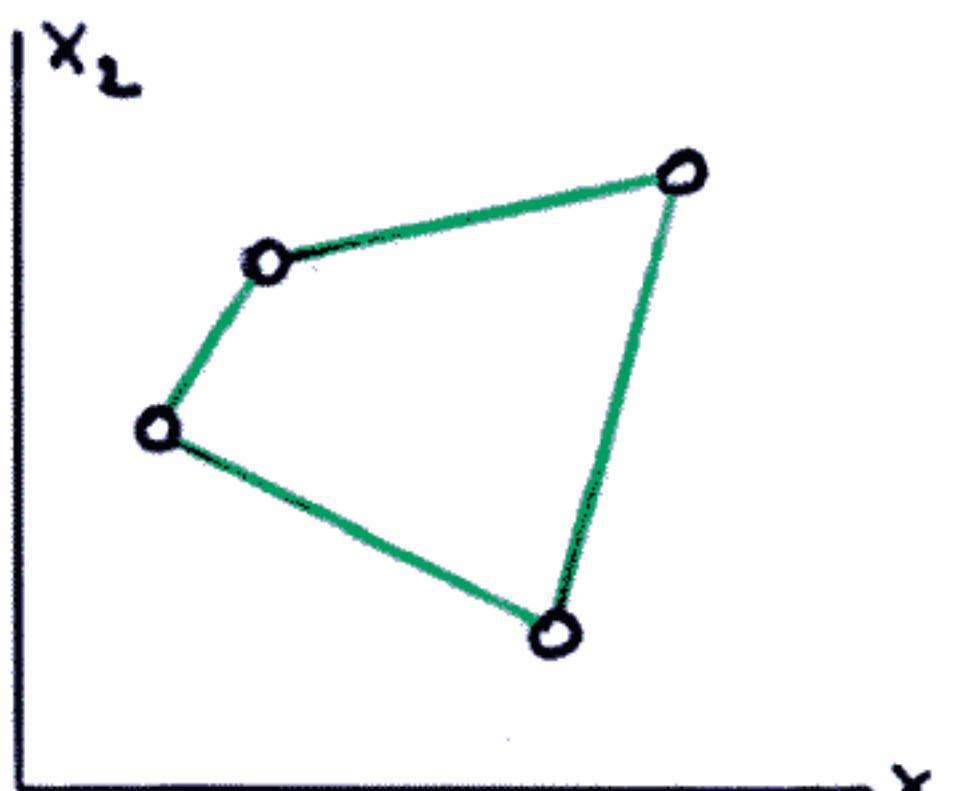
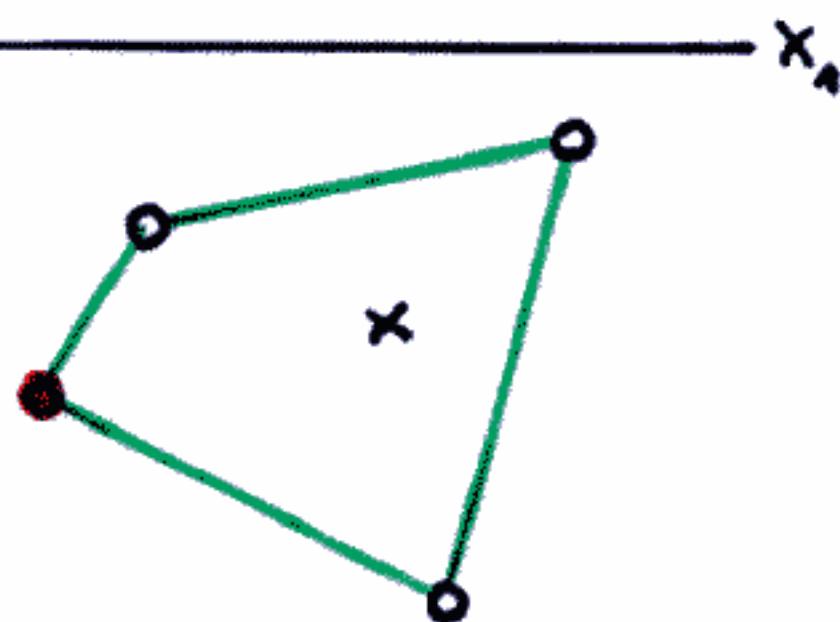


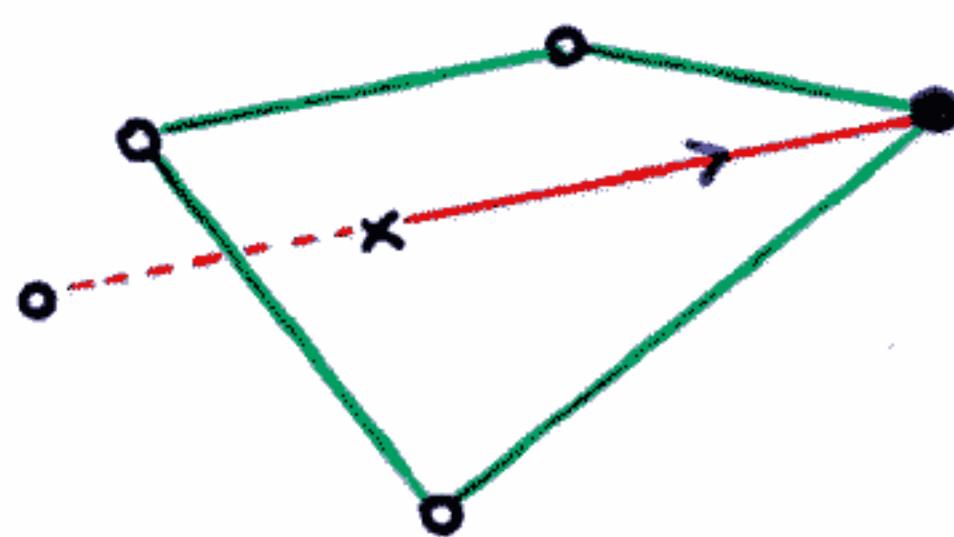
Complex - Strategie von M.J. Box (1965)



Ausgangspolyeder mit
 $N \geq n+1$ Ecken
hier: $n=2$; $N=4$

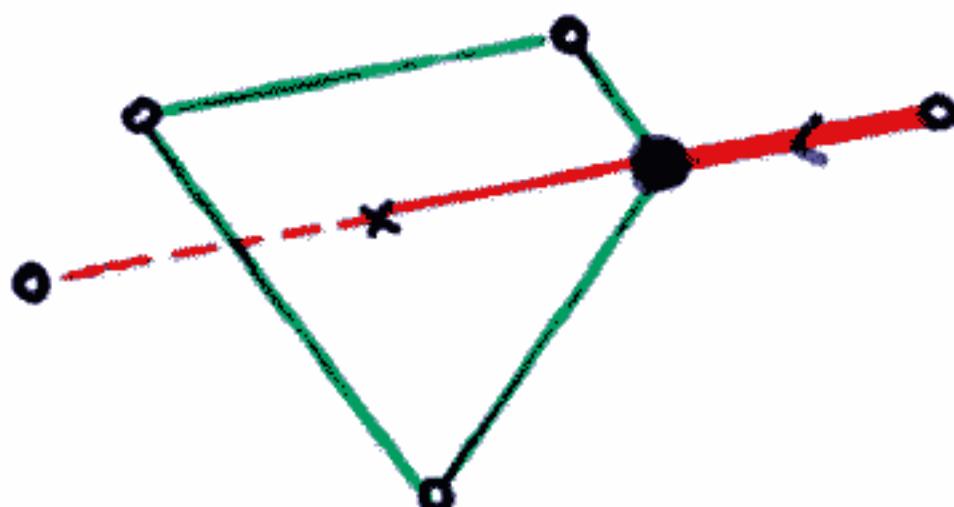


Bestimmung der schlechtesten
Ecke und des Schwerpunkts
der übrigen Ecken • x



Spiegelung von • an x
mit Reflexionsfaktor > 1

bei Erfolg: neue Ecke ersetzt
schlechteste

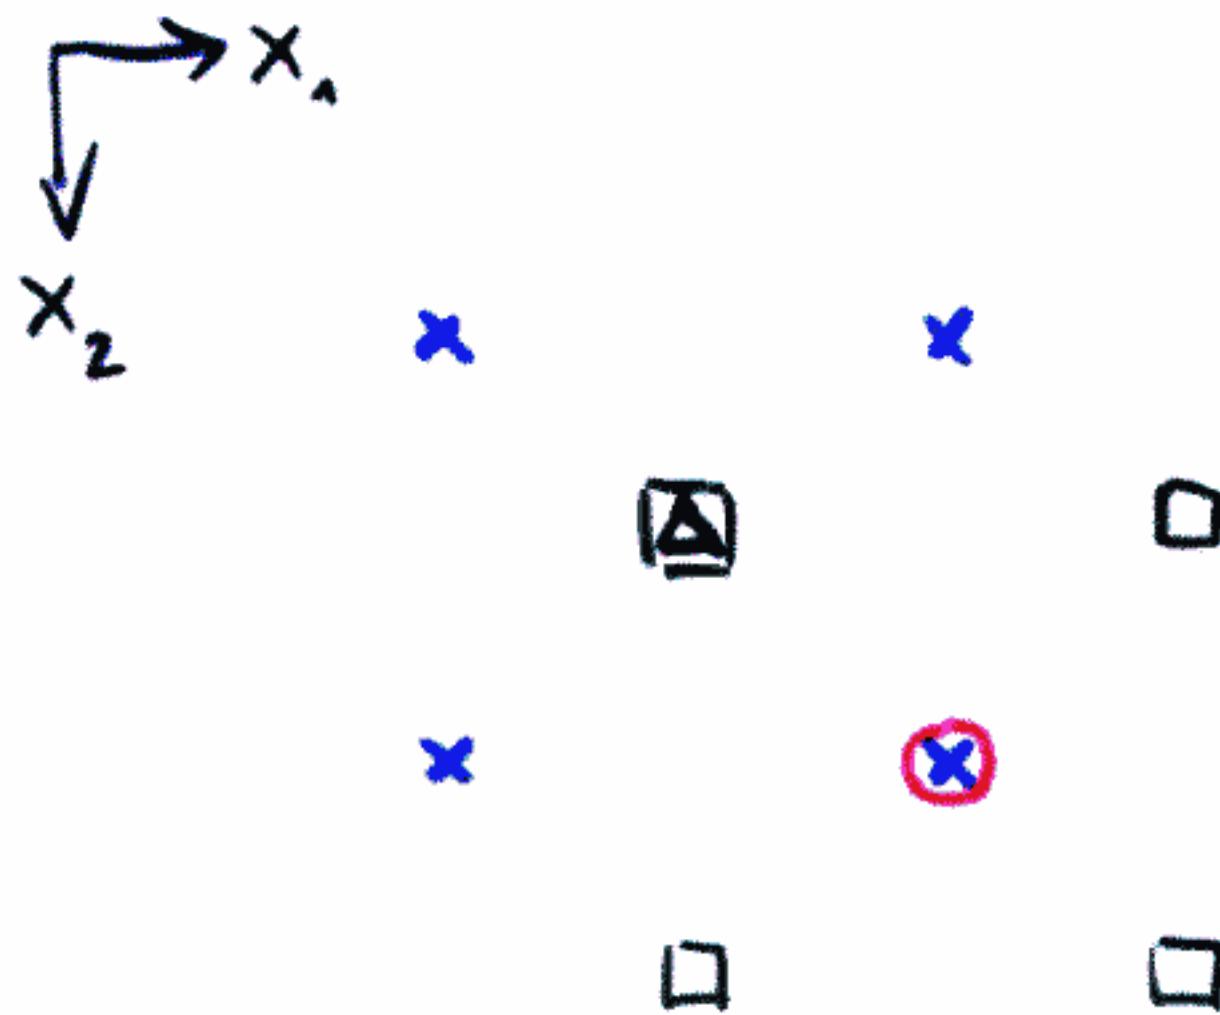


bei Misserfolg:
Rücksetzung auf die Hälfte
zwischen neuer Ecke und
Schwerpunkt

Abschaltregel: 5 aufeinander folgende erfolglose
Rücksetzungen

Nebenbedingungen: wenn verletzt: Rücksetzung
suche nach zuläss. Anfangslösung über Ersatz-
zielfunktion möglich

EVOP evolutionary operation G.E.P. Box



△ Start

✗ 1. Versuchsserie

✖ bester Versuch

□ 2. Versuchsserie

full factorial design

2^{n+1} Hart
 $2^n - 1$ Versuche/Runde
später

Fractional factorial design

$2^m - 1$ " später
 $m < n$

gute Idee: nicht alle Mögl. ausprobieren, sondern
sequentiell an Opt. herantasten

($2^n - 1$ Tests können gleichz. Anzahl gef. werden)

REVOP random EVOP | Satterthwaite)

nur $n+1$ zufällige Proben / Versuchsserie

? Evolution

1 Elter, 2^m Nachkommen
Elter kann überleben
(1 + 2^m) - E.S.

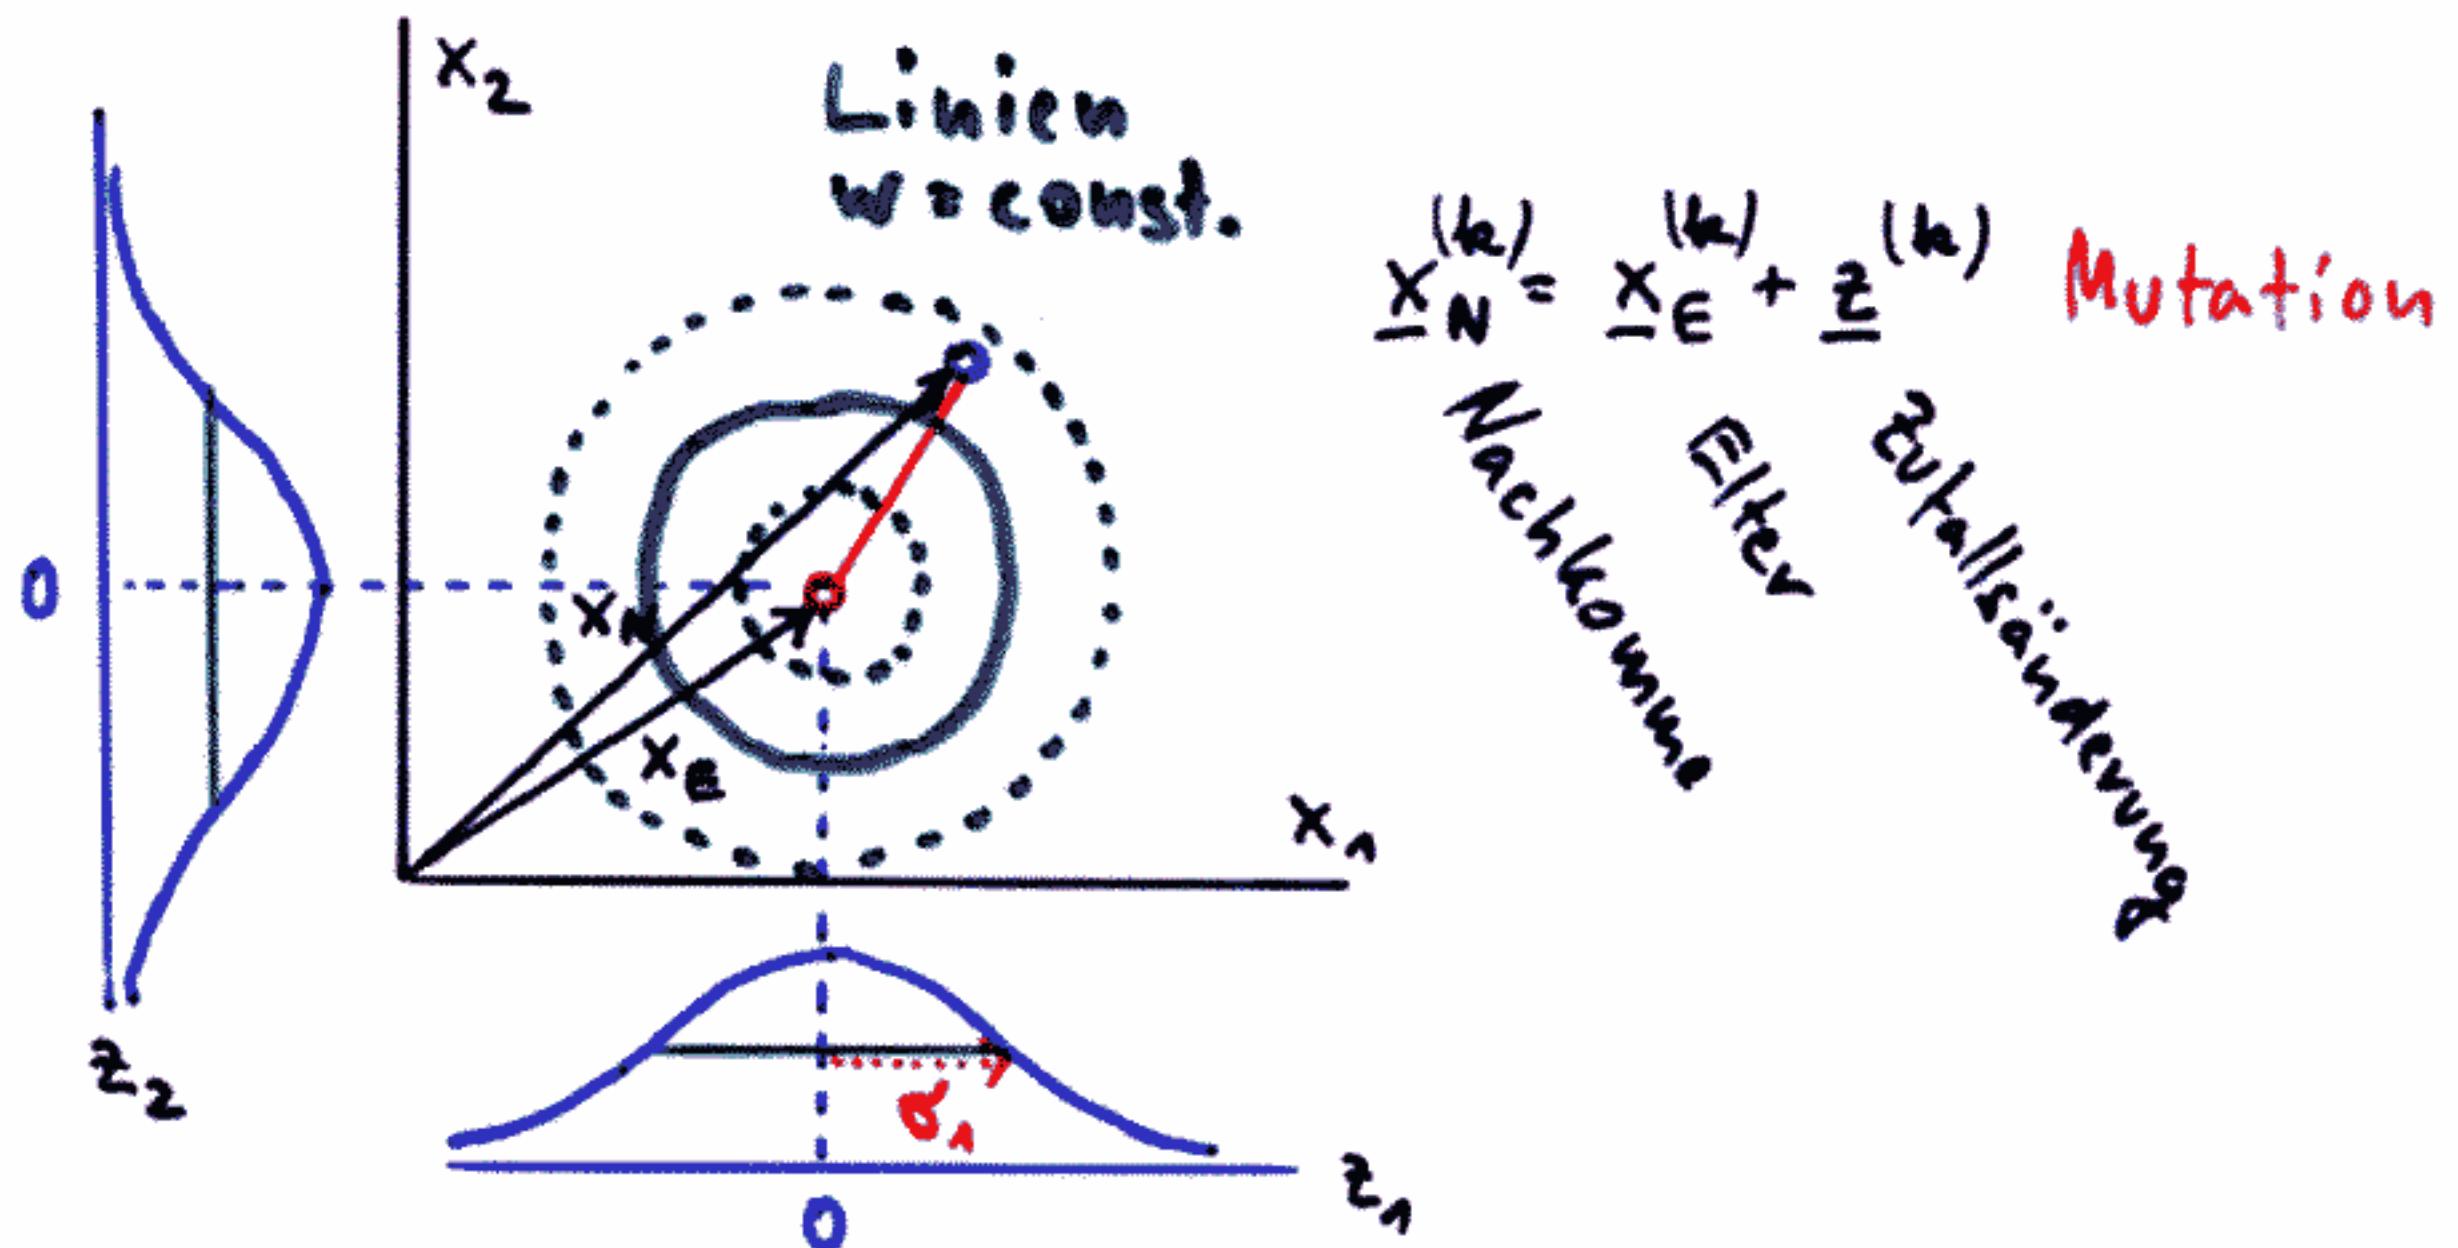
Weitere Varianten: Simplex-Strat. Nelder+Mead
Complex-Strat. M.J. Box

(1+1) - Evolutionsstrategie (Rechenberg, 1970)

$$\underline{x}^{(k+1)} = \underline{x}^{(k)} + s^{(k)} \cdot \underline{z}^{(k)}$$

Richtung: zufällig

„mittlere“ Schrittweite: abhängig Erfolgsrate gesteuert



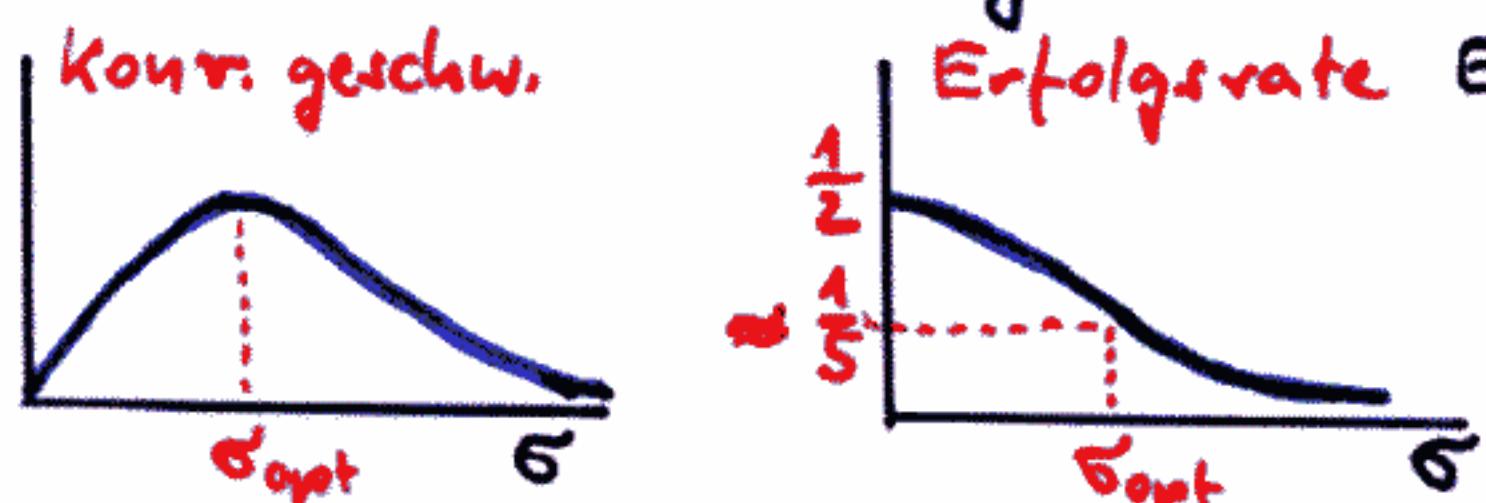
$$w(z_i) = \frac{1}{\sqrt{2\pi} \cdot \sigma_i} \exp\left(-\frac{z_i^2}{2\sigma_i^2}\right) \quad \text{Normalverteilung}$$

Selektion:

$$\underline{x}_E^{(k+1)} = \begin{cases} \underline{x}_N^{(k)} & \text{bei Verbesserung} \\ \underline{x}_E^{(k)} & \text{sonst} \end{cases} \quad \begin{array}{l} (\text{zielf. Wert besser} \\ \text{und all Neb.} \\ \text{erfüllt}) \end{array}$$

Schrittweitensteuerung:

korr. geschw.



$\sigma \uparrow$ wenn $E > \frac{1}{5}$

$\sigma \downarrow$ wenn $E < \frac{1}{5}$

(1+1) : 1 Elter, 1 Nachkomme

Auslese: Elter oder Nachkomme

Evolutionäre Algorithmen EAs

Evolutionary Computation EC

- Sammelbegriff für verschiedene Ansätze, natürliche (biologische, Lebens-) Entwicklungsprozesse algorithmisch nachzuahmen
- Grundideen aus den 60er Jahren
- seit etwa 1985 : exponentiell wachsend, wobei erfolgreiche Anwendungen maßgebend
- jetzt auch zunehmende Akzeptanz in Computer Science / Informatik
- zusammen mit anderen nicht-KI Methoden

NN (künstliche neuronale Netzwerke)

FL Fuzzy-Logik

AL Artificial Life

AA autonome Agenten

CA zelluläre Automaten

noch vorläufige Sammelbegriffe:

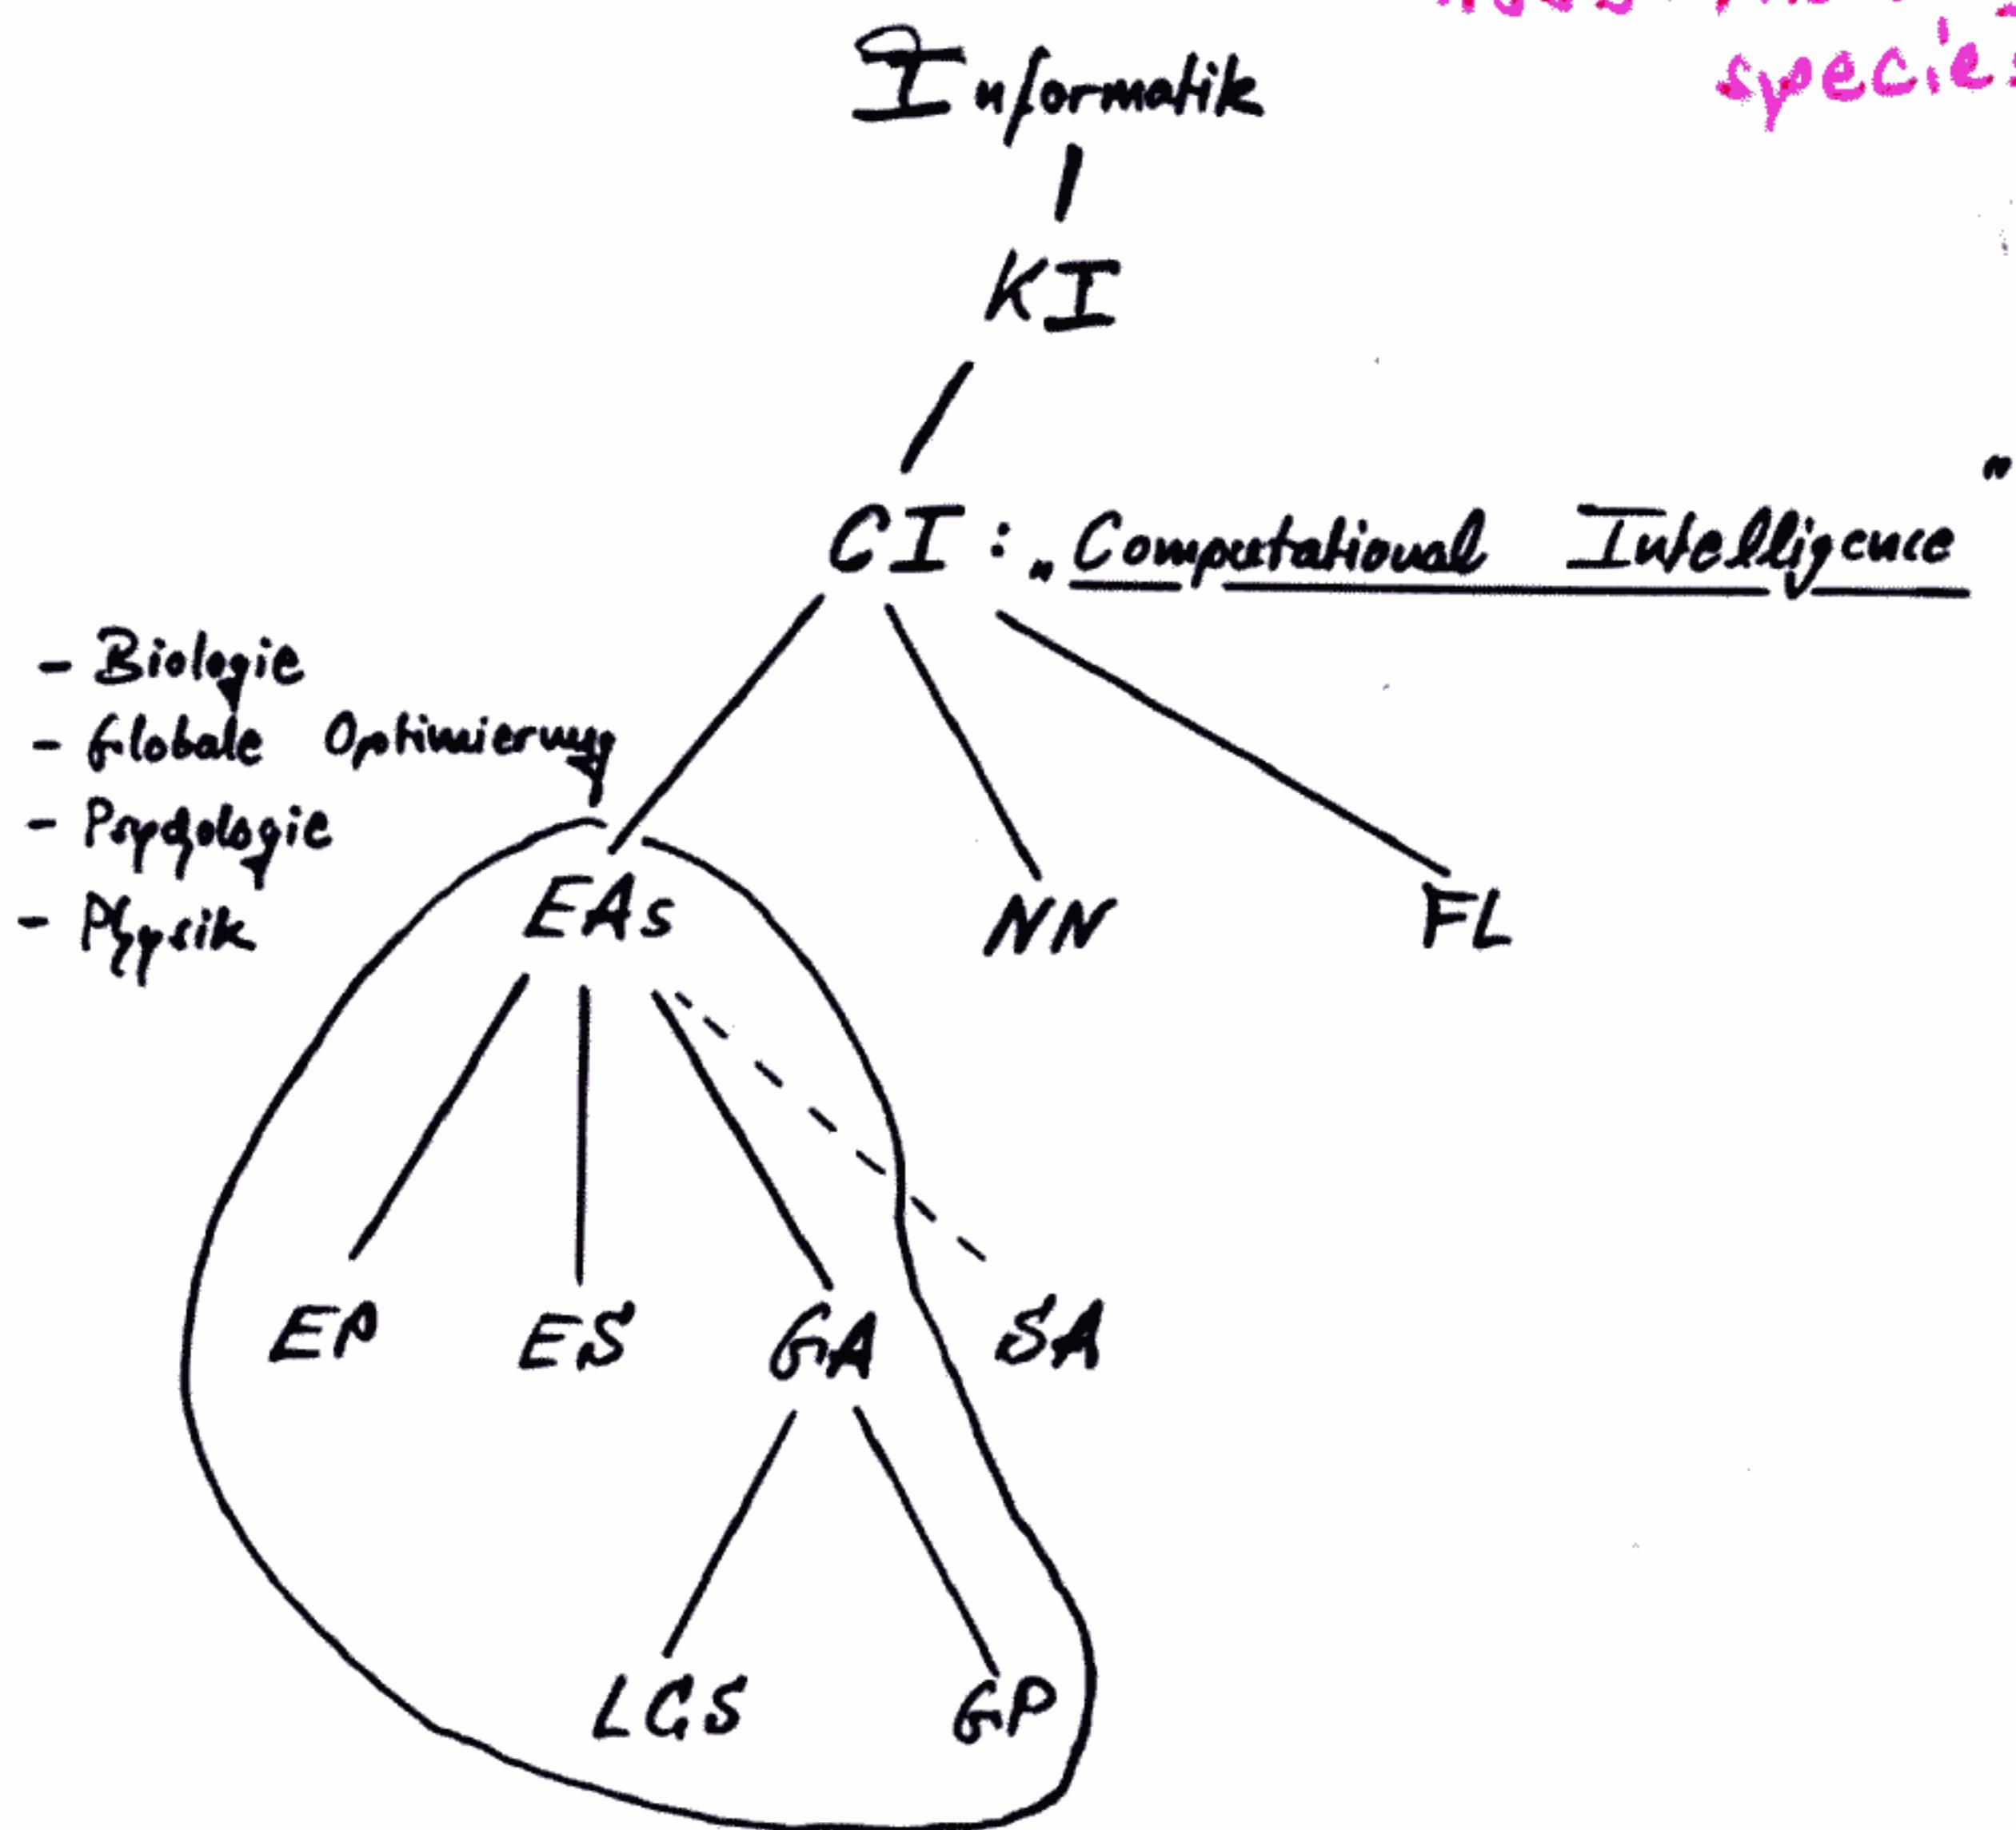
soft computing

Computational Intelligence

intelligente hybride Algorithmen

Bioinformatik / Neuroinformatik

naturanaloge parallele Problemlösungs-strategien



Konferenzen:

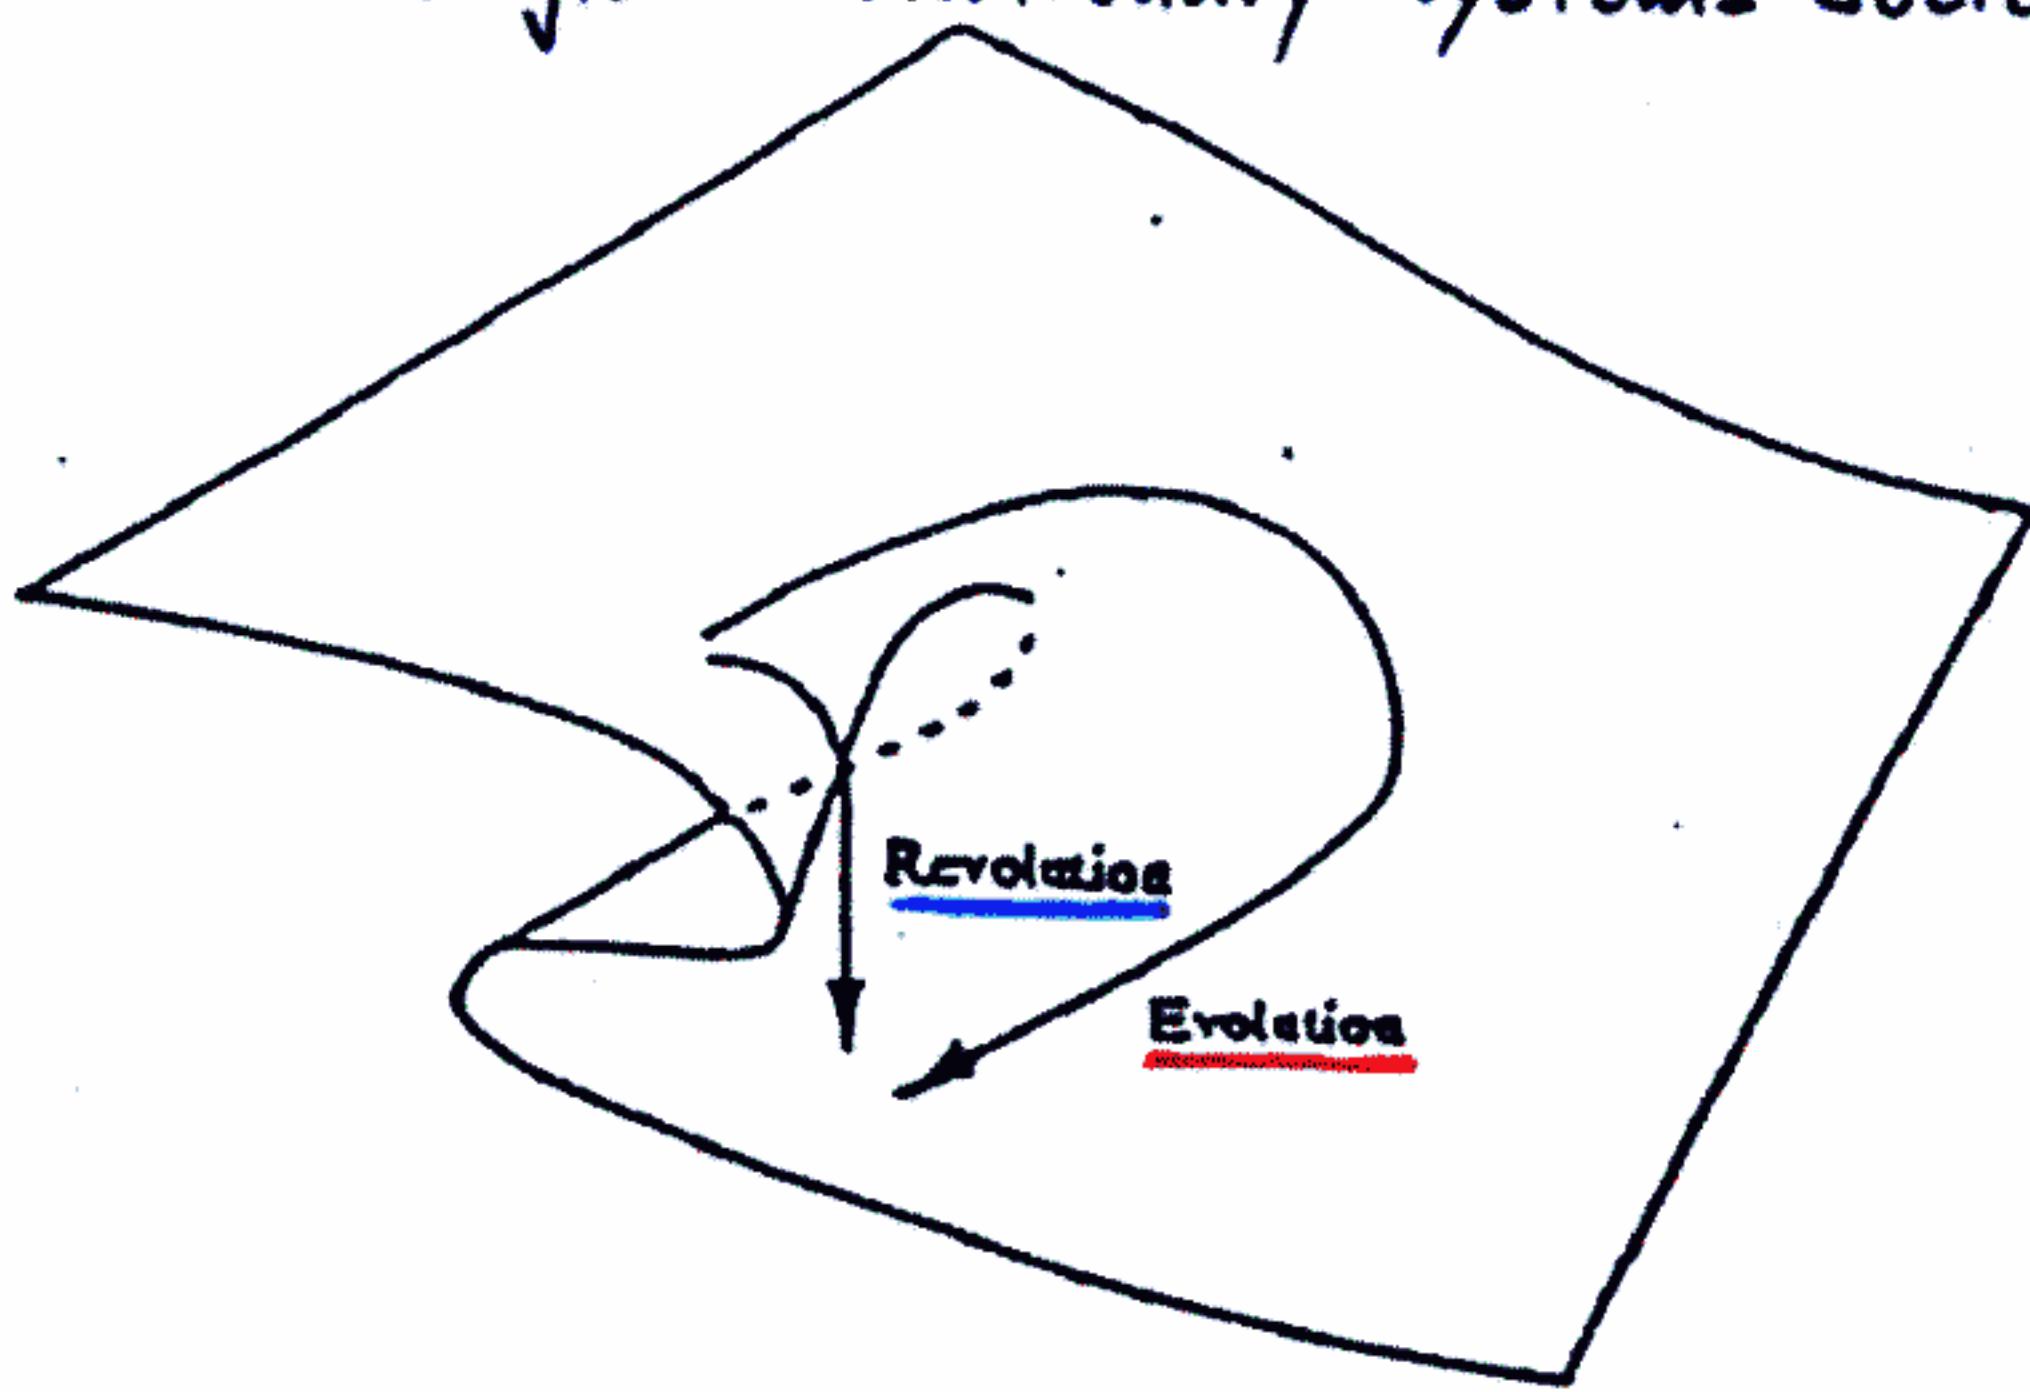
ICGA	85, 87, 89, 91, 93
PPSN	90, 92, 94
FOGA	90, 92, 94
EP	92, 93, 94
IEEE-EG	94

Journals:

Evolutionary Computation
Complex Systems
BioSystems (ab '94)

aus WESS.com

Washington Evolutionary Systems Society journal



falsch: Evolution ist nicht
stetige Adaptation / Höherentwicklung

auch falsch : Evolution ist nicht
wildes Herumprobieren (Monte Carlo)
[z.B. R. Ashby : Design for a Brain]

etwas besseres Modell:

Bewahren des Bewährten: Vererbung

Zulassen von Probe-Innovationen: Mutation
begrenzte Lebensdauer Mischen

Bewährungstest: Selektion, aber, sanft'

[nur 20% Erfolge „optimal“]

Schallplatten, Mode, neue Nahrungsmittel

Naturgesetze → begrenzte Variation

EAs

- sehr stark vereinfachte Nachahmung (unterhalb Einzeller)
- Begriff 'Evolution' offenbar emotionsbeladen
 - falsche Modellvorstellung / Modellierung

z.B. es gibt keine Evolution
 Evolution = Monte Carlo Strategie
 Evolution = stetiger, monotoner Anstieg der Fitness
- Hintergrundgedanken
 - z.B. zeigen, daß Ev. nicht funktionieren kann besserer Verständnis für natürliche Prozesse (vgl. Gehirn / NN)
- nach wie vor 'philosophische' Unterschiede der 3 existierenden 'Schulen'

EP Evolutionary Programming

GA Genetic Algorithms

GAs

GP Genetic Programming

ES Evolutionsstrategien

ESS

Σ EA(s) Evolutionary Algorithms

EC Evolutionary Computation

Evolutionäre Algorithmen (EA)

heute im wesentlichen 3 Gruppen

- Evolutionary Programming (EP)

D. Fogel

1966 : L. Fogel, Artificial Intelligence through Simulated Evolution

- Genetic Algorithms (GAs)

J. Holland, ... De Jong, Grefenstette ...

1975 : J. Holland, Adaptation in Natural and Artificial Systems

- Evolutionsstrategien (ESS)

I. Rechenberg, ... Schwefel

1971/73 : Evolutionsstrategie - Optimierung technischer Systeme nach Prinzipien der biologischen Evolution

(Vorläufer, Seitenzweige)

seit 1985 : ICGA

-Konferenzen (alle 2 Jahre)

seit 1990 : PPSN

auch SA, IN, ...

April 1993 : Evolutionary Computation Aut'l Journal (MIT Press)

Sommer 1994 : Weltkongress WCCI



wichtige Beobachtungen:

Individuen (zu einem Zeitpunkt) verschieden
phänotypische Diversität

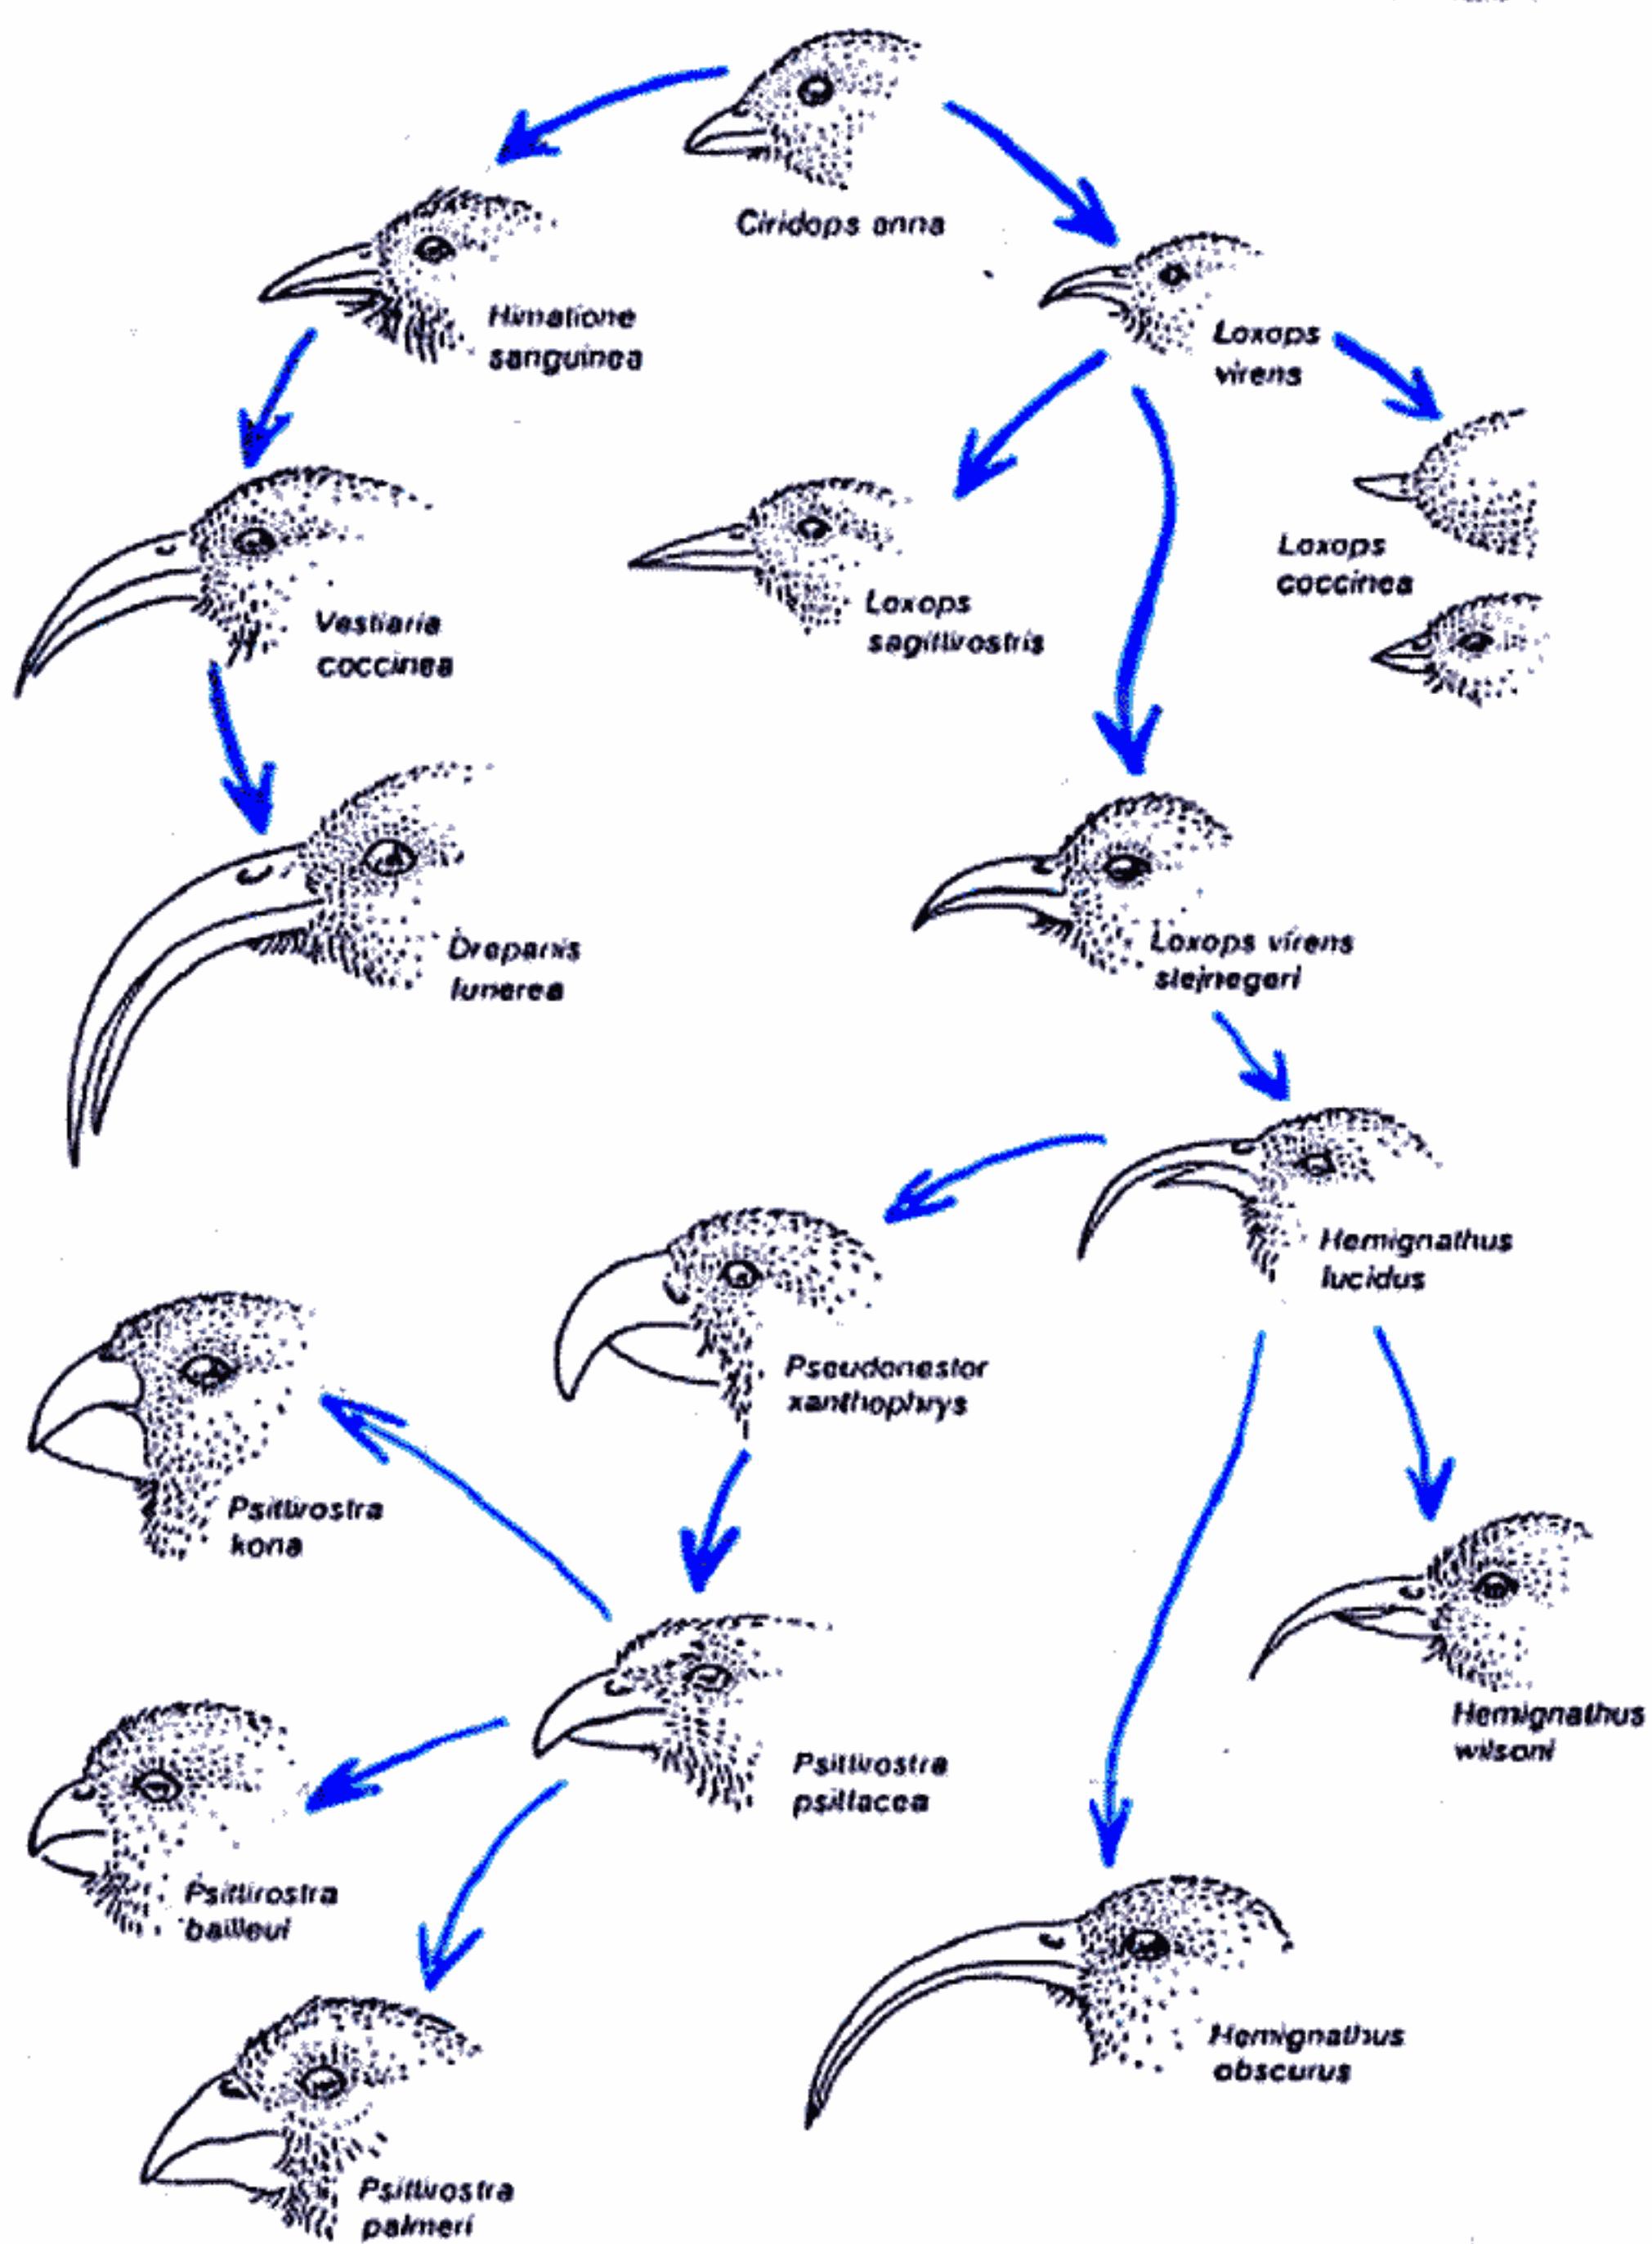
Individuen haben endliche Lebensdauer

Individuen haben Nachkommen (nicht alle),
die etwas verschieden von Vorgängern sind
phänotypische Variabilität

