

# Evolutionäre Algorithmen: Überblick über die Arbeitsprinzipien

Karsten Weicker

HTWK Leipzig

5. Januar 2013

# Überblick

- 1 Wechselspiel Variation – Selektion
- 2 Populationskonzept
- 3 Verknüpfen mehrerer Individuen
- 4 Selbstanpassende Algorithmen
- 5 Zusammenfassung

# Überblick

- 1 Wechselspiel Variation – Selektion
- 2 Populationskonzept
- 3 Verknüpfen mehrerer Individuen
- 4 Selbstanpassende Algorithmen
- 5 Zusammenfassung

# Einfaches binäres Beispiel

EIN-BIT-BINÄRE-MUTATION(Individuum  $A$  mit  $A.G \in \mathbb{B}^l$ )

- 1  $B \leftarrow A$
- 2  $i \leftarrow$  wähle zufällig gemäß  $U(\{1, \dots, l\})$
- 3  $B_i \leftarrow 1 - A_i$
- 4 **return**  $B$

# Einfaches binäres Beispiel

## BINÄRES-HILLCLIMBING(Zielfunktion $F$ )


```
1   $t \leftarrow 0$ 
2   $A(t) \leftarrow$  erzeuge Lösungskandidat
3  bewerte  $A(t)$  durch  $F$ 
4  while Terminierungsbedingung nicht erfüllt
5  do  $\lceil t \leftarrow t + 1$ 
6       $B \leftarrow$  EIN-BIT-BINÄRE-MUTATION( $A(t - 1)$ )
7      bewerte  $B$  durch  $F$ 
8      if  $B.F \succeq A(t - 1).F$ 
9      then  $\lceil A(t) \leftarrow B$ 
10      $\lfloor$  else  $\lceil A(t) \leftarrow A(t - 1)$ 
11 return  $A(t)$ 
```

# Endliche Markovkette

## Definition

- *endliche Markovkette (Zustände, Start, Übergang)*
- mögliche Zustände  $Zustände = \{0, \dots, k\}$
- Anfangswahrscheinlichkeit pro Zustand  
 $Start \in [0, 1]^{k+1}$   
es gilt:  $\sum_{0 \leq i \leq k} Start_i = 1$
- Übergangswahrscheinlichkeit  
 $Übergang : \{0, \dots, k\} \times \{0, \dots, k\} \rightarrow [0, 1]$   
für alle  $i$  gilt:  $\sum_{0 \leq j \leq k} Übergang(i, j) = 1$

# Optimierung als Markovprozess



# Endliche Markovkette

## Satz


**BINÄRES-HILLCLIMBING** *erreicht das Optimum eines Musterabgleichs mit  $l$  Bits in  $\mathcal{O}(l \log l)$  Schritten (als Erwartungswert).*

# Gütelandschaften: Nachbarschaft

## Definition

- Mutationsoperator  $Mut^\xi : \mathcal{G} \times \mathcal{Z} \rightarrow \mathcal{G} \times \mathcal{Z}$  mit  $\mathcal{Z} = \{\perp\}$
- *Nachbarschaftsgraph* ist gerichteter Graph  $G = (V, E)$  mit  $V = \mathcal{G}$  und
$$E = \{(A.G, B.G) \in V \times V \mid \exists \xi \in \Xi : Mut^\xi(A) = B\}$$

# Gütellandschaften: Nachbarschaft




# Gütelandschaft

## Definition

- Geg.: Nachbarschaftsgraphen  $G = (\mathcal{G}, E)$ , induzierte Bewertungsfunktion  $F : \mathcal{G} \rightarrow \mathbb{R}$
- *Gütelandschaft*  $(G, F)$  durch Zuordnung der Güte zu den Punkten
- *Weg in der Landschaft*

# Gütelandschaften: Hillclimbing





# Lokales Optimum

## Definition


- Geg.: Mutationsoperator, dazugehörige Gütelandschaft  $((\mathcal{G}, E), F)$
- $A$  ist *lokales Optimum*, falls alle möglichen Mutanten  $B = Mut(A)$  nicht besser sind und Wege zu besseren Lösungskandidaten über schlechtere führen.
- $A$  ist *Plateau-Punkt*, falls alle möglichen Mutanten  $B = Mut(A)$  nicht besser sind und wenigstens einer gleich gut ist.

# Gütelandschaften: Hillclimbing




# Kodierung: standardbinär

nur standardbinäre Kodierung




eingesetzt in  $f_1$




# Kodierung: Gray

nur Gray-Kodierung




eingesetzt in  $f_1$




# Kodierung: Vergleich der Nachbarschaft

standardbinäre Kodierung



Gray-Kodierung



# Rollen der Mutation

## Exploration oder Erforschung

- stichprobenartiges Erkunden
- auch: weiter entfernte Regionen des Suchraums

## Exploitation oder Feinabstimmung

- lokale Verbesserung eines Lösungskandidaten
- wichtig: Einbettung der phänotypischen Nachbarschaft

# Binäre Mutation

```
BINÄRE-MUTATION(Individuum  $A$  mit  $A.G \in \mathbb{B}^l$ )  
1   $B \leftarrow A$   
2  for  $i \in \{1, \dots, l\}$   
3  do  $\lceil u \leftarrow$  wähle zufällig gemäß  $U([0, 1))$   
4      if  $u \leq p_m$  (Mutationswahrscheinlichkeit)  
5       $\lfloor$  then  $\lfloor B.G_i \leftarrow 1 - A.G_i$   
6  return  $B$ 
```

# Animation

## Binärer Hillclimber

# Eine alternative reellwertige Mutation

## Gauß-Mutation

- direkt auf den reellwertigen Zahlen
- Addition einer normalverteilten Zufallszahl auf jede Komponente

# Eine alternative reellwertige Mutation

## Gauß-Mutation

- direkt auf den reellwertigen Zahlen
- Addition einer normalverteilten Zufallszahl auf jede Komponente

