

# Statische Prozessoptimierung/ Prozessoptimierung 1

## Kapitel 7: Nichtlineare Optimierung beschränkter Probleme

Prof. Dr.-Ing. habil Pu Li

Fachgebiet **Prozessoptimierung**

## Allgemeine Darstellung:

$$\min_{\mathbf{x}, \mathbf{u}} f(\mathbf{x}, \mathbf{u})$$

$$\text{mit } \mathbf{g}(\mathbf{x}, \mathbf{u}) = \mathbf{0}$$

$$\mathbf{h}(\mathbf{x}, \mathbf{u}) \geq \mathbf{0}$$

$$\mathbf{x}_{\min} \leq \mathbf{x} \leq \mathbf{x}_{\max}$$

$$\mathbf{u}_{\min} \leq \mathbf{u} \leq \mathbf{u}_{\max}$$


wobei     $\mathbf{x}$ :  $n$  Zustandsvariablen (abhängige Variablen)  
           $\mathbf{u}$ :  $m$  Steuervariablen (unabhängige Variablen)  
           $\mathbf{g}$ :  $n$  Modellgleichungen  
           $\mathbf{h}$ :  $l$  Beschränkungen

## Simultane Betrachtung:

Das Problem wird in dieser Form betrachtet und direkt mit einem Lösungsverfahren gelöst. Bei der Lösung sind alle Variablen ( $\mathbf{x}$  und  $\mathbf{u}$ ) zu optimieren.

## Sequentielle Betrachtung:

Die Zustandsvariablen hängen von den Steuervariablen ab.



Man kann durch

1. Umformung und Ersetzung
2. Simulation

die Zustandsvariablen  $\mathbf{x}$  und die Gleichungen  $\mathbf{g}$  eliminieren. Also gibt es  $\mathbf{x} = \varphi(\mathbf{u})$  und nun ist das Problem

$$\min_{\mathbf{u}} f(\mathbf{x}(\mathbf{u}), \mathbf{u})$$

$$\text{mit } \mathbf{h}(\mathbf{x}(\mathbf{u}), \mathbf{u}) \geq \mathbf{0}$$

$$\mathbf{x}_{min} \leq \mathbf{x}(\mathbf{u}) \leq \mathbf{x}_{max}$$

$$\mathbf{u}_{min} \leq \mathbf{u} \leq \mathbf{u}_{max}$$

Da nur die Steuervariablen auftauchen, stellt es ein kleines Optimierungsproblem dar. Es gibt keine Gleichungsnebenbedingungen.

Wenn das originale Problem keine Ungleichungsnebenbedingungen hat, <sup>4</sup>  
ist das Problem

$$\min_{\mathbf{u}} f(\mathbf{x}(\mathbf{u}), \mathbf{u}) = f(\mathbf{u}),$$

das mit dem Newton-, dem Gradienten- oder dem Quasi-Newton-Verfahren  
gelöst werden kann.

**Bei Umformung/Ersetzung** muss man aufpassen, manchmal werden  
Gleichungen nicht erfüllt!

**Beispiel:**

$$\begin{aligned} \min_{\mathbf{x}} f(x_1, x_2) &= x_1^2 + x_2^2 \\ (x_1 - 1)^3 - x_2^2 &= 0 \end{aligned}$$

Die Lösung des Problems ist  $x_1^* = 1, x_2^* = 0$ .

Aber wenn man die Gleichung umformt, d. h.

$$x_2^2 = (x_1 - 1)^3$$

und diese in die Zielfunktion einsetzt, erhält man

$$\min_{x_1} f(x_1) = x_1^2 + (x_1 - 1)^3.$$

## Nichtlineare Optimierung: zwei Variablen mit einer Nebenbedingung

$$\min_{\mathbf{x}} f(x_1, x_2)$$

$$\text{mit } g(x_1, x_2) = 0$$

Bei der Lösung  $(x_1^*, x_2^*)$  gibt es:

$$df = \frac{\partial f}{\partial x_1} dx_1 + \frac{\partial f}{\partial x_2} dx_2 = 0$$

$$dg = \frac{\partial g}{\partial x_1} dx_1 + \frac{\partial g}{\partial x_2} dx_2 = 0$$

weil  $dx_1, dx_2 \neq 0$ , ergibt sich

$$\frac{\partial f}{\partial x_1} \frac{\partial g}{\partial x_2} - \frac{\partial f}{\partial x_2} \frac{\partial g}{\partial x_1} = 0$$

d. h.

$$\frac{\frac{\partial f}{\partial x_1} \big|_*}{\frac{\partial g}{\partial x_1} \big|_*} = \frac{\frac{\partial f}{\partial x_2} \big|_*}{\frac{\partial g}{\partial x_2} \big|_*} = \lambda$$

dann

$$\frac{\partial f}{\partial x_1} = \lambda \frac{\partial g}{\partial x_1} \quad \frac{\partial f}{\partial x_2} = \lambda \frac{\partial g}{\partial x_2}$$

Es bedeutet

$$\begin{aligned} \frac{\partial f}{\partial x_1} - \lambda \frac{\partial g}{\partial x_1} &= \frac{\partial}{\partial x_1} [f(x_1, x_2) - \lambda g(x_1, x_2)] = 0 \\ \frac{\partial f}{\partial x_2} - \lambda \frac{\partial g}{\partial x_2} &= \frac{\partial}{\partial x_2} [f(x_1, x_2) - \lambda g(x_1, x_2)] = 0 \end{aligned}$$

die Definition der Lagrange-Funktion:


$$L(x_1, x_2, \lambda) = f(x_1, x_2) - \lambda g(x_1, x_2)$$

$\lambda$  heißt Lagrange-Multiplikator.

Zusätzlich:


$$\begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \end{bmatrix} - \lambda \begin{bmatrix} \frac{\partial g}{\partial x_1} \\ \frac{\partial g}{\partial x_2} \end{bmatrix} = \nabla f - \lambda \nabla g = \mathbf{0}$$

Bei der Lösung sind die zwei Vektoren parallel und entgegengesetzt gerichtet.



Es ergibt sich:  $\nabla f(x_1^*, x_2^*) = 0$ ,  $(\Delta \mathbf{x})^T \nabla^2 f(x_1^*, x_2^*) (\Delta \mathbf{x}) \geq 0$

## NLP mit einer Gleichungsnebenbedingung:



Dann


$$\nabla f(x_1^*, x_2^*) - \lambda_1 \nabla g_1(x_1^*, x_2^*) = 0$$

$$(\Delta \mathbf{x})^T [\nabla^2 f(x_1^*, x_2^*) - \lambda_1 \nabla^2 g_1(x_1^*, x_2^*)] (\Delta \mathbf{x}) \geq 0$$

## NLP mit einer Gleichungs- und einer Ungleichungsnebenbedingung:

8


$g_1$  und  $g_2$  sind aktiv,  $\lambda_2 > 0$



$$\nabla f(x_1^*, x_2^*) - \lambda_1 \nabla g_1(x_1^*, x_2^*) - \lambda_2 \nabla g_2(x_1^*, x_2^*) = 0$$

## NLP mit einer Gleichungs- und zwei Ungleichungsnebenbedingungen:

$g_1$  und  $g_2$  sind aktiv,  $\lambda_2 > 0, \lambda_3 = 0$



$$\nabla f(x_1^*, x_2^*) - \lambda_1 \nabla g_1(x_1^*, x_2^*) - \lambda_2 \nabla g_2(x_1^*, x_2^*) - \lambda_3 \nabla g_3(x_1^*, x_2^*) = 0$$