über längere Zeiträume (Generationen)
bzw. unter verschied. Umweltbedingungen
(z.B. auf Zusein mit verschied. Lebensbedingungen):
erhebliche Veränderungen / Anpassungen

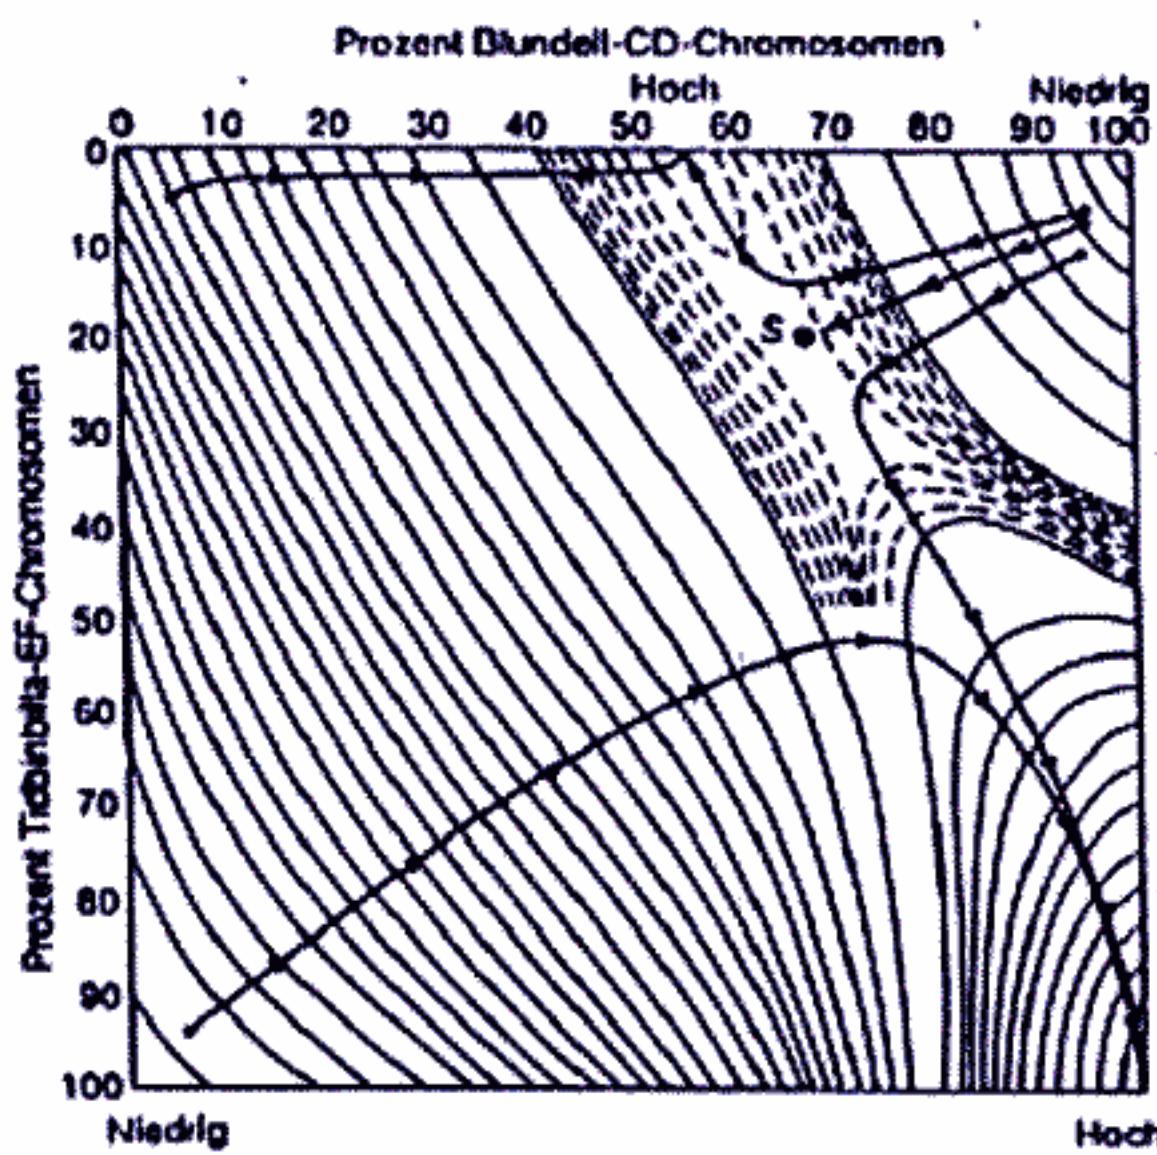
Lit.: Mayr, 1988
Futuyma, 1990

Hawaiische Kleidevögel



Diversifizierung von Arten,
die von gemeinsamen Vorfahren abstammen,
in verschiedene ökologische Nischen

Adaptive Landschaft (Wright, ~1932)



Fitneß in
Abh. von
biolog. Eigensch.

• Sattelpunkt

Abbildung 1:

Adaptive Landschaft einer Population der australischen Heuschrecke *Morabia scurra*, die für die beiden Chromosomen *EF* und *CD* polymorph ist. Ausgehend von den Genotypfrequenzen im Freiland wurde für jeden Genotyp die Lebensfähigkeit berechnet. Aus diesen Werten wurde wiederum die theoretische Fitneß der Population für alle möglichen chromosomalnen Zusammensetzungen berechnet. Kombinationen mit gleichem \bar{w} sind durch Höhenlinien miteinander verbunden. Die gestrichelten Linien geben kleinere Unterscheidungen von \bar{w} an als die durchgezogenen Linien. Es gibt zwei Gipfel (Hoch) und einen Sattelpunkt (S). Die Trajektorien stellen theoretische Änderungen der genetischen Zusammensetzung dar, denen eine Population ausgehend von fünf Anfangszuständen folgen würde. (Nach Lewontin & White 1960)

Fitneß: Überlebens- und Reproduktionsfähigkeit eines Individuums in seiner Umwelt

schematische
Darstellung

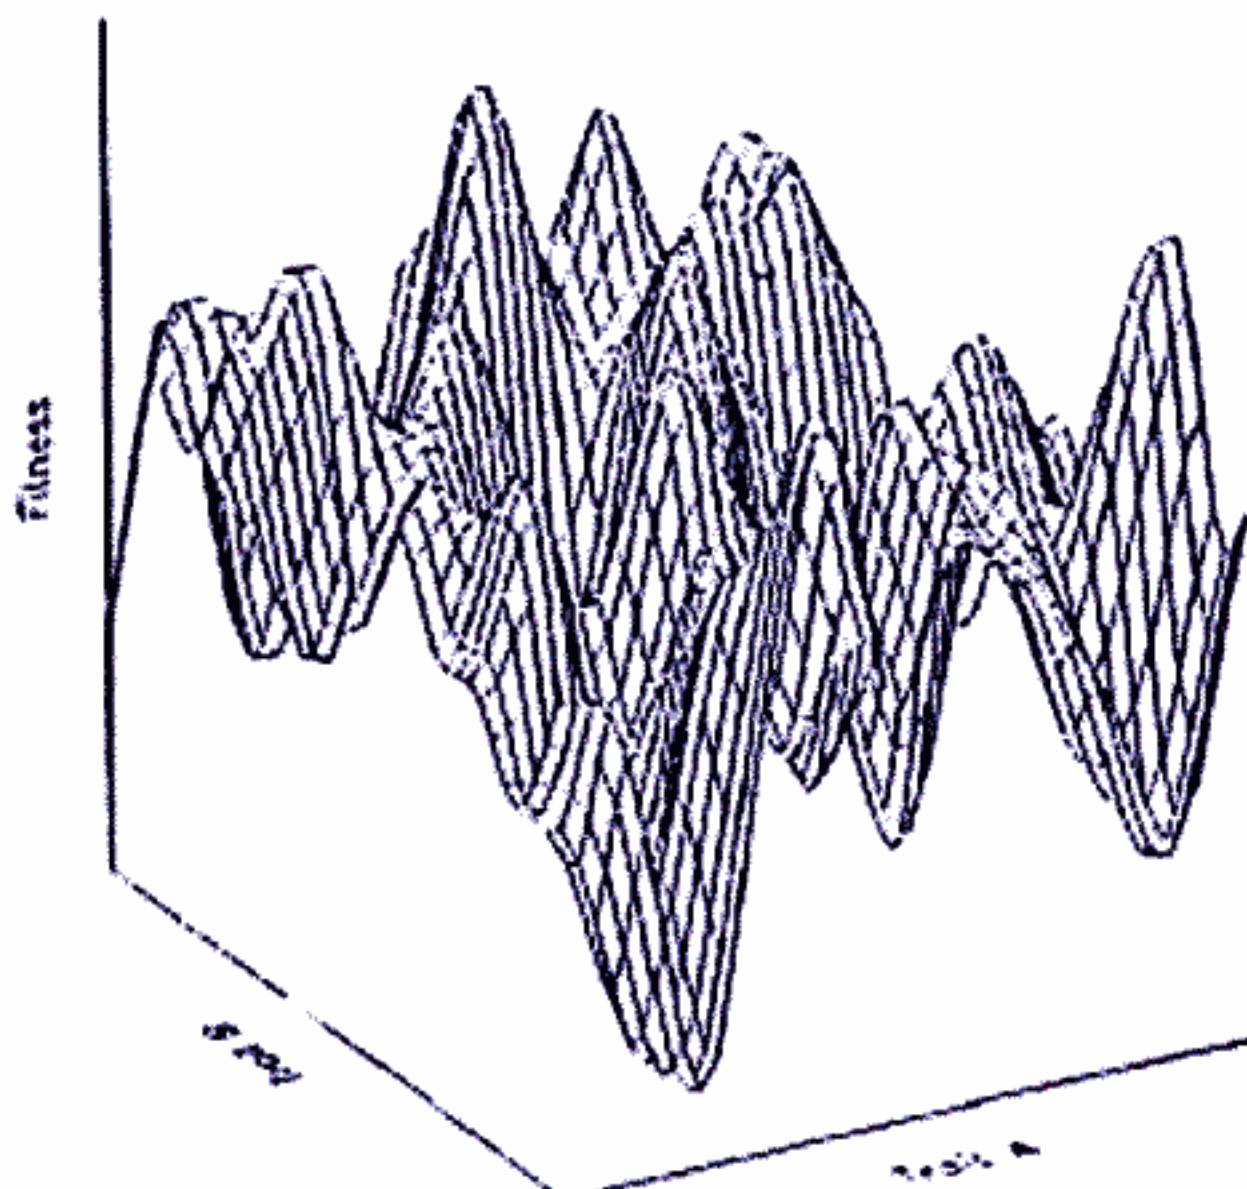
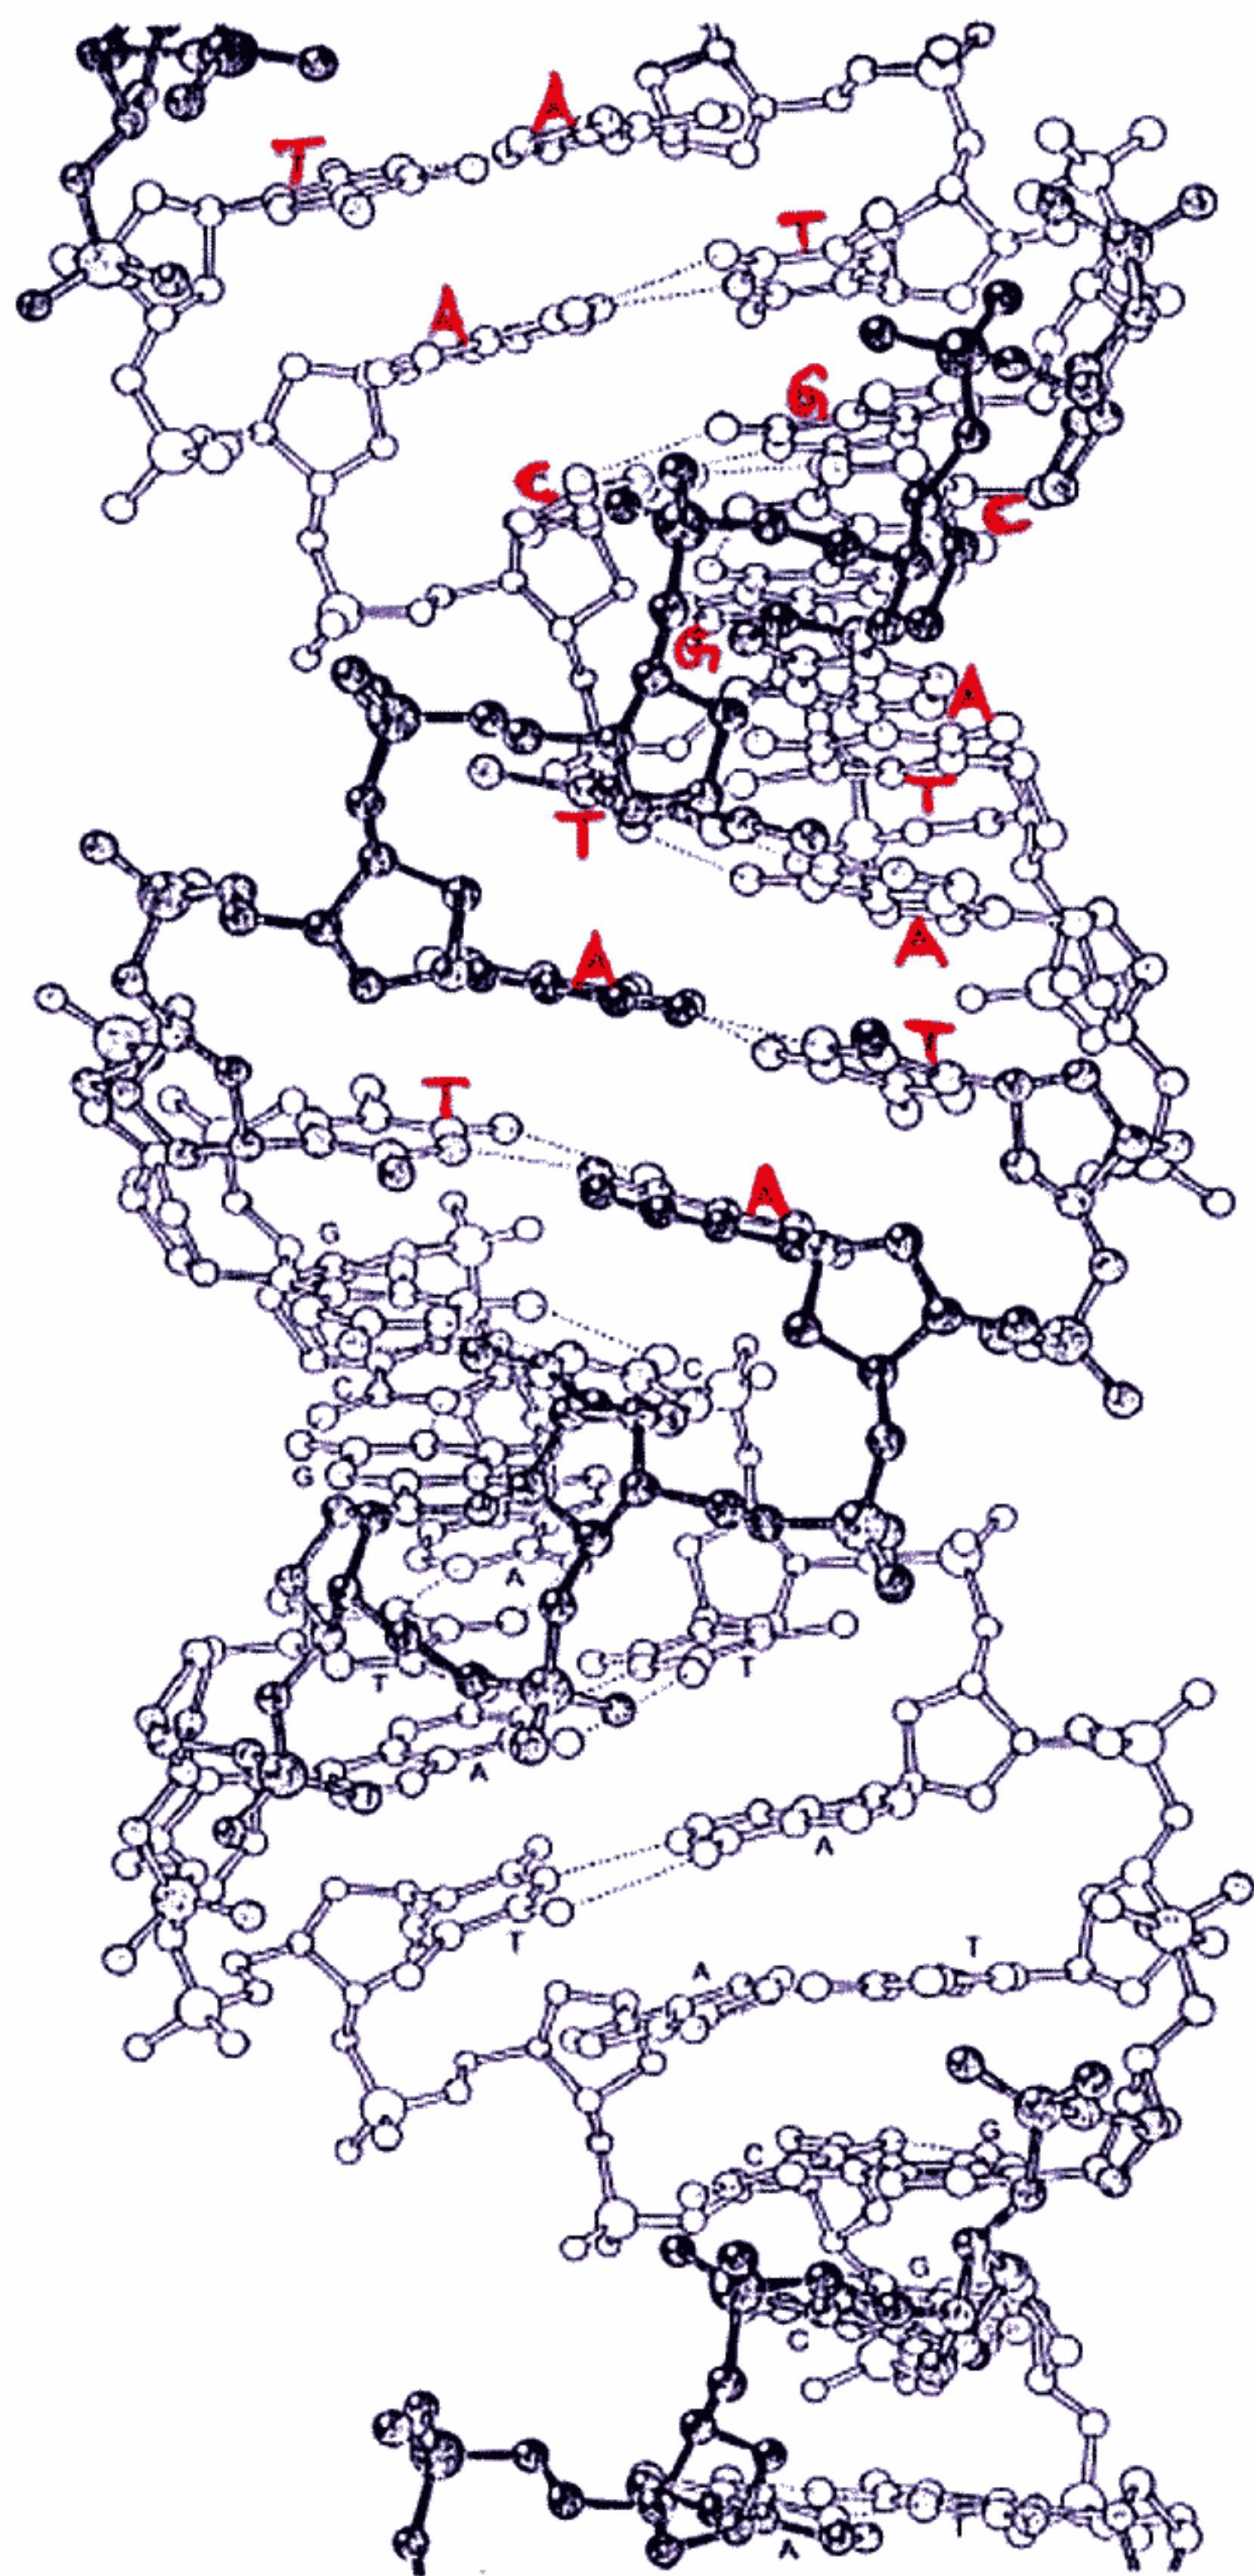


Figure 1.1: Schematic diagram of an adaptive surface.

DNS - Strukturausschnitt



Genetik in Kürze:

in jedem Zellkern befindet sich ein 'Bauplan' des zugehörigen Individuums:

Fadenmolekül DNS Desoxyribonukleinsäure
A

(spiralförmige Doppelhelix, Watson + Crick;
zwei Einzelstränge aus Zucker + Phosphat,
verbunden über H-Brückenbindungen zwischen



Adenin, Thymin



Guanin, Cytosin

(Nukleotidbasen)

DNS ist Charakteristikum (Genotyp) für
Erscheinungsform (Phänotyp) eines Individuums

- Ontogenese Urzelle \rightarrow Lebewesen
 Bauplan \uparrow Ausprägung
- weitere Zellteilungen Umwelt

Mensch: $\sim 3.8 \cdot 10^9$ Nukleotidbasen

(Lungenfisch hat erheblich mehr)

(Bakterien, Hefen am wenigsten)

diploid: 2 Doppelstränge

$4^{3.8 \cdot 10^9} \approx 10^{2300\,000\,000}$ mögl. Genotypen

Zentrales Dogma der Molekulargenetik:

vererbt wird der Genotyp, nicht Phänotyp
 d.h. erworbene Eigenschaften eines Individuums
 sind nicht vererbbar (unge: Lamarckismus)

? Genotyp - Phänotyp - Abbildung

mehrstufiger Prozess, Umwelt spielt mit

1. Stufe

ein Basentriplett codiert eine Aminosäure

$$4^3 = 64 \quad 20$$

(redundanter genetischer Code, fast universell)
(heute)

61 Zuordnungen + 3 Stop-Zeichen

2. Stufe

(30...)100 - 1000(...30 000) Aminosäuren Gen
 codieren ein Protein

3.

Zellen

:

Organe

n. Stufe

Individuum

Genom

Polygenie: kombinierter Einfluss mehrerer Gene
 auf eine phänotypische Eigenschaft

Pleiotropie: ein Gen beeinflusst mehrere phänotyp.
 Eigenschaften

Tabelle I

Der genetische Code. Die 64 Nukleotid-Triplets der mRNA und die dazugehörigen Aminosäuren

		ZWEITES NUKLEOTID								
		U	C	A	G					
ERSTES NUKLEOTID	U	UUU UUC UUA UUG	Phe Leu	UCU UCC UCA UCG	Ser	UAU UAC UAA UAG	Tyr Kettenende Kettenende	UGU UGC UGA UGG	Cys Kettenende Trp	U C A G
	C	CUU CUC CUA CUG	Leu	CCU CCC CCA CCG	Pro	CAU CAC CAA CAG	Ile Gln	CGU CGC CGA CGG	Arg	U C A G
	A	AUU AUC AUA AUG	Ile Met	ACU ACC ACA ACG	Thr	AAU AAC AAA AAG	Asn Lys	AGU AGC AGA AGG	Ser Arg	U C A G
	G	GUU GUC GUA GUG	Val	GCU GCC GCA GCG	Ala	GAU GAC GAA GAG	Asp Glu	GGU GGC GGA GGG	Gly	U C A G
DRITTES NUKLEOTID										

Die in der Tabelle abgekürzten Aminosäuren heißen: Ala, Alanin; Arg, Arginin; Asn, Asparagin; Asp, Asparaginsäure; Cys, Cystin; Gly, Glycin; Glu, Glutaminsäure; Gln, Glutamin; His, Histidin; Ile, Iso-Tryptophan; Tyr, Tyrosin; Val, Valin.

AUG : auch Start

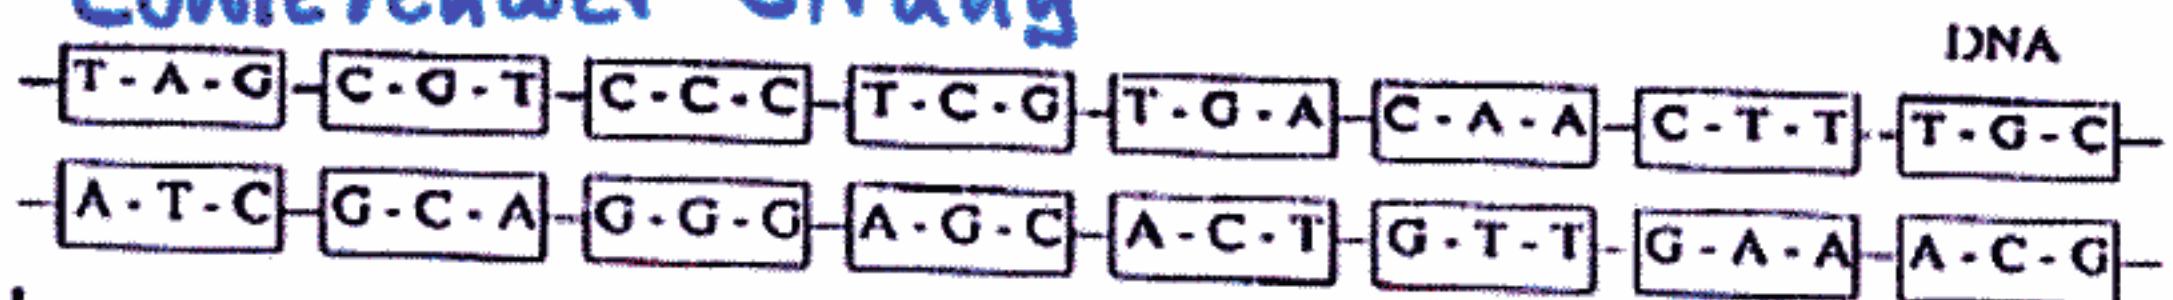
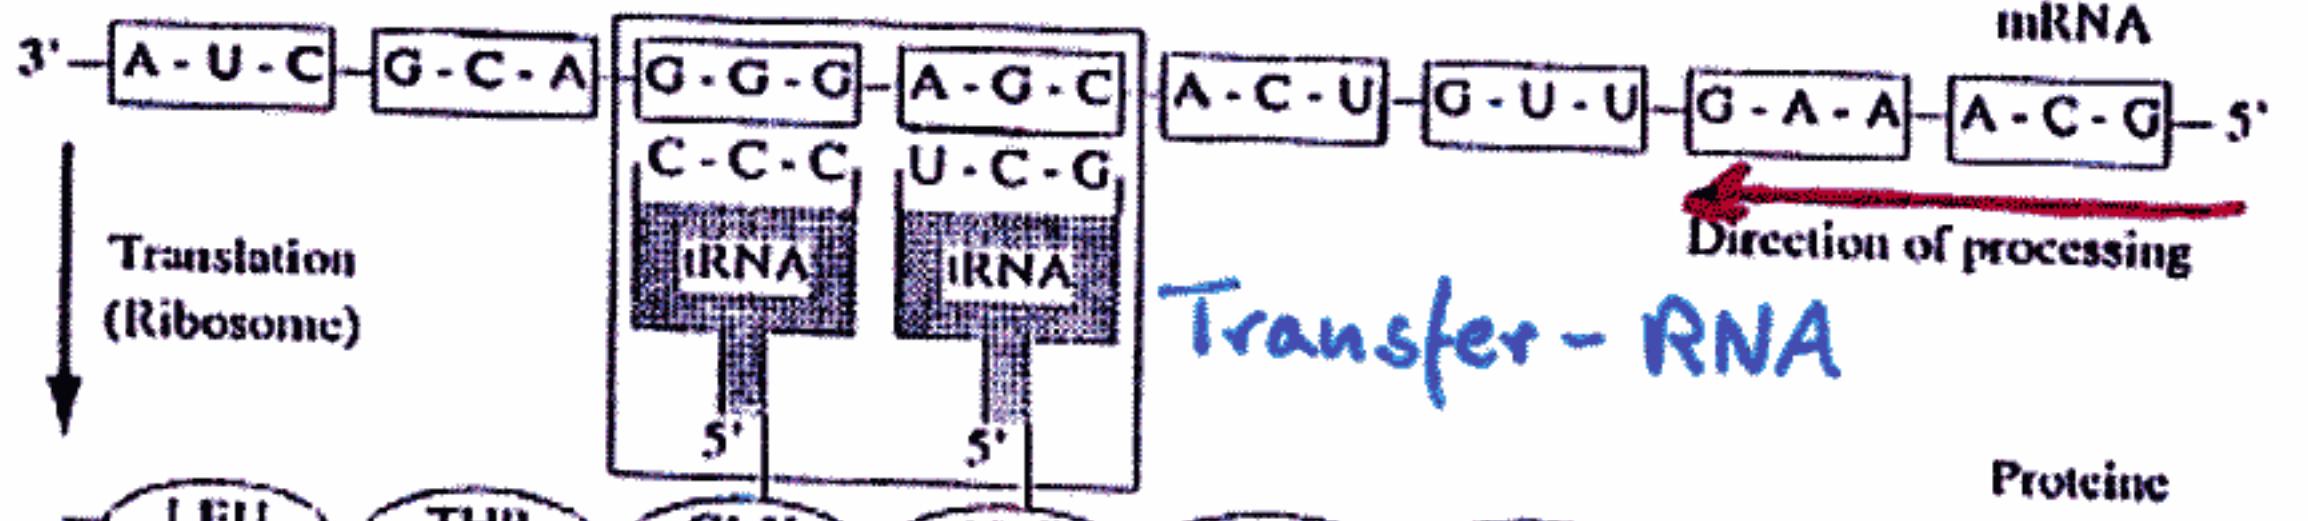
Protein-Biosynthesecodierender StrangTranscription
(Nucleus)

Figure 1.2: Simplified scheme of protein biosynthesis in living cells.