GAUSS-MUTATION(Individuum  $A$  mit  $A.G \in \mathbb{R}^l$ )

```
1  for  $i \in \{1, \dots, l\}$ 
2  do  $\lceil u_i \leftarrow$  wähle zufällig gemäß  $\mathcal{N}(0, \sigma$  (Standardabweichung))
3       $B_i \leftarrow A_i + u_i$ 
4       $B_i \leftarrow \max\{B_i, ug_i$  (untere Wertebereichsgrenze)  $\}$ 
5       $\lfloor B_i \leftarrow \min\{B_i, og_i$  (obere Wertebereichsgrenze)  $\}$ 
6  return  $B$ 
```


# Vergleich der Mutationen

## Ansatz

- Optimierung der einfachen Funktion

$$f_2(x) = \begin{cases} x & \text{falls } x \in [0, 10] \subset \mathbb{R} \\ \text{undef.} & \text{sonst} \end{cases}$$

- zwei Elternindividuen (1,0 und 4,99)
- Ermittlung der Nachkommensverteilung mit jeweils 10 000 Mutationen



# Vergleich der Mutationen

## Binäre Mutation: Ergebnis

- rastert den Suchraum
- weitgestreute Erforschung
- nur beim Graycode: akzeptable Feinabstimmung

## Gauß-Mutation: Ergebnis

- regelmäßiges Verhalten
- gute Feinabstimmung
- schlechte, weit springende Erforschung

# Überblick

- 1 Wechselspiel Variation – Selektion
- 2 Populationskonzept**
- 3 Verknüpfen mehrerer Individuen
- 4 Selbstanpassende Algorithmen
- 5 Zusammenfassung

# Populationskonzept

## Idee

- mehr als ein Individuum existiert in einer Population

## Nutzen

- gleichzeitige Betrachtung mehrerer Individuen
- parallele Suche an verschiedenen Stellen im Suchraum
- Hoffnung: Bedeutung der lokalen Optima verringern

# Diversitätsmaße

## Definition

- Population  $P = \langle A^{(i)} \rangle_{1 \leq i \leq s}$ , Genotyp  $\mathcal{G} = G^l$
- *mittlerer Abstand* der Individuen in der Population

$$\text{Divers}_{\text{Abstand}, d}(P) = \frac{1}{s \cdot (s - 1)} \sum_{1 \leq i, j \leq s} d(A^{(i)}.G, A^{(j)}.G)$$

wobei  $d : \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}$  ein beliebiges Abstandsmaß ist.

# Diversitätsmaße

## Definition

- Population  $P = \langle A^{(i)} \rangle_{1 \leq i \leq s}$ , Genotyp  $\mathcal{G} = \mathbb{B}^l$
- *Shannon-Entropie* als positionsorientierte Diversität

$$\text{Divers}_{\text{Entropie}}(P) =$$

$$\frac{1}{l} \sum_{k=1}^l (-\#_0(P, k) \log \#_0(P, k) - \#_1(P, k) \log \#_1(P, k)),$$

$$\text{mit } \#_1(P, k) = \frac{\#\{1 \leq i \leq s \mid A^{(i)} \cdot G_k = 1\}}{s}$$

$$\text{und } \#_0(P, k) = \frac{\#\{1 \leq i \leq s \mid A^{(i)} \cdot G_k = 0\}}{s}.$$

# Diversitätsmaße

## Definition

- Population  $P = \langle A^{(i)} \rangle_{1 \leq i \leq s}$ , Genotyp  $\mathcal{G} = \mathbb{B}^l$
- *teilstringorientierte Diversität*

$$Divers_{\text{Teilstring}}(P) = \frac{s \cdot \# \left( \bigcup_{1 \leq i \leq s} \text{Teil}(A^{(i)}) \right)}{\sum_{1 \leq i \leq s} \# \text{Teil}(A^{(i)})},$$

$$\text{wobei } \text{Teil}(A) = \bigcup_{1 \leq i \leq j \leq l} \{A.G_i \dots A.G_j\}.$$

# Konvergenz

## Definition

Eine Population  $P = \langle A^{(i)} \rangle_{1 \leq i \leq s}$  heißt *konvergiert*, wenn alle Individuen identisch sind, d. h. für alle  $1 \leq i, j \leq s$  gilt  $A^{(i)} \cdot G = A^{(j)} \cdot G$ .

# Ein vergleichendes Experiment

POPULATIONSBASIERTER-BINÄRER-HILLCLIMBER(Zielfunktion  $F$ )

- 1  $t \leftarrow 0$
- 2  $P(t) \leftarrow$  erzeuge Population mit  $\mu$  (Populationsgröße) Individuen
- 3 bewerte  $P(t)$  durch  $F$
- 4 **while** Terminierungsbedingung nicht erfüllt
- 5 **do**  $\lceil P' \leftarrow P(t)$
- 6     **for**  $i \in \{1, \dots, \mu\}$
- 7     **do**  $\lceil B \leftarrow$  EIN-BIT-BINÄRE-MUTATION( $A^{(i)}$ ) wobei  $P(t) = \langle A^{(k)} \rangle_{1 \leq i \leq \mu}$
- 8         bewerte  $B$  durch  $F$
- 9          $\lfloor P' \leftarrow P' \circ \langle B \rangle$
- 10      $t \leftarrow t + 1$
- 11      $\lfloor P(t) \leftarrow$  Selektion aus  $P'$  mittels BESTEN-SELEKTION
- 12 **return** bestes Individuum aus  $P(t)$


# Selektion der Besten

BESTEN-SELEKTION(Gütwerte  $\langle A.F^{(i)} \rangle_{i=1,\dots,r}$ )

- 1  $I \leftarrow \langle \rangle$
- 2 **for**  $1 \leq j \leq s$  (Anzahl der zu wählenden Individuen)
- 3 **do**  $\lceil index_j \leftarrow$  derjenige Index aus  $\{1, \dots, r\} \setminus I$  mit dem besten Gütwert
- 4  $\lfloor I \leftarrow I \cup \langle index_j \rangle$
- 5 **return**  $I$

