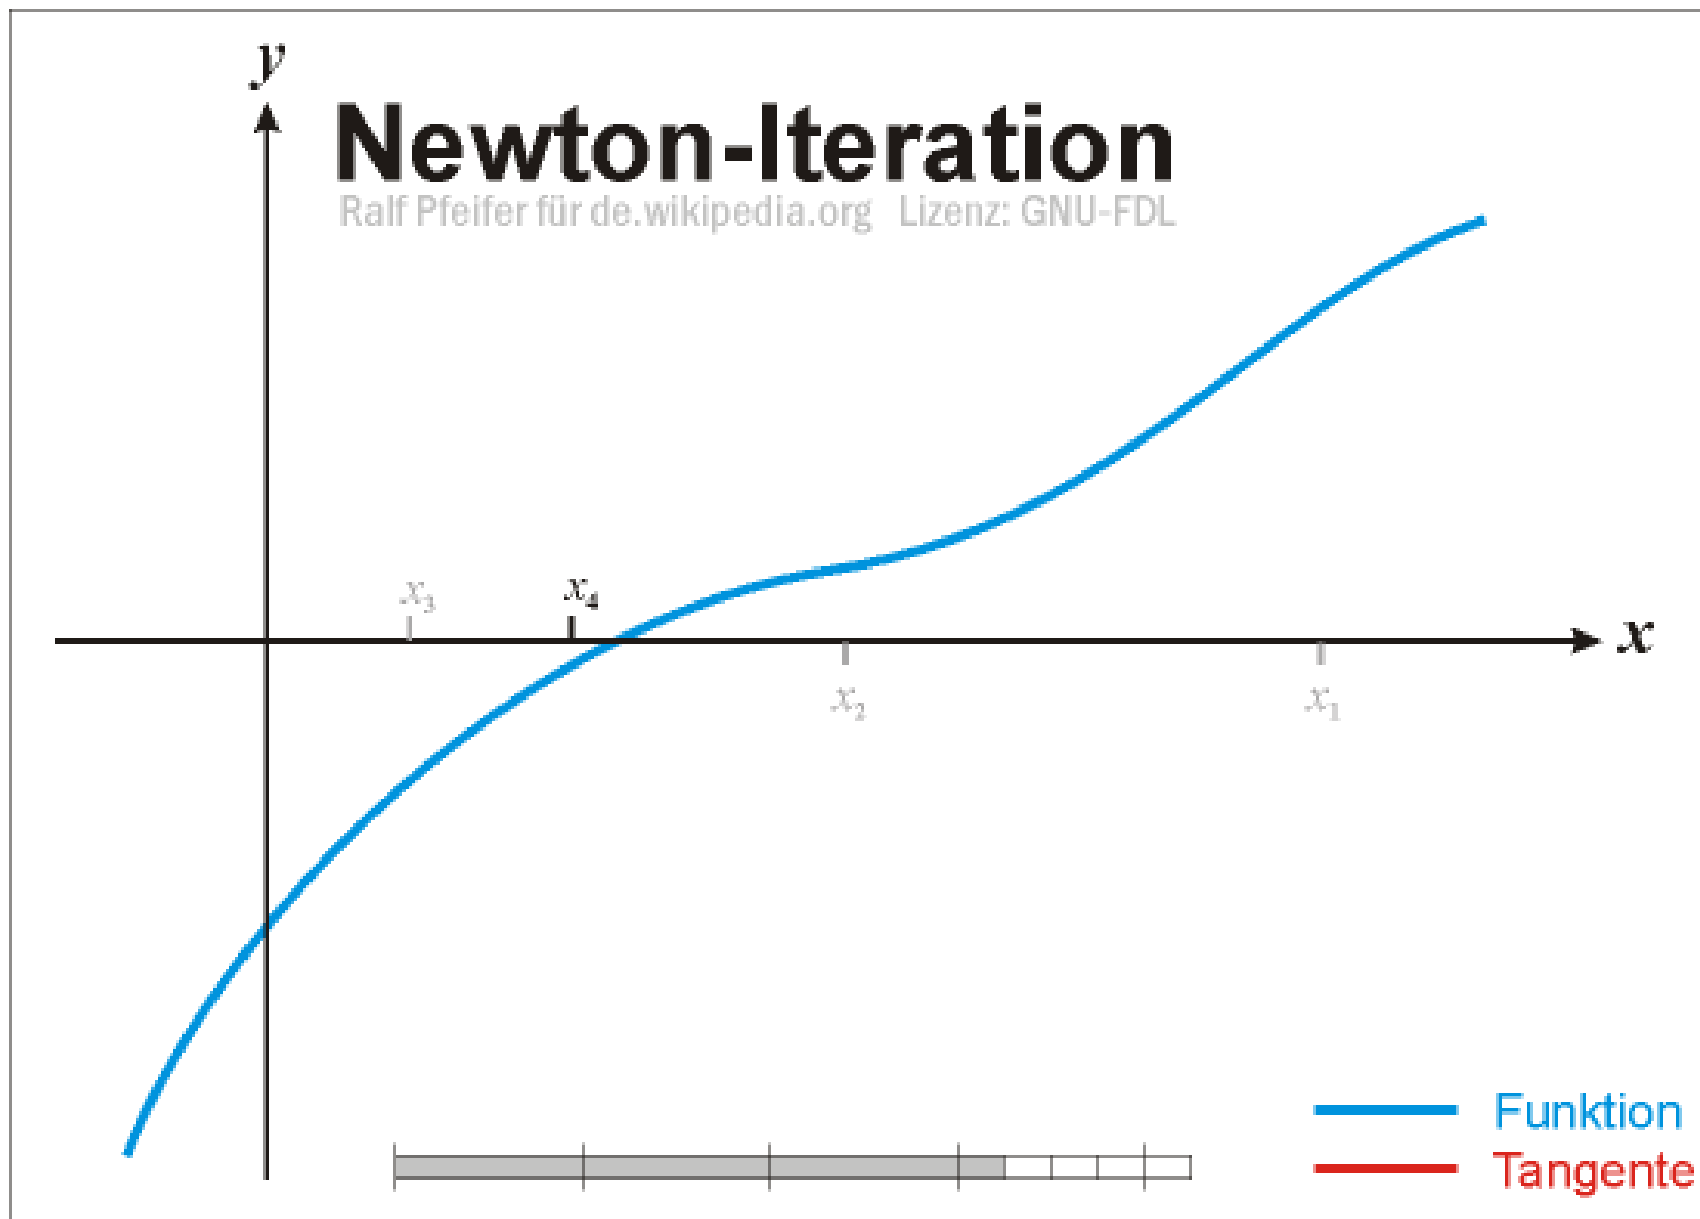
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