U(Uracil) statt T(Thymin) in mRNA

Polyploidie : DNS (Chromosomen-Setz) mehrfach vorhanden

haploid	einfach	
diploid	doppelt	(z.B. Mensch)
polyploid	4, 8, 16 ...	(z.B. Pflanzen nahe Vulkanen, Gletschern)

nur jeweils einer der Allele (homologe Gene)
wird ausgeprägt [Dominanz, Rezessivität]
[homozygot, heterozygot]

Meiose : durch Zellteilung entstehen haploide Keimzellen

Mitose : durch Kernverdopplung und anschl. Zellteilung entstehen wieder diploide Zellen

Vererbung (meiotisch) : Verschmelzung zweier Keimzellen + anschl. 2 Teilungen ; dabei Umordnungsprozesse : Crossover = Segment austausche zwischen Chromosomenpaaren

ferner : Kopierfehler, Übertragungsfehler

Umwelteinflüsse : Höhenstrahlung, Radioaktivität
....

Eigenmaßnahme : Reparaturmechanismen Enzyme

unvollkommene Reparatur! sogar Mutatorgene
→ Behmutationen

(etwas Unordnung / Chaos muß wohl sein)

Gen - Mutationen

- somatisch nur Körperzellen betreffend
- generativ Keimzellen betreffend
(also vererbar)

Chromosomen - Mutationen (meist letal)

- Deletionen , Defizienzen
- Duplicierungen
- Translokationen
- Inversionen

Genom - Mutationen

- Hyperploidie Zunahme d. Chromosomenzahl
- Hypoploidie Abnahme
- Euploidie Komplette Chromosomensätze
Zusätzlich

Exon, Introns : noch weitgehend unverstanden:
mehr oder weniger große Teile des Genoms dienen nicht
zur Ausprägung eines Phänotyps

Mensch : 23 Chromosomen
ca. 100 000 Gene

Hierarchie der (genetischen) Information

Quarks

:

Atome

:

Moleküle

Nukleotidbase

Codon

Gen

Skripton

Repliken

Chromosom

Genom

Einzel-Symbol

Entsch. Variable

Satz von Entsch. Variablen

GA : setzen auf Codierung mit Alphabet
minimaler Kardinalität

→ Binärsstring - Repräsentation
jedes Individuum

EP : setzen auf Artenentwicklung

→ jeder 'Individuum' ist eine Spezies
kein Crossover / keine Rekombination

ES : setzen auf Individuen mit problem abh.

Codierung der Variablen : reell

ganzzahlig, diskret
...

nehmen Genotyp/Phänotyp Abbildung mithilfe
korrelierter Variabilität nach

allgemeiner EA

$t := 0$

initialisiere $P(0) := \{a_1(0), \dots, a_\mu(0)\} \in I^\mu$

bewerte $P(0) : \{f(a_1(0)), \dots f(a_\mu(0))\}$

while ($\mathcal{L}(P(t)) \neq \text{true}$) do

rekombiniere : $P'(t) := \tau_{\Theta_r}(P(t))$

mutiere : $P''(t) := m_{\Theta_m}(P'(t))$

bewerte $P''(t) : \{f(a_1''(t)), \dots f(a_\lambda''(t))\}$

selektiere : $P(t+1) := s_{\Theta_s}(P''(t) \cup Q)$

$t := t + 1$

od

μ Zahl der Eltern

λ Zahl der Nachkommen

L Abschaltkriterium

τ, m, s Operatoren mit Parametern

$\Theta_r, \Theta_m, \Theta_s$

$Q = \{0\}$

$Q = \text{bisher bestes Ind.}$

Elitist - Strategie

Evolutionärer Basisalgorithmus

$t := 0;$

initialisiere $P(0) := \{\vec{a}_1(0), \dots, \vec{a}_\mu(0)\} \in I^\mu;$

bewerte $P(0) : \{\Phi(\vec{a}_1(0)), \dots, \Phi(\vec{a}_\mu(0))\};$

while ($\epsilon(P(t)) \neq \text{true}$) do

$P'(t) := \text{rekompliniere } (P(t));$

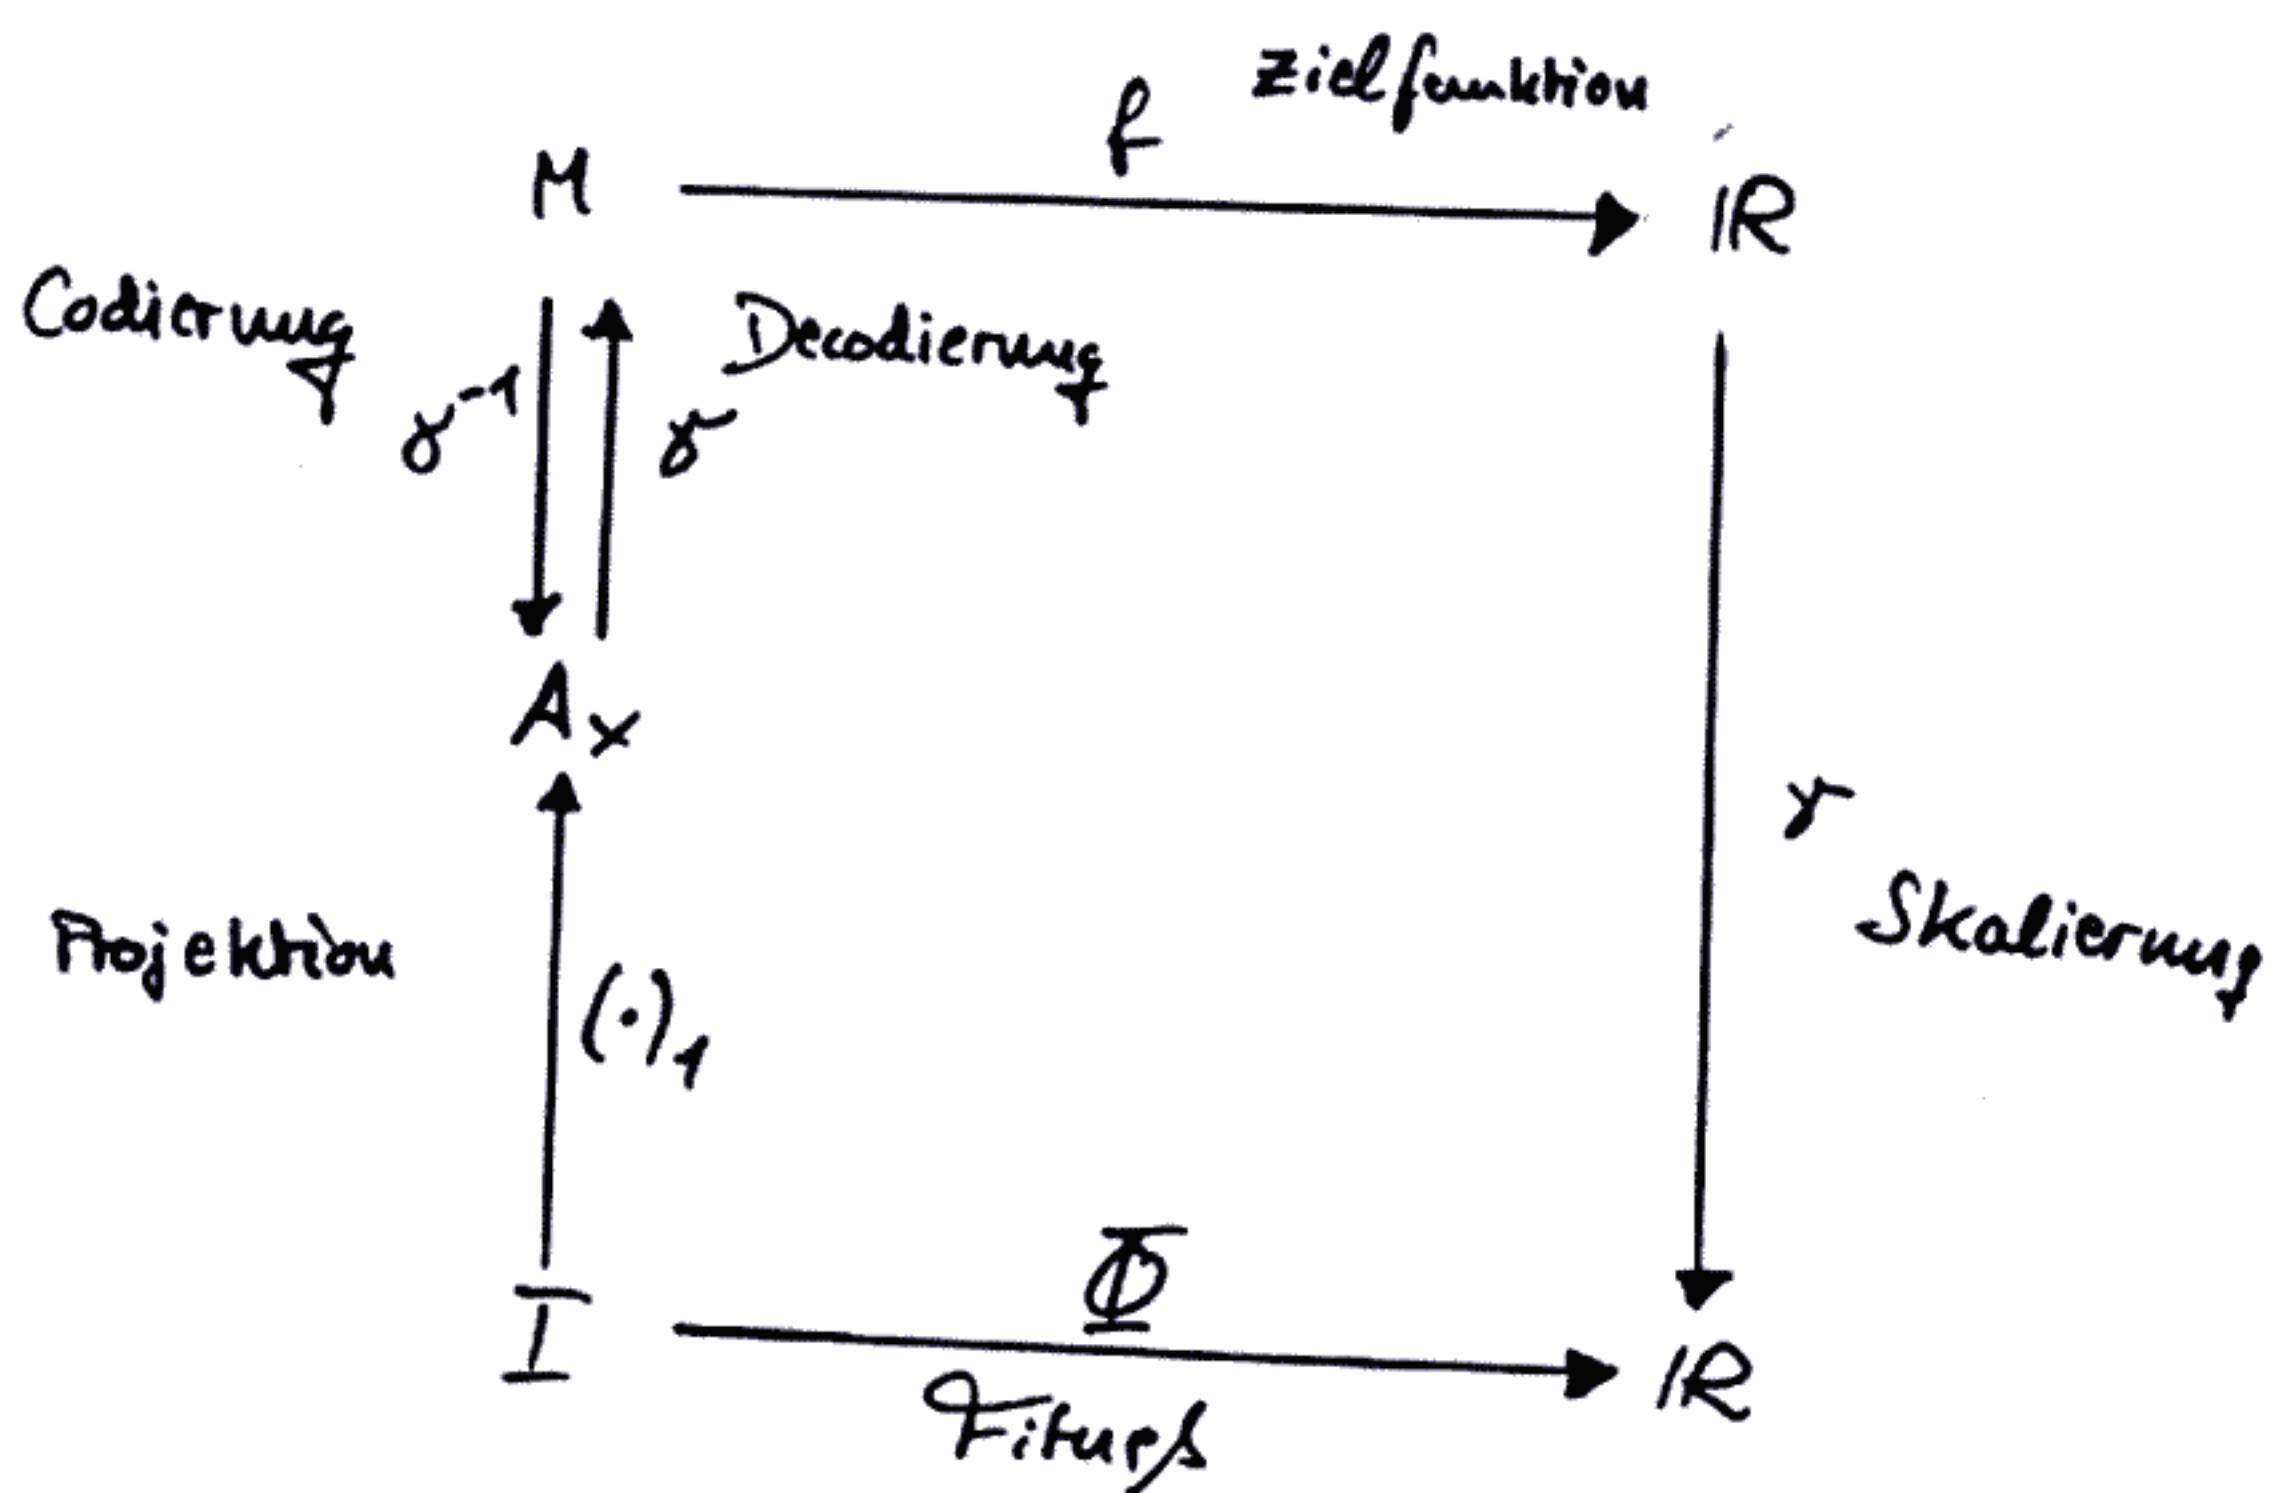
$P''(t) := \text{mutiere } (P'(t));$

bewerte $P''(t) : \{\Phi(\vec{a}_1''(t)), \dots, \Phi(\vec{a}_\lambda''(t))\};$

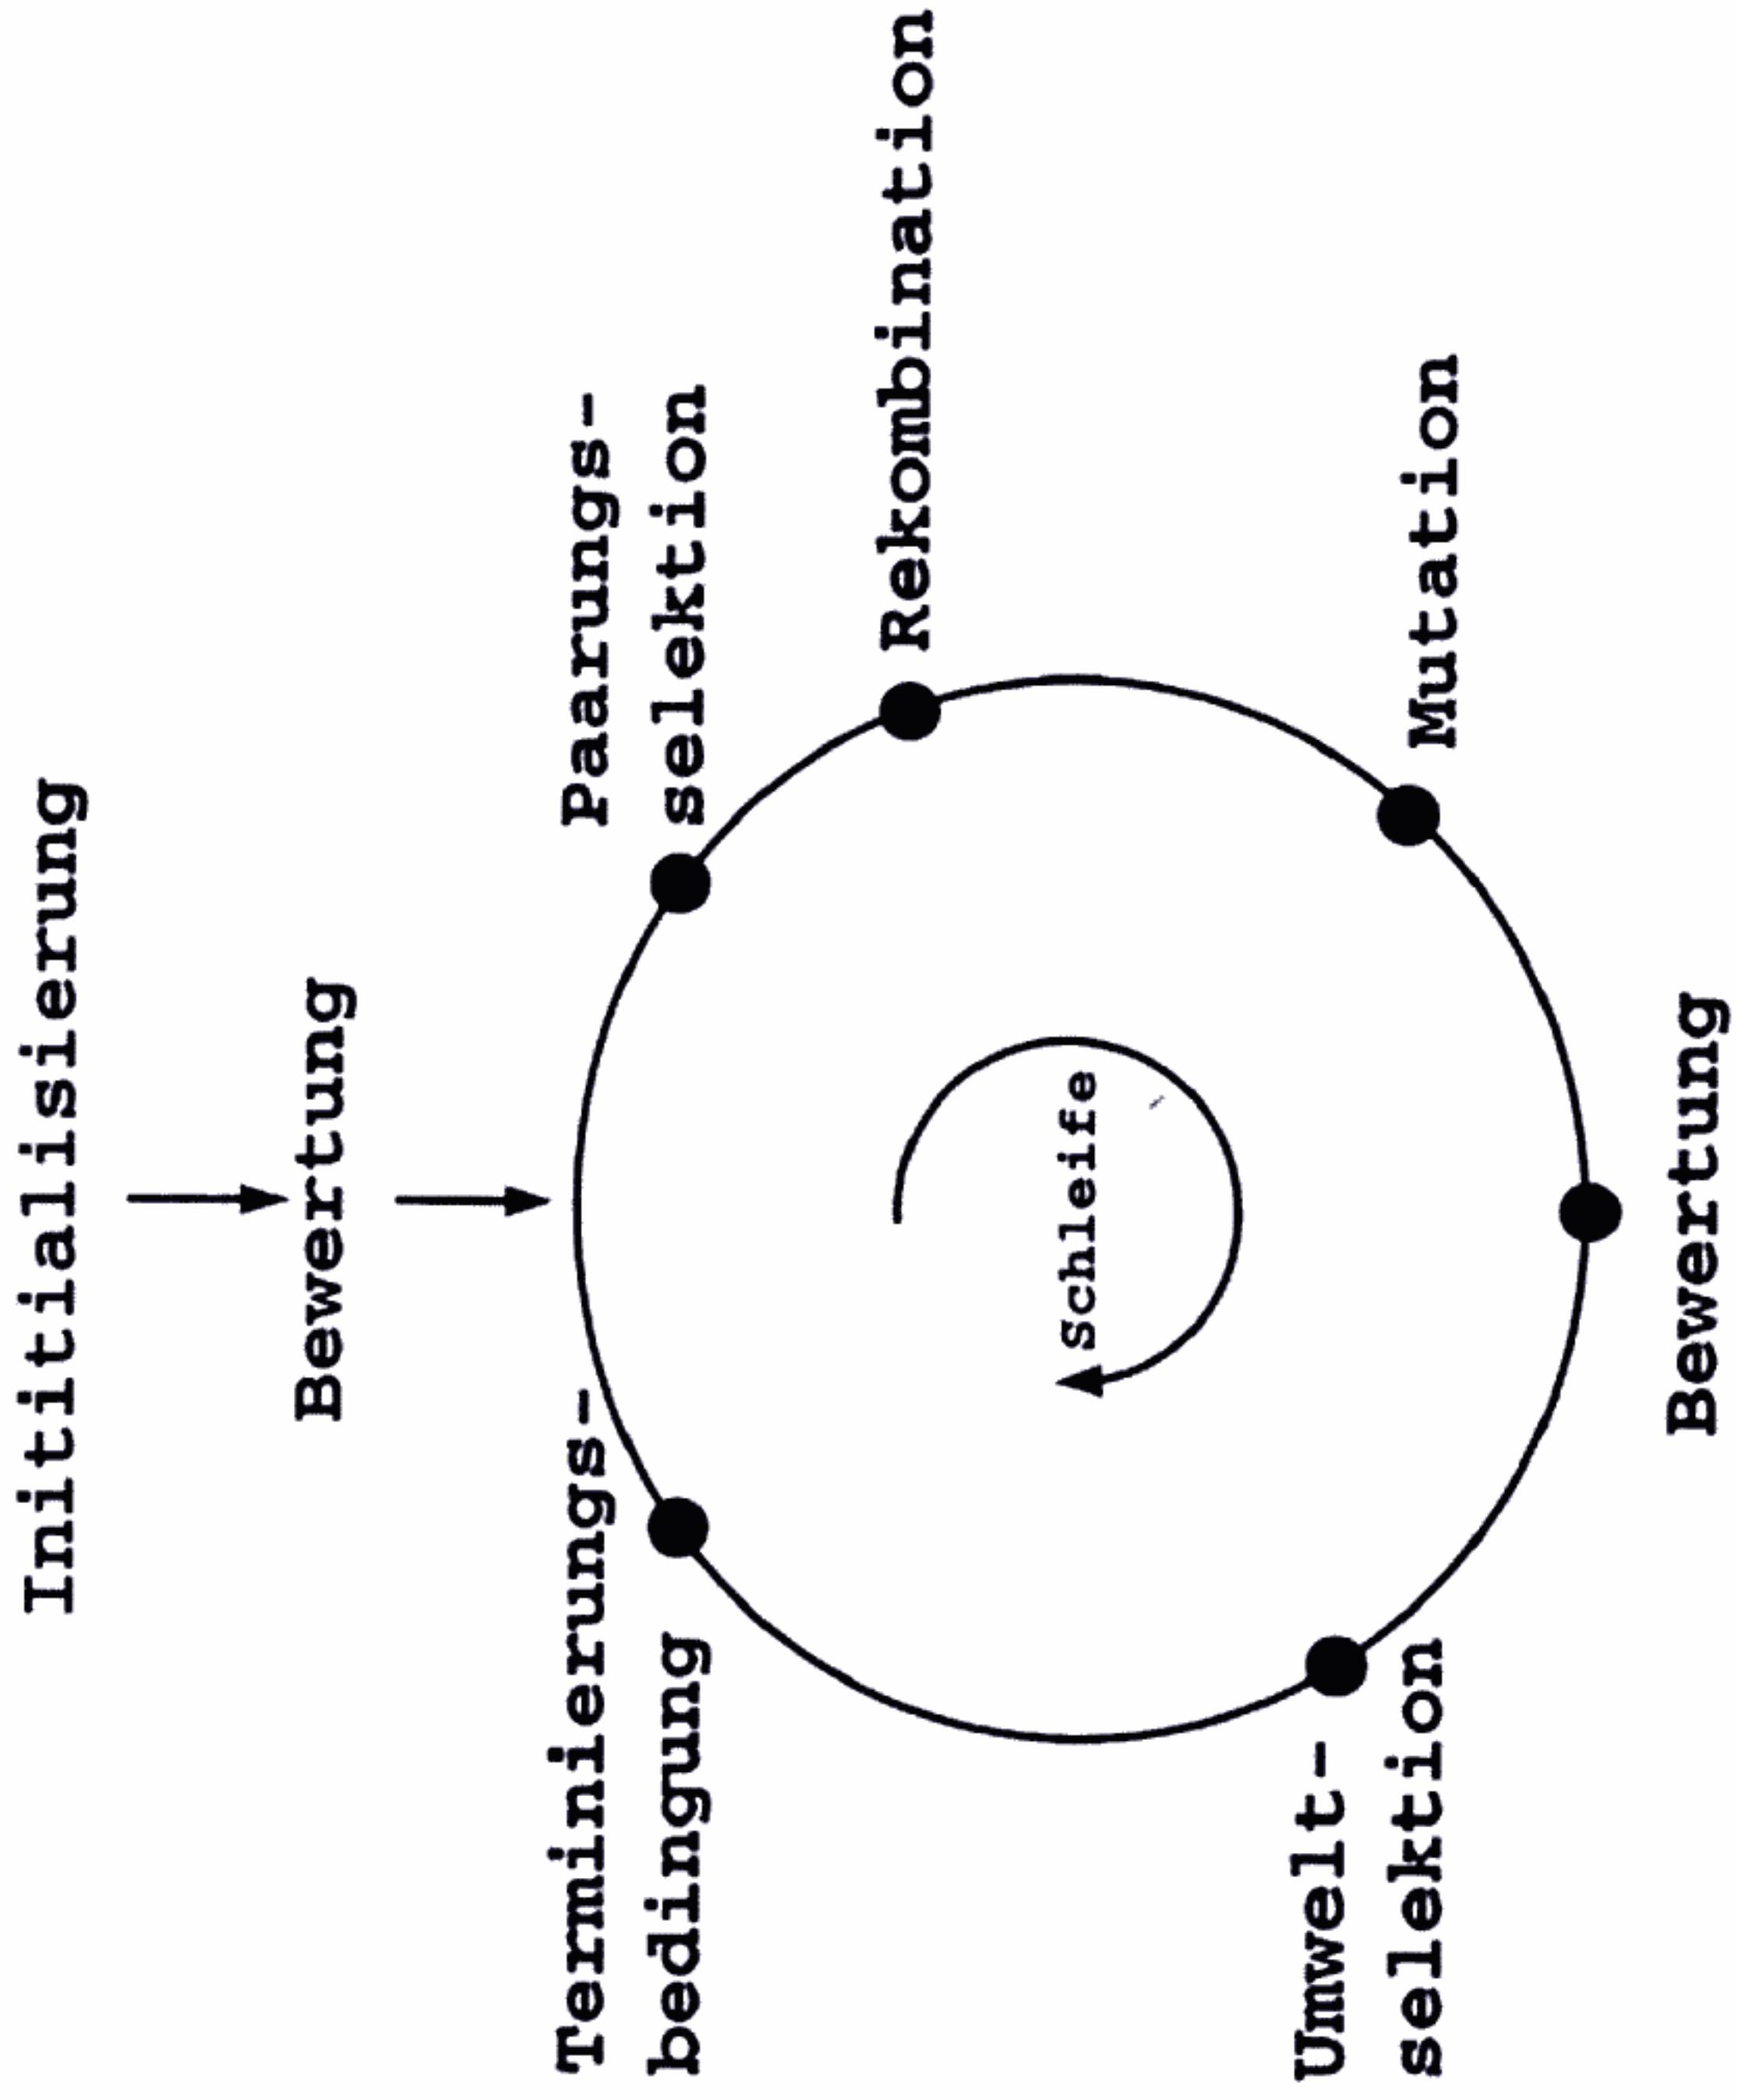
$P(t+1) := \text{selektiere } (P''(t) \cup Q);$

