

Sommersemester 2006

**Mehrkriterielle Optimierung mit Metaheuristiken**  
(Vorlesung)

Prof. Dr. Günter Rudolph

Fachbereich Informatik

Lehrstuhl für Algorithm Engineering (LS XI)

Fachgebiet *Computational Intelligence*





### Arbeitsdefinition:

Metaheuristik  $\stackrel{\text{def}}{=}$

Algorithmischer Rahmen für eine Lösungsstrategie,  
bei der viele Bestandteile initial unspezifiziert sind. ■

- ⇒ viele algorithmische Bestandteile können ausgetauscht werden,  
ohne die generelle Lösungsstrategie zu verändern
- ⇒ viele verschiedene Algorithmen
- ⇒ Aufbau einer Theorie mühsam



**Beispiel:** Monokriterieller (1+1) – EA („evolutionärer Algorithmus“)

wähle  $x_0 \in X$  zufällig; setze  $k = 0$

repeat

$$y_k = x_k \oplus m_k$$

falls  $f(y_k) \in B(f(x_k))$  dann  $x_{k+1} = y_k$

sonst  $x_{k+1} = x_k$

$$k = k + 1$$

until Stoppkriterium erfüllt

Mutation

Selektion

$m_k$  : Zufallsvektor (hier: unspezifiziert)


$f : X \rightarrow \mathbb{R}$  Zielfunktion ( $\rightarrow$  min!)

$B(z^0) = \{z \in F : z < z^0\}$  Zielwerte, die besser als  $z^0$  sind




## Forderungen an Such- / Mutationsverteilung von $m_k$

1. Keine Richtung ohne Grund bevorzugen → Symmetrie um 0
2. Kleine Änderungen wahrscheinlicher als große → Unimodal mit Modus 0
3. Steuerbar: Größe der Umgebung, Streuung → Parametrisierbar
4. Leicht erzeugbar
5. ...




symmetrisch, multimodal



symmetrisch, unimodal



**Gleichverteilung**  $f_m(x) = \frac{1}{2r} \cdot \mathbf{1}_{(-r,r)}(x)$




- symmetrisch
- unimodal
- steuerbar  $\rightarrow r$
- leicht erzeugbar:

$$m = r(2u - 1)$$

wobei  $u \in [0, 1)$   
gleichverteilt  
(aus Bibliothek)




**Betaverteilung**  $f_m(x) = \frac{r^{1-2p}}{\sqrt{\pi}} \cdot \frac{\Gamma(p + \frac{1}{2})}{\Gamma(p)} (1 - x^2)^{p-1} \cdot 1_{(-r,r)}(x)$



- symmetrisch
- unimodal
- steuerbar  $\rightarrow r, p$
- leicht erzeugbar (Bibliothek)




**Normalverteilung**  $f_m(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{x^2}{2\sigma^2}\right)$



- symmetrisch
- unimodal
- steuerbar  $\rightarrow \sigma$
- nicht ganz so leicht erzeugbar (Bibliothek)



Cauchyverteilung  $f_m(x) = \frac{1}{c\pi} \cdot \frac{1}{1 + \left(1 + \frac{x}{c}\right)^2}$




- symmetrisch
- unimodal
- steuerbar  $\rightarrow c$
- leicht erzeugbar (Bibliothek)

**Besonderheit:**  
unendliche Varianz





Höherdimensionale Suchräume: Symmetrie? Unimodalität? Steuerbarkeit?



Rotationssymmetrie

### Definition 5.1:

Sei  $T$  eine  $(n \times n)$ -Matrix mit  $T^T T = I_n$ . ( $I_n$ :  $n$ -dim. Einheitsmatrix)

$T$  heißt **orthogonale Matrix** oder **Rotationsmatrix**. ■

### Beispiel:

$$T = \begin{pmatrix} \cos \omega & -\sin \omega \\ \sin \omega & \cos \omega \end{pmatrix}$$

