

Dynamische Prozessoptimierung

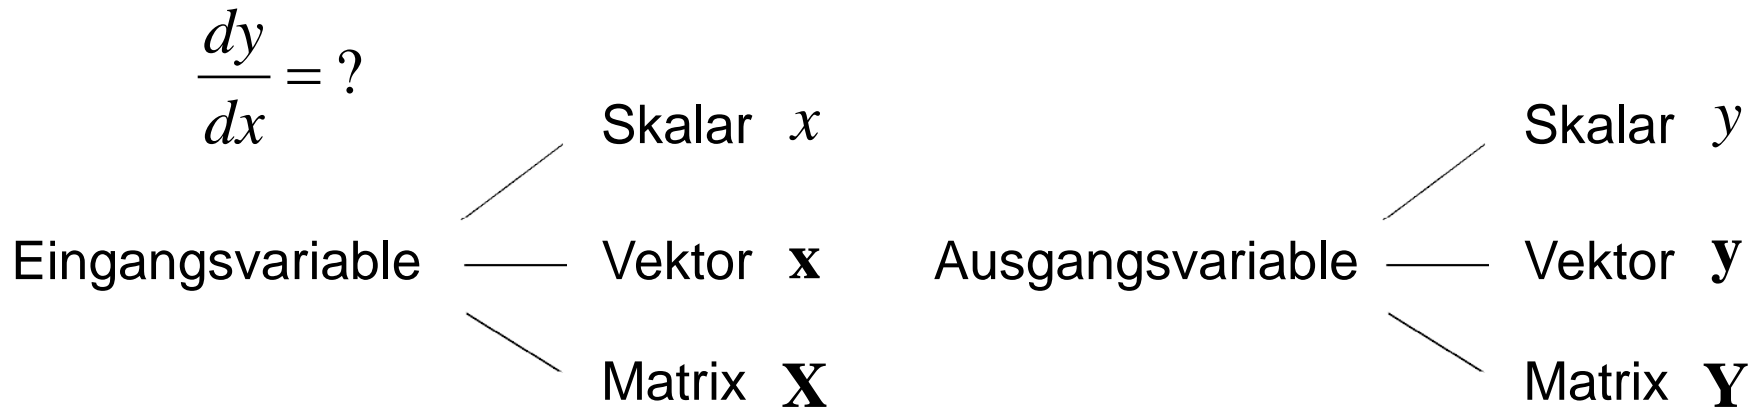
Kapitel 2: Mathematische Grundlagen

Prof. Dr.-Ing. habil. Pu Li

Fachgebiet **Prozessoptimierung**

Mathematische Grundlage: Ableitungen

Grund: Gradientenbasierte Lösungsverfahren brauchen Ableitungen.



Es gibt 9 unterschiedliche Möglichkeiten bzw. Kombinationen:

$\frac{dy}{dx} = ?$	$\frac{dy}{dx} = ?$	$\frac{d\mathbf{Y}}{dx} = ?$
$\frac{dy}{d\mathbf{x}} = ?$	$\frac{dy}{d\mathbf{x}} = ?$	$\frac{d\mathbf{Y}}{d\mathbf{x}} = ?$
$\frac{dy}{d\mathbf{X}} = ?$	$\frac{dy}{d\mathbf{X}} = ?$	$\frac{d\mathbf{Y}}{d\mathbf{X}} = ?$

1. Ableitungen nach einer skalaren Variablen (z.B. Zeit t)

Ein Vektor von Funktionen: $\mathbf{x}(t) = [x_1(t) \quad x_2(t) \quad \cdots \quad x_n(t)]^T$

$$\frac{d\mathbf{x}}{dt} \equiv \left[\frac{dx_1}{dt} \quad \frac{dx_2}{dt} \quad \cdots \quad \frac{dx_n}{dt} \right]^T$$