## Minimierung mit einer Gleichungsnebenbedingung

$$\min_{\mathbf{x}} x_1^2 + x_2^2$$

$$\text{mit } x_1 + x_2 = 1$$

$$f(x_1, x_2) = x_1^2 + x_2^2, \quad g(x_1, x_2) = x_1 + x_2 - 1 = 0$$

dann  $\nabla f(x_1, x_2) = [2x_1 \quad 2x_2]^T, \quad \nabla g(x_1, x_2) = [1 \quad 1]^T$

Der Lösungspunkt:

$$x_1^* = x_2^* = \frac{1}{2}, \quad \nabla g^* = [1 \quad 1]^T, \quad \nabla f^* = [1 \quad 1]^T$$



D. h.  $\nabla f^* = \nabla g^*$  also  $\lambda^* = 1 > 0$

Aber man kann auch schreiben  $g(x_1, x_2) = 1 - x_1 - x_2 = 0$ ,

damit  $\nabla g(x_1, x_2) = [-1 \quad -1]^T$ . Der Lösungspunkt bleibt

$$x_1^* = x_2^* = \frac{1}{2}, \text{ daher } \nabla f^* = -\nabla g^*, \quad \lambda^* = -1 < 0.$$

## Grafische Darstellung:



Die Zielfunktion und die Nebenbedingungen sind nichtlineare Funktionen des Variablenvektors.

$$\min_{\mathbf{x}} f(\mathbf{x})$$

$$\text{mit } g_j(\mathbf{x}) = 0 \quad j = 1, \dots, m \quad (\text{I})$$

$$g_j(\mathbf{x}) \geq 0 \quad j = m + 1, \dots, m + r \quad (\text{II})$$

$$x_{i \min} \leq x_i \leq x_{i \max} \quad i = 1, \dots, N$$

## Karush-Kuhn-Tucker-Bedingungen:

An der Lösung  $\mathbf{x} = \mathbf{x}^*$  müssen die folgenden Bedingungen erfüllt werden:

$$\nabla L(\mathbf{x}^*, \boldsymbol{\lambda}^*) = 0 \quad (\text{I})$$

$$g_j(\mathbf{x}^*) = 0 \quad j = 1, \dots, m \quad (\text{II})$$

$$g_j(\mathbf{x}^*) \geq 0 \quad j = m + 1, \dots, m + r \quad (\text{II})$$

$$\lambda_j^* g_j(\mathbf{x}^*) = 0, \quad \lambda_j^* \geq 0 \quad j = m + 1, \dots, m + r$$

$$\nabla g_j(\mathbf{x}^*) \text{ voneinander unabhängig } j \in A$$

$$(\Delta \mathbf{x})^T [\nabla^2 L(\mathbf{x}^*, \boldsymbol{\lambda}^*)] (\Delta \mathbf{x}) \geq 0$$

# Quadratische Programmierung mit linearen Gleichungsnebenbedingungen

## Das QPE-Problem

$$\min_{\mathbf{x}} \left\{ f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{c}^T \mathbf{x} \right\}$$
$$\text{mit } \mathbf{g}(\mathbf{x}) = \mathbf{A} \mathbf{x} - \mathbf{b} = \mathbf{0}$$

wobei  $\mathbf{Q} = \mathbf{Q}^T \in R^{n \times n}$  eine positiv definite Hesse-Matrix ist und:

$$\mathbf{x}, \mathbf{c} \in R^n$$

$$\mathbf{A} \in R^{m \times n}$$

$$\mathbf{g}(\mathbf{x}), \mathbf{b} \in R^m$$

$$\text{Rang}(\mathbf{A}) = m$$

$n$  : Variablen

$m$ : Gleichungen

## Analytische Lösung

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

KKT-Bedingungen: 
$$\begin{aligned} \nabla L &= \mathbf{Q}\mathbf{x} + \mathbf{c} - \mathbf{A}^T \boldsymbol{\lambda} = \mathbf{0} \\ \mathbf{A}\mathbf{x} - \mathbf{b} &= \mathbf{0} \end{aligned}$$

Hieraus folgt 
$$\begin{aligned} \mathbf{Q}\mathbf{x} - \mathbf{A}^T \boldsymbol{\lambda} &= -\mathbf{c} \\ \mathbf{A}\mathbf{x} &= \mathbf{b} \end{aligned}$$


d. h. 
$$\begin{bmatrix} \mathbf{Q} & \mathbf{A}^T \\ \mathbf{A} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{x} \\ -\boldsymbol{\lambda} \end{bmatrix} = \begin{bmatrix} -\mathbf{c} \\ \mathbf{b} \end{bmatrix}$$

Wenn  $\mathbf{Q}$  positiv definit ist und  $\text{Rang}(\mathbf{A}) = m$

$$\begin{bmatrix} \mathbf{x}^* \\ -\boldsymbol{\lambda}^* \end{bmatrix} = \begin{bmatrix} \mathbf{Q} & \mathbf{A}^T \\ \mathbf{A} & \mathbf{0} \end{bmatrix}^{-1} \begin{bmatrix} -\mathbf{c} \\ \mathbf{b} \end{bmatrix}$$

$$\mathbf{x}^* = -\mathbf{Q}^{-1}\mathbf{c} + \mathbf{Q}^{-1}\mathbf{A}^T(\mathbf{A}\mathbf{Q}^{-1}\mathbf{A}^T)^{-1}(\mathbf{A}\mathbf{Q}^{-1}\mathbf{c} + \mathbf{b})$$

$$\boldsymbol{\lambda}^* = (\mathbf{A}\mathbf{Q}^{-1}\mathbf{A}^T)^{-1}(\mathbf{A}\mathbf{Q}^{-1}\mathbf{c} + \mathbf{b})$$



**Probleme:** 1) Die Daten sind nicht konsistent.  
2) Es führt zu Streit.

**Lösung:** Optimierung (Messwertvalidierung)

$$\min_{F_1, F_2, F_3} \left( \frac{F_1 - F_1^M}{\sigma_1} \right)^2 + \left( \frac{F_2 - F_2^M}{\sigma_2} \right)^2 + \left( \frac{F_3 - F_3^M}{\sigma_3} \right)^2$$

mit  $F_1 + F_2 = F_3$

wobei die Standardabweichung der Messgeräte:

$$\sigma_1 = 0.1 \text{ m}^3/\text{h}$$

$$\sigma_2 = 0.2 \text{ m}^3/\text{h}$$

$$\sigma_3 = 0.3 \text{ m}^3/\text{h}$$

## Die Lagrange-Funktion:

$$L(F_1, F_2, F_3, \lambda) = \left( \frac{F_1 - F_1^M}{\sigma_1} \right)^2 + \left( \frac{F_2 - F_2^M}{\sigma_2} \right)^2 + \left( \frac{F_3 - F_3^M}{\sigma_3} \right)^2 - \lambda(F_1 + F_2 - F_3)$$

Nach der Optimalitätsbedingung:

$$\frac{\partial L}{\partial F_1} = 2 \left( \frac{F_1 - F_1^M}{\sigma_1^2} \right) - \lambda = 0$$

$$\frac{\partial L}{\partial F_2} = 2 \left( \frac{F_2 - F_2^M}{\sigma_2^2} \right) - \lambda = 0$$

$$\frac{\partial L}{\partial F_3} = 2 \left( \frac{F_3 - F_3^M}{\sigma_3^2} \right) - \lambda = 0$$

$$F_1 + F_2 - F_3 = 0$$

## Die validierte Messung:

$$F_1 = F_1^M + \frac{\sigma_1^2 (F_3^M - F_1^M - F_2^M)}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} = 6.4 \text{ m}^3/\text{h}$$

$$F_2 = F_2^M + \frac{\sigma_2^2 (F_3^M - F_1^M - F_2^M)}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} = 14.3 \text{ m}^3/\text{h}$$

$$F_3 = F_3^M + \frac{\sigma_3^2 (F_1^M + F_2^M - F_3^M)}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} = 20.7 \text{ m}^3/\text{h}$$