$y = T^T x \Rightarrow$  Vektor  $x$  wurde um Winkel  $\omega$  gedreht



## Definition 5.2:

n-dimensionaler Zufallsvektor  $x$  heißt

***sphärisch symmetrisch*** oder ***rotationssymmetrisch***


$\Leftrightarrow x \stackrel{d}{=} T'x$  für jede orthogonale Matrix  $T$ . ■

$x \stackrel{d}{=} y$  bedeutet:  $x$  hat die gleiche Verteilung wie  $y$

**Beispiel:** Gleichverteilung auf Kreis (Hyperkugel der Dimension  $n = 2$ )

$u$  gleichverteilt in  $[0, 1] \Rightarrow \omega = 2\pi u$

$$x \stackrel{d}{=} \begin{pmatrix} \cos \omega \\ \sin \omega \end{pmatrix}$$





### **Satz 5.1:**

Zufallsvektor  $x$  rotationssymmetrisch  $\Leftrightarrow x \stackrel{d}{=} r u^{(n)}$ , wobei

$r$  nichtnegative Zufallsvariable und

$u^{(n)}$  Zufallsvektor mit Gleichverteilung auf  $n$ -dim. Hyperkugelrand mit Radius 1. ■

### **Bemerkung:**

$r$  und  $u^{(n)}$  sind stochastisch unabhängig,  $u^{(n)} \stackrel{d}{=} \frac{x}{\|x\|}$

### **Erzeugung von rotationssymmetrischen Zufallsvektoren:**

1. Wähle zufällige Richtung  $u^{(n)}$
2. Wähle zufällige Schrittweite  $r$
3. Multiplikation:  $x = r u^{(n)}$



### Beispiel: Multivariate Normalverteilung

Zufallsvektor  $m$  erzeugbar via

1.  $m = \sigma \cdot (m_1, m_2, \dots, m_n)$ ,  
wobei  $m_i \sim N(0, 1)$  stoch. unabh., oder

2.  $m = r \cdot u$ , wobei  $r \sim \chi_n(\sigma)$ ,  $u \sim U(\partial S_n(1))$ .

↑  
 $\chi$ -Verteilung mit  
n Freiheitsgraden

↑  
Gleichverteilung  
auf Hyperkugelrand

$$\partial S_n(r) = \{ x \in \mathbb{R}^n : \| x \| = r \} \quad \text{Hyperkugelrand}$$



### Beispiel: Multivariate Cauchyverteilung

Zufallsvektor  $m$  erzeugbar via

1.  $m = \sigma \cdot (m_1, m_2, \dots, m_n) / m_0$ ,  
wobei  $m_i \sim N(0, 1)$  stoch. unabh., oder

2.  $m = r \cdot u$ , wobei  $r/n \sim F_{n,1}$ ,  $u \sim U(\partial S_n(1))$ .

F-Verteilung mit  $(n, 1)$   
Freiheitsgraden

↑  
Gleichverteilung  
auf Hyperkugelrand

### **Achtung:**

Zufallsvektor aus  $n$  unabh. Cauchy-Zufallsvariablen nicht rotationssymmetrisch!



### Multikriterieller (1+1)-EA: Was wäre zu ändern?

wähle  $x_0 \in X$  zufällig; setze  $k = 0$

repeat

$$y_k = x_k \oplus m_k$$

falls  $f(y_k) \in B(f(x_k))$  dann  $x_{k+1} = y_k$

sonst  $x_{k+1} = x_k$

$$k = k + 1$$

until Stoppkriterium erfüllt

1. Mutationsvektoren  $\rightarrow$  keine Änderung nötig!
  2. Selektion  $\rightarrow$  Neudefinition:  $B(z^0) = \{ z \in F : z \preceq z^0 \}$
- $\Rightarrow$  keine Änderung an der Rahmenstruktur des Algorithmus!