Inneres Produkt (Skalarprodukt) zweier Vektoren:

$$\mathbf{x}(t) = [x_1(t) \quad x_2(t) \quad \cdots \quad x_n(t)]^T$$

$$\mathbf{y}(t) = [y_1(t) \quad y_2(t) \quad \cdots \quad y_n(t)]^T$$

Bilineare Systeme:

$$\mathbf{x}^T \mathbf{y} = x_1 y_1 + x_2 y_2 + \cdots + x_n y_n = \sum_{i=1}^n x_i y_i$$

$$\frac{d(\mathbf{x}^T \mathbf{y})}{dt} = \frac{d\mathbf{x}^T}{dt} \mathbf{y} + \mathbf{x}^T \frac{d\mathbf{y}}{dt} \quad (\text{Übungsaufgabe!})$$

Eine Matrix von Funktionen:

$$\mathbf{X}(t) = \begin{bmatrix} x_{11}(t) & \cdots & x_{1m}(t) \\ \vdots & \cdots & \vdots \\ x_{n1}(t) & \cdots & x_{nm}(t) \end{bmatrix} = [x_{i,j}]_{n \times m}$$

Die Definition:

$$\frac{d\mathbf{X}}{dt} \equiv \begin{bmatrix} \frac{dx_{11}}{dt} & \cdots & \frac{dx_{1m}}{dt} \\ \vdots & \cdots & \vdots \\ \frac{dx_{n1}}{dt} & \cdots & \frac{dx_{nm}}{dt} \end{bmatrix} \equiv \left[\frac{dx_{i,j}}{dt} \right]_{n \times m}$$

Es gibt:

$$\frac{d(\mathbf{X}_1 \pm \mathbf{X}_2)}{dt} = \frac{d\mathbf{X}_1}{dt} \pm \frac{d\mathbf{X}_2}{dt}$$

$$\frac{d(\lambda \mathbf{X})}{dt} = \frac{d\lambda}{dt} \mathbf{X} + \lambda \frac{d\mathbf{X}}{dt}$$

$$\frac{d(\mathbf{X}_1 \mathbf{X}_2)}{dt} = \frac{d\mathbf{X}_1}{dt} \mathbf{X}_2 + \mathbf{X}_1 \frac{d\mathbf{X}_2}{dt}$$

(Übungsaufgabe!)

Eine quadratische Funktion: $f(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x}$

mit $\mathbf{x}(t) = [x_1(t) \quad x_2(t) \quad \cdots \quad x_n(t)]^T$

$$\mathbf{A} = \begin{bmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \cdots & \vdots \\ a_{1n} & \cdots & a_{nn} \end{bmatrix} = [a_{i,j}]_{n \times n}$$

\mathbf{A} ist eine symmetrische, konstante Matrix.

$$\begin{aligned} \frac{d(\mathbf{x}^T \mathbf{A} \mathbf{x})}{dt} &= \frac{d\mathbf{x}^T}{dt} (\mathbf{A} \mathbf{x}) + \mathbf{x}^T \frac{d(\mathbf{A} \mathbf{x})}{dt} \\ &= \frac{d\mathbf{x}^T}{dt} (\mathbf{A} \mathbf{x}) + \mathbf{x}^T \mathbf{A} \frac{d\mathbf{x}}{dt} = 2\mathbf{x}^T \mathbf{A} \frac{d\mathbf{x}}{dt} = 2\mathbf{x}^T \mathbf{A} \dot{\mathbf{x}} \end{aligned}$$

Beispiel:



	Istwert	Sollwert
Position:	u	u_s
Geschwindigkeit:	v	v_s
Beschleunigung:	w	w_s

Minimierung des Fehlerquadrates:

$$\min_{u,v,w} \int_{t_0}^{t_f} \left[\alpha_1 (u - u_s)^2 + \alpha_2 (v - v_s)^2 + \alpha_3 (w - w_s)^2 \right] dt$$