## Erwartungswert dieser Variablen:

$$\mu_1^V = E(F_1) = E \left[ F_1^M + \frac{\sigma_1^2 (F_3^M - F_1^M - F_2^M)}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} \right] = \mu_1 + \frac{\sigma_1^2 (\mu_3 - \mu_1 - \mu_2)}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}$$



## Varianz der Variablen:

$$(\sigma_1^V)^2 = E[(F_1 - \mu_1^V)^2] = E\left[F_1^M - \mu_1 + \frac{\sigma_1^2 \{(F_3^M - \mu_3) - (F_1^M - \mu_2) - (F_2^M - \mu_1)\}}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}\right]^2$$

Daraus ergibt sich:

$$(\sigma_1^V)^2 = \frac{\sigma_1^2(\sigma_2^2 + \sigma_3^2)}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}$$

dann ist die validierte Standardabweichung:

$$\sigma_1^V = \sigma_1 \sqrt{\frac{\sigma_2^2 + \sigma_3^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}} = 0.096$$

$$\sigma_2^V = \sigma_2 \sqrt{\frac{\sigma_1^2 + \sigma_3^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}} = 0.169$$

$$\sigma_3^V = \sigma_3 \sqrt{\frac{\sigma_1^2 + \sigma_2^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}} = 0.179$$

Das QP-Problem:

$$\begin{aligned} \min_{\mathbf{x}} f(\mathbf{x}) &= \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{c}^T \mathbf{x} \\ \text{mit } g_i(\mathbf{x}) &= \mathbf{a}_i^T \mathbf{x} - b_i = 0 \quad i \in I \\ g_i(\mathbf{x}) &= \mathbf{a}_i^T \mathbf{x} - b_i \geq 0 \quad i \in II \end{aligned}$$

Lagrange-Funktion:

$$\begin{aligned} L(\mathbf{x}, \boldsymbol{\lambda}) &= f(\mathbf{x}) - \boldsymbol{\lambda}^T (\mathbf{A} \mathbf{x} - \mathbf{b}) \\ &= f(\mathbf{x}) - \sum_{i=1}^{m+r} \lambda_i (\mathbf{a}_i^T \mathbf{x} - b_i) \end{aligned}$$

Da das Problem auch Ungleichungsnebenbedingungen besitzt, kann es nicht analytisch gelöst werden. Es wird mit dem sog. „**Aktive-Restriktionen-Verfahren**“ (**active set method**) numerisch iterativ gelöst.

Man fängt mit  $\mathbf{x}^0$  an, berechnet die Änderung  $\mathbf{d}$  und dann

$$\mathbf{x}^1 = \mathbf{x}^0 + \mathbf{d}$$

**Definition 1:** Ein Punkt  $\mathbf{x}^k$  ist zulässig, wenn er für die beiden Nebenbedingungen gültig ist.

**Definition 2:** Die aktive Menge der Restriktionen in der Iteration  $k$  ist

$$A^k = \{j \in II, \quad g_j(\mathbf{x}^k) = \mathbf{a}_j^T \mathbf{x}^k - b_j = 0\}$$

Taylor-Entwicklung von  $\mathbf{x}^k$  mit der Änderung  $\mathbf{d}$

$$f(\mathbf{x}^k + \mathbf{d}) = f(\mathbf{x}^k) + (\mathbf{Q}\mathbf{x}^k + \mathbf{c})^T \mathbf{d} + \frac{1}{2} \mathbf{d}^T \mathbf{Q} \mathbf{d}$$

$$g_i(\mathbf{x}^k + \mathbf{d}) = g_i(\mathbf{x}^k) + \mathbf{a}_i^T \mathbf{d} \quad i \in I \cup II$$

d. h. 
$$L_{xx}^2 = \mathbf{Q}, \quad \nabla f(\mathbf{x}^k) = \mathbf{Q}\mathbf{x}^k + \mathbf{c}, \quad \nabla g_i = \mathbf{a}_i$$

Das neue Optimierungsproblem:

$$\min_{\mathbf{d}} \quad \frac{1}{2} \mathbf{d}^T \mathbf{Q} \mathbf{d} + (\mathbf{Q}\mathbf{x}^k + \mathbf{c})^T \mathbf{d}$$

$$\text{mit } \mathbf{a}_i^T \mathbf{d} = 0 \quad i \in A^k$$

$$g_i(\mathbf{x}^k) + \mathbf{a}_i^T \mathbf{d} > 0 \quad i \notin A^k$$

## Die Zielfunktion:

20

$$\begin{aligned} f(\mathbf{d} + \mathbf{x}^k) &= \frac{1}{2}(\mathbf{d} + \mathbf{x}^k)^T \mathbf{Q}(\mathbf{d} + \mathbf{x}^k) + \mathbf{c}^T(\mathbf{d} + \mathbf{x}^k) \\ &= \frac{1}{2}\mathbf{d}^T \mathbf{Q} \mathbf{d} + \frac{1}{2}\mathbf{d}^T \mathbf{Q} \mathbf{x}^k + \frac{1}{2}(\mathbf{x}^k)^T \mathbf{Q} \mathbf{d} + \frac{1}{2}(\mathbf{x}^k)^T \mathbf{Q} \mathbf{x}^k + \mathbf{c}^T \mathbf{d} + \mathbf{c}^T \mathbf{x}^k \\ &= \frac{1}{2}\mathbf{d}^T \mathbf{Q} \mathbf{d} + (\mathbf{Q} \mathbf{x}^k + \mathbf{c})^T \mathbf{d} + \frac{1}{2}(\mathbf{x}^k)^T \mathbf{Q} \mathbf{x}^k + \mathbf{c}^T \mathbf{x}^k \end{aligned}$$

## Die Nebenbedingungen:

$$\begin{aligned} g_i(\mathbf{d} + \mathbf{x}^k) &= \mathbf{a}_i^T(\mathbf{d} + \mathbf{x}^k) - b_i \\ &= \mathbf{a}_i^T \mathbf{d} + \mathbf{a}_i^T \mathbf{x}^k - b_i = \mathbf{a}_i^T \mathbf{d} + g_i(\mathbf{x}^k) > 0 \end{aligned}$$

## Das Optimierungsproblem:

$$\begin{aligned} \min_{\mathbf{d}} \quad & \frac{1}{2}\mathbf{d}^T \mathbf{Q} \mathbf{d} + (\mathbf{Q} \mathbf{x}^k + \mathbf{c})^T \mathbf{d} \\ \text{mit} \quad & \mathbf{a}_i^T \mathbf{d} = 0 \quad i \in A^k \\ & \mathbf{a}_i^T \mathbf{d} + g_i(\mathbf{x}^k) \geq 0 \quad i \notin A^k \end{aligned}$$

- 1) Einen zulässigen Punkt  $\mathbf{x}^0$  auswählen. Die entsprechende Menge der aktiven Restriktionen identifizieren,  $k = 0$
- 2) Das folgende QPE-Problem lösen

$$\begin{aligned} \min_{\mathbf{d}} \quad & \frac{1}{2} \mathbf{d}^T \mathbf{Q} \mathbf{d} + (\mathbf{Q} \mathbf{x}^k + \mathbf{c})^T \mathbf{d} \\ \text{mit} \quad & \mathbf{a}_i^T \mathbf{d} = 0 \quad i \in A^k \end{aligned}$$

wenn  $\mathbf{d} = \mathbf{0}$ , GOTO 3)

wenn  $\mathbf{d} \neq \mathbf{0}$ , GOTO 4)