$$B(z^0) = \{ z \in F : z \preceq z^0 \}$$

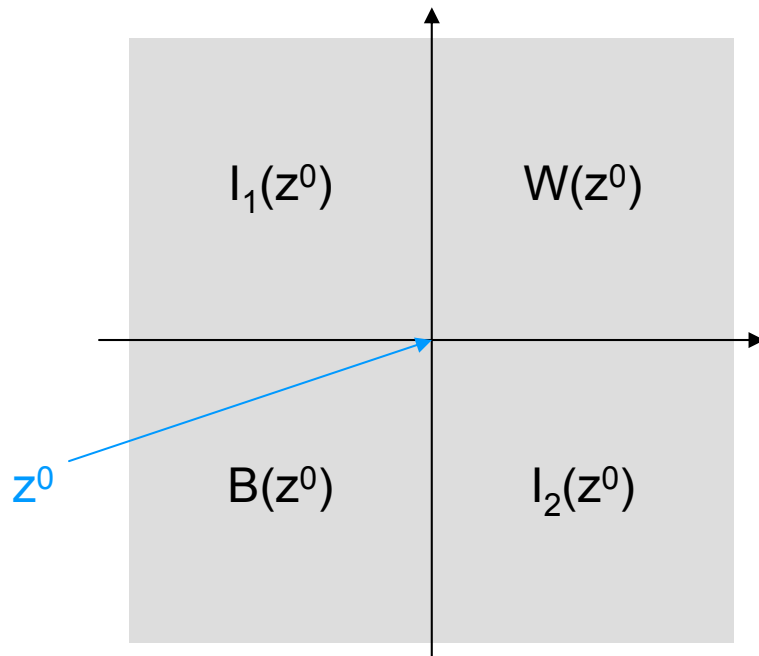
“better than“  $z^0$

$$I(z^0) = \{ z \in F : z \parallel z^0 \}$$

“incomparable to“  $z^0$

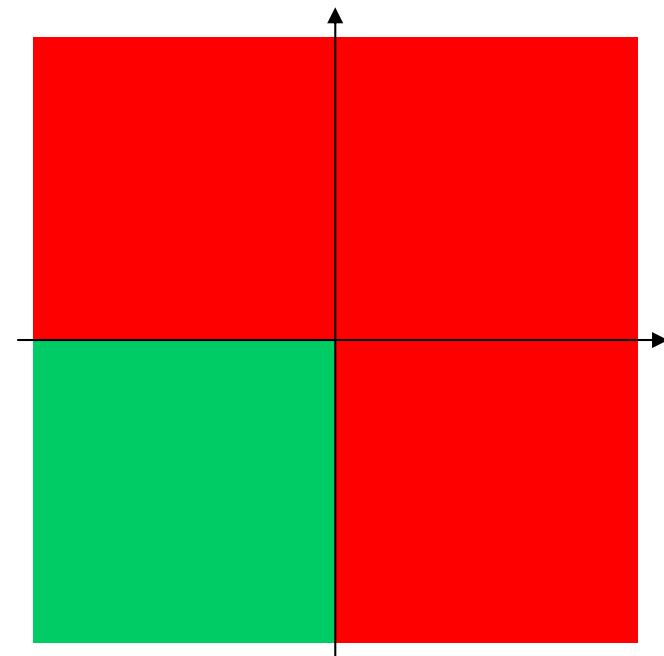
$$W(z^0) = \{ z \in F : z^0 \preceq z \}$$

“worse than“  $z^0$



$\Rightarrow$

## Multikriterieller (1+1)-EA:



akzeptieren

verwerfen



### Beispiel: Monokriterielles Threshold Accepting (TA)

wähle  $x_0 \in X$  zufällig; setze  $k = 0$

repeat

$$y_k = x_k + m_k$$

falls  $f(y_k) \in B(f(x_k) + T_k)$  dann  $x_{k+1} = y_k$

sonst  $x_{k+1} = x_k$

$$T_{k+1} = \gamma(T_k), k = k + 1$$

until Stoppkriterium erfüllt

$m_k$ : Zufallsvektor (hier: unspezifiziert)

Threshold  $T_k \geq 0$

$f : X \rightarrow \mathbb{R}$  Zielfunktion ( $\rightarrow$  min!)

