



Wintersemester 2005/06

Fundamente der Computational Intelligence (Vorlesung)

Prof. Dr. Günter Rudolph
Fachbereich Informatik
Lehrstuhl für Algorithm Engineering



Kapitel 3: Evolutionäre Algorithmen



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

Kapitel 3: Evolutionäre Algorithmen



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
Sortierang	4	3	2	1
Auswahl	-	-	+	+

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

⇒ abhängig von Implementierung!

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

Kapitel 3: Evolutionäre Algorithmen



Schematischer Ablauf eines Evolutionären Algorithmus

	GA	ES	EP
Initialisierung der Population	x	x	x
repeat			
Reproduktionsselektion	x	-	-
Rekombination	x	x	-
Mutation	x	x	x
Überlebensselektion	-	x	x
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 σ_i

auch: Cauchyverteilung („Levy flights“) oder Mixturen

notwendig: Anpassung von C bzw. σ_i während Suche!

Optimierung ohne „Anpassen“ (reine Zufallssuche)

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

Z_k ist gleichverteilt in $S_n(r)$

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

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

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

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

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

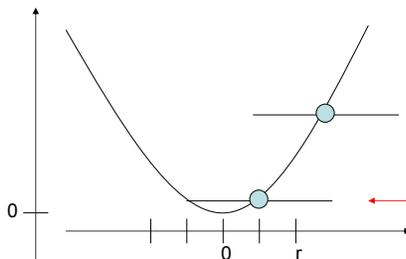
$E[V_k] \rightarrow r^2 \Gamma(1 + 2/n) k^{-2/n}$ für große k

Optimierung ohne „Anpassen“ (lokal gleichverteilt)

$f(x) = \|x\|^2 = x^T x \rightarrow \min!$ 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 $X_{k+1} = X_k$



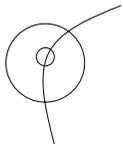
ab hier:
wie reine
Zufallssuche!

(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

Kapitel 3: Evolutionäre Algorithmen

Schrittweite?

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

Man kann zeigen: $E[\|Z\|] \approx \sigma (n - 1/2)^{1/2}$ 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“ ■

Kapitel 3: Evolutionäre Algorithmen

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!

Kapitel 3: Evolutionäre Algorithmen

Analyse

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

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

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 λ Versuchen selektiert, folgt

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

Kapitel 3: Evolutionäre Algorithmen

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

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: $r_k = \gamma \|X_k\|$

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

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

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

$$= \|X_k\|^2 (1 - 2\gamma E[B_{\lambda:\lambda}] + \gamma^2)$$

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