- 3) Lagrange-Multiplikatoren prüfen:

$$L(\mathbf{d}, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{d}^T \mathbf{Q} \mathbf{d} + (\mathbf{Q} \mathbf{x}^k + \mathbf{c})^T \mathbf{d} - \boldsymbol{\lambda}^T (\mathbf{A}_i \mathbf{d})$$

$$\nabla_{\mathbf{d}} L(\mathbf{d}, \boldsymbol{\lambda}) = \mathbf{Q} \mathbf{d} + \mathbf{Q} \mathbf{x}^k + \mathbf{c} - \mathbf{A}_i^T \boldsymbol{\lambda} = \mathbf{0}$$

$$\nabla L(\mathbf{0}, \boldsymbol{\lambda}) = \mathbf{Q} \mathbf{x}^k + \mathbf{c} - \mathbf{A}_i^T \boldsymbol{\lambda} = \mathbf{0}$$

$$\mathbf{Q} \mathbf{x}^k + \mathbf{c} = \sum_i \lambda_i \mathbf{a}_i$$

$$\lambda_j = \min\{\lambda_i, i \in A^k\}$$

wenn  $\lambda_j \geq 0$ , dann  $x^* = x^k$ , STOP

wenn  $\lambda_j < 0$ , dann  $A^k = A^k - \{j\}$ , GOTO 2)

#### 4) Modifikation des berechneten Änderungsschritts

Für die nicht aktiven Nebenbedingungen wird benötigt:

$$g_i(\mathbf{x}^k + \mathbf{d}) = g_i(\mathbf{x}^k) + \mathbf{a}_i^T \mathbf{d} > 0 \quad i \notin A^k$$

weil  $x^k$  zulässig ist, dann  $g_i(\mathbf{x}^k) > 0$ .

Wenn  $\mathbf{a}_i^T \mathbf{d} \geq 0$ , braucht  $\mathbf{d}$  nicht zu modifizieren.

Wenn  $\mathbf{a}_i^T \mathbf{d} < 0$ , dann  $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha \mathbf{d} \quad 0 \leq \alpha \leq 1$

d. h.

$$\mathbf{a}_i^T (\mathbf{x}^k + \alpha \mathbf{d}) - b_i > 0$$

$$\mathbf{a}_i^T \mathbf{x}^k + \alpha \mathbf{a}_i^T \mathbf{d} > b_i$$

$$\alpha \mathbf{a}_i^T \mathbf{d} > b_i - \mathbf{a}_i^T \mathbf{x}^k$$

$$\alpha < \frac{b_i - \mathbf{a}_i^T \mathbf{x}^k}{\mathbf{a}_i^T \mathbf{d}}$$

wenn  $\alpha \geq 1$ , dann  $\alpha = 1$  und  $A^{k+1} = A^k$   
 wenn  $\alpha < 1$ , dann

$$\alpha_p = \min \left\{ \frac{b_i - \mathbf{a}_i^T \mathbf{x}^k}{\mathbf{a}_i^T \mathbf{d}}, \quad i \notin A^k \right\}$$

Eine neue Ungleichungsnebenbedingung ist aktiv.

$$A^{k+1} = A^k \cup \{p\}$$

5)  $k = k + 1$ , GOTO 2)

Beispiel:

$$\min_{\mathbf{x}} f(\mathbf{x}) = x_1^2 + x_2^2 - 4x_1 - 5x_2 + 2$$

$$\text{mit } g_1(\mathbf{x}) = -2x_1 - x_2 + 2 \geq 0 \quad (1)$$

$$g_2(\mathbf{x}) = x_1 \geq 0 \quad (2)$$

$$g_3(\mathbf{x}) = x_2 \geq 0 \quad (3)$$

Standardform der Zielfunktion:

$$f(\mathbf{x}) = \frac{1}{2} \begin{bmatrix} x_1 & x_2 \end{bmatrix} \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} -4 & -5 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + 2$$

$$\mathbf{Q} = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \quad \mathbf{c}^T = \begin{bmatrix} -4 & -5 \end{bmatrix}$$

Die Nebenbedingungen:

$$\begin{bmatrix} g_1(\mathbf{x}) \\ g_2(\mathbf{x}) \\ g_3(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} -2 & -1 \\ 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 2 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} \mathbf{a}_1^T \\ \mathbf{a}_2^T \\ \mathbf{a}_3^T \end{bmatrix} \mathbf{x} + \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix} \geq \mathbf{0}$$

Gradienten der Zielfunktion:

$$\nabla f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \end{bmatrix} = \begin{bmatrix} 2x_1 - 4 \\ 2x_2 - 5 \end{bmatrix}$$



Gradienten der Nebenbedingungen:

$$\nabla g_1(\mathbf{x}) = \begin{bmatrix} -2 \\ -1 \end{bmatrix} \quad \nabla g_2(\mathbf{x}) = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \nabla g_3(\mathbf{x}) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

## Lösung des Problems:

**Step 1:** Ein zulässiger Schätzpunkt:

$$\mathbf{x}^0 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \quad A^0 = \{2, 3\}, \quad k = 0$$

**Step 2:**

$$\begin{aligned} \min_{\mathbf{d}} \quad & \frac{1}{2} \mathbf{d}^T \mathbf{Q} \mathbf{d} + (\mathbf{Q} \mathbf{x}^k + \mathbf{c})^T \mathbf{d} \\ \text{mit} \quad & \mathbf{a}_i^T \mathbf{d} = 0 \quad i \in A^k \end{aligned}$$

Die Nebenbedingungen:

$$i = 2 \quad \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} = 0$$

$$i = 3 \quad \begin{bmatrix} 0 & 1 \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} = 0$$

$$\text{d. h.} \quad d_1 = d_2 = 0$$

**Step 3:**  $\lambda$  prüfen durch

$$\mathbf{Q}\mathbf{x}^k + \mathbf{C} = \sum_i \lambda_i \mathbf{a}_i$$

d. h.

$$\begin{bmatrix} -4 \\ -5 \end{bmatrix} = \lambda_2 \begin{bmatrix} 1 \\ 0 \end{bmatrix} + \lambda_3 \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

Ergibt sich

$$\lambda_2 = -4 \quad \lambda_3 = -5$$

dann

$$\lambda_j = \min\{-4, -5\} = -5 \quad j = 3$$

$$A^k = A^k - \{j\} = \{2\}$$

**Step 2:** Die Nebenbedingung:

$$i = 2 \quad \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} = 0 \quad d_1 = 0$$

Das Optimierungsproblem:

$$\begin{aligned} \min \quad & \frac{1}{2} \begin{bmatrix} 0 & d_2 \end{bmatrix} \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \begin{bmatrix} 0 \\ d_2 \end{bmatrix} + \begin{bmatrix} -4 & -5 \end{bmatrix} \begin{bmatrix} 0 \\ d_2 \end{bmatrix} \\ & = \min d_2^2 - 5d_2 \end{aligned}$$

Die Lösung  $d_2 = 2,5$  und dann  $\mathbf{d} = \begin{bmatrix} 0 \\ 2,5 \end{bmatrix}$