$T_k$  monoton fallend  $\rightarrow 0$

$B(z^0) = \{z \in F : z < z^0\}$  Zielwerte, die besser als  $z^0$  sind





**Idee** bei monokriteriellem Threshold Accepting (TA)

- Akzeptiere jede Verbesserung
- Akzeptiere zu Anfang der Suche auch große Verschlechterungen
- Akzeptiere danach immer geringere Verschlechterungen

⇒ am Ende nahezu keine Akzeptanz von Verschlechterungen mehr

⇒ Verlassen von lokalen Optima durch Akzeptanz von Verschlechterungen

**Regeln für  $T_k$ :**

$$T_k = c T_{k-1}, c \in (0,1)$$

$$T_k = T_0 / (k+1)^\beta, \beta > 0$$

$$T_k = T_0 / \log(k+1)$$

} weitere Regeln denkbar  
und wohl auch im Einsatz



### Multikriterielles Threshold Accepting: Was wäre zu ändern?

wähle  $x_0 \in X$  zufällig; setze  $k = 0$

repeat

$$y_k = x_k + m_k$$

falls  $f(y_k) \in B(f(x_k) + T_k)$  dann  $x_{k+1} = y_k$

sonst  $x_{k+1} = x_k$

$$T_{k+1} = \gamma(T_k), k = k + 1$$

until Stoppkriterium erfüllt

1.  $T_k$  wird m-dimensionaler Vektor (ein Threshold je Zielgröße oder einer für alle)
2. ggf. m verschiedene  $T_k$  – Verringerungsregeln



$$B(z^0) = \{ z \in F : z \preceq z^0 \}$$


“better than“  $z^0$

$$I(z^0) = \{ z \in F : z \parallel z^0 \}$$

“incomparable to“  $z^0$


$$W(z^0) = \{ z \in F : z^0 \preceq z \}$$

“worse than“  $z^0$



$\Rightarrow$

## Multikriterielles TA:





## Alternative Akzeptanzregeln für multikriterielles TA

Sei  $\delta_i = f_i(y_k) - f_i(x_k)$ .

$\delta_i > 0 \Rightarrow$  Verschlechterung bzgl. Ziel  $i$


$\delta_i < 0 \Rightarrow$  Verbesserung bzgl. Ziel  $i$

1.  $\max\{ \delta_i : i = 1, \dots, m \} \leq T_k$

2.  $\sum_i w_i \max\{ \delta_i, 0 \} \leq T_k$

3.  $\sum_i w_i \delta_i \leq T_k$

4. ...



$f(y_k) \in B( f(x_k) + T_k \cdot (1, \dots, 1)' )$



Konvexkombination  $w_1, \dots, w_m$



$$B(z^0) = \{ z \in F : z \preceq z^0 \}$$


“better than“  $z^0$

$$I(z^0) = \{ z \in F : z \parallel z^0 \}$$

“incomparable to“  $z^0$


$$W(z^0) = \{ z \in F : z^0 \preceq z \}$$

“worse than“  $z^0$



$\Rightarrow$

**MTA:**  $\sum_i w_i \max\{ \delta_i, 0 \} \leq T_k$



akzeptieren

verwerfen



$$B(z^0) = \{ z \in F : z \preceq z^0 \}$$


“better than“  $z^0$

$$I(z^0) = \{ z \in F : z \parallel z^0 \}$$

“incomparable to“  $z^0$


$$W(z^0) = \{ z \in F : z^0 \preceq z \}$$

“worse than“  $z^0$



$\Rightarrow$

**MTA:**  $\sum_i w_i \delta_i \leq T_k$



akzeptieren

verwerfen



### Beispiel: Monokriterielles Simulated Annealing (SA)

```
wähle  $x_0 \in X$  zufällig; setze  $k = 0$ 
repeat
   $y_k = x_k + m_k$ 
  falls  $f(y_k) \in B(f(x_k))$  dann  $x_{k+1} = y_k$ 
  falls  $f(y_k) \in W(f(x_k))$ 
    falls  $u < \exp(-\Delta f_k / T_k)$  dann  $x_{k+1} = y_k$ 
    sonst  $x_{k+1} = x_k$ 
   $T_{k+1} = \gamma(T_k)$ ;  $k = k + 1$ 
until Stoppkriterium erfüllt
```

$m_k$  : Zufallsvektor

$B(z^0) = \{z \in F : z < z^0\}$

$W(z^0) = \{z \in F : z > z^0\}$

$u \sim U[0,1]$ ,  $T_k \rightarrow 0$  monoton fallend

Zielwerte, die besser als  $z^0$  sind

Zielwerte, die schlechter als  $z^0$  sind



**Idee** beim monokriteriellem Simulated Annealing:

Akzeptiere auch schlechtere Lösungen mit abnehmender Wahrscheinlichkeit, um aus lokalen Optima zu entkommen!