$t := t + 1;$

od



Allgemeine EA Iterations-Schleife



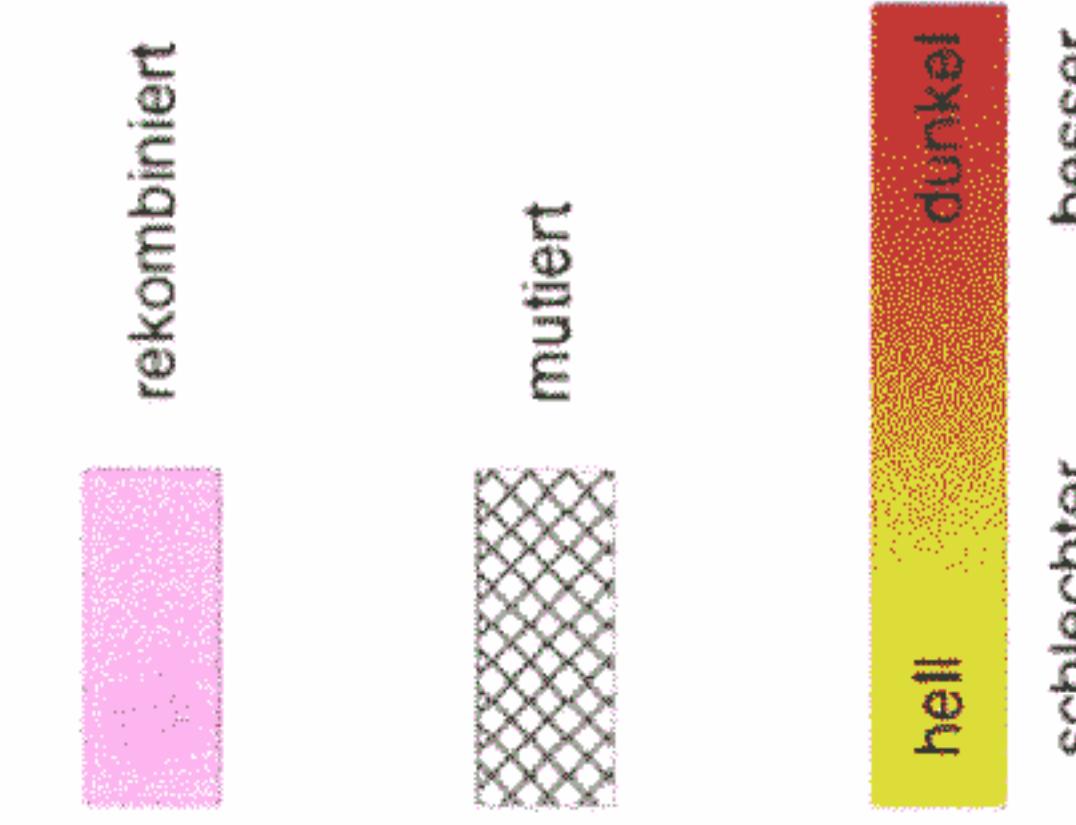
Generationswechsel

Generation Eltern Fitneß-proportionale Heirats-Selektion Nachkommen

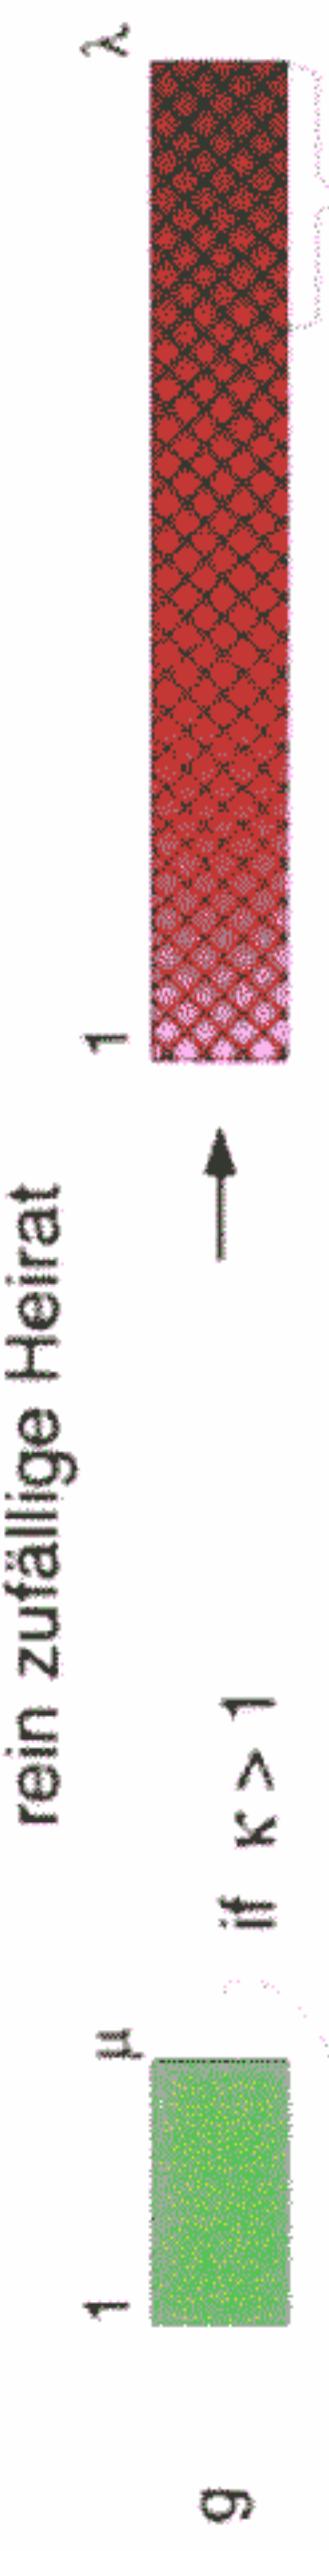


keine Umwelt-Selektion

GA



rein zufällige Heirat

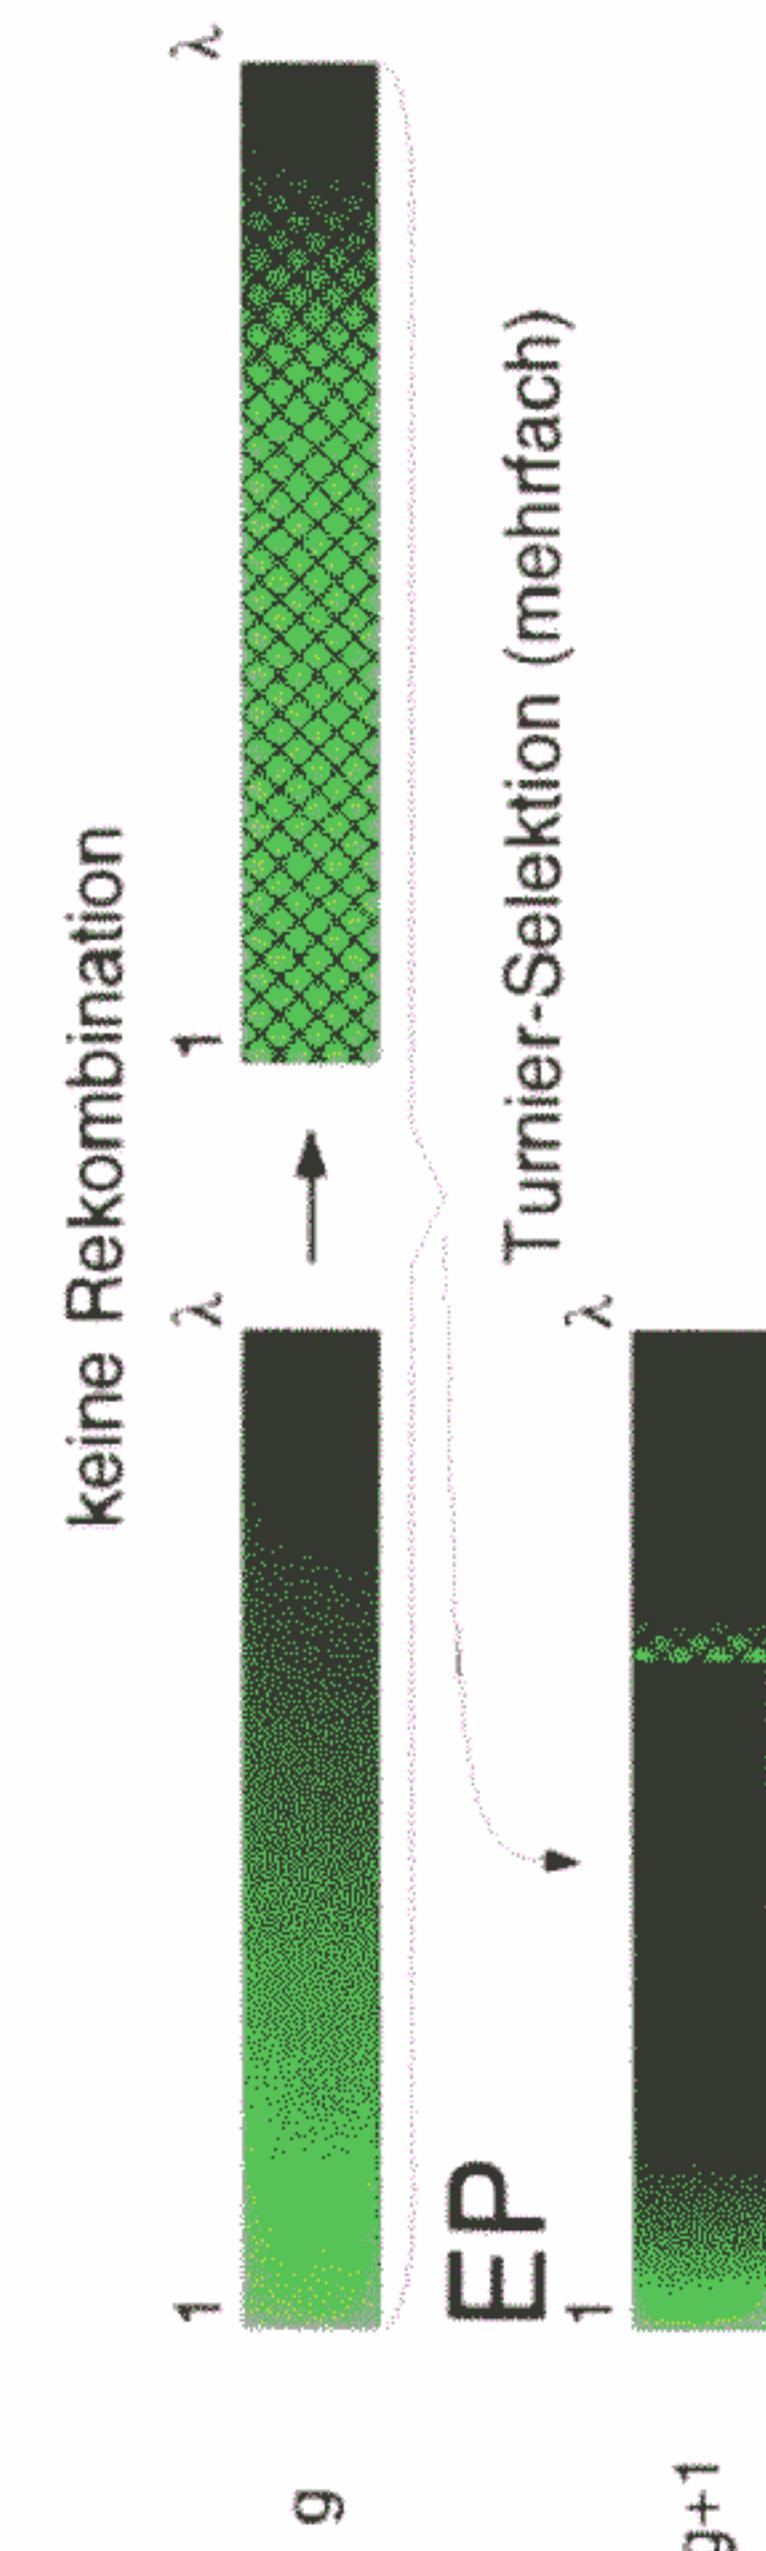


Umwelt-Selektion (deterministisch)



dunkel besser

keine Rekombination



Turnier-Selektion (mehrfach)

Genetische Algorithmen (GA)

anfangs: Modell für Adaptationsprozesse in natürl. u. künstl. Systemen

später: Tool für Pseudo-Boolesche und kombinatorische Optimierung

wichtige Eigenschaften:

- evolvierende Einheit ist das Genom; Zufallsstart in gesamtem Suchgebiet
- Binär-String Repräsentation der Entscheidungsvariablen
- Paarungsselektion abh. von Fitneß; kein Geburtenüberschuß ($\lambda = \mu$)
- Crossover zweier Bitketten und (seltene) Mutation (bit flips)
- keine Umweltselektion

Genetischer Algorithmus (kanonisch)

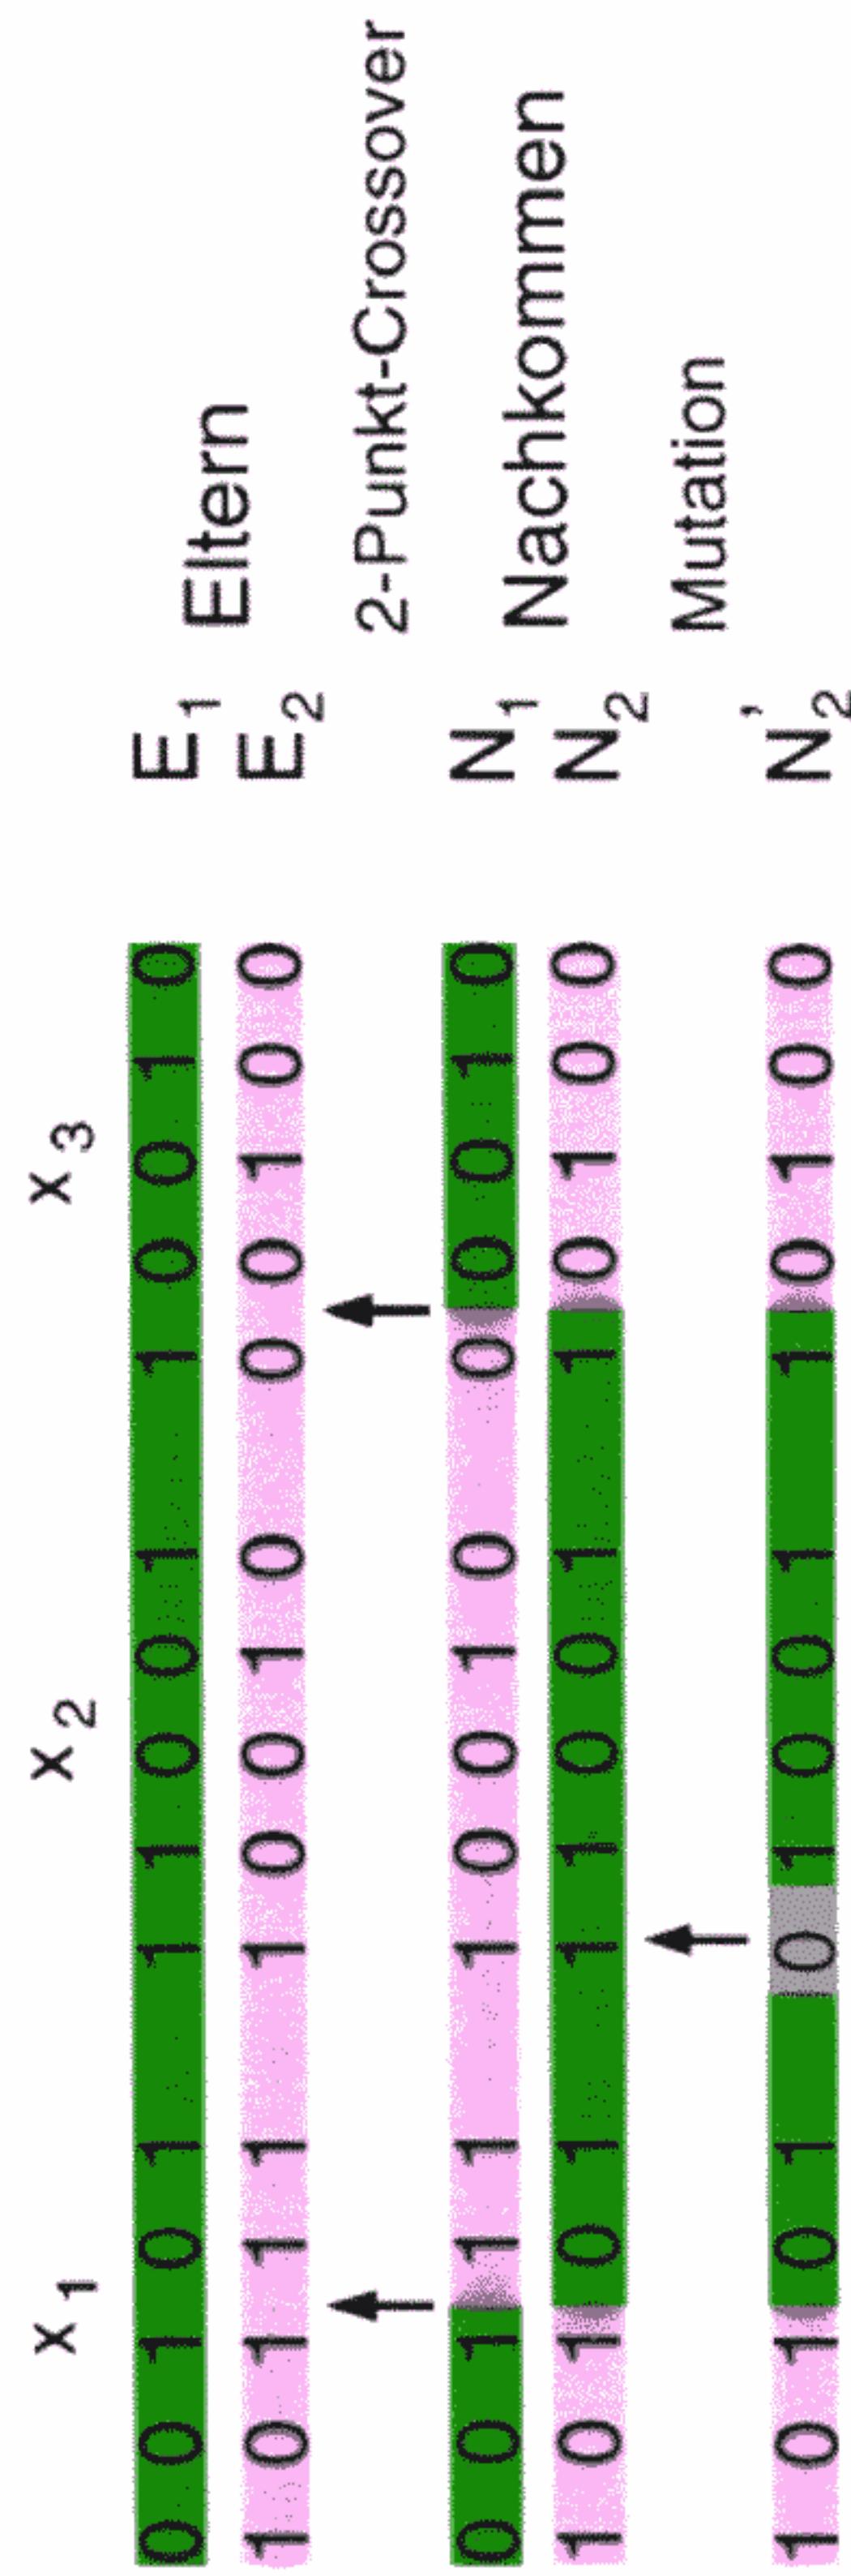
Repräsentation der Individuen : Bitkette

Mutation : Bitinversion, selten ($p_m = 10^{-3}$ fix), Hintergrundoperator

Rekombination : Crossover, häufig ($p_c = 0.6$), Hauptoperator

Reproduktion : $\lambda = \mu$, kein Geburtenüberschuss

Selektion : Nachkommenzahl prop. zu relativer Fitneß (mating selection)



kanonischer GA:

Individuum = Bitstring $\{ \underbrace{100110101100100\dots}_\text{Problem-Variablen} \}$

d.h. Binär-kodierung obligatorisch

\Rightarrow

für alle Variablen muss ein Wertebereich und eine Darstellungsgenauigkeit gewählt werden, bzw. eine Anzahl l von Bits für die Darstellung

Bsp.

$$v_i \leq x_i \leq v_i \quad \forall i=1(1)m$$

$$x_i = v_i + \frac{\epsilon_i}{2^{l-1}} \sum_{j=1}^l a_{ij} 2^{l-j}$$

wobei: $\{a_{ij}\}$ Bitstring der Länge l für x_i :

$$l=4 \quad v_i = 0 \quad v_i = 15 \quad \epsilon_i = 1 = \frac{15-0}{2^4-1}$$

$\{a_{ij}\} =$	0000	$x_i =$	0
	0001		1
	0010		2
	0011		3
	0100		4
	0101		5
	0110		6
	0111		7
	1000		8
	1001		9
	1010		10
	1011		11
	1100		12
	1101		13
	1110		14
	1111		15

Wahrscheinl. für gleichzeitige Änderungen mehrerer Bits (2)

Table 5.2: Transition probabilities for mutations within a GA

		x_i new				
		Genotype	00	01	10	11
x_i old	Phenotype	0	1	2	3	
	00	0	q^2	pq	pq	p^2
	01	1	pq	q^2	p^2	pq
	10	2	pq	p^2	q^2	pq
	11	3	p^2	pq	pq	q^2

keine Änderung

GA - Übergangswahrscheinlichkeiten
für Mutation mit $l=2$ $x \in \{0, 1, 2, 3\}$

z. B.

$$p = p_m = 0.001$$

$$q = (1-p_m) = 0.999$$

$$q^2 = 0.998001$$

$$pq = 0.000999$$

$$p^2 = 0.000001$$

Übergänge $1 \leftrightarrow 2$ am unwahrsch. einlichsten
obwohl phänotypisch benachbart

Für sukzessive Verbesserungen (\neq großes Los ziehen)
ist entscheidend: Veränderung Δx : der
phänotyp. Variablen von Generation zu
Generation

(Volumen- vs. path-orientierte Suche)

Gray - Code

Bsp. 3 bits für ganzzahlige Variable $x \in \{0, \dots, 7\}$

x	Standard-Binärcode	Gray-Code
0	000	000
1	001	001
2	010	011
3	011	010
4	100	110
5	101	111
6	110	101
7	111	100
	$\{a_{ij}\}$	$\{b_{ij}\}$

Umwandlung Standard \leftrightarrow Gray

$$\mathfrak{F}: b_{ij} = \begin{cases} a_{ij} & \text{für } j=1 \\ a_{ij-1} \oplus a_{ij} & \text{für } j>1 \end{cases}$$

$$\mathfrak{F}^{-1}: a_{ij} = \bigoplus_{k=1}^j b_{ik}$$

\oplus : modulo 2 - Addition

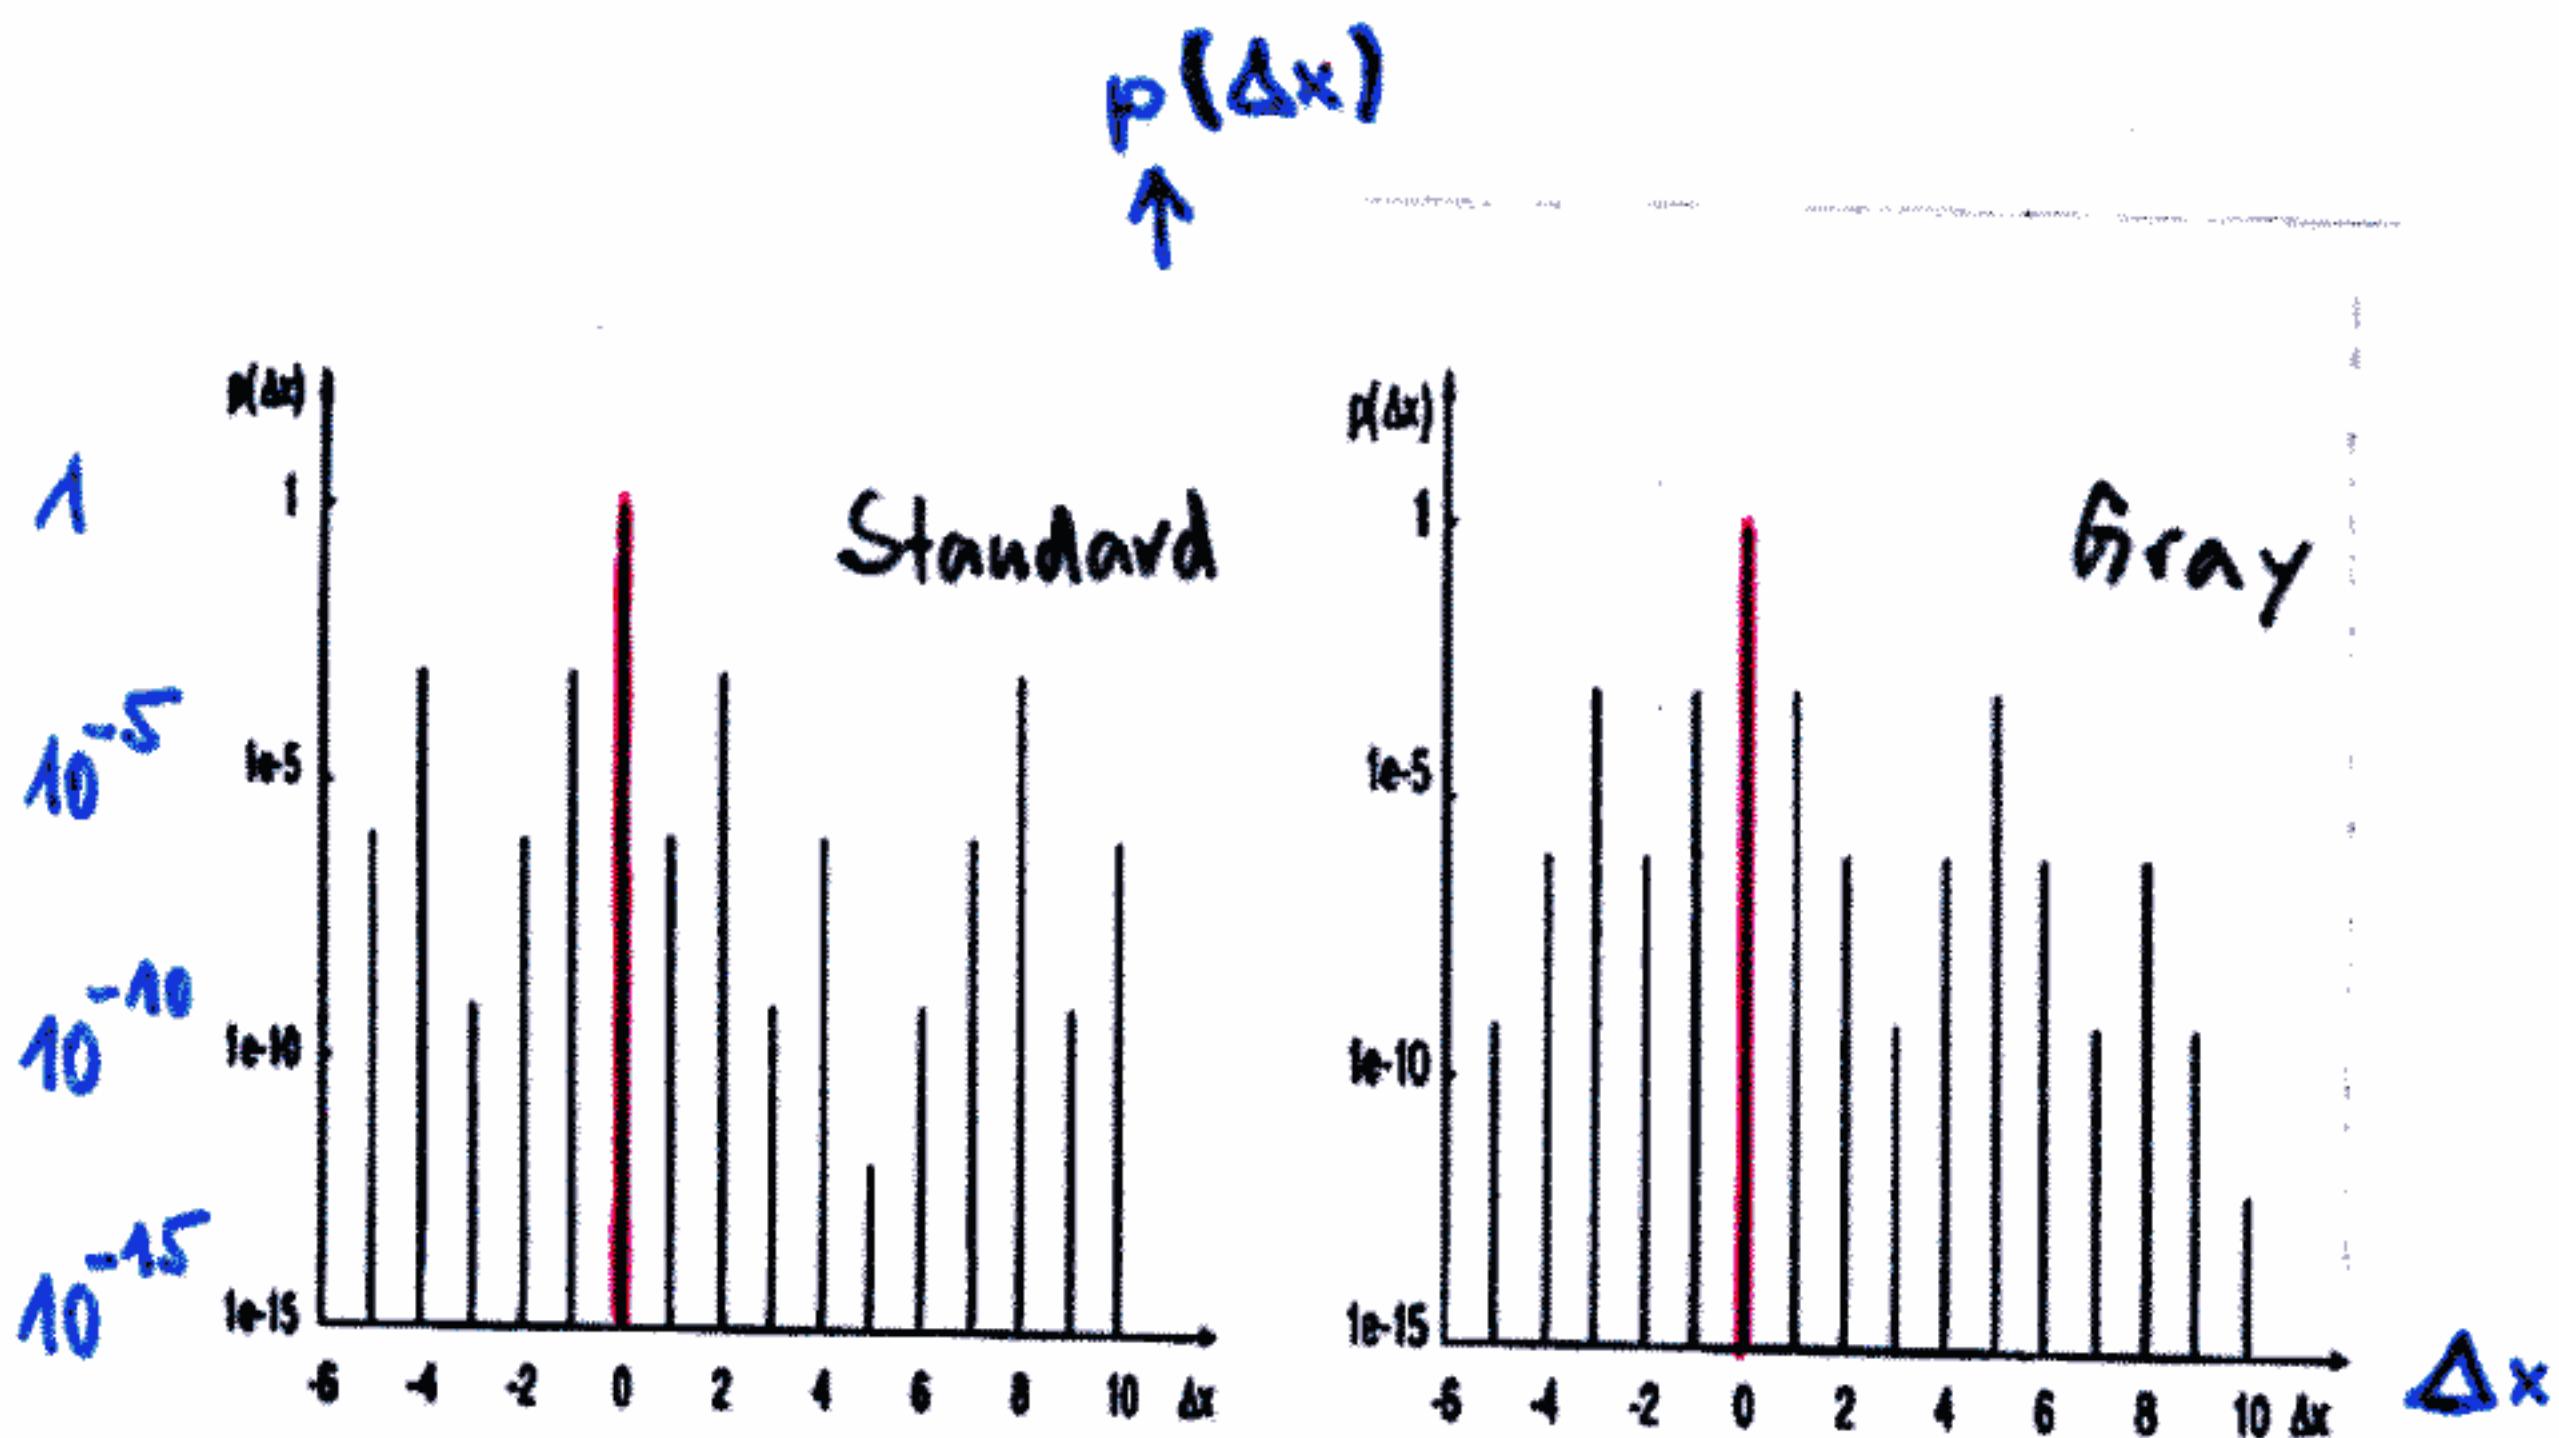


Figure 5.10: Probability distributions for GA mutations / left: normal binary code; right: Gray code