Inversion einer Matrix: $\mathbf{X}^{-1}(t)$ mit $\mathbf{X}(t) = \begin{bmatrix} x_{11}(t) & \cdots & x_{1n}(t) \\ \vdots & \cdots & \vdots \\ x_{n1}(t) & \cdots & x_{nn}(t) \end{bmatrix} = [x_{i,j}]_{n \times n}$

Da $\mathbf{X}\mathbf{X}^{-1} = \mathbf{E}$, $\frac{d\mathbf{E}}{dt} = \mathbf{0}$, gibt es

$$\frac{d(\mathbf{X}\mathbf{X}^{-1})}{dt} = \frac{d\mathbf{X}}{dt}\mathbf{X}^{-1} + \mathbf{X}\frac{d\mathbf{X}^{-1}}{dt} = \mathbf{0}$$

Dann $\mathbf{X}\frac{d\mathbf{X}^{-1}}{dt} = -\frac{d\mathbf{X}}{dt}\mathbf{X}^{-1}$

$$\frac{d\mathbf{X}^{-1}}{dt} = -\mathbf{X}^{-1}\frac{d\mathbf{X}}{dt}\mathbf{X}^{-1}$$

Achtung: \mathbf{X} muss invertierbar sein.
d.h. $\det[\mathbf{X}(t)] \neq 0$

Eine Ableitung nach der **Zeit** wird die Dimension nicht verändern!

Sie ist eine Totalableitung / ein totales Differential!

2. Ableitungen nach einem Vektor von Variablen

Eine Funktion: $f(\mathbf{x})$ mit $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]^T$

$$\frac{df(\mathbf{x})}{d\mathbf{x}} \equiv \left[\frac{\partial f(\mathbf{x})}{\partial x_1} \quad \frac{\partial f(\mathbf{x})}{\partial x_2} \quad \dots \quad \frac{\partial f(\mathbf{x})}{\partial x_n} \right]^T \equiv \nabla f(\mathbf{x})$$

$$\frac{df(\mathbf{x})}{d\mathbf{x}^T} \equiv \left[\frac{\partial f(\mathbf{x})}{\partial x_1} \quad \frac{\partial f(\mathbf{x})}{\partial x_2} \quad \dots \quad \frac{\partial f(\mathbf{x})}{\partial x_n} \right] \equiv (\nabla f(\mathbf{x}))^T$$

Es existieren:

$$\frac{d(f(\mathbf{x}) \pm g(\mathbf{x}))}{d\mathbf{x}} = \frac{df(\mathbf{x})}{d\mathbf{x}} \pm \frac{dg(\mathbf{x})}{d\mathbf{x}}$$

$$\frac{d(f(\mathbf{x}) \cdot g(\mathbf{x}))}{d\mathbf{x}} = g(\mathbf{x}) \frac{df(\mathbf{x})}{d\mathbf{x}} + f(\mathbf{x}) \frac{dg(\mathbf{x})}{d\mathbf{x}}$$

Die Ableitung einer **Funktion** nach einem Vektor führt zu einem **Vektor**!

Die Elemente sind Partialableitungen!

Ein Vektor: $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \quad f_2(\mathbf{x}) \quad \cdots \quad f_m(\mathbf{x})]^T$

mit $\mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T$

Die Definition:

$$\frac{d\mathbf{f}(\mathbf{x})}{d\mathbf{x}} \equiv \frac{d\mathbf{f}(\mathbf{x})}{d\mathbf{x}^T} \equiv \begin{bmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \cdots & \frac{\partial f_1(\mathbf{x})}{\partial x_n} \\ \vdots & \cdots & \vdots \\ \frac{\partial f_m(\mathbf{x})}{\partial x_1} & \cdots & \frac{\partial f_m(\mathbf{x})}{\partial x_n} \end{bmatrix} = \left[\frac{\partial f_i(\mathbf{x})}{\partial x_j} \right]_{m \times n} \quad (\text{Jacobi-Matrix})$$