**Satz** (Hayek 1988, Haario & Saksman 1991)

$T_k = T_0 / \log(k + 1)$ ,  $m_k$  mit beschränktem Träger  
⇒ SA konvergiert gegen globales Optimum mit W'keit 1 ■

→ sehr langsame Temperaturverringernung!

→ Praxis:  $T_{k+1} = c \cdot T_k$  mit  $c \in (0,1)$

**Satz** (Belisle 1992)

$T_k = c^k \cdot T_0$ ,  $c \in (0,1)$  und  $\text{supp}(m_k) = \mathbb{R}^n$   
⇒ SA konvergiert zum globalen Optimum mit W'keit 1 ■





### Multikriterielles Simulated Annealing: Was wäre zu ändern?

```
wähle  $x_0 \in X$  zufällig; setze  $k = 0$ 
repeat
   $y_k = x_k + m_k$ 
  falls  $f(y_k) \in B(f(x_k))$  dann  $x_{k+1} = y_k$ 
  falls  $f(y_k) \in W(f(x_k)) \cup I(f(x_k))$ 
    falls  $u < \exp(-\Delta_k / T_k)$  dann  $x_{k+1} = y_k$ 
    sonst  $x_{k+1} = x_k$ 
   $T_{k+1} = \gamma(T_k)$ ;  $k = k + 1$ 
until Stoppkriterium erfüllt
```

$$\delta_i(k) = f_i(y_k) - f_i(x_k)$$

$$\Delta_k = \max\{\delta_i(k) : i = 1, \dots, m\}$$

$$B(z^0) = \{z \in F : z \preceq z^0\}$$

Zielwerte, die besser als  $z^0$  sind

$$W(z^0) = \{z \in F : z \succeq z^0\}$$

Zielwerte, die schlechter als  $z^0$  sind



$$B(z^0) = \{ z \in F : z \preceq z^0 \}$$


“better than“  $z^0$

$$I(z^0) = \{ z \in F : z \parallel z^0 \}$$

“incomparable to“  $z^0$


$$W(z^0) = \{ z \in F : z^0 \preceq z \}$$

“worse than“  $z^0$



$\Rightarrow$

## Multikriterielles SA:



akzeptieren

verwerfen



### Multikriterielles Simulated Annealing: Serafini (1992)

wähle  $x_0 \in X$  zufällig; setze  $k = 0$

repeat

$$y_k = x_k + m_k$$

falls  $f(y_k) \in B(f(x_k))$  dann  $x_{k+1} = y_k$

sonst

falls  $u < \vartheta(\delta(k), T_k)$  dann  $x_{k+1} = y_k$

sonst  $x_{k+1} = x_k$

$$T_{k+1} = \gamma(T_k); k = k + 1$$

until Stoppkriterium erfüllt

$$\vartheta: \mathbb{R}^m \times \mathbb{R}_+ \rightarrow [0, 1]$$

$$\delta(k) = (\delta_1(k), \dots, \delta_m(k))' \text{ mit } \delta_i(k) = f_i(y_k) - f_i(x_k)$$

$\text{supp}(m_k)$  kann beschränkt sein



### MSA (Serafini 1992)

Sei  $f(y_k) \notin B(f(x_k))$ , so dass  $\exists i : \delta_i(k) > 0$ .

$$\vartheta(\delta(k), T_k) = \left\{ \begin{array}{l} \exp \left( \sum_{i=1, \delta_i(k) > 0}^m w_i \delta_i(k) / T_k \right) \\ \prod_{i=1, \delta_i(k) > 0}^m \exp(-\delta_i(k) / T_k) \\ \min_{i=1, \dots, m} \{ \exp(-w_i \delta_i(k) / T_k) : \delta_i(k) > 0 \} \\ \max_{i=1, \dots, m} \{ \exp(-w_i \delta_i(k) / T_k) : \delta_i(k) > 0 \} \end{array} \right.$$

zzgl. zusammengesetzte Regeln:  $\vartheta(\cdot) = \alpha \vartheta_1(\cdot) + (1 - \alpha) \vartheta_2(\cdot)$