GA - Mutationen am Beispiel

$$x^{(0)} = 5 ; l = 4 ; \rho_m = 0.001$$

$\{0101\}$ in Standard-Binärdarstellung

$$\Delta x = x^{(1)} - x^{(0)} \quad ; \quad x^{(1)} = \text{mutiertes } x^{(0)}$$

$p(\Delta x)$ nicht symmetrisch
nicht unimodal

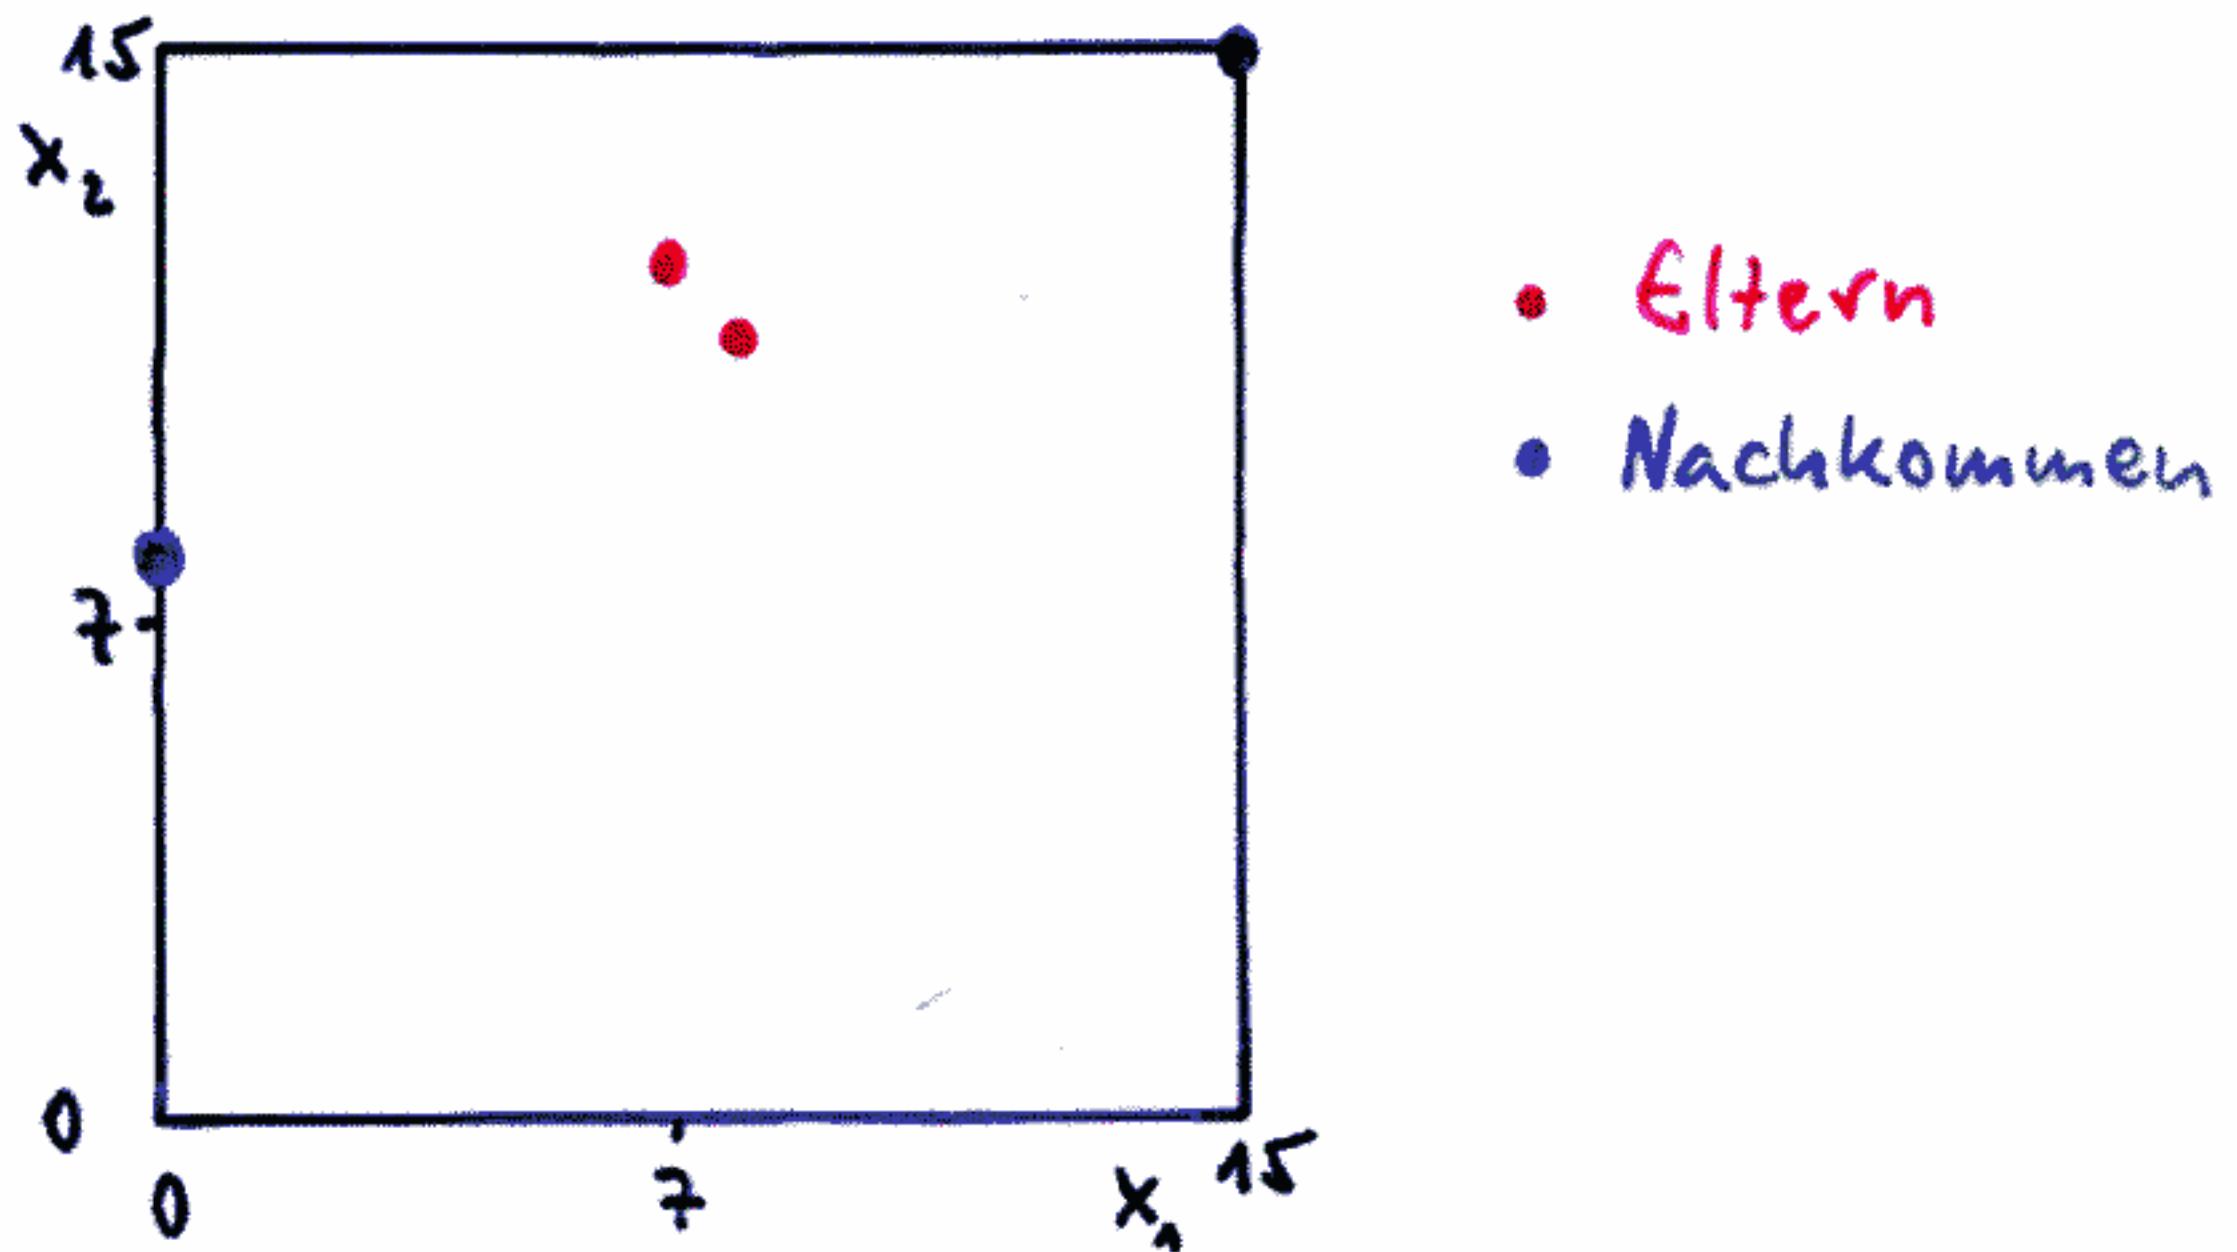
Erwartungswert $\neq 0$
(positionabhängig)

Table 5.1: Two point crossover within a GA and its effect on the phenotypes

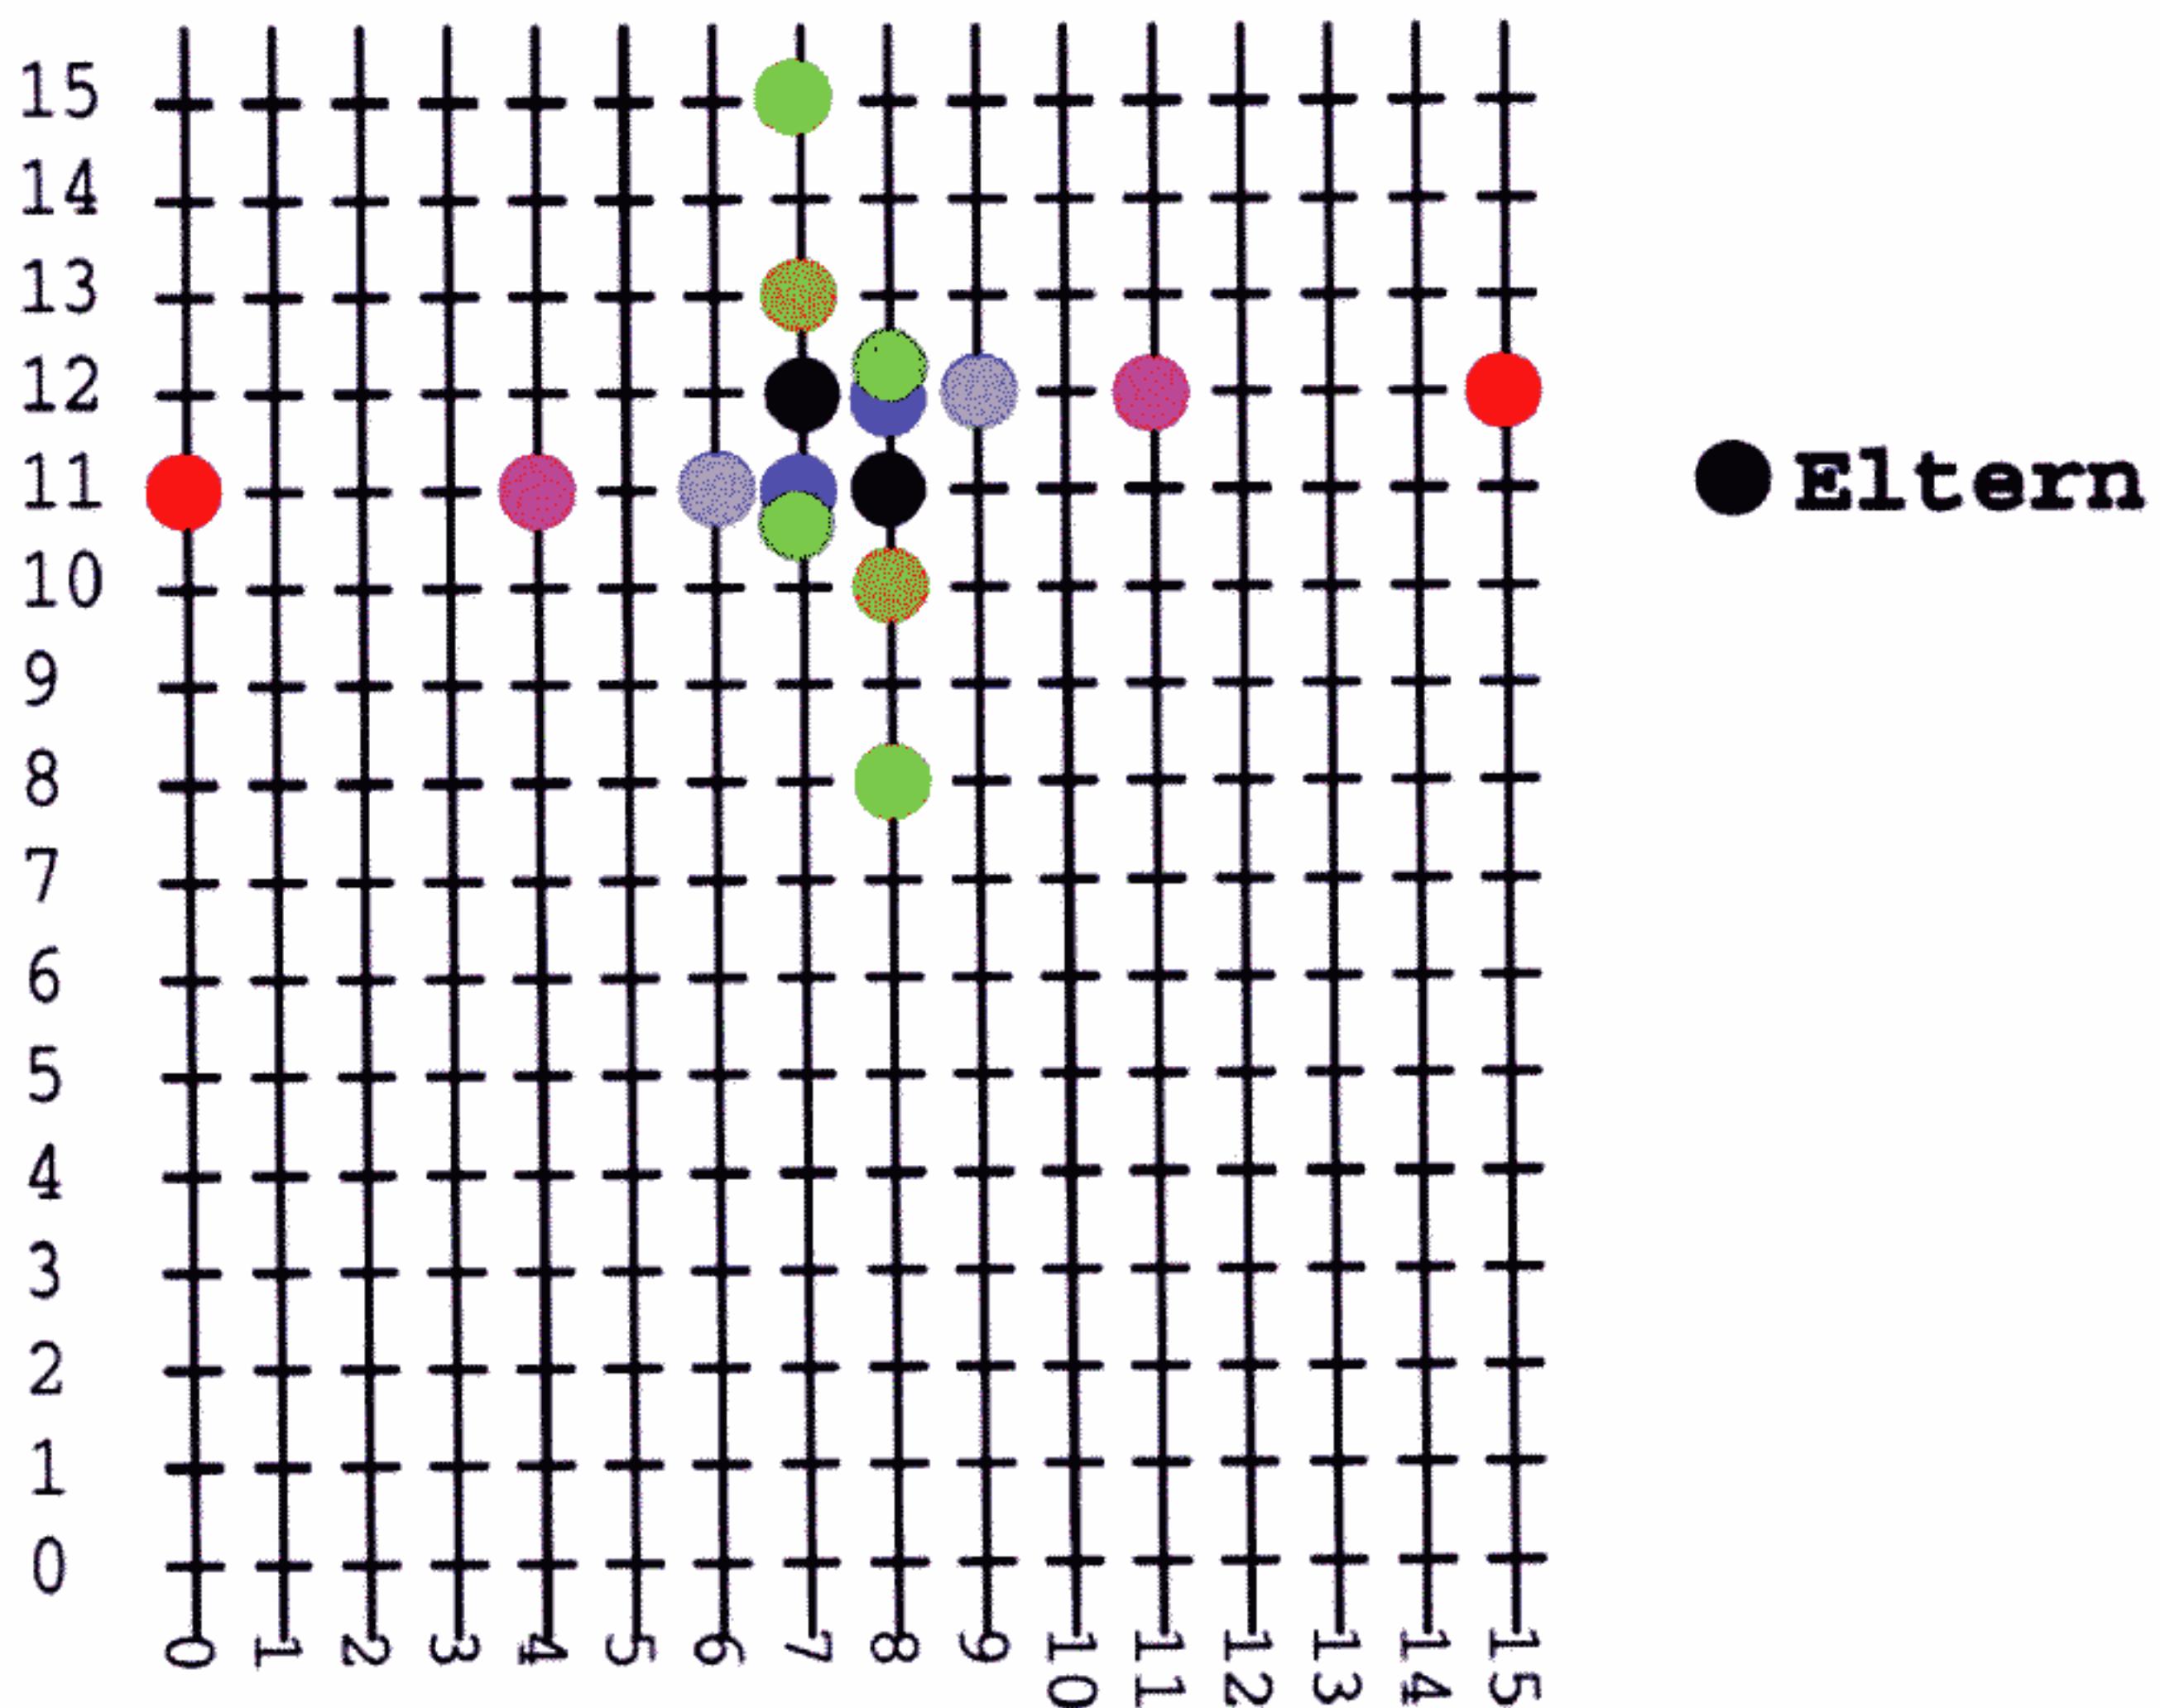
	$\overbrace{x_1 \quad x_2}$	$\overbrace{x_1 \quad x_2}$
Parent 1	Bit strings 0111 1100	Phenotype 7 12
Parent 2	1000 1011	8 11
	Two point crossover	
Offspring 1	0000 1000	0 8
Offspring 2	1111 1111	15 15