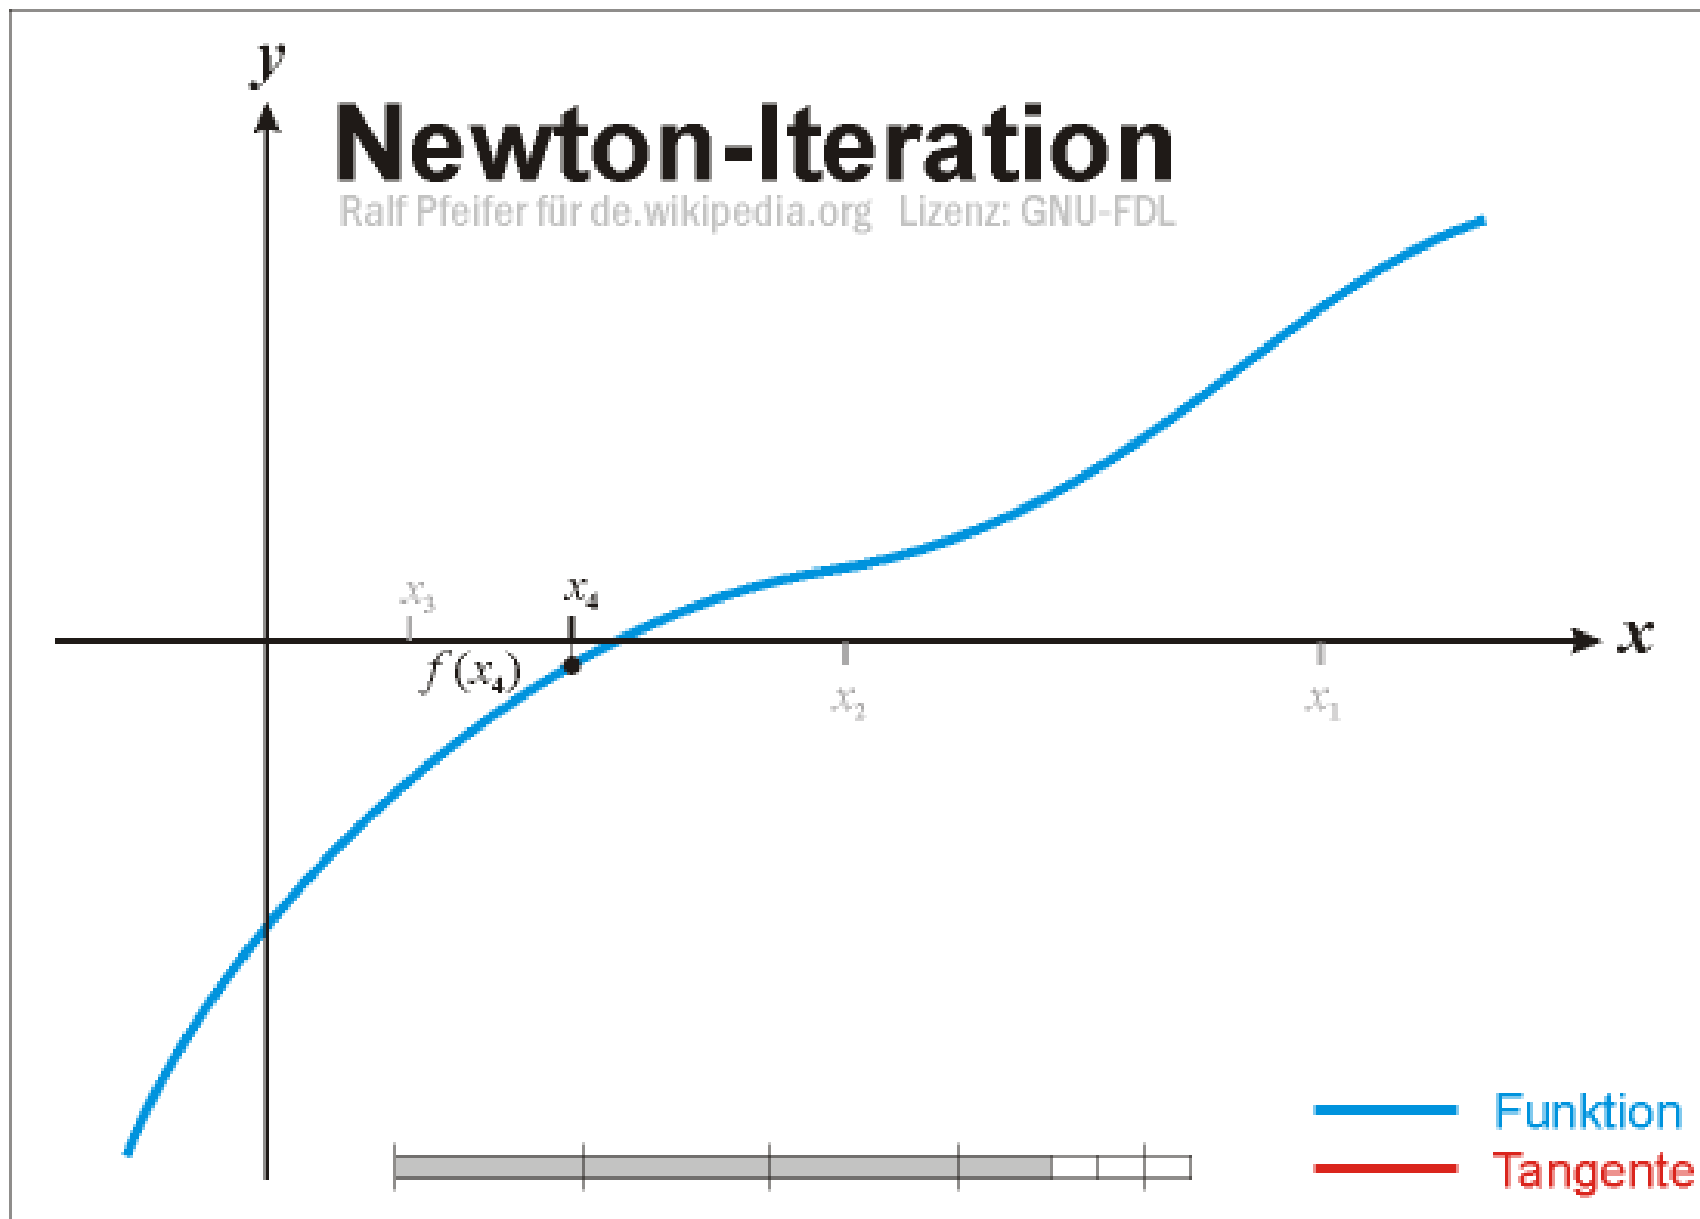
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