Rastrigin-Funktion:

$f(X) = 10 \cdot n + \sum_{i=1}^n (X_i^2 - 10 \cdot \cos(2\pi \cdot X_i))$  mit  $n = 2$   
und  $-5,12 \leq X_1, X_2 \leq 5,12$



# HC vs. Populationsbasiertes HC


## Rahmenbedingungen

- 100 Optimierungsläufe
- Populationsgröße  $\mu = 50$
- 10000 evaluierte Individuen

## Ergebnis

	Hillclimbing	Populationsbas. Hillclimbing
erfolgreich	63%	76%
durchschnittliche Endgüte	0,429	0,297

# Diversität in der Population



# Folgerungen für die Selektion

## Elternselektion

- alle Individuen haben Chance, gewählt zu werden
- entweder: jedes Individuum ist Elter für  $m > 0$  Kinder
- oder: Eltern mit einer Wahrscheinlichkeit wählen

## Umweltselektion

- Vielfalt erhalten UND bessere Individuen übernehmen
- entweder: reine Auswahl der Besten
- oder: zufällige Auswahl, die bessere Individuen bevorzugt

# Eigenschaften der Selektion

## Definition

Sei  $IS^\xi : \mathbb{R}^r \rightarrow \{1, \dots, r\}^s$  Indexselektion.

- *deterministisch*, falls

$$\forall v \in \mathbb{R}^r \quad \forall \xi, \xi' \in \Xi : IS^\xi(v) = IS^{\xi'}(v),$$

- *probabilistisch* genau dann, wenn nicht deterministisch, und

- *duplikatfrei*, falls

$$\forall v \in \mathbb{R}^r \quad \forall \xi \in \Xi \quad \forall 1 \leq i < j \leq r : (IS^\xi(v))_i \neq (IS^\xi(v))_j$$

# ZWEI MINUTEN

Welche Aussagen sind richtig?

- Bestenselektion (TSP) ist duplikatfrei
- Uniforme Zufallswahl jedes Elters ist duplikatfrei
- Selektion des Hillclimbers ist probabilistisch
- zufällige Zahl  $0 < k < \mu$  wählen, dann die  $k$  besten und die  $\mu - k$  schlechtesten wählen ist probabilistisch
- Probabilistische Wahl kann die Übernahme des Besten nicht garantieren

# ZWEI MINUTEN

Welche Aussagen sind richtig?

- Bestenselektion (TSP) ist duplikatfrei
- Uniforme Zufallswahl jedes Elters ist duplikatfrei
- Selektion des Hillclimbers ist probabilistisch
- zufällige Zahl  $0 < k < \mu$  wählen, dann die  $k$  besten und die  $\mu - k$  schlechtesten wählen ist probabilistisch
- Probabilistische Wahl kann die Übernahme des Besten nicht garantieren

# Überlappende Populationen

## Definition

- Eltern  $P = \langle A^{(i)} \rangle_{1 \leq i \leq \mu}$ , Kinder  $P' = \langle A^{(i)} \rangle_{1 \leq i \leq \lambda}$
- Sei  $IS^\xi : \mathbb{R}^r \rightarrow \{1, \dots, r\}^s$  Umweltsel. auf  $P \circ P'$
- *überlappend*, falls wenigstens ein Tupel  $x \in \mathbb{R}^r$  existiert, so dass  $IS^\xi(x)$  einen Wert aus  $\{1, \dots, \mu\}$  enthält.
- *überlappend mit einem Überlappungsgrad*  $g \in \{1, \dots, \mu - 1\}$ , falls für alle  $x \in \mathbb{R}^r$  genau  $g$  Werte in  $IS^\xi(x)$  aus  $\{1, \dots, \mu\}$
- *elitär*, falls immer ein Wert  $k$  mit  $A^{(k)}.F \succeq A^{(i)}.F$  für alle  $1 \leq i \leq \mu$  in  $IS^\xi(x)$  enthalten ist.

# Turnier als Umweltselektion

SELEKTION-Q-STUFIGES-TURNIER(Gütwerte  $\langle A^{(i)}.F \rangle_{i=1,\dots,r}$ )

```

1  Scores  $\leftarrow \langle \rangle$ 
2  for  $i = 1, \dots, r$ 
3  do  $\lceil$  Siege  $\leftarrow 0$ 
4      for  $j = 2, \dots, q$  (Anzahl der direkten Turniere)
5      do  $\lceil$   $u \leftarrow$  wähle Zufallszahl gemäß  $U(\{1, \dots, r\})$ 
6          if  $A^{(i)}.F \succ A^{(u)}.F$ 
7           $\lfloor$  then  $\lceil$  Siege  $\leftarrow$  Siege + 1
8       $\lfloor$  Scores  $\leftarrow$  Scores  $\circ$   $\langle$  Siege  $\rangle$ 
9  I  $\leftarrow \langle \rangle$ 
10 for  $1 \leq j \leq s$  (Anzahl der zu wählenden Individuen)
11 do  $\lceil$  index  $\leftarrow$  derjenige Index aus  $\{1, \dots, r\} \setminus I$  mit maximalem Wert  $Score^{(index)}$ 
12      $\lfloor$  I  $\leftarrow$  I  $\circ$   $\langle$  index  $\rangle$ 
13 return I

```

# Ein Beispiel zur Turniererselektion

Individuum	Turniere gegen Gegner			Siege	Wahl
$A^{(1)}.F = 3, 1$	3	8	5		
$A^{(2)}.F = 1, 0$	1	2	9		
$A^{(3)}.F = 4, 5$	10	4	7		
$A^{(4)}.F = 2, 4$	6	9	10		
$A^{(5)}.F = 3, 6$	1	8	7		
$A^{(6)}.F = 2, 1$	3	6	4		
$A^{(7)}.F = 2, 7$	2	5	8		
$A^{(8)}.F = 1, 8$	3	9	1		
$A^{(9)}.F = 2, 2$	6	7	4		
$A^{(10)}.F = 3, 5$	2	10	5		