und

$$\frac{d\mathbf{f}(\mathbf{x})^T}{d\mathbf{x}} \equiv \left(\frac{d\mathbf{f}(\mathbf{x})}{d\mathbf{x}} \right)^T = \begin{bmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \cdots & \frac{\partial f_m(\mathbf{x})}{\partial x_1} \\ \vdots & \cdots & \vdots \\ \frac{\partial f_1(\mathbf{x})}{\partial x_n} & \cdots & \frac{\partial f_m(\mathbf{x})}{\partial x_n} \end{bmatrix} = \left[\frac{\partial f_j(\mathbf{x})}{\partial x_i} \right]_{n \times m}$$

Daher

$$\frac{d\mathbf{x}}{d\mathbf{x}^T} = \frac{d\mathbf{x}^T}{d\mathbf{x}} = \mathbf{E} \quad \text{Achtung:} \quad d\mathbf{x} = d\mathbf{x}^T \quad \Rightarrow \quad \frac{d\mathbf{x}}{d\mathbf{x}^T} = \mathbf{E}$$

Die Ableitung eines **Vektors** nach einem Vektor führt zu einer **Matrix**!

Es existieren:
$$\frac{d(\mathbf{f}(\mathbf{x}) \pm \mathbf{g}(\mathbf{x}))}{d\mathbf{x}} = \frac{d\mathbf{f}(\mathbf{x})}{d\mathbf{x}} \pm \frac{d\mathbf{g}(\mathbf{x})}{d\mathbf{x}}$$

$$\frac{d(\mathbf{f}(\mathbf{x})^T \mathbf{g}(\mathbf{x}))}{d\mathbf{x}} = \frac{d\mathbf{f}(\mathbf{x})^T}{d\mathbf{x}} \mathbf{g}(\mathbf{x}) + \frac{d\mathbf{g}(\mathbf{x})^T}{d\mathbf{x}} \mathbf{f}(\mathbf{x}) \quad (\text{Übungsaufgabe!})$$

daher
$$\frac{d(\mathbf{a}^T \mathbf{f}(\mathbf{x}))}{d\mathbf{x}} = \frac{d\mathbf{a}^T}{d\mathbf{x}} \mathbf{f}(\mathbf{x}) + \frac{d\mathbf{f}(\mathbf{x})^T}{d\mathbf{x}} \mathbf{a} = \frac{d\mathbf{f}(\mathbf{x})^T}{d\mathbf{x}} \mathbf{a}$$

Lineares System:

$$\mathbf{f}(\mathbf{x}) = \begin{bmatrix} f_1(\mathbf{x}) \\ \vdots \\ f_m(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} a_{11}x_1 + \dots + a_{1n}x_n \\ \vdots \\ a_{m1}x_1 + \dots + a_{mn}x_n \end{bmatrix} = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \dots & \vdots \\ a_{m1} & \dots & a_{m1} \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} = \mathbf{A}\mathbf{x}$$

$$\frac{d\mathbf{f}(\mathbf{x})}{d\mathbf{x}} \equiv \begin{bmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \dots & \frac{\partial f_1(\mathbf{x})}{\partial x_n} \\ \vdots & \dots & \vdots \\ \frac{\partial f_m(\mathbf{x})}{\partial x_1} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_n} \end{bmatrix} = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \dots & \vdots \\ a_{m1} & \dots & a_{m1} \end{bmatrix} = \mathbf{A}$$

Eine quadratische Funktion: $f(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x}$

mit $\mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T$ $\mathbf{A} = \begin{bmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \cdots & \vdots \\ a_{1n} & \cdots & a_{nn} \end{bmatrix} = [a_{i,j}]_{n \times n}$

\mathbf{A} ist eine symmetrische, konstante Matrix.

