

Wintersemester 2005/06

**Fundamente der Computational Intelligence**  
**(Vorlesung)**

Prof. Dr. Günter Rudolph

Fachbereich Informatik

Lehrstuhl für Algorithm Engineering





## Inhalt

- Grundlagen Optimierung
- Nachbarschaftssuche
- (1+1)-EA
  - Erwartete Laufzeit
    - Counting Ones
    - Leading Ones
  - Konvergenz
- Populationsbasierte EA
  - EA im  $\mathbb{B}^n$
  - EA im  $\mathbb{R}^n$



Nachtrag: EP-Selektion (Beispiel für Verlust des Besten)

$\mu = \lambda = 2$  bei Minimierung,  $q = 2$

Index	1	2	3	4
f(x)	12.3	1.9	4.2	8.1
Rang	4	1	2	3
Siege	0	2	2	2
Sortierrang	4	3	2	1
Auswahl	-	-	+	+

Annahme: Sortierung nach Anzahl der Siege mit „selection sort“

⇒ abhängig von Implementierung!

⇒ Lösung: Bestem **vorher**  $q+1$  Siege zuweisen!



## Schematischer Ablauf eines Evolutionären Algorithmus

	<u>GA</u>	<u>ES</u>	<u>EP</u>
Initialisierung der Population	<b>x</b>	<b>x</b>	<b>x</b>
repeat			
Reproduktionsselektion	<b>x</b>	-	-
Rekombination	<b>x</b>	<b>x</b>	-
Mutation	<b>x</b>	<b>x</b>	<b>x</b>
Überlebensselektion	-	<b>x</b>	<b>x</b>
until Abbruch			

Heute: Keine Unterscheidung zwischen GA/ES/EP, da Übergänge fließend



## EA im $\mathbb{R}^n$

**Selektion:** unabhängig von Representation

**Rekombination:** k-Punkt-Crossover, Uniform Crossover  
funktioniert auf allen Produkträumen!

zusätzlich:

Intermediäre Rekombination  $z_i = \alpha_i x_i + (1-\alpha_i) y_i$ ,  $\alpha_i \in (0,1)$

$\alpha_i \equiv \alpha$ : auf Verbindungslinie zwischen  $x$  und  $y$   
sonst innerhalb des durch  $x$  und  $y$  definierten Hyperrechtecks

auch: Varianten mit  $> 2$  Eltern

**Mutation:** additiv via Normalverteilung  $N(0, C)$ ,  $C$  Kovarianzmatrix  
häufig:  $C = \sigma^2 \cdot I_n$  oder individuelle  $\sigma_i$

auch: Cauchyverteilung („Levy flights“) oder Mixturen

**notwendig:** Anpassung von  $C$  bzw.  $\sigma_i$  während Suche!



### Optimierung ohne „Anpassen“ (reine Zufallssuche)

$$f(x) = \|x\|^2 = x'x \rightarrow \min! \quad \text{wobei } x \in S_n(r) = \{x \in \mathbb{R}^n : \|x\| \leq r\}$$

$Z_k$  ist gleichverteilt in  $S_n(r)$

$$X_{k+1} = Z_k \text{ falls } f(Z_k) < f(X_k), \text{ sonst } X_{k+1} = X_k$$

$$\Rightarrow V_k = \min \{ f(Z_1), f(Z_2), \dots, f(Z_k) \} \quad \text{bester ZF-Wert bis Iteration } k$$

$$P\{ \|Z\| \leq x \} = P\{ Z \in S_n(x) \} = \text{Vol}(S_n(x)) / \text{Vol}(S_n(r)) = (x/r)^n, \quad 0 \leq x \leq r$$

$$P\{ \|Z\|^2 \leq x \} = P\{ \|Z\| \leq x^{1/2} \} = x^{n/2} / r^n, \quad 0 \leq x \leq r^2$$

$$P\{ V_k \leq x \} = 1 - (1 - P\{ \|Z\|^2 \leq x \})^k = 1 - (1 - x^{n/2} / r^n)^k$$

$$E[V_k] \rightarrow r^2 \Gamma(1 + 2/n) k^{-2/n} \quad \text{für große } k$$




## Optimierung ohne „Anpassen“ (lokal gleichverteilt)

$f(x) = \|x\|^2 = x'x \rightarrow \min!$  wobei  $x \in S_n(r) = \{x \in \mathbb{R}^n : \|x\| \leq r\}$

$Z_k$  ist gleichverteilt in  $[-r, r]$ ,  $n = 1$

$X_{k+1} = X_k + Z_k$  falls  $f(X_k + Z_k) < f(X_k)$ , sonst  $X_{k+1} = X_k$



ab hier:  
wie reine  
Zufallssuche!