# Ein Beispiel zur Turniererselektion

Individuum	Turniere gegen Gegner			Siege	Wahl
$A^{(1)}.F = 3, 1$	3	8✓	5		
$A^{(2)}.F = 1, 0$	1	2	9		
$A^{(3)}.F = 4, 5$	10✓	4✓	7✓		
$A^{(4)}.F = 2, 4$	6✓	9✓	10		
$A^{(5)}.F = 3, 6$	1✓	8✓	7✓		
$A^{(6)}.F = 2, 1$	3	6	4		
$A^{(7)}.F = 2, 7$	2✓	5	8✓		
$A^{(8)}.F = 1, 8$	3	9	1		
$A^{(9)}.F = 2, 2$	6✓	7	4		
$A^{(10)}.F = 3, 5$	2✓	10	5		

# Ein Beispiel zur Turniererselektion

Individuum	Turniere gegen Gegner			Siege	Wahl
$A^{(1)}.F = 3, 1$	3	8✓	5	1	
$A^{(2)}.F = 1, 0$	1	2	9	0	
$A^{(3)}.F = 4, 5$	10✓	4✓	7✓	3	
$A^{(4)}.F = 2, 4$	6✓	9✓	10	2	
$A^{(5)}.F = 3, 6$	1✓	8✓	7✓	3	
$A^{(6)}.F = 2, 1$	3	6	4	0	
$A^{(7)}.F = 2, 7$	2✓	5	8✓	2	
$A^{(8)}.F = 1, 8$	3	9	1	0	
$A^{(9)}.F = 2, 2$	6✓	7	4	1	
$A^{(10)}.F = 3, 5$	2✓	10	5	1	

# Ein Beispiel zur Turniererselektion

Individuum	Turniere gegen Gegner			Siege	Wahl
$A^{(1)}.F = 3, 1$	3	8✓	5	1	✓
$A^{(2)}.F = 1, 0$	1	2	9	0	
$A^{(3)}.F = 4, 5$	10✓	4✓	7✓	3	✓
$A^{(4)}.F = 2, 4$	6✓	9✓	10	2	✓
$A^{(5)}.F = 3, 6$	1✓	8✓	7✓	3	✓
$A^{(6)}.F = 2, 1$	3	6	4	0	
$A^{(7)}.F = 2, 7$	2✓	5	8✓	2	✓
$A^{(8)}.F = 1, 8$	3	9	1	0	
$A^{(9)}.F = 2, 2$	6✓	7	4	1	
$A^{(10)}.F = 3, 5$	2✓	10	5	1	

# Selektionsintensität

## Definition

- Sei  $\bar{F}$  durchschnittliche Güte einer Population,
- $\sigma$  deren Standardabweichung und
- $\bar{F}_{sel}$  die durchschnittliche Güte nach der Selektion
- Dann ist die Selektionsintensität definiert als

$$Intensität = \begin{cases} \frac{\bar{F}_{sel} - \bar{F}}{\sigma} & \text{falls } \bar{F}_{sel} > \bar{F} \\ \frac{\bar{F} - \bar{F}_{sel}}{\sigma} & \text{sonst.} \end{cases}$$

# Fitnessproportionale Selektion

## Idee

- ein Fitnesswert der Individuen bestimmt die Auswahlwahrscheinlichkeit (und damit die Anzahl der Kinder)
- Biologie: Ursache und Wirkung vertauscht
- zunächst: Fitness = Güte

## Definition

Auswahlwahrscheinlichkeiten der *fitnessproportionalen Selektion*:

$$Pr[A^{(i)}] = \frac{A^{(i)} \cdot F}{\sum_{k=1}^r A^{(k)} \cdot F}$$

# Fitnessproportionale Selektion

SELEKTION-FITNESSPROPORTIONAL(Gütwerte  $\langle A^{(i)}.F \rangle_{1 \leq i \leq r}$ )

```

1   $\langle Fitness^{(i)} \rangle_{1 \leq i \leq r} \leftarrow$  berechne Fitnesswerte aus  $\langle A^{(i)}.F \rangle_{1 \leq i \leq r}$ 
2   $I \leftarrow \langle \rangle$ 
3  for  $i \in \{1, \dots, s$  (Anzahl der zu wählenden Individuen)  $\}$ 
4  do  $\lceil j \leftarrow 1$ 
5       $sum \leftarrow Fitness^{(j)}$ 
6       $u \leftarrow$  wähle Zufallszahl gemäß  $U([0, 1))$ 
7      while  $sum < u$ 
8      do  $\lceil j \leftarrow j + 1$ 
9           $index \leftarrow j$ 
10          $\lfloor sum \leftarrow sum + Fitness^{(j)}$ 
11      $\lfloor I \leftarrow I \circ \langle index \rangle$ 
12 return  $I$ 

```

# Verbesserungen

## Skalieren

- Idee: nur den interessanten Gütebereich heranziehen
- *schlechteste*  $F_W^{(t)}$  = schlechtester Gütewert der letzten  $W$  Generationen
- *beste*  $F_W^{(t)}$  = bester Gütewert der letzten  $W$  Generationen
- *lineare Skalierung*:

$$Fitness = \frac{A.F - \textit{schlechteste}F_W^{(t)}}{\textit{beste}F_W^{(t)} - \textit{schlechteste}F_W^{(t)}}$$