Daher
$$\begin{aligned} \frac{d(\mathbf{x}^T \mathbf{A} \mathbf{x})}{d\mathbf{x}} &= \frac{d\mathbf{x}^T}{d\mathbf{x}} (\mathbf{A} \mathbf{x}) + \frac{d(\mathbf{A} \mathbf{x})^T}{d\mathbf{x}} \mathbf{x} \\ &= \mathbf{E}(\mathbf{A} \mathbf{x}) + \left(\frac{d(\mathbf{A} \mathbf{x})}{d\mathbf{x}} \right)^T \mathbf{x} = \mathbf{A} \mathbf{x} + \mathbf{A}^T \mathbf{x} = (\mathbf{A} + \mathbf{A}^T) \mathbf{x} = 2\mathbf{A} \mathbf{x} \end{aligned}$$

Dann
$$\begin{aligned} \frac{d(\boldsymbol{\lambda}^T \mathbf{B} \mathbf{x})}{d\mathbf{x}} &= \frac{d\boldsymbol{\lambda}^T}{d\mathbf{x}} (\mathbf{B} \mathbf{x}) + \frac{d(\mathbf{B} \mathbf{x})^T}{d\mathbf{x}} \boldsymbol{\lambda} \\ &= \left(\frac{d(\mathbf{B} \mathbf{x})}{d\mathbf{x}} \right)^T \boldsymbol{\lambda} = \mathbf{B}^T \boldsymbol{\lambda} \end{aligned}$$

Beispiel:

$$f(\mathbf{x}) = x_1^2 + x_1x_2 + x_2^2 - 4x_2x_3 + x_3^2 + 3x_1 - 2x_2 - 6x_3$$

11

Die Matrix/Vektor-Form:

$$f(\mathbf{x}) = \begin{bmatrix} x_1 & x_2 & x_3 \end{bmatrix} \begin{bmatrix} 1 & 1/2 & 0 \\ 1/2 & 1 & -2 \\ 0 & -2 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} 3 & -2 & -6 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{c}^T \mathbf{x}$$

Die ersten Ableitungen:

$$\begin{aligned} \nabla f(\mathbf{x}) &= \frac{df(\mathbf{x})}{d\mathbf{x}} = \frac{d(\mathbf{x}^T \mathbf{Q} \mathbf{x})}{d\mathbf{x}} + \frac{d(\mathbf{c}^T \mathbf{x})}{d\mathbf{x}} = 2\mathbf{Q} \mathbf{x} + \mathbf{c} \\ &= 2 \begin{bmatrix} 1 & 1/2 & 0 \\ 1/2 & 1 & -2 \\ 0 & -2 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} 3 \\ -2 \\ -6 \end{bmatrix} = \begin{bmatrix} 2 & 1 & 0 \\ 1 & 2 & -4 \\ 0 & -4 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} 3 \\ -2 \\ -6 \end{bmatrix} \end{aligned}$$

Die zweiten Ableitungen (die Hesse-Matrix):

$$\nabla^2 f(\mathbf{x}) = \frac{d(\nabla f(\mathbf{x}))}{d\mathbf{x}} = \frac{d(2\mathbf{Q} \mathbf{x} + \mathbf{c})}{d\mathbf{x}} = 2\mathbf{Q} = \begin{bmatrix} 2 & 1 & 0 \\ 1 & 2 & -4 \\ 0 & -4 & 2 \end{bmatrix}$$

Eine Matrix:

$$\mathbf{F}(\mathbf{x}) = \begin{bmatrix} f_{11}(\mathbf{x}) & \cdots & f_{1l}(\mathbf{x}) \\ \vdots & \cdots & \vdots \\ f_{m1}(\mathbf{x}) & \cdots & f_{ml}(\mathbf{x}) \end{bmatrix} = [f_{i,j}(\mathbf{x})]_{m \times l}$$

mit


$$\mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T$$

Die Definition:

$$\frac{d\mathbf{F}(\mathbf{x})}{d\mathbf{x}} \equiv \left[\frac{\partial \mathbf{F}(\mathbf{x})}{\partial x_1} \quad \frac{\partial \mathbf{F}(\mathbf{x})}{\partial x_2} \quad \cdots \quad \frac{\partial \mathbf{F}(\mathbf{x})}{\partial x_n} \right]^T$$

wobei

$$\frac{\partial \mathbf{F}(\mathbf{x})}{\partial x_k} = \begin{bmatrix} \frac{\partial f_{11}(\mathbf{x})}{\partial x_k} & \cdots & \frac{\partial f_{1l}(\mathbf{x})}{\partial x_k} \\ \vdots & \cdots & \vdots \\ \frac{\partial f_{m1}(\mathbf{x})}{\partial x_k} & \cdots & \frac{\partial f_{ml}(\mathbf{x})}{\partial x_k} \end{bmatrix} = \left[\frac{\partial f_{i,j}(\mathbf{x})}{\partial x_k} \right]_{m \times l} \quad k = 1, \dots, n$$



Der Rechenaufwand ist sehr hoch!

4. Ableitungen nach Variablen in Funktionen

Eine Funktion: $f(\mathbf{x})$ mit $\mathbf{x}(t) = [x_1(t) \ x_2(t) \ \dots \ x_n(t)]^T$

$$\frac{df(\mathbf{x}(t))}{dt} = \frac{df(\mathbf{x}(t))}{d\mathbf{x}^T} \frac{d\mathbf{x}(t)}{dt} \quad (\text{Übungsaufgabe!})$$

Beispiel: $f(\mathbf{x}) = \sin(\mathbf{c}^T \mathbf{x})$

mit $\mathbf{c}^T \mathbf{x} = c_1 x_1 + c_2 x_2 + \dots + c_n x_n = \sum_{i=1}^n c_i x_i$

$$\frac{df}{d\mathbf{x}^T} = \left(\frac{df}{d\mathbf{x}} \right)^T = \left(\frac{d}{d\mathbf{x}} \sin(\mathbf{c}^T \mathbf{x}) \right)^T = [\mathbf{c} \cos(\mathbf{c}^T \mathbf{x})]^T = \mathbf{c}^T \cos(\mathbf{c}^T \mathbf{x})$$


daher $\frac{df(\mathbf{x}(t))}{dt} = \frac{df(\mathbf{x}(t))}{d\mathbf{x}^T} \frac{d\mathbf{x}(t)}{dt} = [\cos(\mathbf{c}^T \mathbf{x}(t))] \mathbf{c}^T \dot{\mathbf{x}}(t)$

Eine Funktion: $z = f(\mathbf{y})$

mit $\mathbf{y}(\mathbf{x}) = [y_1(\mathbf{x}) \quad y_2(\mathbf{x}) \quad \cdots \quad y_m(\mathbf{x})]^T$

$\mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T$

Physikalische Bedeutung:



Weil $df = \frac{df}{d\mathbf{y}^T} d\mathbf{y}$, $d\mathbf{y} = \frac{d\mathbf{y}}{d\mathbf{x}^T} d\mathbf{x}$ dann $df = \frac{df}{d\mathbf{y}^T} \frac{d\mathbf{y}}{d\mathbf{x}^T} d\mathbf{x}$

daher

$$\frac{df}{d\mathbf{x}} = \left(\frac{df}{d\mathbf{y}^T} \frac{d\mathbf{y}}{d\mathbf{x}^T} \right)^T = \left(\frac{d\mathbf{y}}{d\mathbf{x}^T} \right)^T \left(\frac{df}{d\mathbf{y}^T} \right)^T = \frac{d\mathbf{y}^T}{d\mathbf{x}} \frac{df}{d\mathbf{y}}$$

Beispiel: $f(\mathbf{x}) = (\mathbf{Ax} - \mathbf{b})^T \mathbf{R}(\mathbf{Ax} - \mathbf{b})$

mit $\mathbf{A} = [a_{ij}]_{m \times n}$, $\mathbf{R} = [r_{ij}]_{m \times m}$, $\mathbf{b} = [b_1 \ \dots \ b_m]$