### MSA (Engrand et al. 1998)

Ersatzzielfunktion  $f(x) = \sum_{i=1}^m \log f_i(x)$

→ erfordert  $\forall i : \forall x: f_i(x) > 0$

**Skalarisierung!**



vermutlich nicht alle  
Lösungen erreichbar!

$$\begin{aligned} \Delta f_k &= f(y) - f(x) \\ &= \sum_{i=1}^m \log f_i(y) - \sum_{i=1}^m \log f_i(x) \\ &= \sum_{i=1}^m (\log f_i(y) - \log f_i(x)) \\ &= \sum_{i=1}^m \log \left( \frac{f_i(y)}{f_i(x)} \right) \end{aligned}$$



### MSA (Engrand et al. 1998)

Ersatzzielfunktion  $f(x) = \sum_{i=1}^m \log f_i(x)$



Ansatz:  $g_i(x) = \exp(f_i(x)) \longrightarrow \forall i : \forall x : g_i(x) > 0$



lokale und globale Minimalstellen identisch!

Ersatzzielfunktion  $g(x) = \sum_{i=1}^m g_i(x) = m \sum_{i=1}^m w_i g_i(x)$  mit  $w_i = 1/m$

⇒ kann nur Pareto-optimale Lösungen im konvexen Zielbereich finden!



### Beispiel: Monokriterielles Tabu Search (TS)

```
wähle  $x_0 \in X$  zufällig; setze  $L_k = ()$  und  $k = 0$   
repeat  
     $x_{k+1} = \operatorname{argmin}\{f(x) : x \in N(x_k) \setminus L_k\}$   
     $L_{k+1} = \operatorname{tail}(\operatorname{append}(L_k, x_k), \ell)$   
     $k = k + 1$   
until Stoppkriterium erfüllt
```

Tabu-Liste  $L_k$  mit max. Länge  $\ell$

Nachbarschaft  $N(x)$  von  $x \in X$

→ auch schlechtere neue Punkte werden akzeptiert!

zugeschnitten für  
diskrete Probleme



**Bisher:** Ein Lauf → ein Lösungskandidat

**Erwünscht:** Approximation der Paretomenge

**Ansatz:** Einsammeln nicht-dominiertes Lösungen

→ Knowles & Corne (2000): Pareto-Archived ES (PAES)





### (1+1)-PAES (Knowles & Corne 2000)

wähle  $x_0 \in X$  zufällig;  $A_0 = \{x_0\}$ ; setze  $k = 0$

repeat

$$y_k = x_k + m_k$$

falls  $f(y_k) \in B(f(x_k))$  dann  $x_{k+1} = y_k$ ;  $A_k = A_k \cup \{y_k\}$

sonst falls  $f(y_k) \in W(f(x_k))$  dann  $x_{k+1} = x_k$

sonst falls  $\exists a \in A_k : f(y_k) \in W(f(a))$  dann  $x_{k+1} = x_k$

sonst  $x_{k+1} = \text{replace}(A_k, x_k, y_k)$

$$k = k + 1$$

until Stoppkriterium erfüllt

$A_k$  : Archiv zum Zeitpunkt  $k$



### (1+1)-PAES (Knowles & Corne 2000)

```
replace( $A_k, x_k, y_k$ ):=
```

```
falls  $A_k$  nicht voll
```

$$A_k = A_k \cup \{y_k\}$$

```
falls lessCrowded( $y_k, x_k; A_k$ ) dann return  $y_k$ 
```

```
sonst return  $x_k$ 
```

```
sonst
```

```
falls  $\exists a \in A_k : \text{lessCrowded}(y_k, a; A_k)$ 
```

$$A_k = A_k \cup \{y_k\}; A_k = A_k \setminus \{a\}$$

```
falls lessCrowded( $y_k, x_k; A_k$ ) dann return  $y_k$ 
```


```
sonst return  $x_k$ 
```



## (1+1)-PAES (Knowles & Corne 2000)

```
boolean lessCrowded( $y, x; A$ ):=  
    return cell( $y; A$ ).size()  $\leq$  cell( $x; A$ ).size();
```

**Idee:** Zielraum unterteilen in Raster mit  $2^{d \cdot s}$  Zellen (cells);  $d = \dim(F)$



Speichereffiziente  
Implementierung möglich  
→ **quadtree**