# Verbesserungen


## Rangbasierte Selektion

- Idee: Individuen nach ihrem Gütewert sortieren, Fitness nur nach Rang vergeben
- Sei  $A^{(1)}.F \succeq A^{(2)}.F \succeq \dots \succeq A^{(r)}.F$
- Wahrscheinlichkeiten werden linear zugewiesen


$$Pr[A^{(i)}] = \frac{2}{r} \left( 1 - \frac{i-1}{r-1} \right)$$

# Stochastische Universelles Sampling

fitnessproportionale Selektion



stochastisches universelles Sampling



# Stochastische Universelles Sampling

STOCHASTISCHES-UNIVERSELLES-SAMPLING (Gütwerte  $\langle A^{(i)}.F \rangle_{1 \leq i \leq r}$ )

```

1   $Summe_1 \leftarrow$  berechne Fitnesswert aus  $A^{(1)}.F$ 
2  for  $i \in \{2, \dots, r\}$ 
3  do  $\lceil Fitness \leftarrow$  berechne Fitnesswert aus  $A^{(i)}.F$ 
4      $\lfloor Summe_i \leftarrow Summe_{i-1} + Fitness$ 
5   $u \leftarrow$  wähle Zufallszahl gemäß  $U([0, \frac{Summe_r}{s}])$ 
6   $j \leftarrow 1$ 
7   $l \leftarrow \langle \rangle$ 
8  for  $i \in \{1, \dots, s\}$ 
9  do  $\lceil$  while  $Summe_j < u$ 
10     do  $\lceil j \leftarrow j + 1$ 
11          $\lfloor sum \leftarrow sum + Fitness^{(j)}$ 
12      $u \leftarrow u + \frac{Summe_r}{s}$ 
13      $\lfloor l \leftarrow l \circ \langle j \rangle$ 
14 return  $l$ 

```

# Eine Alternative: Turniererselektion (Eltern)

TURNIER-SELEKTION(Gütwerte  $\langle A^{(i)}.F \rangle_{1 \leq i \leq r}$ )

1  $I \leftarrow \langle \rangle$

2 **for**  $i = 1, \dots, s$  (Anzahl der zu wählenden Individuen)

3 **do**  $\lceil index \leftarrow$  wähle Zufallszahl gemäß  $U(\{1, \dots, r\})$

4 **for**  $j = 2, \dots, q$  (Anzahl der Gegner)

5 **do**  $\lceil u \leftarrow$  wähle Zufallszahl gemäß  $U(\{1, \dots, r\})$

6 **if**  $A^{(u)}.F \succ A^{(index)}.F$

7  $\quad \lfloor$  **then**  $\lfloor index \leftarrow u$

8  $\quad \lfloor I \leftarrow I \circ \langle index \rangle$

9 **return**  $I$

# Kombinationen Eltern-/Umweltselektion

Umweltselektion ↓ Elternsel. →	uniforme Auswahl	Identität	probabilistisch
Identität	kein Sel.druck	kein Sel.druck	GA
duplikatfrei prob. (überlappend)	?	×	?
prob. überlappend	?	EP (90er)	?
deterministisch (überlappend)	ES (Komma)	SA	steady state GA
	ES (Plus)	kein Sel.druck	?
		EP (60er)	steady state GA

# Parametrierung von $\mu$ und $\lambda$

- großer Einfluss auf Erfolg und/oder Geschwindigkeit der Optimierung
- Extrembeispiel: Selektion der Besten  
⇒ Selektionsdruck hängt von  $\frac{\mu}{\lambda}$  ab
- Populationsgrößen abstimmen mit
  - Schwierigkeit und der Charakter des Optimierungsproblems,
  - involvierter Selektionsoperator und
  - Erforschung und Feinabstimmung durch Mutation und Rekombination.


# Experimenteller Vergleich

## Selektionsszenarien

- Eltern: 3-faches Turnier, Umwelt: Identität
- Eltern: fitnessproportional, Umwelt: Identität
- Eltern: Identität, Umwelt: Besten-Selektion
- Eltern: Identität, 5-tufige 2-fache Turniererselektion

## Experimenteller Rahmen

- $\mu = \lambda = 20$
- Sphäre  $f(X) = \sum_{i=1}^n X_i^2$  mit  $n = 2$  (Minimierung)
- Gauß-Mutation



# Überblick

- 1 Wechselspiel Variation – Selektion
- 2 Populationskonzept
- 3 Verknüpfen mehrerer Individuen**
- 4 Selbstanpassende Algorithmen
- 5 Zusammenfassung

# Drittes Prinzip: Verknüpfen mehrerer Individuen

- andere mögliche Wege im Suchraum entstehen durch das Verknüpfen mehrerer Individuen
- drei verschiedene Arbeitsweisen:
  - sprichwörtliche „Rekombination“
  - interpolierende Operatoren
  - extrapolierende Operatoren

# Kombinierende Operatoren

## Idee

- Bestandteile verschiedener Individuen werden neu zusammengestellt
- es entsteht nichts eigentlich Neues

## Beobachtungen

- Arbeitsweise hängt von der hohen Diversität ab
- systematisches Durchforsten des Suchraums

# Uniformer Crossover

UNIFORMER-CROSSOVER(Individuum  $A$ , Individuum  $B$ )

```

1  for  $i \in \{1, \dots, l\}$ 
2  do  $\lceil b \leftarrow$  wähle zufällig gemäß  $U(\mathbb{B})$ 
3      if  $b$ 
4      then  $\lceil C.G_i \leftarrow A.G_i$ 
5               $\lfloor D.G_i \leftarrow B.G_i$ 
6      else  $\lceil C.G_i \leftarrow B.G_i$ 
7               $\lfloor D.G_i \leftarrow A.G_i$ 
8  return  $C, D$ 

```

# Interpolierende Operatoren

## Idee

- vermischen die Charakteristika der Eltern
- neue Eigenschaften entstehen

## Beobachtungen

- Stabilität statt systematischer Erforschung
- konzentriert Population auf gemeinsamen Nenner (Schwerpunkt der Population)
- fördert Feinabstimmung
- Gegengewicht: diversitätserhaltende Mutation

# Arithmetischer Crossover

ARITHMETISCHER-CROSSOVER(Individuen  $A, B$  mit  $A.G$ ,

- 1  $u \leftarrow$  wähle zufällig aus  $U([0, 1])$
- 2 **for**  $i \in \{1, \dots, l\}$
- 3 **do**  $C.G_i \leftarrow u \cdot A.G_i + (1 - u) \cdot B.G_i$
- 4 **return**  $C$

# Extrapolierende Operatoren

## Idee


- gezielt Information aus mehreren Individuen ableiten
- Prognose, wo Güteverbesserungen zu erwarten sind

## Beobachtungen

- können bisheriges Suchgebiet verlassen
- einzige Rekombination, die Gütewerte benutzt!