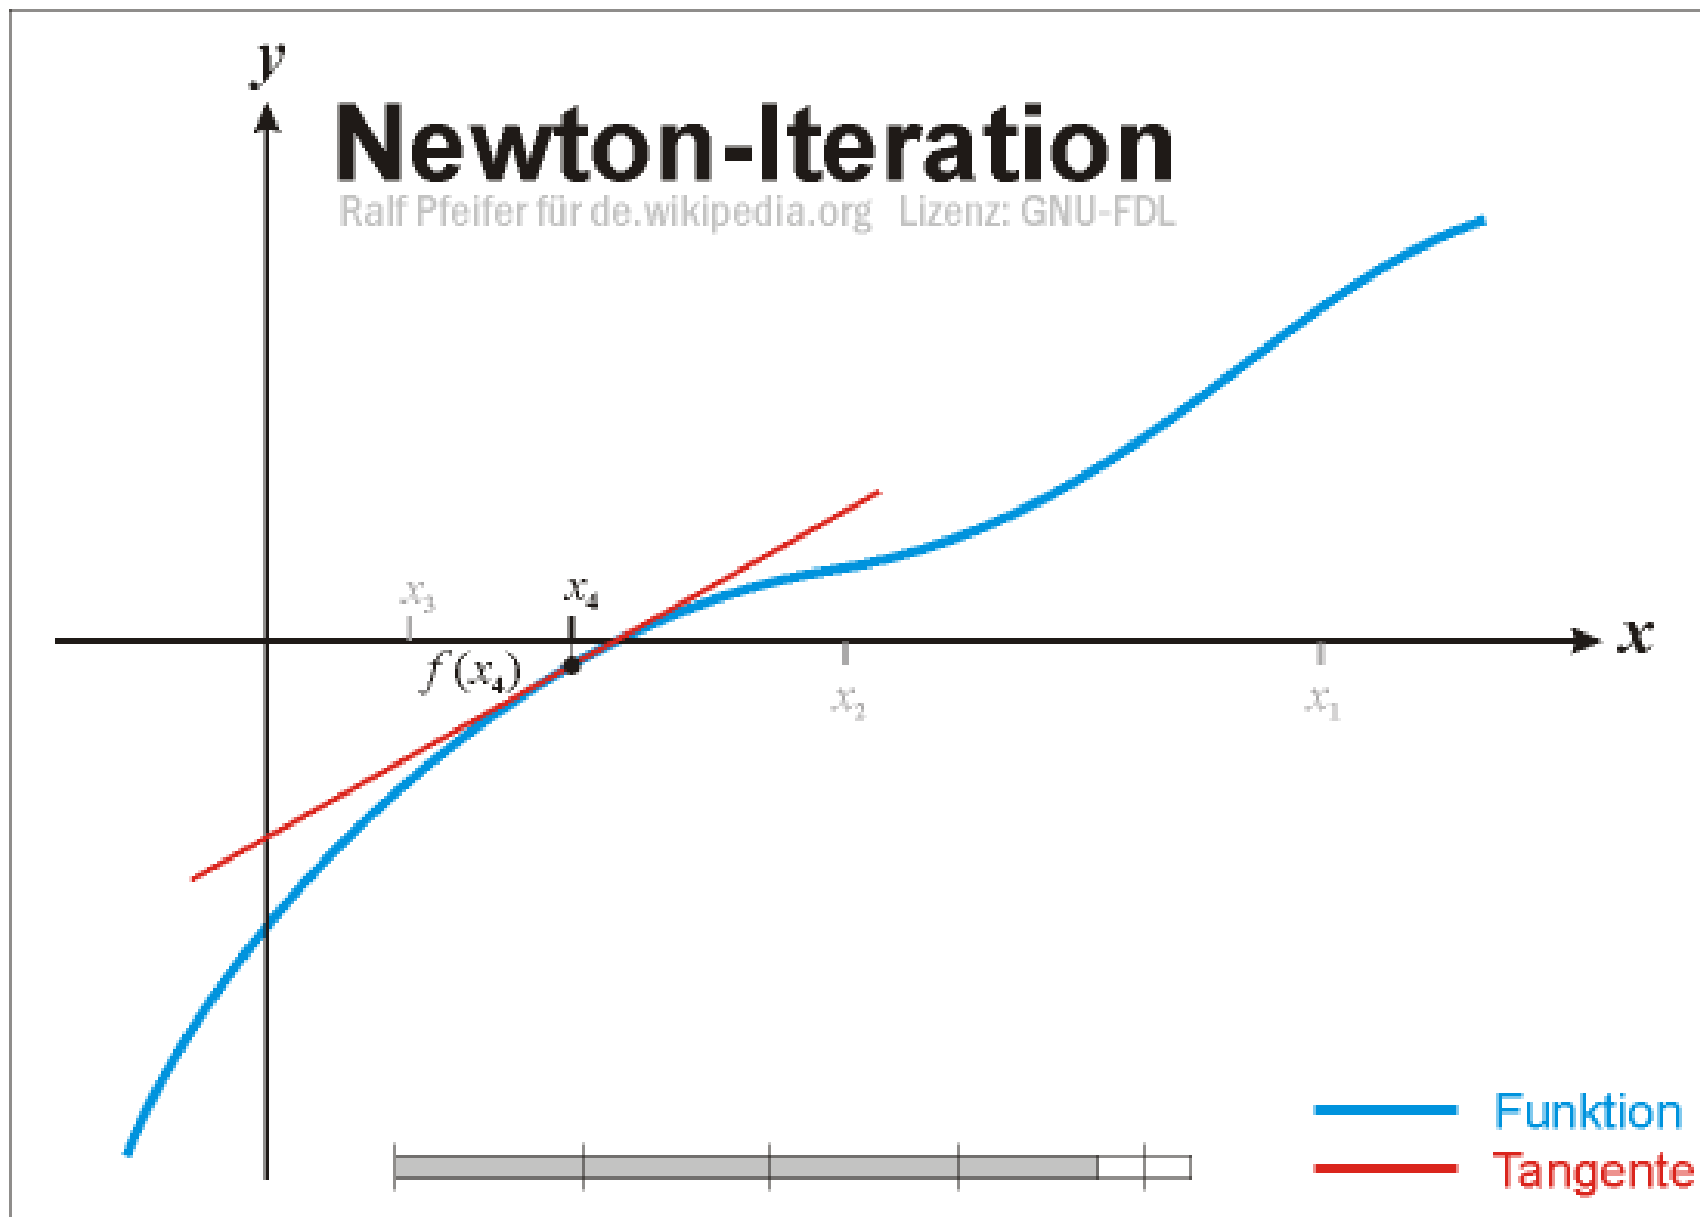
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