### Step 4:

$$\alpha_p = \min \left\{ \frac{b_i - \mathbf{a}_i^T \mathbf{x}^k}{\mathbf{a}_i^T \mathbf{d}}, \quad i \notin A^k \right\}$$

$$i = 1 \quad \mathbf{a}_1^T \mathbf{d} = \begin{bmatrix} -2 & -1 \end{bmatrix} \begin{bmatrix} 0 \\ 2,5 \end{bmatrix} = -2,5 < 0$$

$$\alpha = \frac{-2}{-2,5} = 0,8$$

$$i = 3 \quad \mathbf{a}_3^T \mathbf{d} = \begin{bmatrix} 0 & 1 \end{bmatrix} \begin{bmatrix} 0 \\ 2,5 \end{bmatrix} = 2,5 > 0$$

dann  $p = 1, \quad A^{k+1} = A^k \cup \{1\} = \{1, 2\}$

**Step 5:**  $k = 1$

$$\mathbf{x}^1 = \mathbf{x}^0 + \alpha \mathbf{d} = 0,8 \begin{bmatrix} 0 \\ 2,5 \end{bmatrix} = \begin{bmatrix} 0 \\ 2 \end{bmatrix}$$

GOTO Step 2

**Die Lösung des Problems:**

$$\mathbf{x}^* = \begin{bmatrix} 0,2 \\ 1,6 \end{bmatrix} \quad \boldsymbol{\lambda}^* = \begin{bmatrix} 1,8 \\ 0 \\ 0 \end{bmatrix}$$

**Grafische Darstellung der Lösung:**


$$\min_{\mathbf{x}} f(\mathbf{x}) = x_1^2 + x_2^2 - 4x_1 - 5x_2 + 2$$

$$\text{mit } g_1(\mathbf{x}) = -2x_1 - x_2 + 2 \geq 0 \quad (1)$$

$$g_2(\mathbf{x}) = x_1 \geq 0 \quad (2)$$

$$g_3(\mathbf{x}) = x_2 \geq 0 \quad (3)$$

## Grafische Darstellung:




# Optimale Betriebsplanung eines Wasserwerks für 24 Stunden

30

## Diskrete Formulierung ( $k = 1, \dots, 24$ ):

- Wasserbedarf  $F_{out}(k)$  ist bekannt.
- Betriebskosten sind eine Funktion der Zeit  $c(k)$ , d. h. sie sind unterschiedlich am Tag und in der Nacht.
- Was ist die optimale Fahrweise für  $F_{in}(k)$ ?



$$\min_{F_{in}} \sum_{k=1}^{24} c(k) F_{in}(k) + \beta \sum_{k=1}^{24} [F_{in}(k) - F_{in}(k-1)]^2$$

$$\text{mit } L(k+1) = L(k) + \frac{1}{A} [F_{in}(k) - F_{out}(k)]$$

$$L(24) = L(0) = L_0$$

$$L_{min} \leq L(k) \leq L_{max} \quad k = 1, \dots, 24$$

$$F_{min} \leq F_{in}(k) \leq F_{max}$$

## Parameter im Problem:

- Wasserbedarf (m<sup>3</sup>/h):  $F_{out}(k) = 500 - (16 - k)^2$
- Kostenfunktion (\$/m<sup>3</sup>):  $c(k) = \exp[-(k - 12)^2/72]$
- Tankfläche (m<sup>2</sup>):  $A = 200$
- Initialfüllstand (m):  $L_0 = 5$
- Grenze des Füllstands (m):  $L_{min} = 2, L_{max} = 8$
- Stromgrenze (m<sup>3</sup>/h):  $F_{in,min} = 200, F_{in,max} = 700$
- Gewichtungsfaktor:  $\beta = 0.01$

## Variablen:

- Steuervariablen:  $F_{in}(k) \quad k = 1, \dots, 24$
- Zustandsvariablen:  $L(k) \quad k = 1, \dots, 24$

## Restriktionen:





### Gleichungsnebenbedingungen:

$$L(k+1) = L(k) + \frac{1}{A} [F_{in}(k) - F_{out}(k)] \quad k = 1, \dots, 24$$
$$L(24) = L(0) = L_0$$

### Ungleichungsnebenbedingungen:

$$L_{min} \leq L(k) \leq L_{max} \quad k = 1, \dots, 24$$
$$F_{min} \leq F_{in}(k) \leq F_{max} \quad k = 1, \dots, 24$$





- Kosten beim optimalen Fahrplan: 5784.24 \$
- Kosten beim konventionellen Fahrplan: 6558.07 \$

Mit Gleichungsnebenbedingungen

$$\begin{aligned} \min f(\mathbf{x}) \\ \mathbf{g}(\mathbf{x}) = \mathbf{0} \end{aligned}$$

Lagrange-Funktion:

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

KKT-Bedingungen:

$$\begin{aligned} \nabla L(\mathbf{x}, \boldsymbol{\lambda}) = \nabla f(\mathbf{x}) - [\nabla \mathbf{g}(\mathbf{x})]^T \boldsymbol{\lambda} &= \mathbf{0} \\ \mathbf{g}(\mathbf{x}) &= \mathbf{0} \end{aligned}$$

Taylor-Entwicklung erster Ordnung von:  $\mathbf{x}^k, \boldsymbol{\lambda}^k$

$$\nabla L(\mathbf{x}^k, \boldsymbol{\lambda}^k) + \nabla^2 L(\mathbf{x}^k, \boldsymbol{\lambda}^k) \Delta \mathbf{x}^k - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \Delta \boldsymbol{\lambda}^k = \mathbf{0}$$

d. h.

$$\nabla f(\mathbf{x}^k) - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \boldsymbol{\lambda}^k + \nabla_{\mathbf{x}}^2 L(\mathbf{x}^k, \boldsymbol{\lambda}^k) \Delta \mathbf{x}^k - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \Delta \boldsymbol{\lambda}^k = \mathbf{0}$$

und

$$\mathbf{g}(\mathbf{x}^k) + [\nabla \mathbf{g}(\mathbf{x}^k)]^T \Delta \mathbf{x}^k = \mathbf{0}$$

d. h.

$$\begin{bmatrix} \nabla^2 L(\mathbf{x}^k, \boldsymbol{\lambda}^k) & [\nabla \mathbf{g}(\mathbf{x}^k)]^T \\ \nabla \mathbf{g}(\mathbf{x}^k) & 0 \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x}^k \\ -\Delta \boldsymbol{\lambda}^k \end{bmatrix} = \begin{bmatrix} -\nabla f(\mathbf{x}^k) + [\nabla \mathbf{g}(\mathbf{x}^k)]^T \boldsymbol{\lambda}^k \\ -\mathbf{g}(\mathbf{x}^k) \end{bmatrix}$$

Die Lösung des Gleichungssystems ist die Lösung des folgenden QPE-Problems mit  $\mathbf{d} = \Delta \mathbf{x}^k$

$$\min_{\mathbf{d}} \frac{1}{2} \mathbf{d}^T [\nabla^2 L(\mathbf{x}^k, \boldsymbol{\lambda}^k)] \mathbf{d} + [\nabla f(\mathbf{x}^k)]^T \mathbf{d}$$

mit  $\nabla \mathbf{g}(\mathbf{x}^k) \mathbf{d} + \mathbf{g}(\mathbf{x}^k) = \mathbf{0}$

$$\begin{aligned}\tilde{L}(\mathbf{d}, \boldsymbol{\mu}) = & \frac{1}{2} \mathbf{d}^T L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d} + [\nabla f(\mathbf{x}^k)]^T \mathbf{d} \\ & - \boldsymbol{\mu}^T \{ \mathbf{g}(\mathbf{x}^k) + \nabla \mathbf{g}(\mathbf{x}^k) \mathbf{d} \}\end{aligned}$$