## Algorithmus

- Arithmetischer Crossover mit  $u$  aus  $U([1, 2])$



# Schema-Theorie

- zunächst: genetischer Algorithmus
- 1-Punkt-Crossover
- Frage: was für eine Suchdynamik ergibt sich durch die kombinierende Rekombination?



# GA: 1-Punkt-Crossover

EIN-PUNKT-CROSSOVER(Individuen  $A, B$ )

```
1  $j \leftarrow$  wähle zufällig gemäß  $U(\{1, \dots, l - 1\})$ 
2 for  $i \in \{1, \dots, j\}$ 
3   do  $\lceil C.G_i \leftarrow A.G_i$ 
4        $\lfloor D.G_i \leftarrow B.G_i$ 
5 for  $i \in \{j + 1, \dots, l\}$ 
6   do  $\lceil C.G_i \leftarrow B.G_i$ 
7        $\lfloor D.G_i \leftarrow A.G_i$ 
8 return  $C, D$ 
```

GENETISCHER-ALGORITHMUS(Zielfunktion  $F$ )


```

1   $t \leftarrow 0$ 
2   $P(t) \leftarrow$  erzeuge Population mit  $\mu$  (gerade Populationsgröße) Individuen
3  bewerte  $P(t)$  durch  $F$ 
4  while Terminierungsbedingung nicht erfüllt
5  do  $\lceil P' \leftarrow$  Selektion aus  $P(t)$  mittels SELEKTION-FITNESSPROPORTIONAL
6       $\lceil$  Es sei:  $P' = \langle A^{(1)}, \dots, A^{(\mu)} \rangle \lceil$ 
7       $P'' \leftarrow \langle \rangle$ 
8      for  $1 \leq i \leq \frac{\mu}{2}$ 
9      do  $\lceil u \leftarrow$  wähle Zufallszahl gemäß  $U([0, 1])$ 
10         if  $u \leq p_x$  (Rekombinationswahrscheinlichkeit)
11         then  $\lceil \langle B, C \rangle \leftarrow$  EIN-PUNKT-CROSSOVER( $A^{(2i-1)}, A^{(2i)}$ )
12         else  $\lceil \langle B, C \rangle \leftarrow \langle A^{(2i-1)}, A^{(2i)} \rangle$ 
13          $B \leftarrow$  BINÄRE-MUTATION( $B$ )
14          $C \leftarrow$  BINÄRE-MUTATION( $C$ )
15          $\lceil P'' \leftarrow P'' \circ \langle B, C \rangle$ 
16         bewerte  $P''$  durch  $F$ 
17          $t \leftarrow t + 1$ 
18          $\lceil P(t) \leftarrow P''$ 
19 return bestes Individuum aus  $P(t)$ 

```

# Motivation

Wie kann sich die Laufzeit durch Kombination ändern?



# Grundbegriffe

## Def.: Schema

- Sei  $\mathcal{G} = \mathbb{B}^l$
- Dann:  $H \in \{0, 1, *\}^l$  heißt Schema und beschreibt

$$\mathcal{I}(H) = \{A.G_1 \cdots A.G_l \in \mathcal{G} \mid \forall 1 \leq i \leq l: (H_i \neq *) \Rightarrow (A.G_i = H_i)\}.$$



- Ordnung von  $H$ :

$$o(H) = \#\{i \mid (1 \leq i \leq l) \wedge (H_i \neq *)\}.$$

- definierende Länge von  $H$ :

$$\delta(H) = \max\{|i - j| \mid (1 \leq i, j \leq l) \wedge (H_i \neq *) \wedge (H_j \neq *)\}$$


# Hyperebenen



# Schema-Theorem: Überblick

Ein bestimmter Anteil der Population hat ein Merkmal (d.h. diese Individuen sind Vertreter des Schemas  $H$ )

Wie verändert sich dieser Anteil durch Anwendung einer Generation?



- welche Eigenschaften (Schemata) vermehren sich besonders stark?

# Schema-Theorem

- GENETISCHER-ALGORITHMUS auf  $\mathcal{G} = \mathbb{B}^l$
- für beliebiges Schema  $H$  und Population  $P(t) = \langle A^{(t,i)} \rangle_{1 \leq i \leq \mu}$  gilt:

$$\text{Erw}[p_H^{(t+1)}] \geq p_H^{(t)} \cdot \frac{\bar{F}_H^{(t)}}{\bar{F}^{(t)}} \cdot (1 - p_m)^{o(H)} \cdot \left(1 - p_x \cdot \frac{\delta(H)}{l-1} \cdot \left(1 - p_H^{(t)} \cdot \frac{\bar{F}_H^{(t)}}{\bar{F}^{(t)}}\right)\right)$$

$$\text{mit } p_H^{(t)} = \frac{\#\{1 \leq i \leq \mu \mid A^{(t,i)} \cdot G \in \mathcal{I}(H)\}}{\mu},$$

- mit durchschnittlicher Güte  $\bar{F}^{(t)}$  in der Population und  $\bar{F}_H^{(t)}$  der Schema-Vertreter

# Beispiel

Individuum	Güte	Individuum	Güte
10101...	3	00001...	1
01101...	3	10001...	2
01100...	2	01001...	2
11101...	4	11001...	3
11000...	2	01110...	3

# Korollar: Einfaches Schema-Theorem

## Einfaches Schema-Theorem

Durch einige einfache Abschätzungen erhält man die folgende bekanntere Form des Schema-Theorems:

$$\text{Erw}[p_H^{(t+1)}] \geq p_H^{(t)} \cdot \frac{\overline{F}_H^{(t)}}{\underline{F}^{(t)}} \cdot \left(1 - o(H) \cdot p_m - p_x \cdot \frac{\delta(H)}{l-1}\right).$$