Definiert man $\mathbf{y} = \mathbf{Ax} - \mathbf{b}$ dann $f(\mathbf{y}) = \mathbf{y}^T \mathbf{R} \mathbf{y}$

Weil $\frac{df}{d\mathbf{x}} = \frac{d\mathbf{y}^T}{d\mathbf{x}} \frac{df}{d\mathbf{y}}$

mit $\frac{d\mathbf{y}^T}{d\mathbf{x}} = \frac{d(\mathbf{Ax} - \mathbf{b})^T}{d\mathbf{x}} = \frac{d(\mathbf{Ax})^T}{d\mathbf{x}} = \left(\frac{d(\mathbf{Ax})}{d\mathbf{x}} \right)^T = \mathbf{A}^T$

$$\frac{df}{d\mathbf{y}} = \frac{d(\mathbf{y}^T \mathbf{R} \mathbf{y})}{d\mathbf{y}} = (\mathbf{R}^T + \mathbf{R}) \mathbf{y}$$

Daher

$$\frac{df}{d\mathbf{x}} = \frac{d\mathbf{y}^T}{d\mathbf{x}} \frac{df}{d\mathbf{y}} = \mathbf{A}^T (\mathbf{R}^T + \mathbf{R}) (\mathbf{Ax} - \mathbf{b})$$

5. Taylor-Entwicklung und Extrempunkte einer Funktion 16

$$f(\mathbf{x}) = f(\mathbf{x}_0) + \left(\frac{df}{d\mathbf{x}} \right)_0^T \Delta\mathbf{x} + \frac{1}{2} \Delta\mathbf{x}^T \left(\frac{d^2f}{d\mathbf{x}^2} \right)_0 \Delta\mathbf{x} + (O^3)$$

$$= f(\mathbf{x}_0) + \nabla f_0^T \Delta\mathbf{x} + \frac{1}{2} \Delta\mathbf{x}^T (\nabla^2 f)_0 \Delta\mathbf{x} + (O^3)$$

$$f(\mathbf{x}, \mathbf{u}) = f(\mathbf{x}_0, \mathbf{u}_0) + \begin{bmatrix} \frac{\partial f}{\partial \mathbf{x}^T} & \frac{\partial f}{\partial \mathbf{u}^T} \end{bmatrix}_0 \begin{bmatrix} \Delta\mathbf{x} \\ \Delta\mathbf{u} \end{bmatrix} + \frac{1}{2} \begin{bmatrix} \Delta\mathbf{x} & \Delta\mathbf{u} \end{bmatrix} \begin{pmatrix} \frac{\partial^2 f}{\partial \mathbf{x}^2} & \frac{\partial^2 f}{\partial \mathbf{x} \partial \mathbf{u}} \\ \frac{\partial^2 f}{\partial \mathbf{x} \partial \mathbf{u}} & \frac{\partial^2 f}{\partial \mathbf{u}^2} \end{pmatrix}_0 \begin{bmatrix} \Delta\mathbf{x} \\ \Delta\mathbf{u} \end{bmatrix} + (O^3)$$

Ist $(\mathbf{x}_0, \mathbf{u}_0)$ ein Extrempunkt, dann $\begin{bmatrix} \frac{\partial f}{\partial \mathbf{x}^T} & \frac{\partial f}{\partial \mathbf{u}^T} \end{bmatrix}_0 = \mathbf{0}$

Ist die Hesse-Matrix **positiv** definit, dann ist der Punkt ein **Minimum**punkt.

Ist die Hesse-Matrix **negativ** definit, dann ist der Punkt ein **Maximum**punkt.

Achtung: die Funktion $f(\mathbf{x})$ muss zweimal differenzierbar sein!