KKT-Bedingungen:

$$\begin{aligned}\nabla_{\mathbf{d}} \tilde{L}(\mathbf{d}, \boldsymbol{\mu}) = & L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d} + \nabla f(\mathbf{x}^k) - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \boldsymbol{\mu} = \mathbf{0} \\ \mathbf{g}(\mathbf{x}^k) + & [\nabla \mathbf{g}(\mathbf{x}^k)]^T \mathbf{d} = \mathbf{0}\end{aligned}$$

nun setzt man

$$\mathbf{d} = \Delta \mathbf{x}, \quad \boldsymbol{\mu} = \Delta \boldsymbol{\lambda} + \boldsymbol{\lambda}^k = \boldsymbol{\lambda}^{k+1}$$

dann

$$\begin{aligned}\nabla \tilde{L}(\mathbf{d}, \boldsymbol{\mu}) = & L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) \Delta \mathbf{x} + \nabla f(\mathbf{x}^k) - [\nabla \mathbf{g}(\mathbf{x}^k)]^T (\Delta \boldsymbol{\lambda} + \boldsymbol{\lambda}^k) \\ = & L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) \Delta \mathbf{x} + \nabla f(\mathbf{x}^k) - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \boldsymbol{\lambda}^k - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \Delta \boldsymbol{\lambda} \\ = & L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) \Delta \mathbf{x} + \nabla L(\mathbf{x}^k, \boldsymbol{\lambda}^k) - [\nabla \mathbf{g}(\mathbf{x}^k)]^T \Delta \boldsymbol{\lambda} = \mathbf{0}\end{aligned}$$

und 
$$\mathbf{g}(\mathbf{x}^k) + \nabla \mathbf{g}(\mathbf{x}^k) \Delta \mathbf{x} = \mathbf{0}$$

d. h. beim Problem mit Gleichungsnebenbedingungen kann man eine Änderung  $\mathbf{d}$  durch Lösung des folgenden Problems erhalten:

$$\begin{aligned} \min_{\mathbf{d}} \quad & \frac{1}{2} \mathbf{d}^T L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d} + [\nabla f(\mathbf{x}^k)]^T \mathbf{d} \\ \text{mit} \quad & \mathbf{g}(\mathbf{x}^k) + \nabla \mathbf{g}(\mathbf{x}^k) \mathbf{d} = \mathbf{0} \\ & \mathbf{x}^{k+1} = \mathbf{x}^k + \mathbf{d} \end{aligned}$$

### Beispiel:

$$\begin{aligned} \min_{\mathbf{x}} \quad & f(\mathbf{x}) = (x_1 - 5)^2 + x_2^2 \\ \text{mit} \quad & g(\mathbf{x}) = x_2 - x_1^2 = 0 \end{aligned}$$

Die Lagrange-Funktion:

$$L(\mathbf{x}, \lambda) = (x_1 - 5)^2 + x_2^2 - \lambda(x_2 - x_1^2)$$

Die Hesse-Matrix von der Lagrange-Funktion und der Gradientenvektor von der Zielfunktion:

$$L_{xx}^2(\mathbf{x}^k, \boldsymbol{\lambda}^k) = \begin{bmatrix} 2 + 2\lambda^k & 0 \\ 0 & 2 \end{bmatrix} \quad \nabla f(\mathbf{x}^k) = [2(x_1^k - 5) \quad 2x_2^k]^T$$

Das QPE-Problem:

$$\min_{d_1, d_2} \frac{1}{2} [d_1 \quad d_2] \begin{bmatrix} 2 + 2\lambda^k & 0 \\ 0 & 2 \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} + [2(x_1^k - 5) \quad 2x_2^k] \begin{bmatrix} d_1 \\ d_2 \end{bmatrix}$$

$$\text{mit} \quad [-2x_1^k \quad 1] \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} + x_2^k - (x_1^k)^2 = 0$$

$$[\nabla \mathbf{g}(\mathbf{x}^k)]^T \mathbf{d} + \mathbf{g}(\mathbf{x}^k) = \mathbf{0}$$

Die Lagrange-Funktion dieses Problems:

$$\begin{aligned} \tilde{L}(d_1, d_2, \mu) = & (1 + \lambda^k)d_1^2 + d_2^2 + 2(x_1^k - 5)d_1 + 2x_2^k d_2 \\ & - \mu[-2x_1^k d_1 + d_2 + x_2^k - (x_1^k)^2] \end{aligned}$$

$$\frac{\partial \tilde{L}}{\partial d_1} = 2(1 + \lambda^k)d_1 + 2(x_1^k - 5) + 2\mu x_1^k = 0$$

$$\frac{\partial \tilde{L}}{\partial d_2} = 2d_2 + 2x_2^k - \mu = 0$$

$$-2x_1^k d_1 + d_2 + x_2^k - (x_1^k)^2 = 0$$

Fängt man mit  $x_1^0 = x_2^0 = 5$ ,  $\lambda^0 = 0$  an:

$k$	$x_1^k$	$x_2^k$	$\lambda^k$	$d_1^k$	$d_2^k$	$f^k$	$g^k$
1	5.000000	5.000000	0.000000	-2.475248	-4.752476	25.000000	-20.000000
2	2.524752	0.247524	0.495049	-1.100755	0.568582	6.188119	-6.126850
3	1.423997	0.816106	1.632212	-0.204692	0.628699	13.453825	-1.211662
4	1.219305	1.444805	2.889610	0.015779	0.080377	16.381119	-0.041899
5	1.235083	1.525182	3.050364	-0.000310	-0.000518	16.500778	-0.000249
6	1.234773	1.524664	3.049328	0.000000	0.000000	16.501535	0.000000

Die Suchrichtung in jeder Iteration  $\mathbf{p}^k$  zur Reduktion der Zielfunktion, aber beim neuen Punkt werden die Nebenbedingungen verletzt.

### Wie groß soll die Schrittlänge sein?

Ein Kompromiss zwischen dem Zielfunktionsabstieg und der Zulässigkeit wird durch Line-Search gefunden.

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha \mathbf{d}^k$$

Man definiert sog. Merit Function (Straffunktion):

$$\begin{aligned} \min_{\mathbf{x}} \varphi(\mathbf{x}^{k+1}) &= \varphi(\mathbf{x}^k + \alpha \mathbf{d}^k) \\ &= f(\mathbf{x}^k + \alpha \mathbf{d}^k) + \frac{1}{\mu} \sum_{j=1}^m |g_j(\mathbf{x}^k + \alpha \mathbf{d}^k)| \end{aligned}$$

oder

$$\begin{aligned} \min_{\mathbf{x}} \varphi(\mathbf{x}^{k+1}) &= f(\mathbf{x}^k + \alpha \mathbf{d}^k) - \sum_{j=1}^m \lambda_j g_j(\mathbf{x}^k + \alpha \mathbf{d}^k) \\ &\quad + \frac{1}{\mu} \sum_{j=1}^m [g_j(\mathbf{x}^k + \alpha \mathbf{d}^k)]^2 \end{aligned}$$



# Algorithmus Line-Search-SQP (Sequentielle Quadratische Programmierung)

## Nur mit Gleichungsnebenbedingungen

- Schritt 1:  $k = 0$ , Vorgabe Schätzwerte  $\mathbf{x}^0, \boldsymbol{\lambda}^0$  ( $\mathbf{x}^0$  nicht unbedingt zulässig).
- Schritt 2: In Iteration  $k$ , Berechnung des Gradientenvektors  $\nabla f(\mathbf{x}^k)$  und Approximation der Hesse-Matrix  $\mathbf{H}_L(\mathbf{x}^k, \boldsymbol{\lambda}^k)$  mit der BFGS-Formel.
- Schritt 3: Lösung des QPE-Problems

$$\min_{\mathbf{d}} \frac{1}{2} \mathbf{d}^T \mathbf{H}_L(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d} + [\nabla f(\mathbf{x}^k)]^T \mathbf{d}$$

$$\text{mit } \mathbf{g}(\mathbf{x}^k) + [\nabla \mathbf{g}(\mathbf{x}^k)]^T \mathbf{d} = \mathbf{0}$$

Durch analytische Lösung erhält man  $\mathbf{d}^*, \boldsymbol{\mu}^*$ .