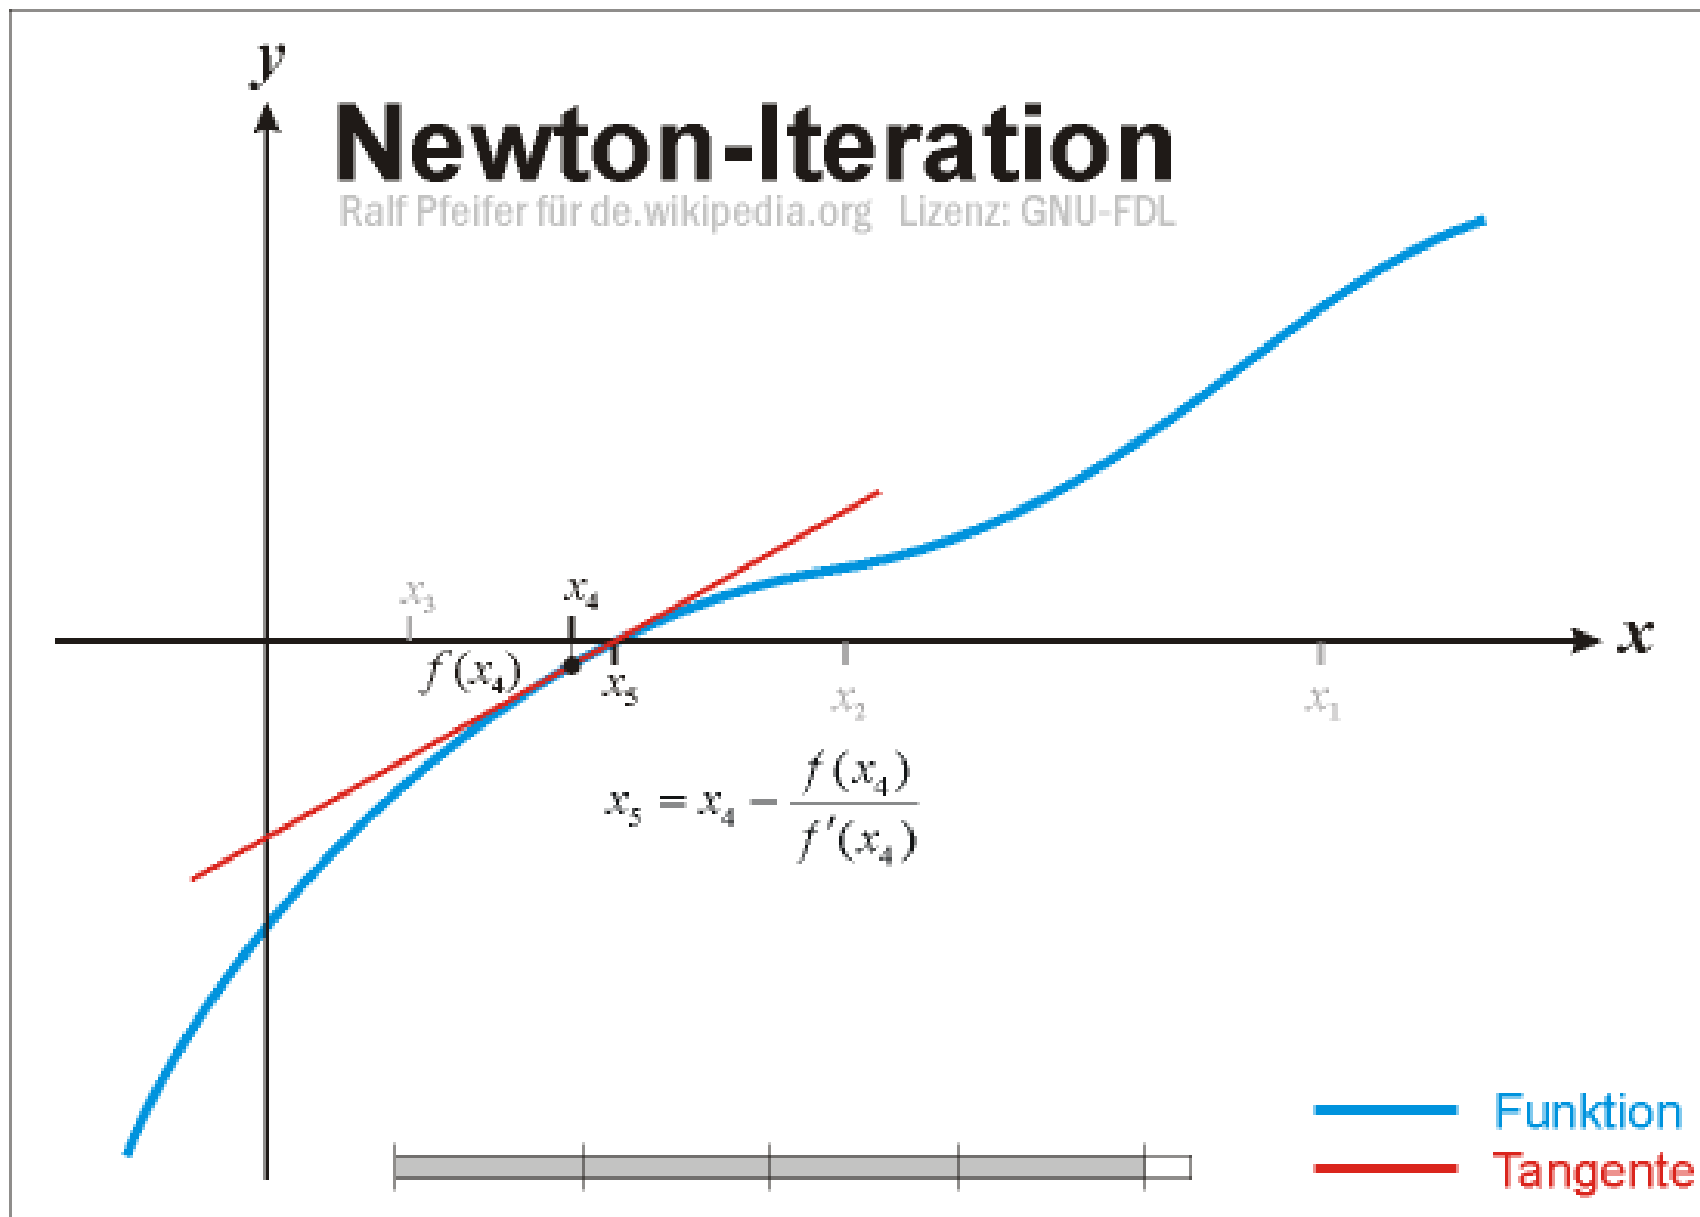
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