(1+1)-EA mit Schrittweitenanpassung (1/5-Erfolgsregel, Rechenberg 1973)

### Idee:

- Wenn viele erfolgreiche Mutationen, dann Schrittweite zu klein.
- Wenn wenige erfolgreiche Mutationen, dann Schrittweite zu groß.

bei infinitesimal  
kleinem Radius ist  
Erfolgsrate =  $1/2$



### Ansatz:

- Protokolliere erfolgreiche Mutationen in gewissem Zeitraum
- Wenn Anteil größer als gewisse Schranke (z. B.  $1/5$ ), dann Schrittweite erhöhen, sonst Schrittweite verringern





### Schrittweite?

Normalverteilter Vektor  $Z = N(0, \sigma^2 I_n)$  hat zufällige Länge  $\|Z\|$

Man kann zeigen:  $E[\|Z\|] \approx \sigma (n - \frac{1}{2})^{1/2}$  mit Varianz von etwa  $\sigma^2 / 2$

### Definition:

Zufallsvektor  $X = (x_1, \dots, x_n)$  sphärisch verteilt

wenn  $X$  für jede orthonormale Matrix  $T$

die gleiche Verteilung wie  $TX$  besitzt (also rotationsinvariant ist). ■

### Satz:

$X = (x_1, \dots, x_n)$  sphärisch verteilt gdw.  $X = r \cdot U$ , wobei

$r$  nicht negative Zufallsvariable,


$U$   $n$ -dim. Zufallsvektor gleichverteilt auf Kugelrand und

= im Sinne von „gleich in Verteilung“ ■



Wenn Zufallsschrittweite  $r$  wie  $\chi_n(\sigma)$ -verteilt, dann  $X$  normalverteilt  $N(0, \sigma^2 I_n)$

Für große  $n$ :



⇒ Normalverteilung verhält sich ähnlich wie Kugelrandverteilung!

⇒ fast alle sphärischen Verteilungen verhalten sich für große  $n$  ähnlich!

fast alle? alle mit finiter Varianz!



### Analyse

(1,  $\lambda$ )-EA mit  $f(x) = \|x\|^2$

$$\begin{aligned}\|Y_k\|^2 &= \|X_k + r_k U_k\|^2 = (X_k + r_k U_k)' (X_k + r_k U_k) \\ &= X_k' X_k + 2r_k X_k' U_k + r_k^2 U_k' U_k \\ &= \|X_k\|^2 + 2r_k \underbrace{X_k' U_k}_{= 1} + r_k^2 \|U_k\|^2 = \|X_k\|^2 + 2X_k' U_k + r_k^2 \\ &= 1\end{aligned}$$

da das zufällige Skalarprodukt  $x'U$  die gleiche Verteilung hat wie  $\|x\| B$ , wobei Zufallsvariable  $B$  betaverteilt mit Parametern  $(n-1)/2$  auf  $[-1, 1]$  ist, folgt

$$\|Y_k\|^2 = \|X_k\|^2 + 2r_k \|X_k\| B + r_k^2$$

da der  $(1, \lambda)$  den besten Wert aus  $\lambda$  Versuchen selektiert, folgt

$$\|X_{k+1}\|^2 = \|X_k\|^2 + 2r_k \|X_k\| B_{1:\lambda} + r_k^2$$



$$\| X_{k+1} \|^2 = \| X_k \|^2 + 2r_k \| X_k \| B_{1:\lambda} + r_k^2$$

↓ bedingte Erwartungswerte auf beiden Seiten

$$E\| X_{k+1} \|^2 = \| X_k \|^2 + 2r_k \| X_k \| E[ B_{1:\lambda} ] + r_k^2$$

↓ Ansatz:  $r_k = \gamma \| X_k \|^2$

$$E\| X_{k+1} \|^2 = \| X_k \|^2 + 2\gamma \| X_k \|^3 E[ B_{1:\lambda} ] + \gamma^2 \| X_k \|^4$$

↓ wg. Symmetrie von B folgt  $E[B_{1:\lambda}] = -E[B_{\lambda:\lambda}] < 0$

$$\begin{aligned} E\| X_{k+1} \|^2 &= \| X_k \|^2 - 2\gamma \| X_k \|^3 E[ B_{\lambda:\lambda} ] + \gamma^2 \| X_k \|^4 \\ &= \| X_k \|^2 (1 - 2\gamma E[B_{\lambda:\lambda}] + \gamma^2) \end{aligned}$$

Parabelscheitel bei  $\gamma^* = E[B_{\lambda:\lambda}]$ , also  $E\| X_{k+1} \|^2 = \| X_k \|^2 (1 - E[B_{\lambda:\lambda}]^2)$