Schritt 4: Wenn die Optimalitätsbedingungen erfüllt sind, STOP.  
Ansonsten geht zu Schritt 5.

Schritt 5: Line Search zur Ermittlung  $\alpha$ .

Schritt 6:  $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha \mathbf{d}^*, \boldsymbol{\lambda}^{k+1} = \boldsymbol{\mu}^*$

Schritt 7:  $k \leftarrow k + 1$ , Fortschritt mit Schritt 2.

# Sequentielle quadratische Programmierung (das SQP-Verfahren)

43

Problemdarstellung:

$$\min_{\mathbf{x}} f(\mathbf{x})$$

$$\text{mit } g_i(\mathbf{x}) = 0 \quad i = 1, \dots, m$$

$$g_i(\mathbf{x}) \geq 0 \quad i = m + 1, \dots, m + r$$

$$x_{\min j} \leq x_j \leq x_{\max j} \quad j = 1, \dots, n$$

$f(\mathbf{x}), g_i(\mathbf{x})$  sind nichtlineare Funktionen, zusätzlich

$$g_{m+r+j} = x_{\max j} - x_j \geq 0 \quad j = 1, \dots, n$$

$$g_{m+r+n+j} = x_j - x_{\min j} \geq 0 \quad j = 1, \dots, n$$

Lagrange-Funktion:

$$L(\mathbf{x}, \boldsymbol{\lambda}) = f(\mathbf{x}) - \sum_{i=1}^{m+r+2n} \lambda_i g_i(\mathbf{x})$$

Taylor-Entwicklung von  $\mathbf{x}^k$

$$L(\mathbf{x}^k + \mathbf{d}) = f(\mathbf{x}^k) + [\nabla f(\mathbf{x}^k)]^T \mathbf{d} + \frac{1}{2} \mathbf{d}^T \mathbf{H}_L(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d}$$

$$g_i(\mathbf{x}^k + \mathbf{d}) = g_i(\mathbf{x}^k) + [\nabla f(\mathbf{x}^k)]^T \mathbf{d} [\nabla g_i(\mathbf{x}^k)]^T \mathbf{d}$$

$\mathbf{H}(\mathbf{x}^k, \boldsymbol{\lambda}^k)$  ist eine positive definite Approximation der Hesse-Matrix von  $L(\mathbf{x}, \boldsymbol{\lambda})$ .

Nun sieht das Optimierungsproblem wie folgt aus:

$$\min_{\mathbf{d}} \frac{1}{2} \mathbf{d}^T \mathbf{H}(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d} + [\nabla f(\mathbf{x}^k)]^T \mathbf{d}$$

$$\text{mit } g_i(\mathbf{x}^k) + \nabla g_i(\mathbf{x}^k) \mathbf{d} = 0 \quad i = 1, \dots, m$$

$$g_i(\mathbf{x}^k) + \nabla g_i(\mathbf{x}^k) \mathbf{d} \geq 0 \quad i = m + 1, \dots, m + r + 2n$$

Dieses Problem kann mit dem „active set“ Verfahren gelöst werden. In Iteration  $k$  werden mit  $\mathbf{x}^k, \boldsymbol{\lambda}^k, \mathbf{H}^k$  für Iteration  $k + 1$   $\mathbf{x}^{k+1}, \boldsymbol{\lambda}^{k+1}$  berechnet. Die Hesse-Matrix der Langrange-Funktion wird mit dem BFGS-Ansatz approximiert.

## Das SQP-Verfahren:

- $f(\mathbf{x})$  mit einer quadratischen Funktion annähern
- $g(\mathbf{x})$  mit linearen Funktionen annähern
- Das Problem mit dem „active set“ Verfahren lösen.
- Aufgrund der Annäherung treten Konvergenzprobleme auf.

# Algorithmus Active-Set-SQP (Sequentielle Quadratische Programmierung)

## Mit Gleichungs- und Ungleichungsnebenbedingungen

- Schritt 1:  $k = 0$ , Vorgabe Schätzwerte  $\mathbf{x}^0, \boldsymbol{\lambda}^0$ ,  
 $\mathbf{x}^0$  muss zulässig sein. Identifikation Active-Set  $A^0$ .
- Schritt 2: In Iteration  $k$ , Berechnung des Gradientenvektors  $\nabla f(\mathbf{x}^k)$   
 und Approximation der Hesse-Matrix  $\mathbf{H}_L(\mathbf{x}^k, \boldsymbol{\lambda}^k)$  mit der  
 BFGS-Formel.
- Schritt 3: Iterative Lösung des QP-Problems

$$\min_{\mathbf{d}} \frac{1}{2} \mathbf{d}^T \mathbf{H}_L(\mathbf{x}^k, \boldsymbol{\lambda}^k) \mathbf{d} + [\nabla f(\mathbf{x}^k)]^T \mathbf{d}$$

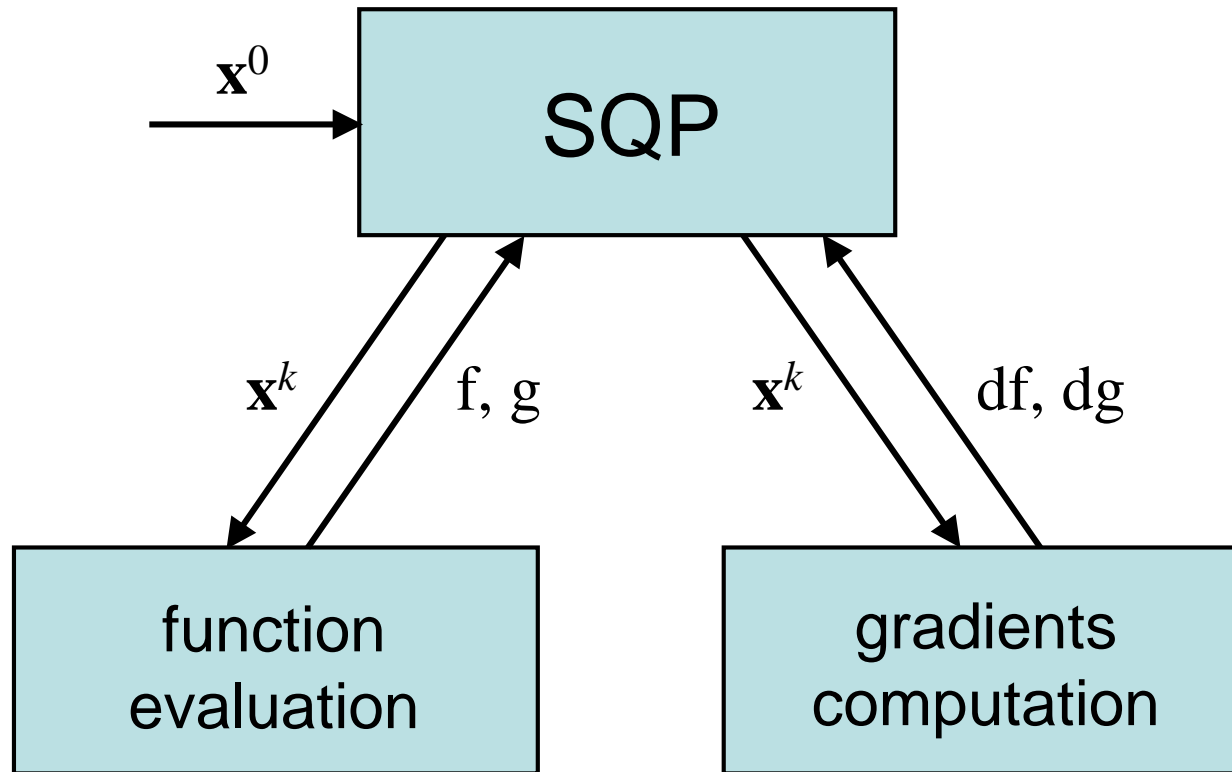
$$\text{mit } \mathbf{g}_i(\mathbf{x}^k) + [\nabla \mathbf{g}_i(\mathbf{x}^k)]^T \mathbf{d} = 0 \quad i \in A^k$$

$$\mathbf{g}_i(\mathbf{x}^k) + [\nabla \mathbf{g}_i(\mathbf{x}^k)]^T \mathbf{d} \geq 0 \quad i \notin A^k$$

mit dem Active-Set-Verfahren. Man erhält  $\mathbf{d}^*, \boldsymbol{\mu}^*$ .