Beispiel: $f(\mathbf{x}) = x_1^2 + x_1x_2 + x_2^2 - 4x_2x_3 + x_3^2 + 3x_1 - 2x_2 - 6x_3$

Problemdefinition eines Problems mit Gleichungsbeschränkungen:

$$\begin{array}{ll} \min_x & f(\mathbf{x}) \\ \text{mit} & \mathbf{g}(\mathbf{x}) = \mathbf{0} \end{array} \quad \text{wobei} \quad \mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T$$
$$\mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}) \quad g_2(\mathbf{x}) \quad \cdots \quad g_m(\mathbf{x})]^T$$

Welche Beziehung besteht zwischen n und m ?

Lagrange-Funktion: $L(\mathbf{x}, \boldsymbol{\lambda}) = f(\mathbf{x}) + \boldsymbol{\lambda}^T \mathbf{g}(\mathbf{x})$

Die notwendige Bedingung: $\frac{\partial L}{\partial \mathbf{x}} = \frac{\partial f}{\partial \mathbf{x}} + \frac{\partial \mathbf{g}^T}{\partial \mathbf{x}} \boldsymbol{\lambda} = \mathbf{0}$

also

$$\begin{array}{l} \nabla L = \nabla f + \nabla \mathbf{g}^T \boldsymbol{\lambda} = \mathbf{0} \\ \mathbf{g}(\mathbf{x}) = \mathbf{0} \end{array}$$

Die Modellgleichungen:

Die hinreichende Bedingung: positiv definite Hesse-Matrix von $L(\mathbf{x}, \boldsymbol{\lambda})$

Beispiel:

$$\begin{aligned} \min_x \quad & x_1^2 + x_2^2 \\ \text{mit} \quad & x_1 + x_2 = 1 \end{aligned}$$

18

Lagrange-Funktion: $L(\mathbf{x}, \lambda) = x_1^2 + x_2^2 + \lambda(x_1 + x_2 - 1)$


dann

$$\frac{\partial L}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial L}{\partial x_1} \\ \frac{\partial L}{\partial x_2} \end{bmatrix} = \begin{bmatrix} 2x_1 - \lambda \\ 2x_2 - \lambda \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$\frac{\partial L}{\partial \lambda} = x_1 + x_2 - 1 = 0$$

Der Lösungspunkt: $x_1^* = x_2^* = \frac{1}{2}$

Die Hesse-Matrix: $\mathbf{H}_L(\mathbf{x}^*, \lambda^*) = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix}$



7. Die Karush-Kuhn-Tucker-Bedingungen (KKT)

Problemdefinition eines Problems mit Gleichungs- und Ungleichungsbeschränkungen:

$$\begin{array}{ll} \min_x & f(\mathbf{x}) \\ \text{mit} & \mathbf{g}(\mathbf{x}) = \mathbf{0} \\ & \mathbf{h}(\mathbf{x}) \geq \mathbf{0} \end{array} \quad \text{wobei} \quad \begin{array}{l} \mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T \\ \mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}) \quad g_2(\mathbf{x}) \quad \cdots \quad g_m(\mathbf{x})]^T \\ \mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}) \quad h_2(\mathbf{x}) \quad \cdots \quad h_r(\mathbf{x})]^T \end{array}$$

Lagrange-Funktion: $L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu}) = f(\mathbf{x}) - \boldsymbol{\lambda}^T \mathbf{g}(\mathbf{x}) - \boldsymbol{\mu}^T \mathbf{h}(\mathbf{x})$

Beim Lösungspunkt:

- $\nabla L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*) = \mathbf{0}$
- $\mathbf{g}(\mathbf{x}^*) = \mathbf{0}$
- $\mathbf{h}(\mathbf{x}^*) \geq \mathbf{0}$
- $\mu_i h_i(\mathbf{x}^*) = 0, \quad \mu_i \geq 0, \quad i = 1, \dots, r$
- $\nabla^2 L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$ positiv definit