## Bausteine

Schemata mit

- überdurchschnittlicher Güte,
- kleiner definierender Länge und
- geringer Ordnung

# Beispiel

- Rekombinationswahrscheinlichkeit  $p_x = 1.0$
- Mutationsrate  $p_m = \frac{1}{16}$
- Genotyp: mit 16 Bit encodierte Zahl (Maximum: 65536)
- Populationsgröße 400



# Kritik am Schema-Theorem

- Relevanz der Aussage
  - Ergebnis lässt sich nicht iterativ anwenden  
⇒ Bausteinhypothese (exponentielles Wachstum von Schemata) gilt nicht
  - implizite Annahme: Kombination guter Schemata verbessert die Güte  
⇒ muss nicht gelten!
- Randbedingungen der evolutionären Algorithmen
  - Wahrscheinlichkeitsaussagen in sehr kleinen Mengen sind fragwürdig
  - beobachtete Güte eines Schemas muss nicht der tatsächlichen entsprechen  
Stichpunkt: Konvergenz einzelner Bits

# „Fehlendes“ Schema-Theorem

- laut Altenberg: Es fehlt ein Schema-Theorem mit einer Aussage zum Suchfortschritt
- Ausgangssituation:
  - GENETISCHER-ALGORITHMUS mit fitnessprop. Selektion und ohne Mutation
  - allgemeine Rekombination  $Merk \subseteq \{1, \dots, l\}$
  - mögliche Eltern von Individuum  $A$ :  $H_{Merk}(A.G)$  und  $H_{\widetilde{Merk}}(A.G)$  mit  $\widetilde{Merk} = \{1, \dots, l\} \setminus Merk$
  - kommen mit Wahrscheinlichkeiten  $p_{Merk}$  vor

# Verknüpfung Schema/Suchfortschritt

Auf zwei Ebenen:

- am Ende im Ergebnis: Wie ändert sich die durchschnittliche Güte?
- durch Verknüpfen von Eltern und Kindgüte

$$\text{Cov} \left[ A.F, \frac{\overline{F}_{H_{\text{Merk}}(A.G)}^{(t)} \cdot \overline{F}_{\widetilde{H}_{\text{Merk}}(A.G)}^{(t)}}{(\overline{F}^{(t)})^2} \right]$$

# Lemma


Es gilt:

$$\begin{aligned} & \text{Cov} \left[ A.F, \frac{\overline{F}_{H_{\text{Merk}}(A.G)}^{(t)} \cdot \overline{F}_{H_{\widetilde{\text{Merk}}}(A.G)}^{(t)}}{(\overline{F}^{(t)})^2} \right] \\ &= \sum_{A.G \in \mathcal{G}} \left( A.F - \overline{F}^{(t)} \right) \cdot \frac{\overline{F}_{H_{\text{Merk}}(A.G)}^{(t)} \cdot \overline{F}_{H_{\widetilde{\text{Merk}}}(A.G)}^{(t)}}{(\overline{F}^{(t)})^2} \cdot p_{A.G} , \end{aligned}$$


mit Häufigkeit  $p_{A.G}$  von Individuum  $A$  in der Population


# Beispiel:

- $\mathcal{G} = \mathbb{B}^8$  enkodiert standardbinär  $\{0, \dots, 255\}$



- Rekombination:





# Satz: „Fehlendes“ Schema-Theorem




Für einen genetischen Algorithmus nur mit Rekombination gilt:

$$\begin{aligned} \text{Erw} \left[ \bar{F}^{(t+1)} \right] - \bar{F}^{(t)} &= \sum_{\text{Merk} \subseteq \{1, \dots, l\}} p_{\text{Merk}} \cdot \left( \text{Cov} \left[ A.F, \frac{\bar{F}_{H_{\text{Merk}}(A.G)} \cdot \bar{F}_{\widetilde{H}_{\text{Merk}}(A.G)}}{(\bar{F}^{(t)})^2} \right] \right. \\ &- \left. \sum_{A.G \in \mathcal{G}} (p_{A.G} - p_{H_{\text{Merk}}(A.G)} \cdot p_{\widetilde{H}_{\text{Merk}}(A.G)}) \cdot (A.F - \bar{F}^{(t)}) \cdot \frac{\bar{F}_{H_{\text{Merk}}(A.G)} \cdot \bar{F}_{\widetilde{H}_{\text{Merk}}(A.G)}}{(\bar{F}^{(t)})^2} \right) \end{aligned}$$


mit Häufigkeiten  $p_{H_{\text{Merk}}(A.G)}$  und  $p_{\widetilde{H}_{\text{Merk}}(A.G)}$  der erzeugenden Schemata von  $A.G$  und durchschnittlichen Schematagütwerten  $\bar{F}_{H_{\text{Merk}}(A.G)}$  und  $\bar{F}_{\widetilde{H}_{\text{Merk}}(A.G)}$ .

# Beispiel

- 1-Punkt-Crossover
- Rekombinationswahrscheinlichkeit  $p_x = 1.0$
- keine Mutation
- Genotyp: mit 16 Bit encodierte Zahl (Maximum: 65536)
- Populationsgröße 400



Beitrag des Kovarianzterms zur  
prognostizierten Güteveränderung



# Überblick

- 1 Wechselspiel Variation – Selektion
- 2 Populationskonzept
- 3 Verknüpfen mehrerer Individuen
- 4 Selbstanpassende Algorithmen**
- 5 Zusammenfassung

# Einfluss des Stands der Suche



## Grundgedanke

- bisher: argumentiert, dass Mutation eine kleine Veränderung bzgl. des Phänotyps vornehmen soll
- jetzt: gilt das immer zu jedem Zeitpunkt der Optimierung?