- Schritt 4: Überprüfung der nicht aktiven Ungleichungen.  
Ermittlung der Schrittlänge  $\alpha$ .
- Schritt 5:  $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha \mathbf{d}^*$ ,  $\boldsymbol{\lambda}^{k+1} = \boldsymbol{\mu}^*$ , Update Active-Set.
- Schritt 6: Wenn die Optimalitätsbedingungen erfüllt sind, STOP.  
Ansonsten zu Schritt 7.
- Schritt 7:  $k \leftarrow k + 1$ , Fortschritt mit Schritt 2.

# Computation strategy for solving NLP problems





## Vorhandene NLP Software

- NLPQL, Schittkowski (1986), *Annals of Operations Research*, Vol. 5, S. 485-500.
- MINOS, Murtagh und Saunders (1978), *Mathematical Programming*, Vol. 14, S. 41-72.
- GINO, Lieman et al. (1986), *Modelling and Optimization with GINO*, Redwood City, Scientific Press.
- GAMS, Brooke et al. (1988), *GAMS-A User Guide*, Redwood City, Scientific Press.
- IMSL, (1987) Math/Library, IMSL User`s Manual.
- **SNOPT, Gill, Stanford University**
- **IPOPT, Biegler, Carnegie Mellon University**

## Anwendungsbeispiele:

Morari und Grossmann (1991), Chemical Engineering Optimization Problems with GAMS, *CACHE Design Case Studies*, Vol. 6.

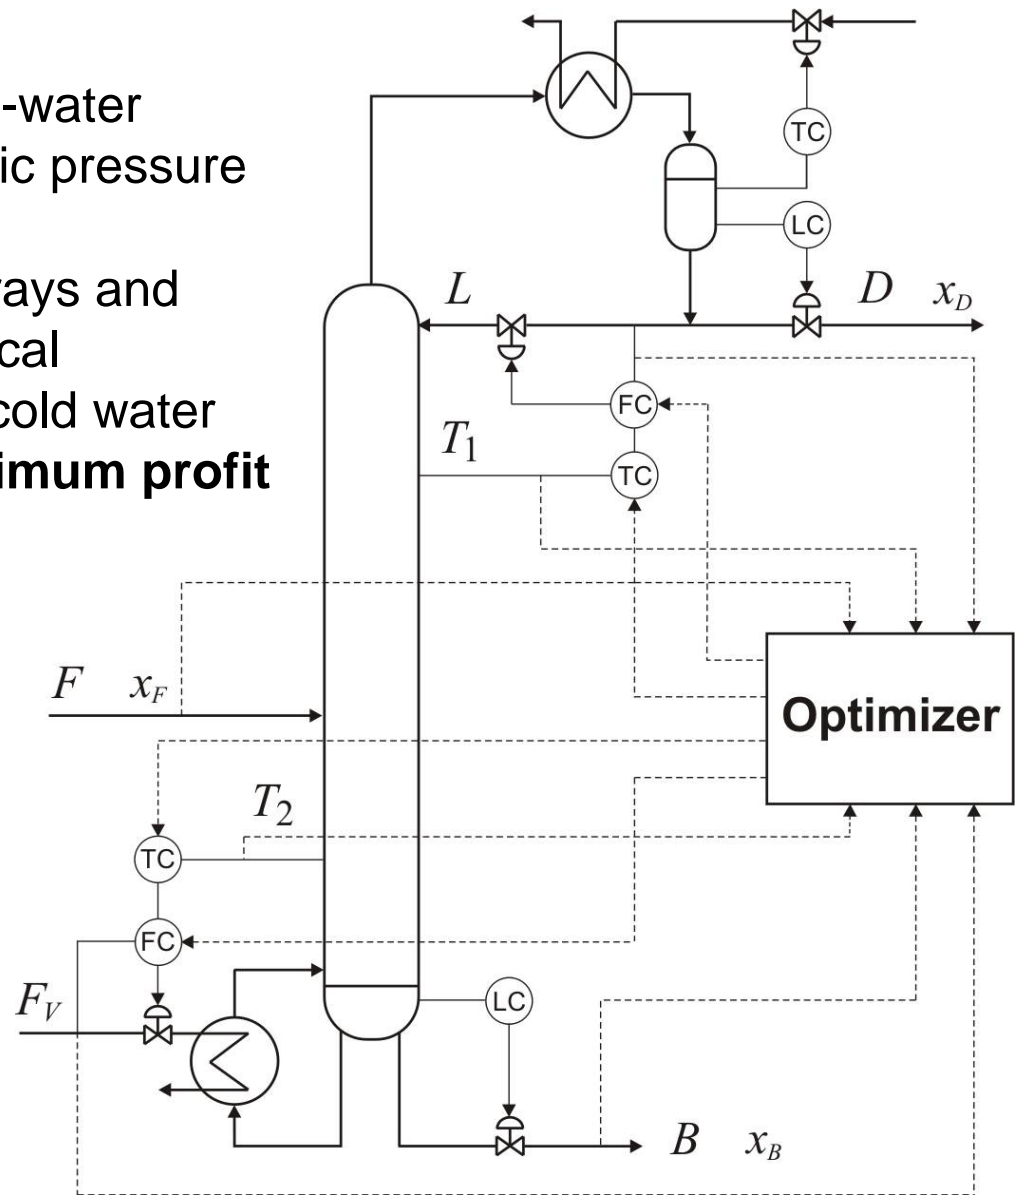
Biegler et al. (1997), Systematic Methods of Chemical Process Design, Prentice Hall.

# On-line Optimization of a distillation column

Separation of a methanol-water mixture under atmospheric pressure

Column: 20 bubble cap trays and 100 mm diameter. Electrical reboiler, condenser with cold water

Aim of optimization: **maximum profit**



## Objective function:

$$\max_{L, F_V} \quad c_1 D x_D + c_2 B x_B - c_3 F x_F - c_4 F_V - c_5 F_W$$

## Equality constraints for each tray:

- Component balances
- Vapor-liquid equilibrium relations
- Energy balance
- Tray hydraulics

## Inequality constraints:

- State variable constraint
- Control variable constraint

## Influential factors on optimality:


- Price factors:  $c_1, c_2, c_3, c_4, c_5$
- Feed conditions:  $F, x_F$
- Product specifications:  $D, B, x_D, x_B$

## Degree of freedom: 2


- $x_D, x_B$
- or  $L, Q$

# Optimal operating point changing based on $C_1$


52



## Influence of $C_1$



## Minimum point is inside the feasible region



## Minimum point is outside the feasible region