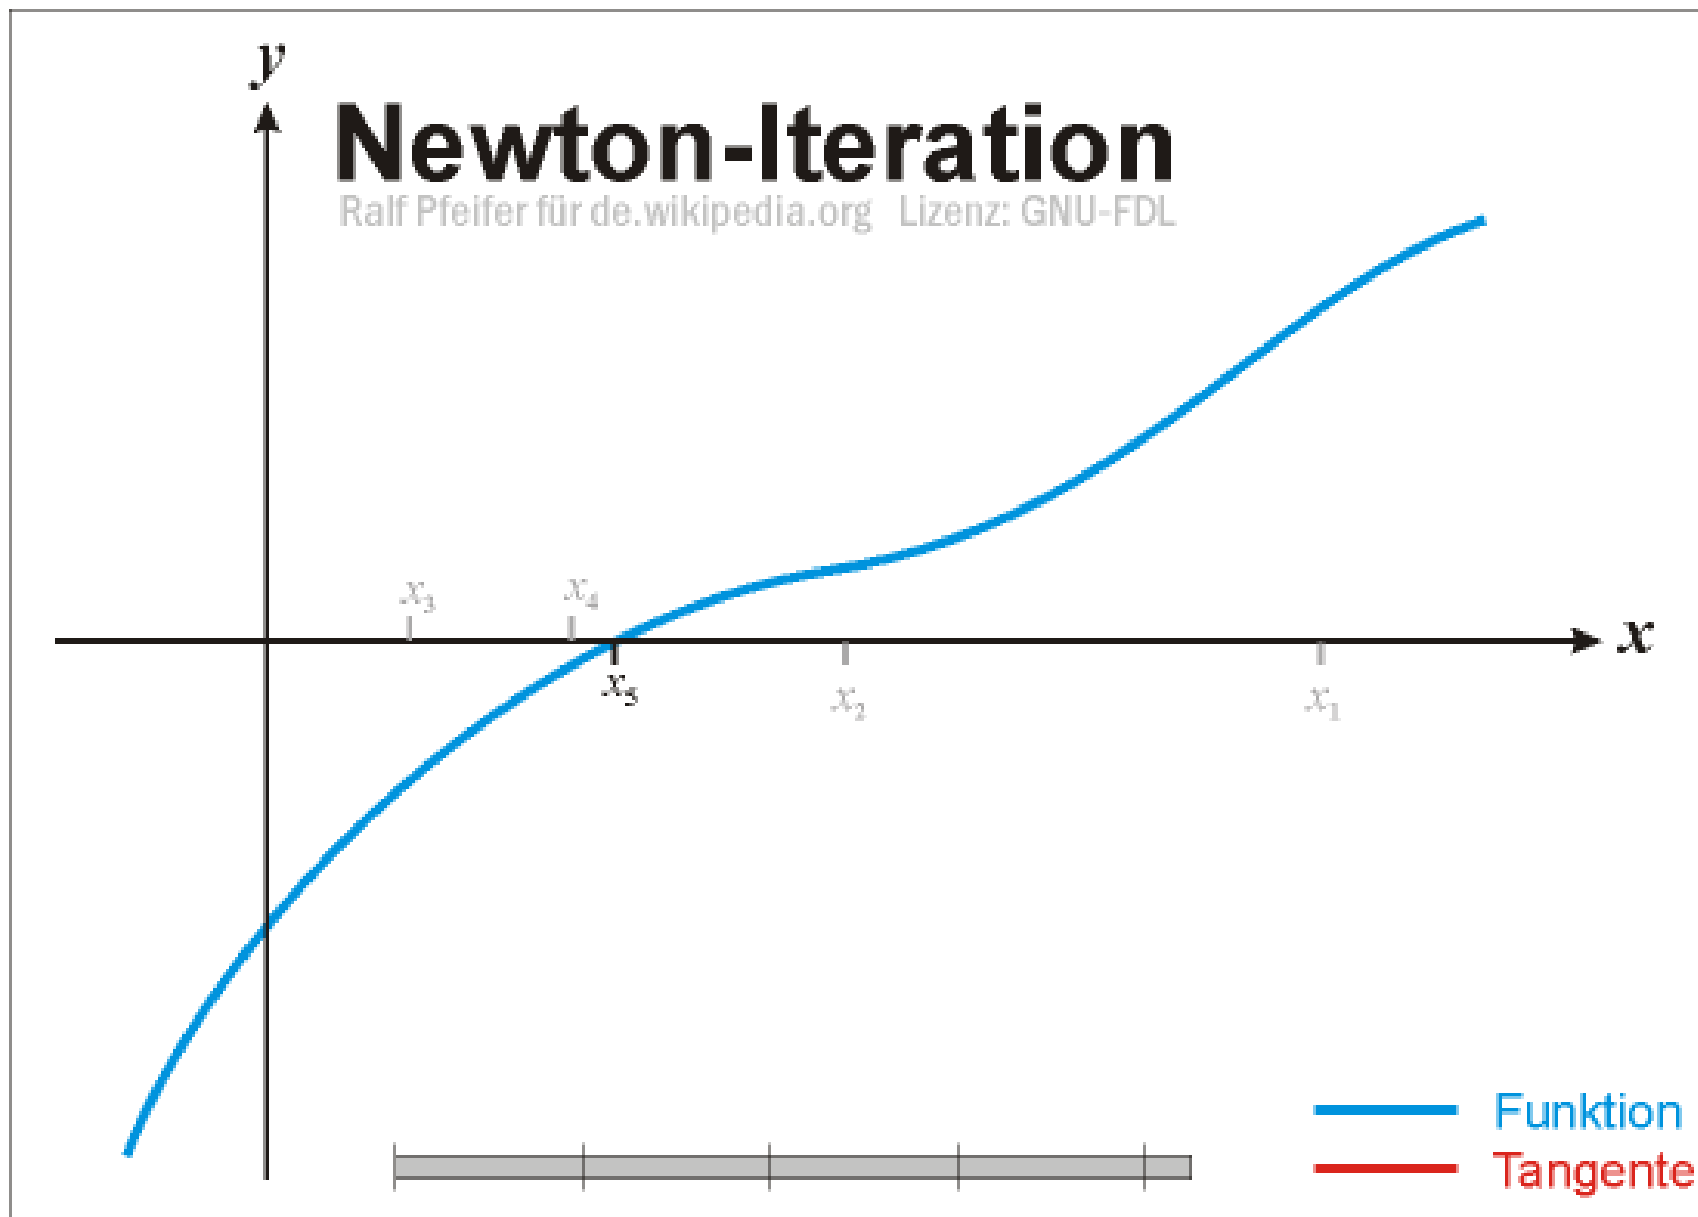
Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