## Kontrollexperiment

- Hillclimbing-Szenario
- Handlungsreisendenproblem
- unterschiedlich lokale Mutationsoperatoren:
  - Invertieren eines Teilstücks
  - Tausch dreier Städte


# Vergleich: Geschwindigkeit







# Gesamter Suchraum




# Varianz der erzeugten Gütewerte





# (Beweisbares) Ergebnis der Überlegungen



# Anpassungstechniken

## Vordefiniert

- die Veränderung wird vorab festgelegt

## Adaptiv

- es werden Maßzahlen für die Angepasstheit erhoben
- aufgrund von Regeln, wird daraus die Anpassung abgeleitet

## Selbstadaptiv

- Zusatzinformationen im Individuum werden genutzt
- zufallsbasiert sollen sich Parameter individuell einstellen

# Vordefinierte Anpassung

## Betrachteter Parameter

- reellwertige Gauss-Mutation
- $\sigma$  bestimmt die durchschnittliche Schrittweite

## Umsetzung

VORDEFINIERTER ANPASSUNG (Standardabweichung  $\sigma$ )

- 1  $\sigma' \leftarrow \sigma \cdot \alpha$  (Modifikationsfaktor)
- 2 **return**  $\sigma'$

- z.B. mit  $\alpha = 0,98$

# Adaptation

## Umsetzung

- Maß: Anteil der verbessernden Mutationen in den letzten  $k$  Generationen
- falls dieser „hoch“ ist,  $\sigma$  vergrößern

ADAPTIVE-ANPASSUNG (Standardabweichung  $\sigma$ , Erfolgsrate  $p_s$ )

```
1  if  $p_s > \Theta$  (Schwellwert)
2  then [  $\sigma' \leftarrow \sigma \cdot \alpha$  (Modifikationsfaktor ( $\alpha > 1$ )) ]
3  else [ if  $p_s < \Theta$ 
4          then [  $\sigma' \leftarrow \frac{\sigma}{\alpha}$ 
5          else [  $\sigma' \leftarrow \sigma$ 
6  return  $\sigma'$ 
```

# Selbstadaptation

## Umsetzung

- die Standardabweichung  $\sigma$  bei der Erzeugung des Individuums wird in den Zusatzinformationen gemerkt
- sprich: *Strategieparameter*
- wird beim Mutieren wieder leicht zufällig variiert
- „gute“ Werte für  $\sigma$  setzen sich durch bessere Güte der Kinder durch

# Experimenteller Vergleich

## Testumgebung



- 10-dimensionale Sphäre
- Hillclimber
- aber: pro Generation werden  $\lambda = 10$  Kindindividuen erzeugt
- reellwertige Gauß-Mutation mit  $\sigma = 1$
- Umweltselektion des Besten aus Elter und Kindern


# Selbstadaptation

SELBSTADAPTIVE-GAUSS-MUTATION(Individuum A)

```
1  $u \leftarrow \mathcal{N}(0, 1)$ 
2  $B.S \leftarrow A.S e^{\frac{1}{\sqrt{l}} u}$ 
3 for  $i \in \{1, \dots, l\}$ 
4   do  $\lceil u_i \leftarrow$  wähle zufällig gemäß  $\mathcal{N}(0, B.S)$ 
5      $B_i \leftarrow A_i + u_i$ 
6      $B_i \leftarrow \max\{B_i, ug_i$  (untere Wertebereichsgrenze)  $\}$ 
7      $\lfloor B_i \leftarrow \min\{B_i, og_i$  (obere Wertebereichsgrenze)  $\}$ 
8 return  $B$ 
```


# Ergebnis des Vergleichs





# Überblick

- 1 Wechselspiel Variation – Selektion
- 2 Populationskonzept
- 3 Verknüpfen mehrerer Individuen
- 4 Selbstanpassende Algorithmen
- 5 Zusammenfassung**



# Zusammenhänge (1)

Bedingung	Zielgröße	Erwarteter Effekt
Genotyp	Mutation	Nachbarschaft des Mutationsoperators wird beeinflusst
Mutation	Erforschung	zufälliger Mutationen unterstützen die Erforschung
Mutation	Feinabst.	gütelokale Mutationen unterstützen die Feinabstimmung
Mutation	Diversität	die Mutation vergrößert die Diversität
Mutation	lokale Optima	gütelokale Mutationen erhalten lokale Optima des Phänotyps, zufälliger Mutationen können sogar mehr einführen
Rekombination	Erforschung	extrapolierende Operatoren stärken die Erforschung
Rekombination	Feinabst.	interpolierende Operatoren stärken die Feinabstimmung

# Zusammenhänge (2)

Bedingung	Zielgröße	Erwarteter Effekt
Div./Rekomb.	Mutation	geringe Diversität und interpolierende Rekombination dämpft Ausreisser der Mutation
Diversität	Rekombination	hohe Diversität unterstützt die Funktionsweise der Rekombination
Selektion	Erforschung	geringer Selektionsdruck stärkt die Erforschung
Selektion	Feinabst.	hoher Selektionsdruck stärkt die Feinabstimmung
Selektion	Diversität	Selektion verringert meist die Diversität
Div./Rekomb.	Erforschung	kombinierende Rekombination stärkt die Erforschung bei hoher Diversität
Div./Rekomb.	Feinabst.	kombinierende Rekombination stärkt die Feinabstimmung bei geringer Diversität

# Zusammenhänge (3)

Bedingung	Zielgröße	Erwarteter Effekt
Erforschung	Diversität	erforschende Operationen erhöhen die Diversität
Feinabst.	Diversität	feinabstimmende Operationen verringern die Diversität
Diversität	Selektion	geringe Diversität verringert den Selektionsdruck der fitnessproportionalen Selektion
Rekombination	Forma-Verarb.	Rekombination gemäß den Forma-Regeln unterstützt das Schema-Theorem
Forma-Verarb.	Suchfortschritt	Erfolgreiche Forma-Verarbeitung unterstützt den Suchfortschritt
lokale Optima	Suchfortschritt	viele lokale Optima hemmen den Suchfortschritt
Erf./Fein./Sel.	Suchfortschritt	Ausbalancieren der drei Faktoren ist notwendig