

VORL. 7: NICHTLINEARE OPTIMIERUNG 7 ①

MIT GLEICHUNGS- UND UNGLEICHUNGS-
BESCHRÄNKUNGEN

ALLGEMEINES NLP:

(1)
$$\begin{array}{l} \min_{x \in \mathbb{R}^n} f(x) \\ \text{s.t.} \quad C_E(x) = 0 \\ \quad \quad C_I(x) \geq 0 \end{array}$$

$C_E: \mathbb{R}^n \rightarrow \mathbb{R}^{m_E}$ $E = \text{"EQUALITIES"}$
 $C_I: \mathbb{R}^n \rightarrow \mathbb{R}^{m_I}$ $I = \text{"INEQUALITIES"}$

NLP IST

KONVEX, FALLS C_E AFFIN, f KONVEX, $(C_I)_i$ KONKAV

7.1 NICHTLINEARE INNERE PUNKTE (NIP) METHODE
 TRANSFORMATION AUF STA-NORMFORM DURCH EINFÜHRUNG
 VON SCHLUPFVARIABLEN

$s \in \mathbb{R}^{m_I}, \quad x^+ \in \mathbb{R}^n, \quad x^- \in \mathbb{R}^n$

$$\begin{array}{l} \min_{x^+, x^-, s} f(x^+ - x^-) \\ \text{s.t.} \quad C_E(x^+ - x^-) = 0 \\ \quad \quad C_I(x^+ - x^-) - s = 0 \\ \quad \quad x^+ \geq 0 \\ \quad \quad x^- \geq 0 \\ \quad \quad s \geq 0 \end{array}$$



$$\begin{array}{l} \min_{x \in \mathbb{R}^n} f(x) \\ \text{s.t.} \quad C(x) = 0 \\ \quad \quad x \geq 0 \end{array} \quad (2)$$

$$\begin{bmatrix} x^+ \\ x^- \\ s \end{bmatrix} =: x$$

$$\begin{bmatrix} C_E(x^+ - x^-) \\ C_I(x^+ - x^-) - s \end{bmatrix} =: C(x)$$

$C: \mathbb{R}^n \rightarrow \mathbb{R}^{m_I}$

BETRACHTE AB JETZT NLP (2).

LAGRANGE FUNKTION (MIT UNGLEICHUNGS-MULTIPLIKATOR $\gamma \in \mathbb{R}^{m_I}$)

$$\mathcal{L}(x, \lambda, \gamma) = f(x) - C(x)^T \lambda - \gamma^T x$$

KKT-BEDINGUNGEN

$$\nabla_x \mathcal{L}(x, \lambda, y) = 0$$


$$C(x) = 0$$

$$\left. \begin{array}{l} x_i \geq 0 \\ y_i \geq 0 \\ x_i y_i = 0 \end{array} \right\} \text{ FÜR } i=1, \dots, n$$

"KOMPLEMENTARITÄTS-BEDINGUNGEN"

PROBLEM: KOMPLEMENTARITÄTSBED. BESCHREIBEN FÜR JEDES

NICHT-DIFFERENZIERBARE MENGE IN $(x_i, y_i) =$
(N-FORM)!



IDEE 1: GLÄTTE ECKE DURCH PARAMETER $\mu > 0$ UND VERLANGE STATT $x_i y_i = 0$ EINFACH $x_i y_i = \mu$

"GELÄTTETE KKT BEDINGUNGEN" SIND

$$\begin{array}{l} \nabla_x \mathcal{L}(x, \lambda, y) = 0 \\ C(x) = 0 \\ x_i \cdot y_i = \mu \Rightarrow i=1, \dots, n \end{array} \quad (3)$$

$(x_i \geq 0, y_i \geq 0)$ ← WIRD AUTOMATISCH ERFÜLLT, WENN $x_i y_i = \mu > 0$

FASSE WIEDER ALLES ALS EIN
NULLSTELLENPROBLEM AUF:

$$z := \begin{bmatrix} x \\ \lambda \\ y \end{bmatrix} \in \mathbb{R}^{(n+m+n)}$$

$$F(z, \mu) := \begin{bmatrix} \nabla_x \mathcal{L}(x, \lambda, y) \\ c(x) \\ x_1 y_1 - \mu \\ \vdots \\ x_n y_n - \mu \end{bmatrix} \in \mathbb{R}^{(n+m+n)}$$

LÖSE $F(z, \mu) = 0$ FÜR $\mu > 0$ DURCH NEWTON-
VERFAHREN,
(SIEHE 6.3)

IDEE 2: STARTE MIT GROSSEM μ , VERRINGERE
 μ SCHRITTWEISE, BIS DU ERGEBNIS ERHÄLTST

NIP-
ALGORITHMUS:

- 1) WÄHLE $z^{(0)}$, $\mu_1 \gg 0$, SETZE $k=0$
- 2) CHECKE OB $\|F(z^{(k)}, \mu_k)\| \leq \varepsilon$
- 3) LÖSE $F(z, \mu_{k+1}) = 0$ MIT NEWTON-VERFAHREN,
ERGEBNIS: $z^{(k+1)}$ BESTARTET IN $z^{(k)}$.
- 4) SETZE $k \leftarrow k+1$
- 5) VERRINGERE $\mu_{k+1} = \alpha \mu_k$ $\mu = \alpha \mu_1$