Příklad: Hledání kořenu funkce jedné proměnné vede na iteraci: $x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$



Newtonova metoda pro minimalizaci funkce

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

Newtonova metoda pro minimalizaci funkce

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Položíme $\mathbf{g}(\mathbf{x}) = f'(\mathbf{x})^T$ a pomocí Newtonovy metody řešíme $\mathbf{g}(\mathbf{x}) = \mathbf{0}$, tedy iterujeme

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

Newtonova metoda pro minimalizaci funkce

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Položíme $\mathbf{g}(\mathbf{x}) = f'(\mathbf{x})^T$ a pomocí Newtonovy metody řešíme $\mathbf{g}(\mathbf{x}) = \mathbf{0}$, tedy iterujeme

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

to odpovídá sestupné metodě

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

Newtonova metoda pro minimalizaci funkce

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Položíme $\mathbf{g}(\mathbf{x}) = f'(\mathbf{x})^T$ a pomocí Newtonovy metody řešíme $\mathbf{g}(\mathbf{x}) = \mathbf{0}$, tedy iterujeme

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

to odpovídá sestupné metodě

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

- ◆ Pokud $\alpha_k = 1$ jedná se o čistou Newtonovu metodu.

Newtonova metoda pro minimalizaci funkce

- ◆ Cíl: chceme nalézt lokální minimum funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

- ◆ Položíme $\mathbf{g}(\mathbf{x}) = f'(\mathbf{x})^T$ a pomocí Newtonovy metody řešíme $\mathbf{g}(\mathbf{x}) = \mathbf{0}$, tedy iterujeme

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

to odpovídá sestupné metodě

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

- ◆ Pokud $\alpha_k = 1$ jedná se o čistou Newtonovu metodu.
- ◆ Postačující podmínkou pro sestupný směr, je aby Hessian $f''(\mathbf{x}_k)$ byl pozitivně definitní

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

Newtonova metoda pro minimalizaci funkce

- ◆ Newtonovu metodu pro minimalizaci funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lze odvodit i jinak.

Newtonova metoda pro minimalizaci funkce

- ◆ Newtonovu metodu pro minimalizaci funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lze odvodit i jinak.
- ◆ Aproximujeme funkci $f(\mathbf{x})$ kolem bodu \mathbf{x}_k Taylorovým polynomem 2. řádu

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

Newtonova metoda pro minimalizaci funkce

- ◆ Newtonovu metodu pro minimalizaci funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lze odvodit i jinak.
- ◆ Aproximujeme funkci $f(\mathbf{x})$ kolem bodu \mathbf{x}_k Taylorovým polynomem 2. řádu

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

- ◆ Novou iteraci \mathbf{x}_{k+1} získáme minimalizací

$$\min_{\mathbf{x} \in \mathbb{R}^n} \tilde{f}(\mathbf{x})$$

Newtonova metoda pro minimalizaci funkce

- ◆ Newtonovu metodu pro minimalizaci funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lze odvodit i jinak.
- ◆ Aproximujeme funkci $f(\mathbf{x})$ kolem bodu \mathbf{x}_k Taylorovým polynomem 2. řádu

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

- ◆ Novou iteraci \mathbf{x}_{k+1} získáme minimalizací

$$\min_{\mathbf{x} \in \mathbb{R}^n} \tilde{f}(\mathbf{x})$$

což můžeme řešit jako soustavu lineárních rovnic

$$\tilde{f}'(\mathbf{x}_{k+1}) = \mathbf{0} \quad \Rightarrow \quad f'(\mathbf{x}_k)^T + f''(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k) = \mathbf{0}$$

Newtonova metoda pro minimalizaci funkce

- ◆ Newtonovu metodu pro minimalizaci funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lze odvodit i jinak.
- ◆ Aproximujeme funkci $f(\mathbf{x})$ kolem bodu \mathbf{x}_k Taylorovým polynomem 2. řádu

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

- ◆ Novou iteraci \mathbf{x}_{k+1} získáme minimalizací

$$\min_{\mathbf{x} \in \mathbb{R}^n} \tilde{f}(\mathbf{x})$$


což můžeme řešit jako soustavu lineárních rovnic

$$\tilde{f}'(\mathbf{x}_{k+1}) = \mathbf{0} \quad \Rightarrow \quad f'(\mathbf{x}_k)^T + f''(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k) = \mathbf{0}$$


a pokud je Hessian $f''(\mathbf{x}_k)$ regulární dostaneme řešení


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


Konec





m p





























































































y


Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL



Newton-Iteration


Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL



y


Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL




Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL



Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL



Newton-Iteration

Ralf Pfeifer für de.wikipedia.org Lizenz: GNU-FDL