THEOREM: DAS PROBLEM (3)

7 4

$$\boxed{F(z, \mu) = 0} \text{ IST ÄQUIVALENT}$$

ZUM "BARRIERE-OPTIMIERUNGSPROBLEM"

$$\boxed{\begin{array}{l} \min_{x \in \mathbb{R}^n} f(x) - \mu \sum_{i=1}^n \log x_i \\ \text{s.t. } C(x) = 0 \end{array}} \quad (4)$$

BEWEIS: (3) IST GLEICH

$$\boxed{\begin{array}{l} \nabla F(x) - \frac{\partial C}{\partial x}(x)^T \cdot \lambda - \gamma = 0 \\ C(x) = 0 \\ x_i \gamma_i = \mu \end{array}} \Rightarrow \left. \begin{array}{l} \\ \\ \text{FÜR } i=1, \dots, n \end{array} \right\} \Leftrightarrow \gamma_i = \frac{\mu}{x_i}$$

ELIMINATION VON $\gamma_1, \dots, \gamma_n$ ERGIBT KEIT VON (4)


$$\boxed{\begin{array}{l} \nabla F(x) - \mu \begin{bmatrix} x_1^{-1} \\ \vdots \\ x_n^{-1} \end{bmatrix} - \frac{\partial C}{\partial x}(x)^T \cdot \lambda = 0 \\ C(x) = 0 \end{array}} \quad \square$$

INTERPRETATION:

75

UNGLEICHUNG $x_i \geq 0$ WIRD DURCH "BARRIERE"

$\mu \log x_i$
ERZWUNGEN.



ALLE ITERIERTEN ZW
SIND "INNERE PUNKTE" (IP) DER ZULÄSSIGEN MENGE,

IP-METHODEN KÖNNEN ^(AUCH SEHR ZUVERLÄSSIG & EFFIZIENT) ZUR LÖSUNG VON

- LINEAREN PROGRAMMEN (LP) UND
- QUADRATISCHEN PROGRAMMEN (QP)

ANBEWENDET WERDEN. WG. DER KONVEXITÄT SIND
DIE LÖSUNGEN DANN GLOBAL OPTIMAL.

7.2 SEQUENTIELLE QUADRATISCHE PROGRAMMIERUNG (SQP)

BETRACHTE WIEDER (1)

$$\begin{aligned} \min_x & f(x) \\ x \in \mathbb{R}^n \\ \text{s.t.} & C_E(x) = 0 \\ & C_I(x) \geq 0 \end{aligned}$$

FALLS WIR EINEN QP-LÖSER VERFÜGBAR HABEN (Z.B. IP-METHODE), DANN KÖNNEN WIR ITERATIV QPs LÖSEN, DIE DURCH LINEARISIERUNG AN STELLE x_k BEWONNEN WERDEN:

QP(x_k , Q_k)

$$\begin{aligned} \min_{x \in \mathbb{R}^n} & \nabla f(x_k)^T (x - x_k) + \frac{1}{2} (x - x_k)^T Q_k (x - x_k) \\ \text{s.t.} & C_E(x_k) + \frac{\partial C_E}{\partial x}(x_k)(x - x_k) = 0 \\ & C_I(x_k) + \frac{\partial C_I}{\partial x}(x_k)(x - x_k) \geq 0 \end{aligned}$$

WAHL DER "HESSE MATRIX APPROXIMATION" SOLLTE

a) POSITIV DEFINIT SEIN (KONVEXITÄT DES QP!)

b) ÄHNLICH ZU $\nabla_x^2 \mathcal{L}(x, \lambda_E, \lambda_I)$ SEIN

(QUADRATISCHE KURVENANNÄHERUNG)

7.2.1 BESCHRÄNKTES GAUSS-NEURON (GN) VERFAHREN

FALLS $f(x) = \frac{1}{2} \|r(x)\|_2^2$ UND $J(x) = \frac{\partial r}{\partial x}(x)$,

DANN IST $Q_k := J(x_{k+1})^T J(x_{k+1})$

EINE GUTE WAHL. DAS QP IST DANN ÄQUIVALENT ZU

$\min_{x \in \mathbb{R}^n} \frac{1}{2} \|r(x_{k+1}) + J(x_{k+1})(x - x_{k+1})\|_2^2$
=: $f_{GN}(x, x_{k+1})$
 s.t. $C_E(x_{k+1}) + \frac{\partial C_E}{\partial x}(x_{k+1})(x - x_{k+1}) = 0$
 $C_I(x_{k+1}) + \dots \geq 0$

BEWEIS: $\nabla f(x_{k+1}) = J(x_{k+1})^T r(x_{k+1}) = \nabla f_{GN}(x_{k+1}, x_{k+1})$

UND $Q_k = J(x_{k+1})^T J(x_{k+1}) = \nabla^2 f_{GN}(x_{k+1}, x_{k+1})$

VORTEIL VON GN-SQP: KONVEXE STRUKTUREN BLEIBEN IN QP ERHALTEN, ZUVERLÄSSIGE & ROBUSTE KONVERGENZ.