Bruchstellen

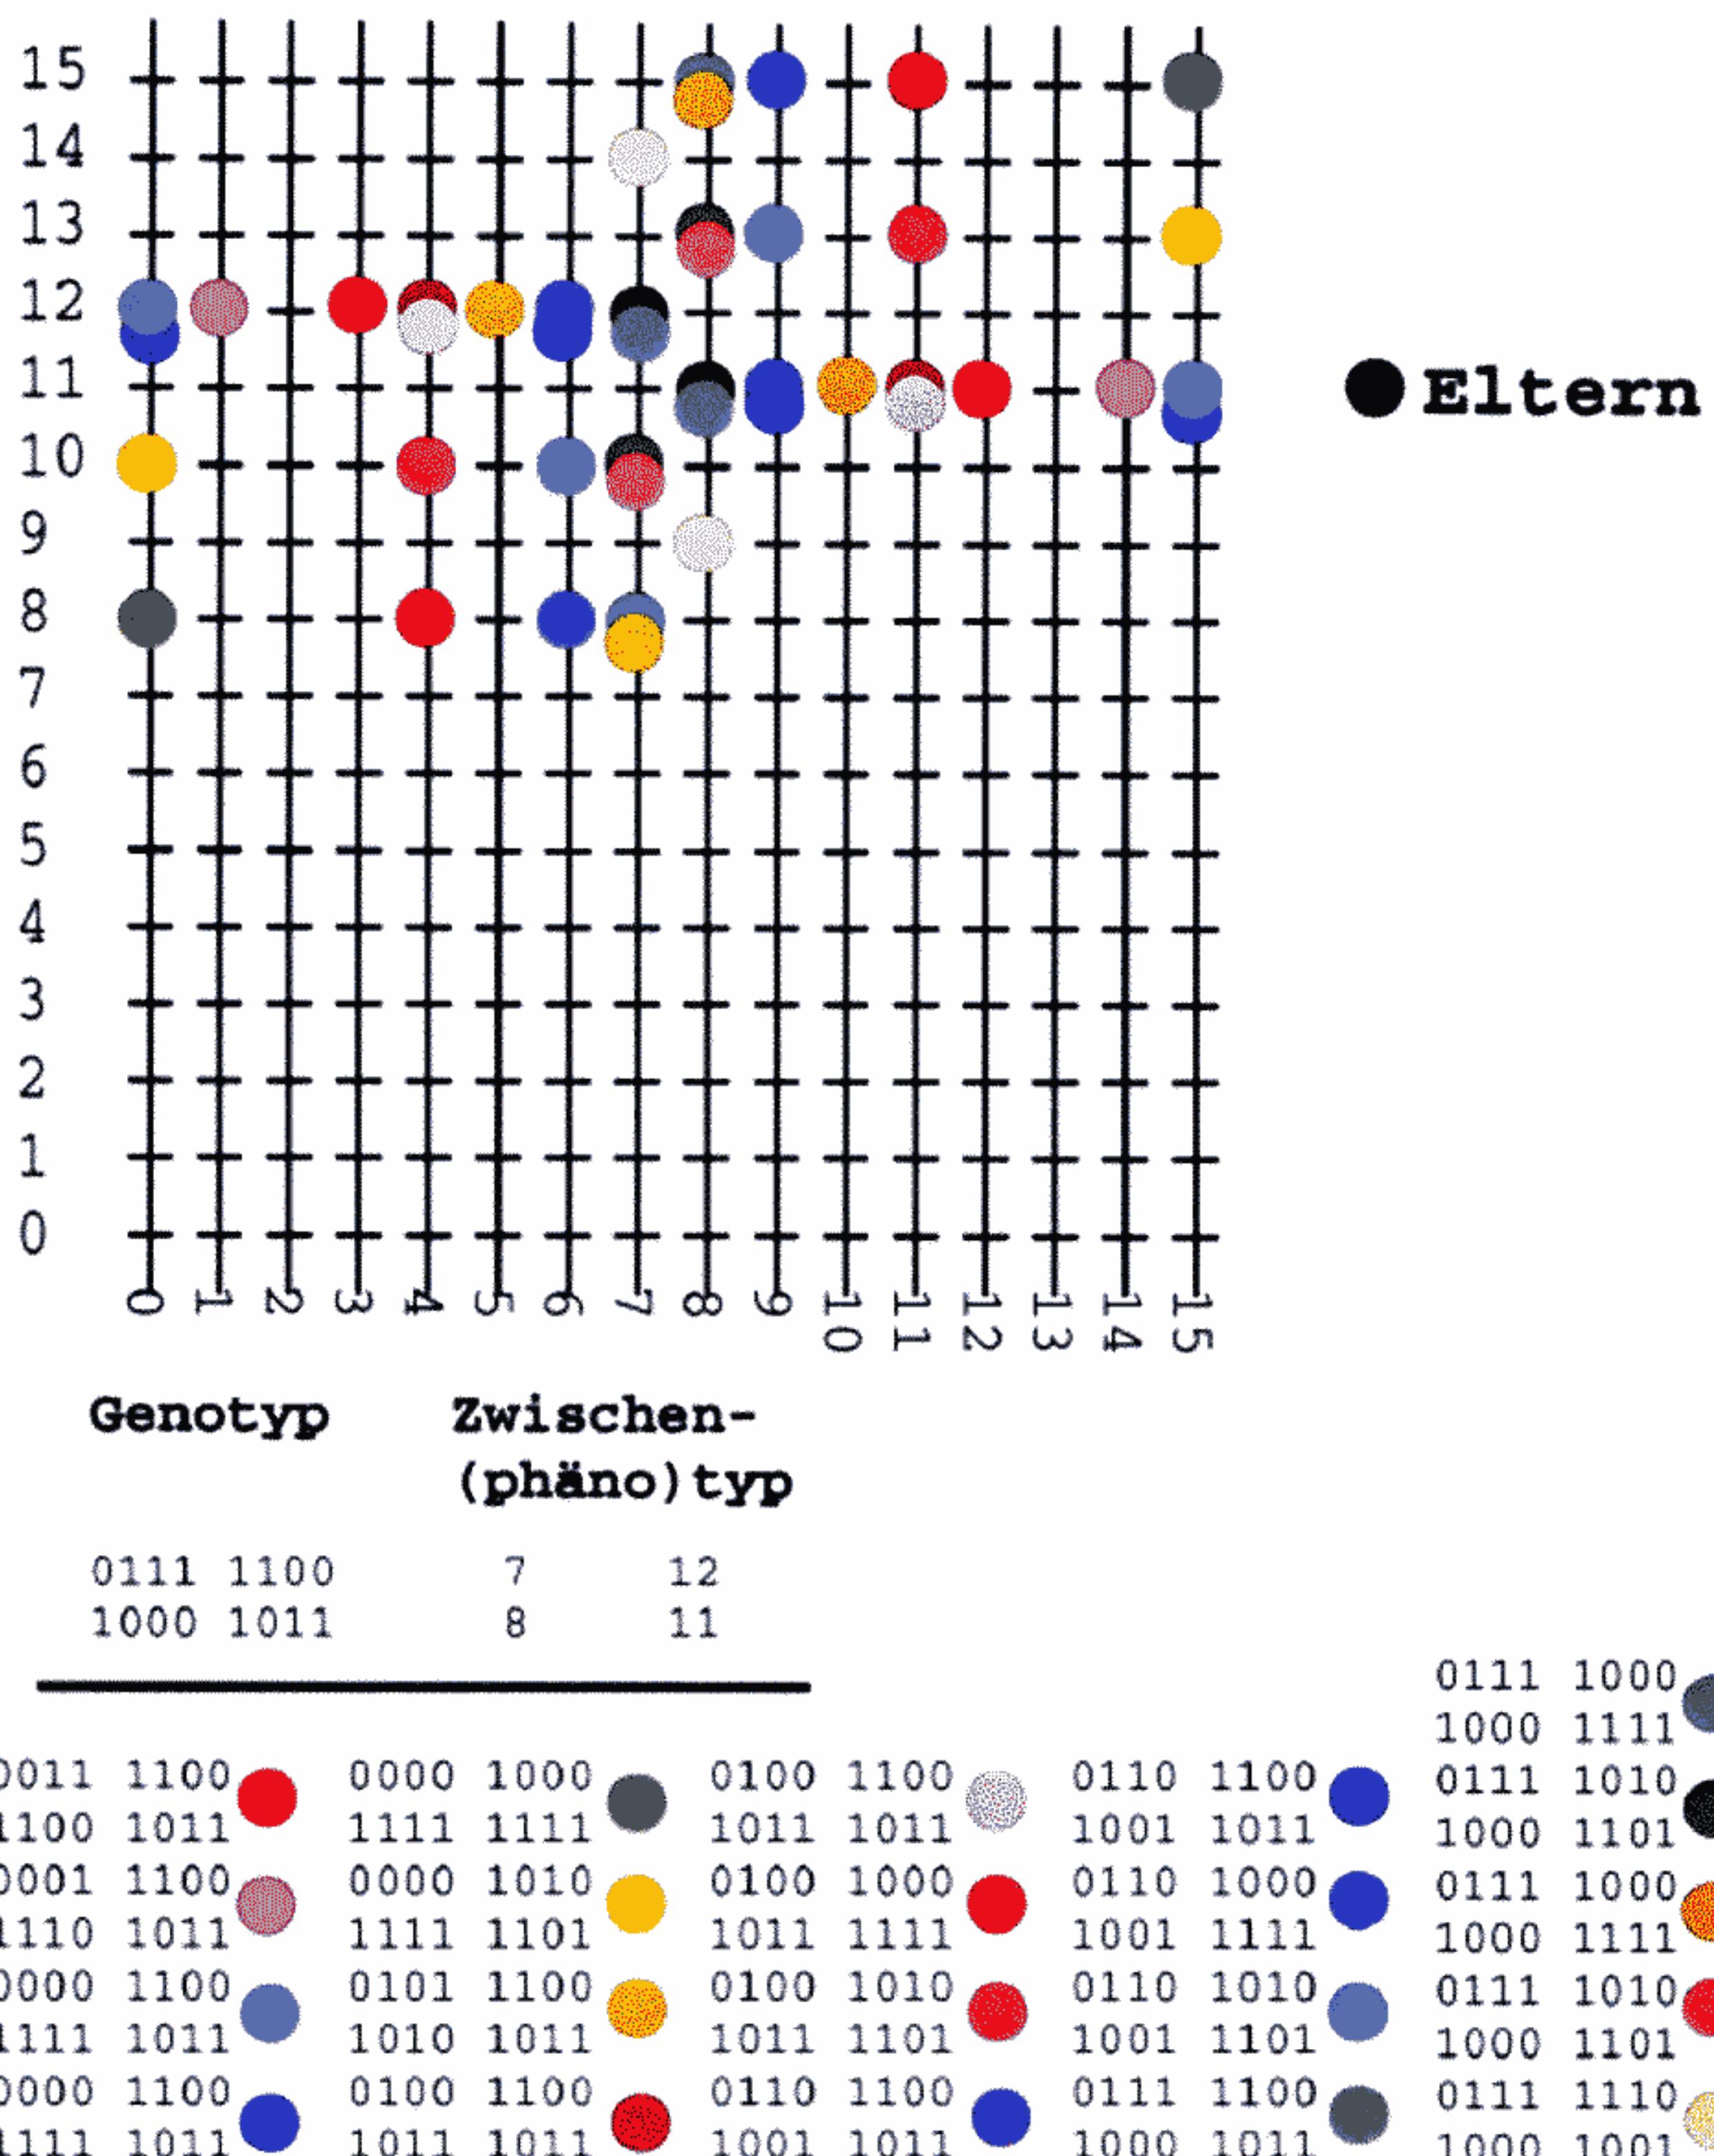
GA - Zweipunkt-Crossover am Beispiel

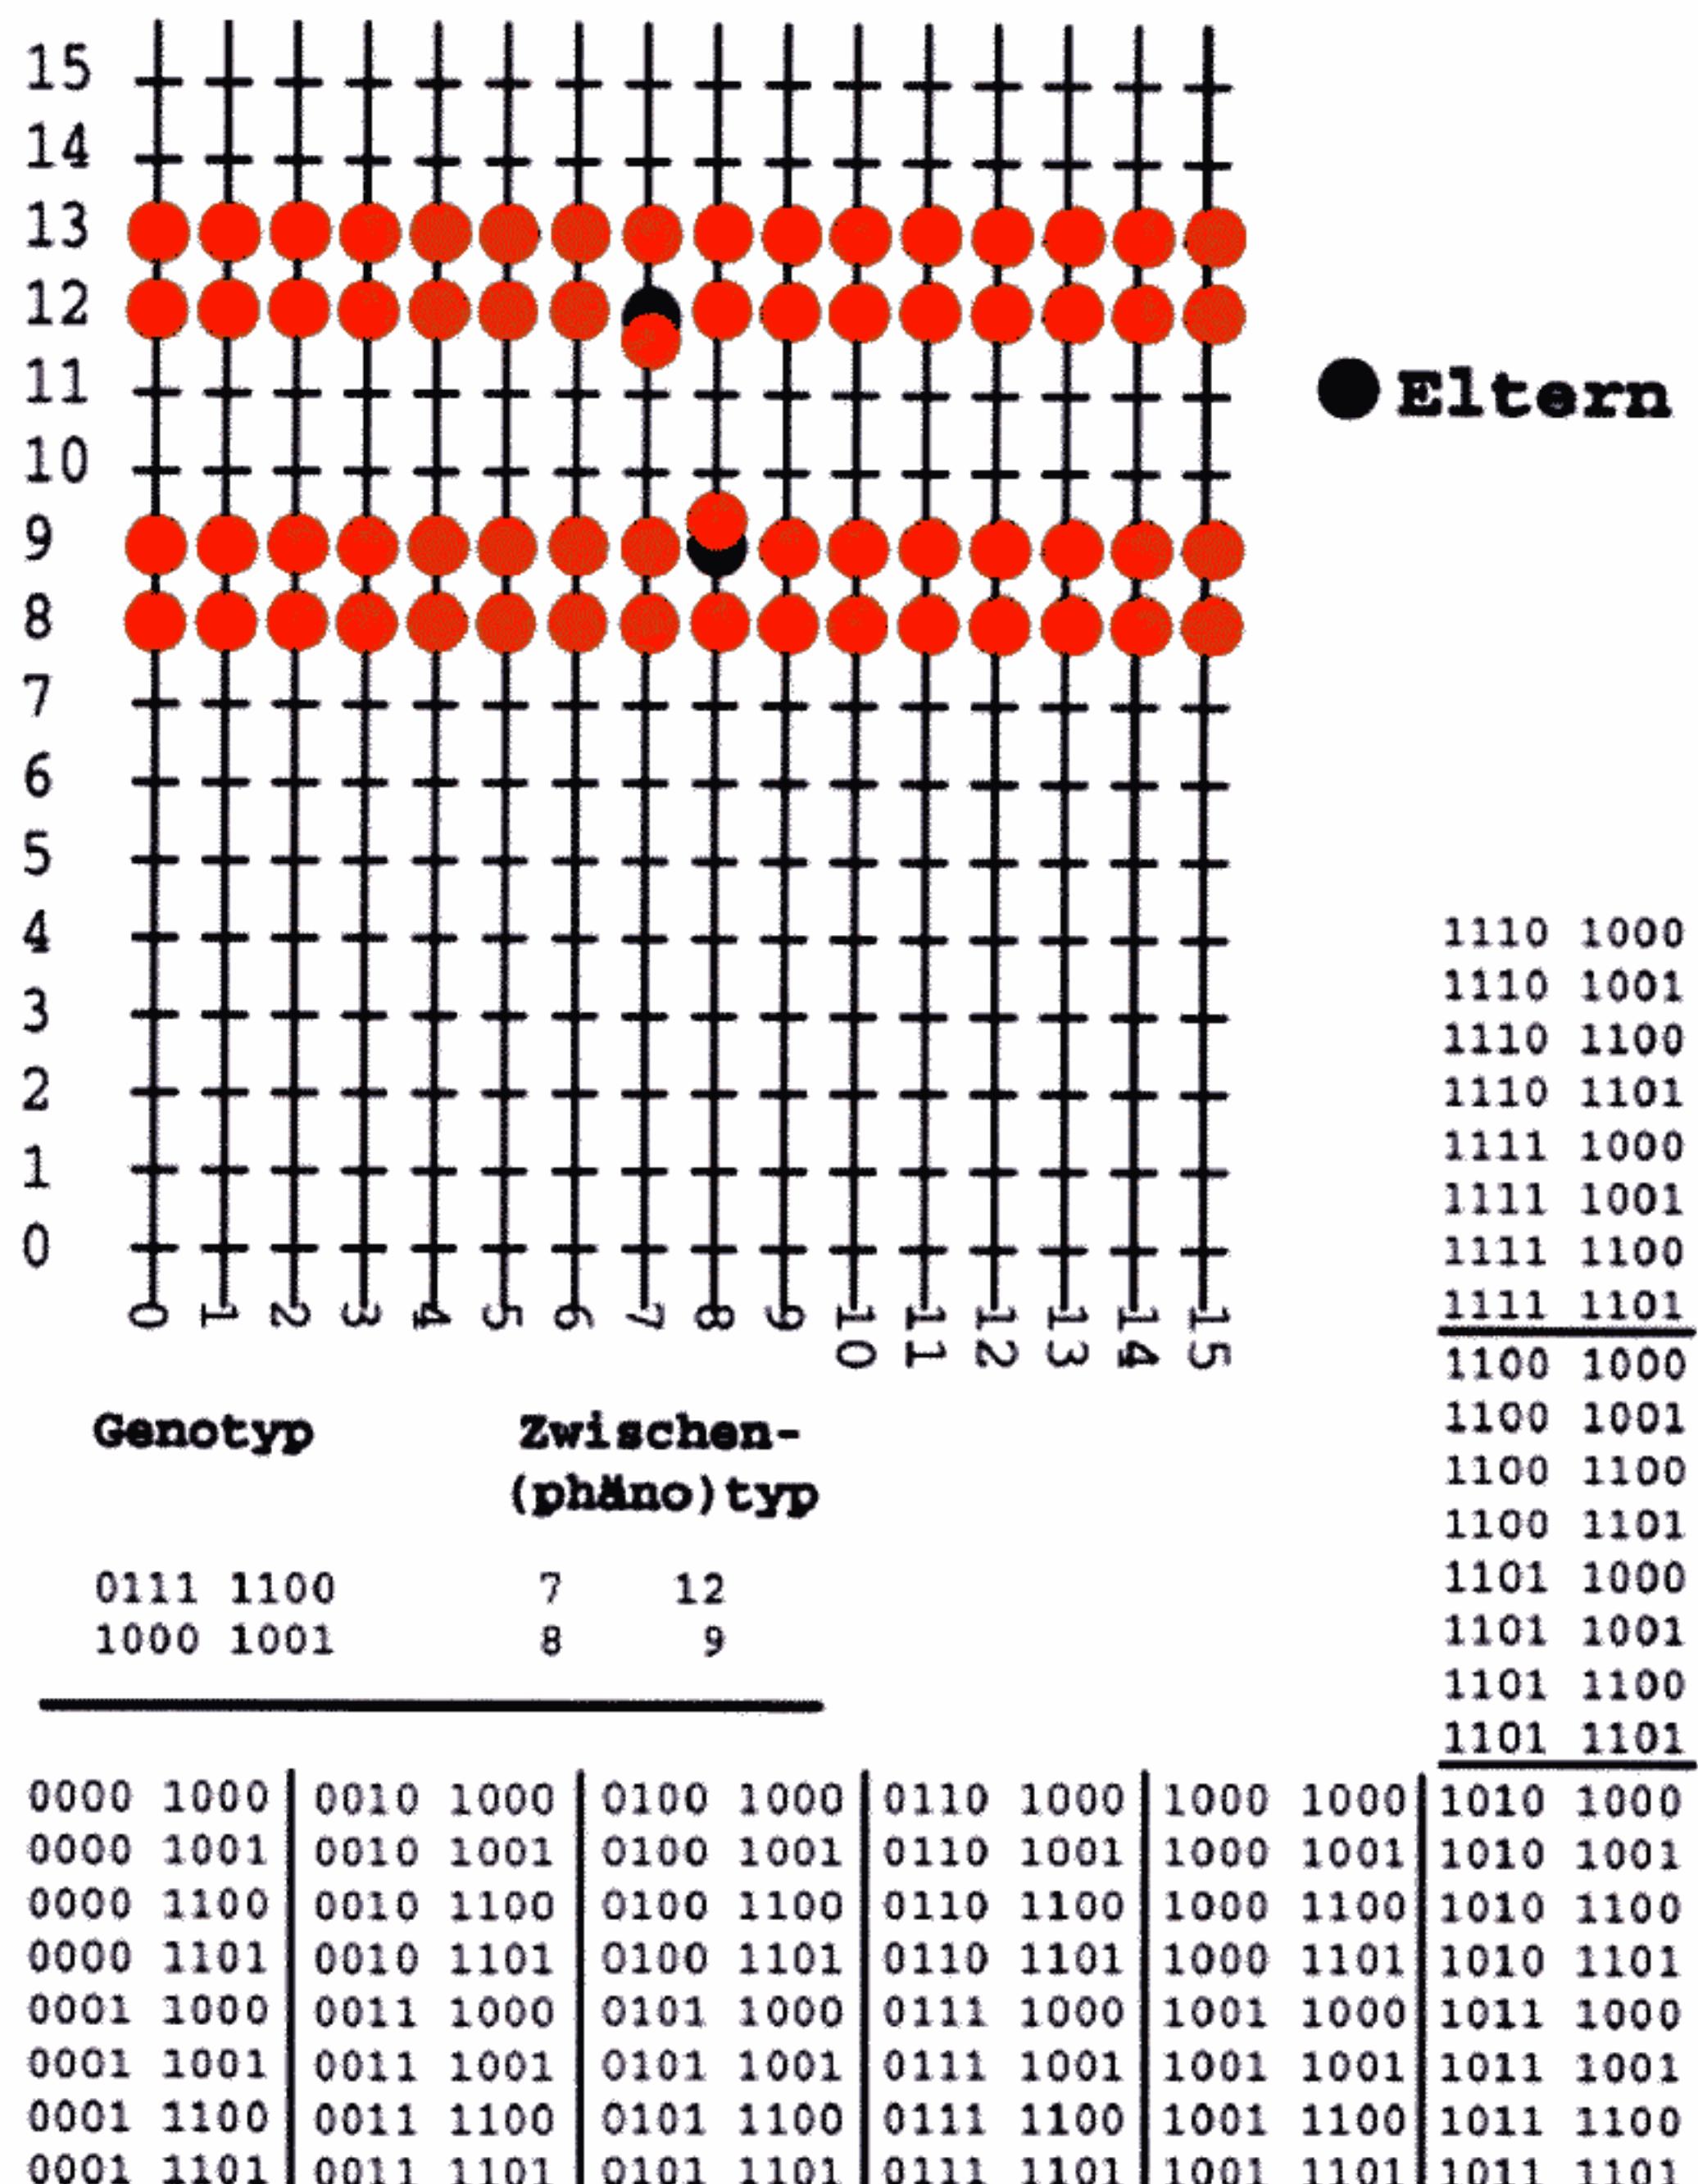


Rekombination kann zu „wilden“ Neutypen führen
aber: viele verschiedene Vorschläge
z.B. uniform crossover
gene pool recombination



Genotyp	Zwischen-(phäno)typ	Genotyp	Zwischen-(phäno)typ	Genotyp	Zwischen-(phäno)typ
0111 1100 1000 1011	7 12 8 11	0000 1011 1111 1100 0100 1011 1011 1100 0110 1011 1001 1100 0111 1011 1000 1100	0 11 15 12 4 11 11 12 6 11 9 12 7 11 8 12	11 12 12 11 11 12 11 12 11 12 12 11 11 12 12 11	● Eltern ● Eltern ● Eltern ● Eltern ● Eltern ● Eltern ● Eltern ● Eltern
		0111 1111 1000 1000 0111 1101 1000 1010		0111 1111 1000 1000 0111 1101 1000 1010	7 15 8 8 7 13 8 10





Beispiel für standard - Codierung (6A)

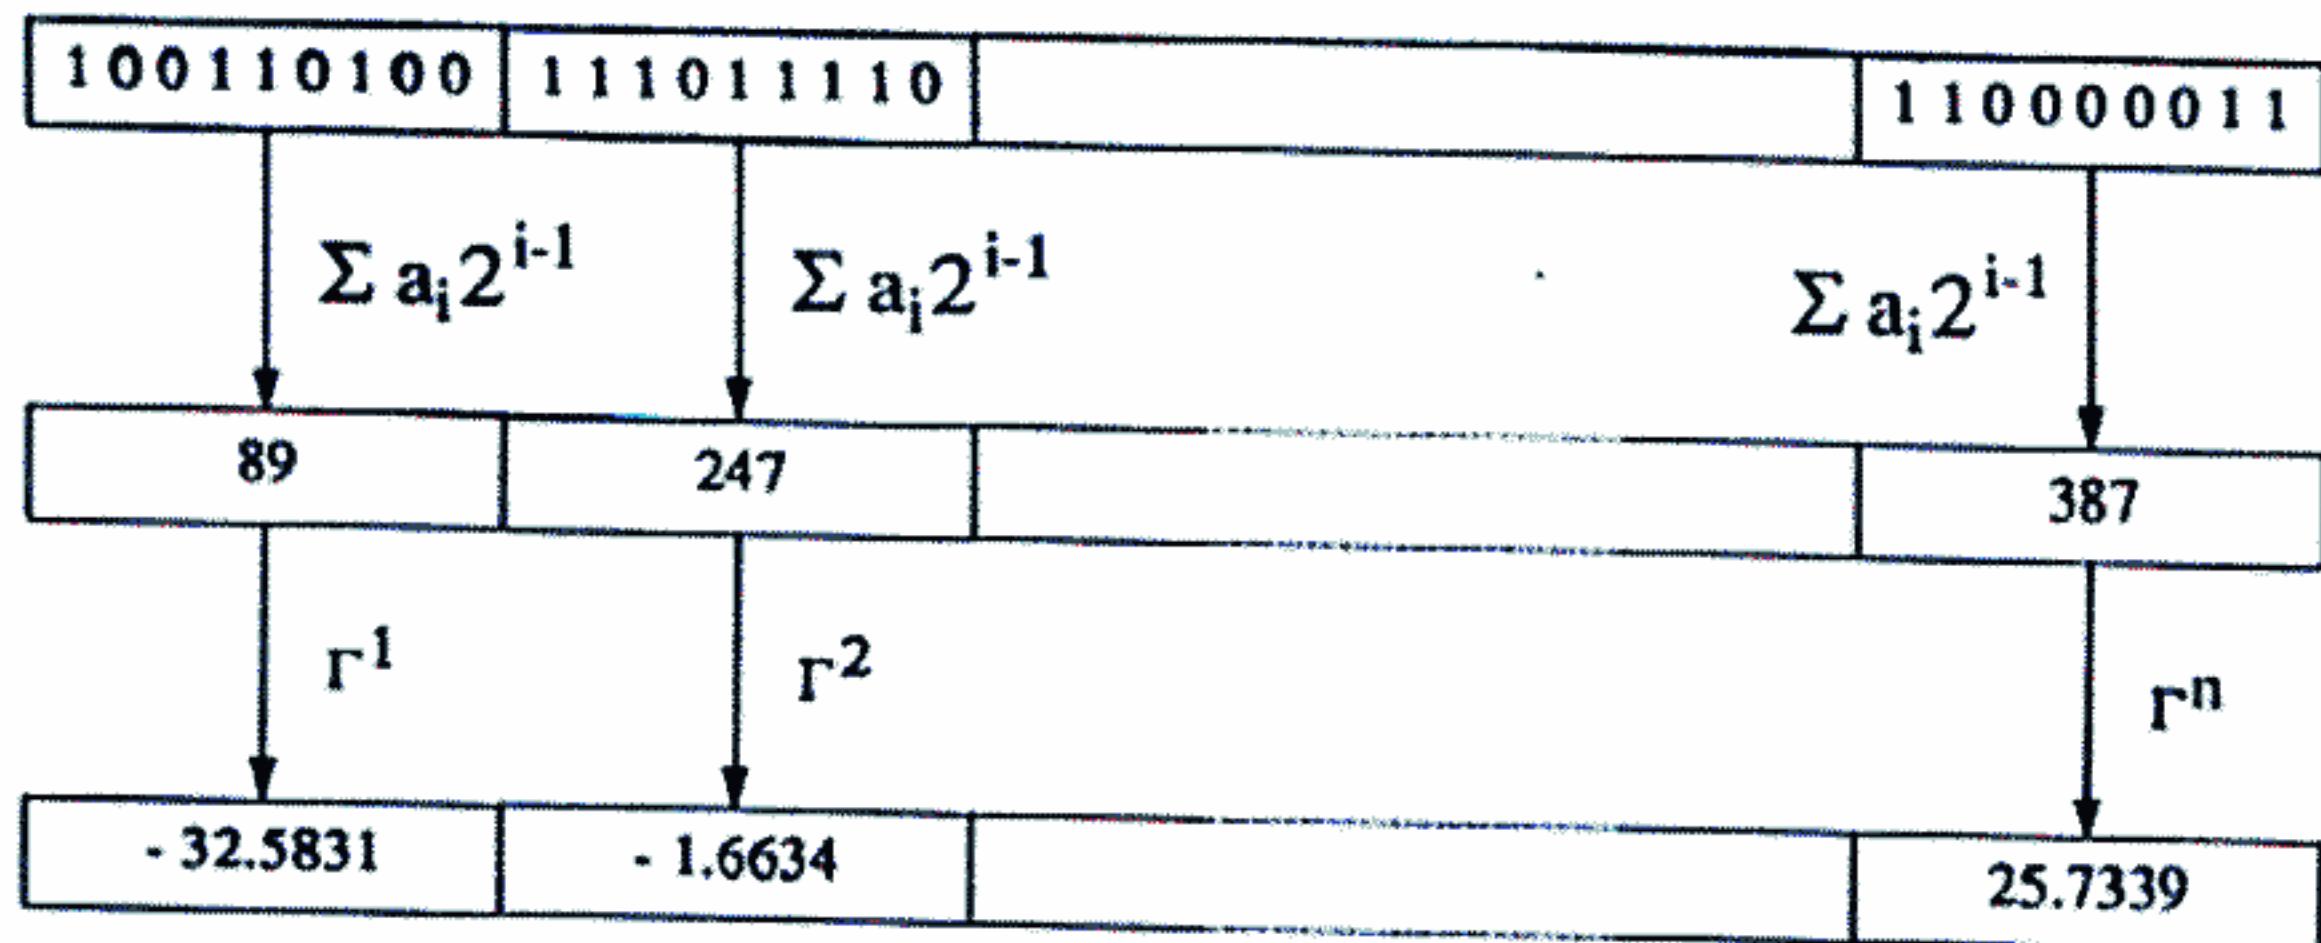
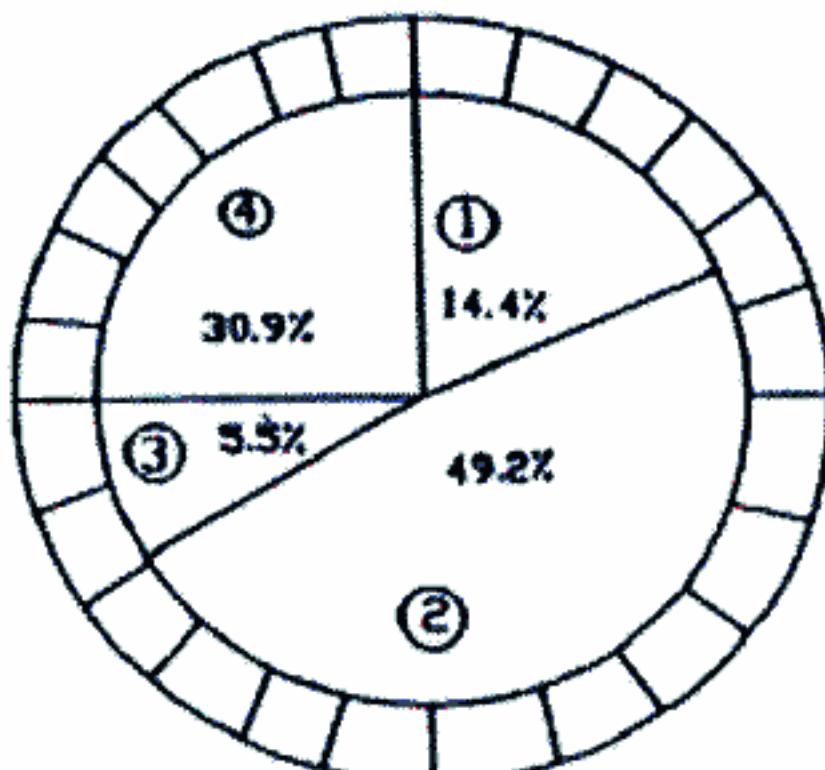


Abbildung 3: Der Dekodierungs-Prozeß.

proportionale Selektion (Rouletterad)



κ	Φ_κ	$p_{s\kappa} (\%)$
1	169	14.4
2	576	49.2
3	64	5.5
4	361	30.9

FIGURE 1.7 Simple reproduction allocates offspring strings using a roulette wheel with slots sized according to fitness. The sample wheel is sized for the problem of Tables 1.1 and 1.2.

Wahrsch., bei Rekombination als Elter „gezogen“ zu werden, abh. von relativer Fitneß

$$P_{s\kappa} = \frac{\Phi_\kappa}{\sum_{j=1}^n \Phi_j} \quad (\text{Bed.: } \Phi > 0)$$

meist: Umselektion notwendig

Notation

Individuum $a \in I$

Individuen-Raum $I = B^\ell$ für GA

Population $P^{(t)} = \{a_1, \dots, a_\lambda\} \in I^\lambda$

Strategieparameter (fest für einen Lauf)

p_c Rekombinationswahrscheinl.

z Zahl der Crossover Stellen

p_m Mutationswahrscheinlichkeit

Skalierungsparameter für Bewertung (Fitness)

Rekombination $\text{rec}_{\{p_c, z\}}: I^\lambda \times I^\lambda \rightarrow I (x I)$

Mutation $\text{mut}_{\{p_m\}}: I \rightarrow I$

Selektion $\text{sel}_{\{\dots\}}: I^\lambda \rightarrow I^\lambda$

entsprechend Paarungswahrsch. p_s

$$\text{z.B. } p_s(a_k(t)) = \Phi(a_k(t)) / \sum_{i=1}^{\lambda} \Phi(a_i(t))$$

$$\Phi(a(t)) = \alpha f(x(t)) + \beta > 0$$

t : Iterationszähler

λ : Populationegröße ($\lambda = \mu$)

Genetischer Algorithmus

$t := 0$

initialisiere $P^{(0)} := \{a_1(0), \dots, a_\lambda(0)\} \in I^\lambda$ mit $I \in \mathbb{B}^l$
 bewerte $P^{(0)} : \{\Phi(a_1(0)), \dots, \Phi(a_\lambda(0))\}$

While $(L(P(t)) \neq \text{true})$ do

re kombiniere $a'_k(t) := \text{vec}_{\{j\}}(P(t)) \quad \forall k \in \{1 \dots \lambda\}$

mutiere $a''_k(t) := \text{Mut}_{\{j\}}(a'_k(t)) \quad \forall k \in \{1 \dots \lambda\}$

bewerte $P''(t) := \{a''_1(t), \dots, a''_\lambda(t)\} :$
 $\{\Phi(a''_1(t)), \dots, \Phi(a''_\lambda(t))\}$

selektiere $P(t+1) := \text{sel}_{\{j\}}(P''(t))$

mit Selektionswahrscheinlichkeiten

$$p_s(a''_k(t)) = \frac{\Phi(a''_k(t))}{\sum_{i=1}^{\lambda} \Phi(a''_i(t))}$$

$t := t + 1$

od.

$$\Phi(a) = \delta(\underline{f(x)}(g^*(a)))$$

$x = \text{decode}(a)$

Qualifizierung

wobei
 $Q = P(t)$
 oder
 $Q = I_{\text{best}}^{(t)}$

Selektionsvarianten bei GAs

proportionale Selektion

vor hierfür „gilt“ das Schema-Theorem

probabilistische „Auslese“ (mating selection)

rangbasierte Selektion

$$p_s = f(\text{Rang})$$

tournament selection

wähle λ mal $g < \lambda$ Konkurrenten;
bestes „überlebt“ (ggf. mehrfach)

:

truncation selection

à la ES

Reproduktion

stets $\lambda = \mu$ (non-Darwinian!)

heute: Hunderte von speziellen GAs

cGA canonical GA (Holland)

sGA simple GA (Goldberg)

Michigan approach

Pittsburgh approach

:

pGA parallel GA

:

mGA messy GA (unordentlich; Goldberg)

:

bGA breeder GA (Mühlenbein)

truncation selection

gene pool recombination

} à la ES

Buch von Zbigniew Michalewicz:

Data Structures + Genetic Algorithms

= Evolution Programs

! Problem - Modellierung ; Variablen - Codierung

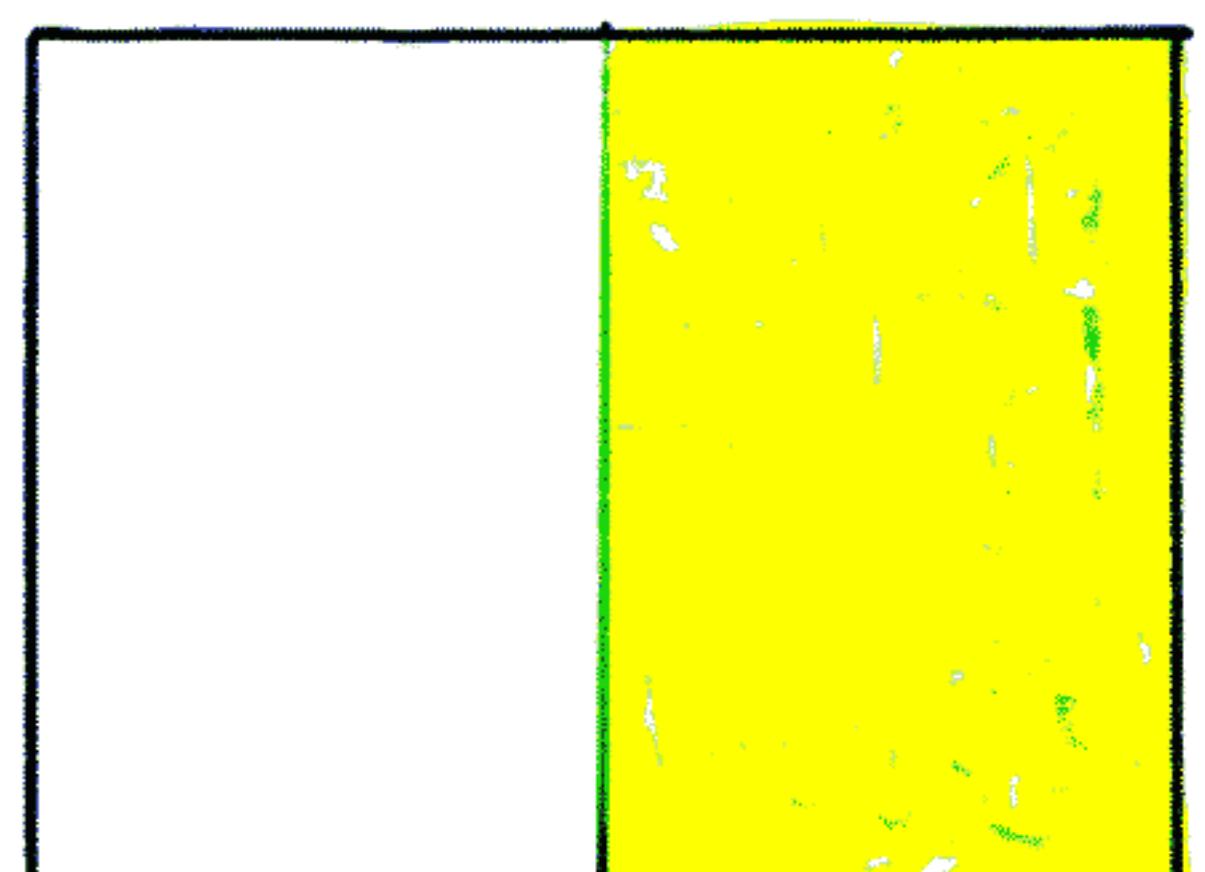
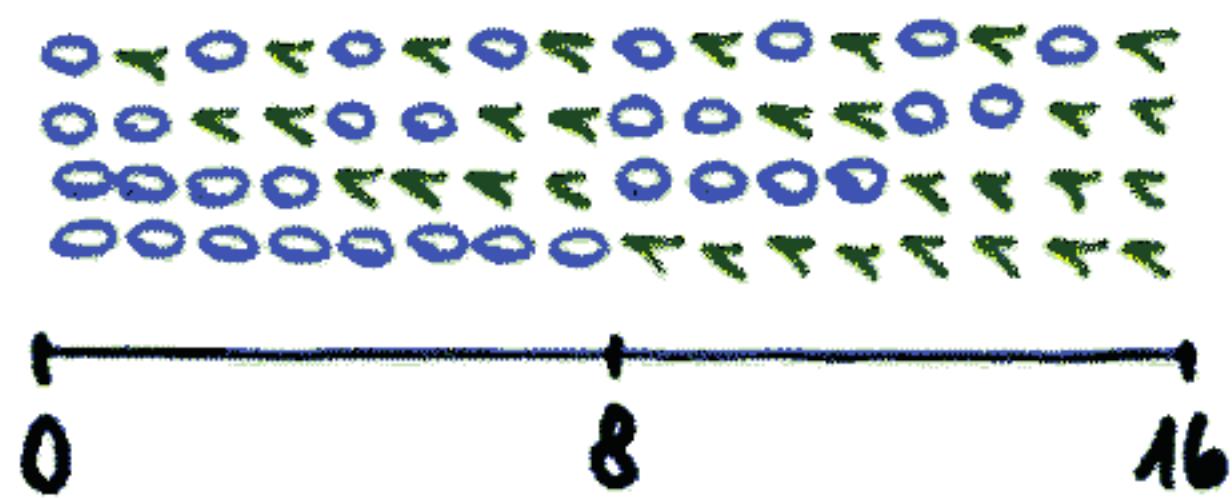
! angepasste Operatoren für Mutation } Variation
Rekombination } Variation

real coded GAs

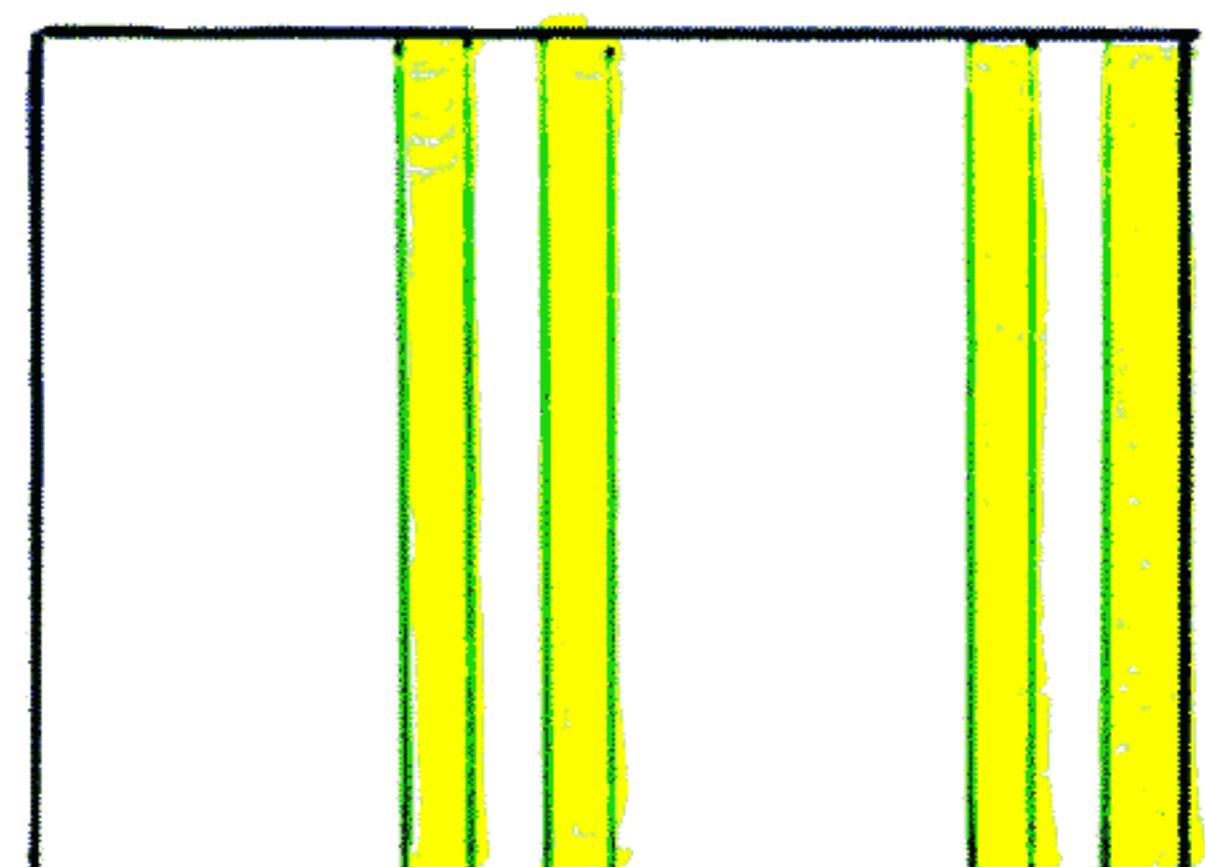
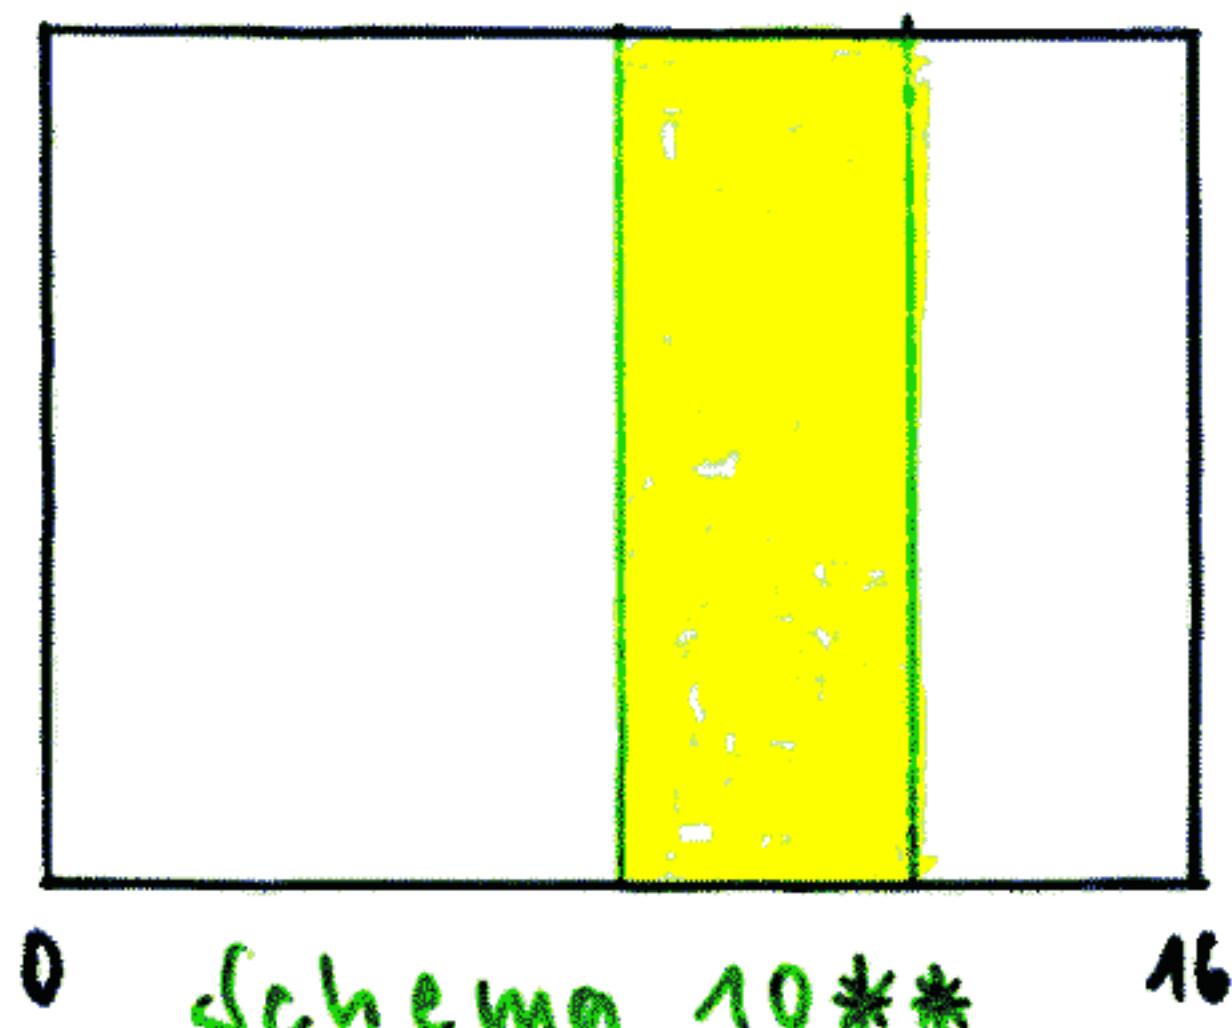
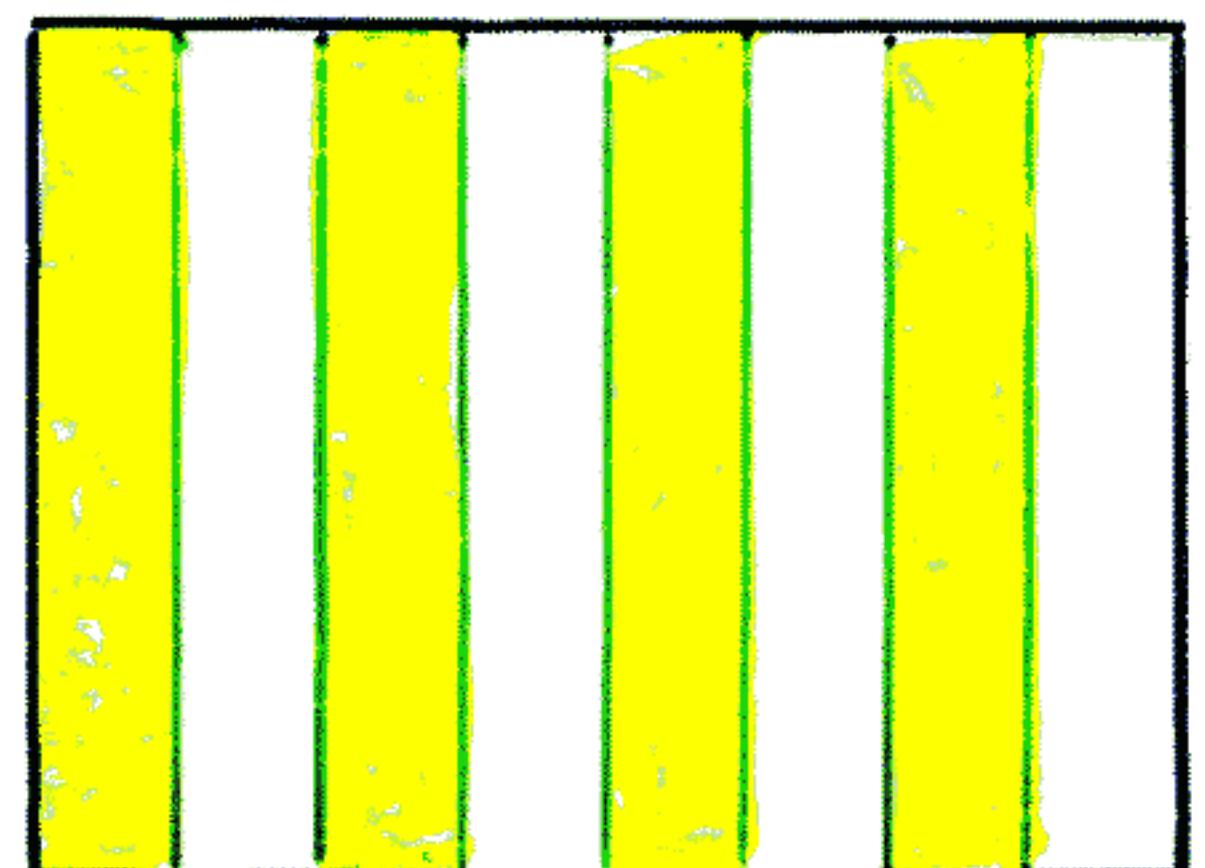
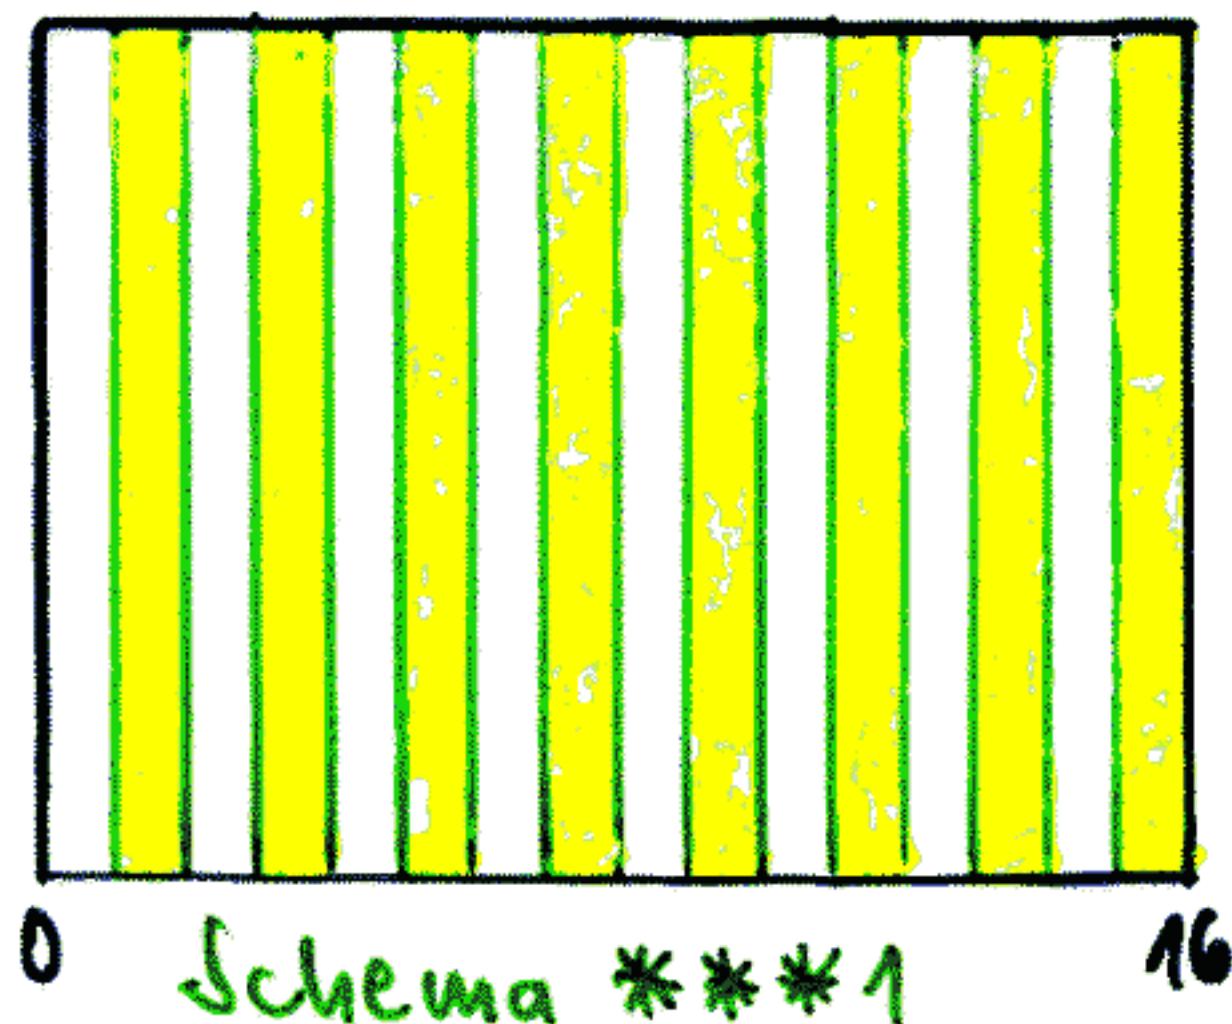
ESS gleichwertig oder besser

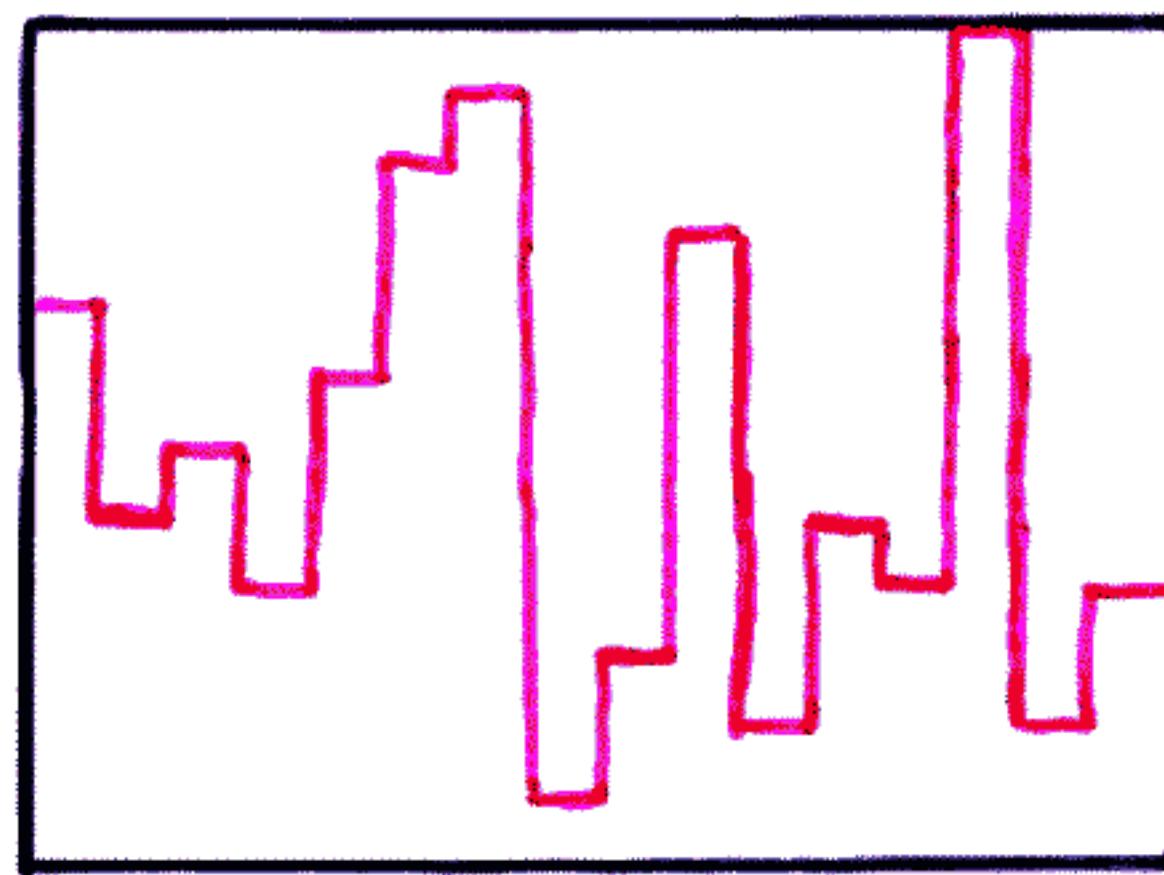
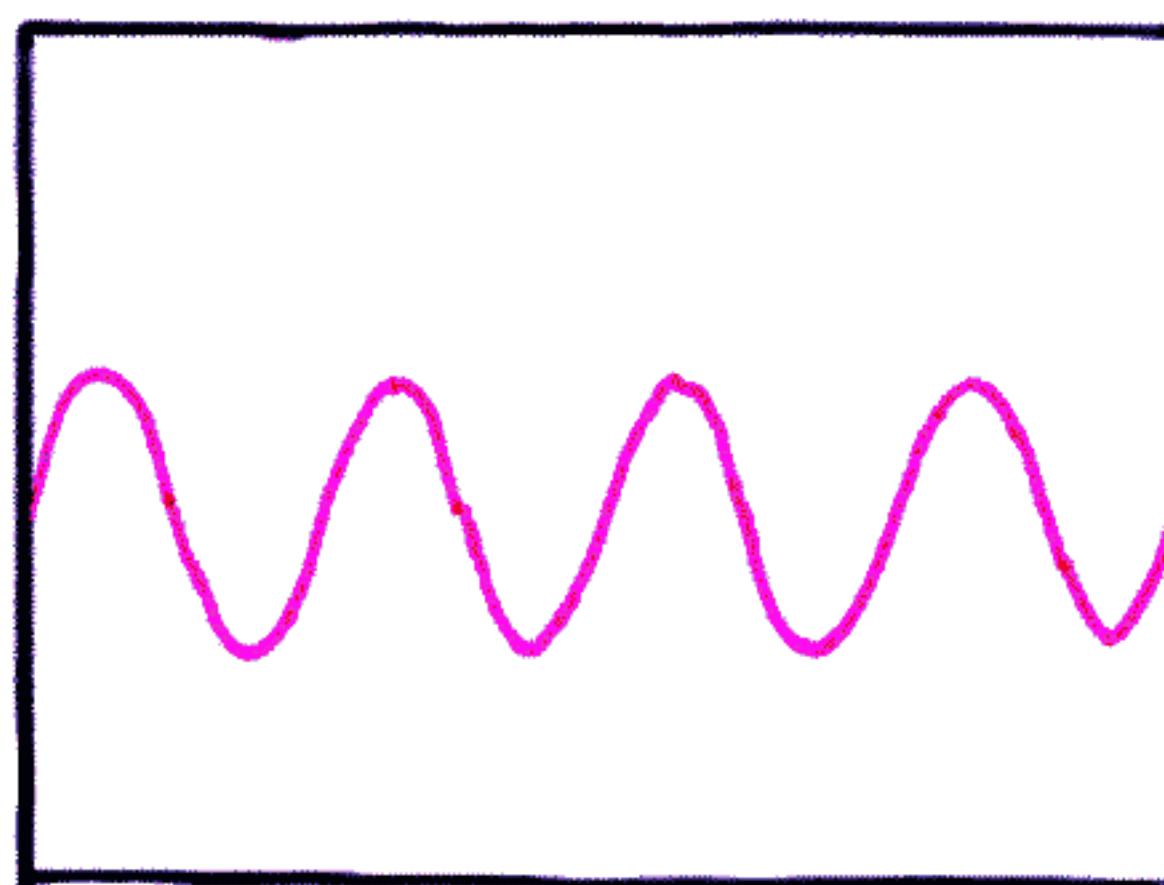
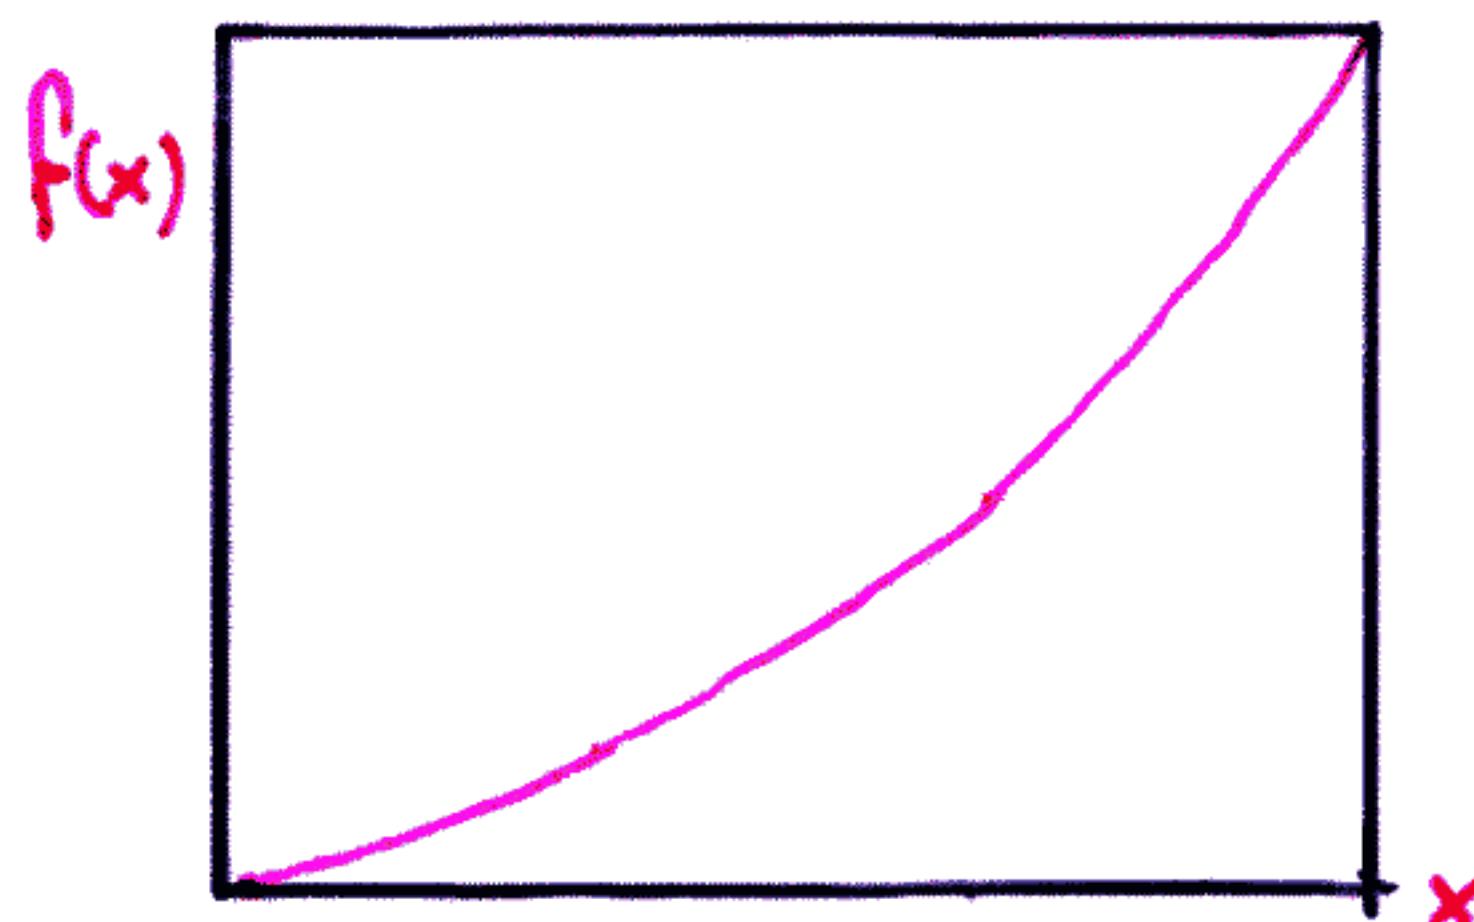
EP ?

Schemata =
Hyperebenen
Bsp.: $\ell=4$ Bits



Schema $1***16$





Schema-Theorem (J. Holland, 1975)

binäre Hyperebene $H \in \{0,1,*\}^l$

wild card

z.B. $H_1 = (1****)$

$H_2 = (01**1*)$

zugehörige Instanzen $I(H)$

$$I(H_2) = \{(01010), (01011), (01110), (01111)\}$$

$/h_1 \quad /h_2$

Ordnung $\sigma(H) = |\{i | h_i \in \{0,1\}\}|$

Bsp. $\sigma(0***1*) = 2$

definierende Länge $\Delta(H) = \max\{\overbrace{i | h_i \in \{0,1\}}^k\} - \min\{k\}$

Bsp. $\Delta(0***1*) = 4 - 1 = 3$

$$\begin{aligned} \text{Anzahl } N_{t+1}(H) &= N_t(H) \cdot \frac{\Phi(H)}{\bar{\Phi}} \cdot \left[1 - \frac{p_c \Delta H}{l-1} \left(1 - \frac{N_t(H)}{\lambda} \right) \right] (1-p_m)^{\sigma(H)} \\ &\approx N_t(H) \cdot \frac{\Phi(H)}{\bar{\Phi}} \cdot \left[1 - \frac{p_c \Delta H}{l-1} - \sigma(H) \cdot p_m \right] \end{aligned}$$

Kurze überdurchschnittlich gute Schemata geringer Ordnung (building blocks) vermehren sich exponentiell [und diese werden dann durch Cross-over zusammengefügt]

$$\bar{\Phi} = \frac{1}{\lambda} \sum_{i=1}^{\lambda} \Phi_i$$

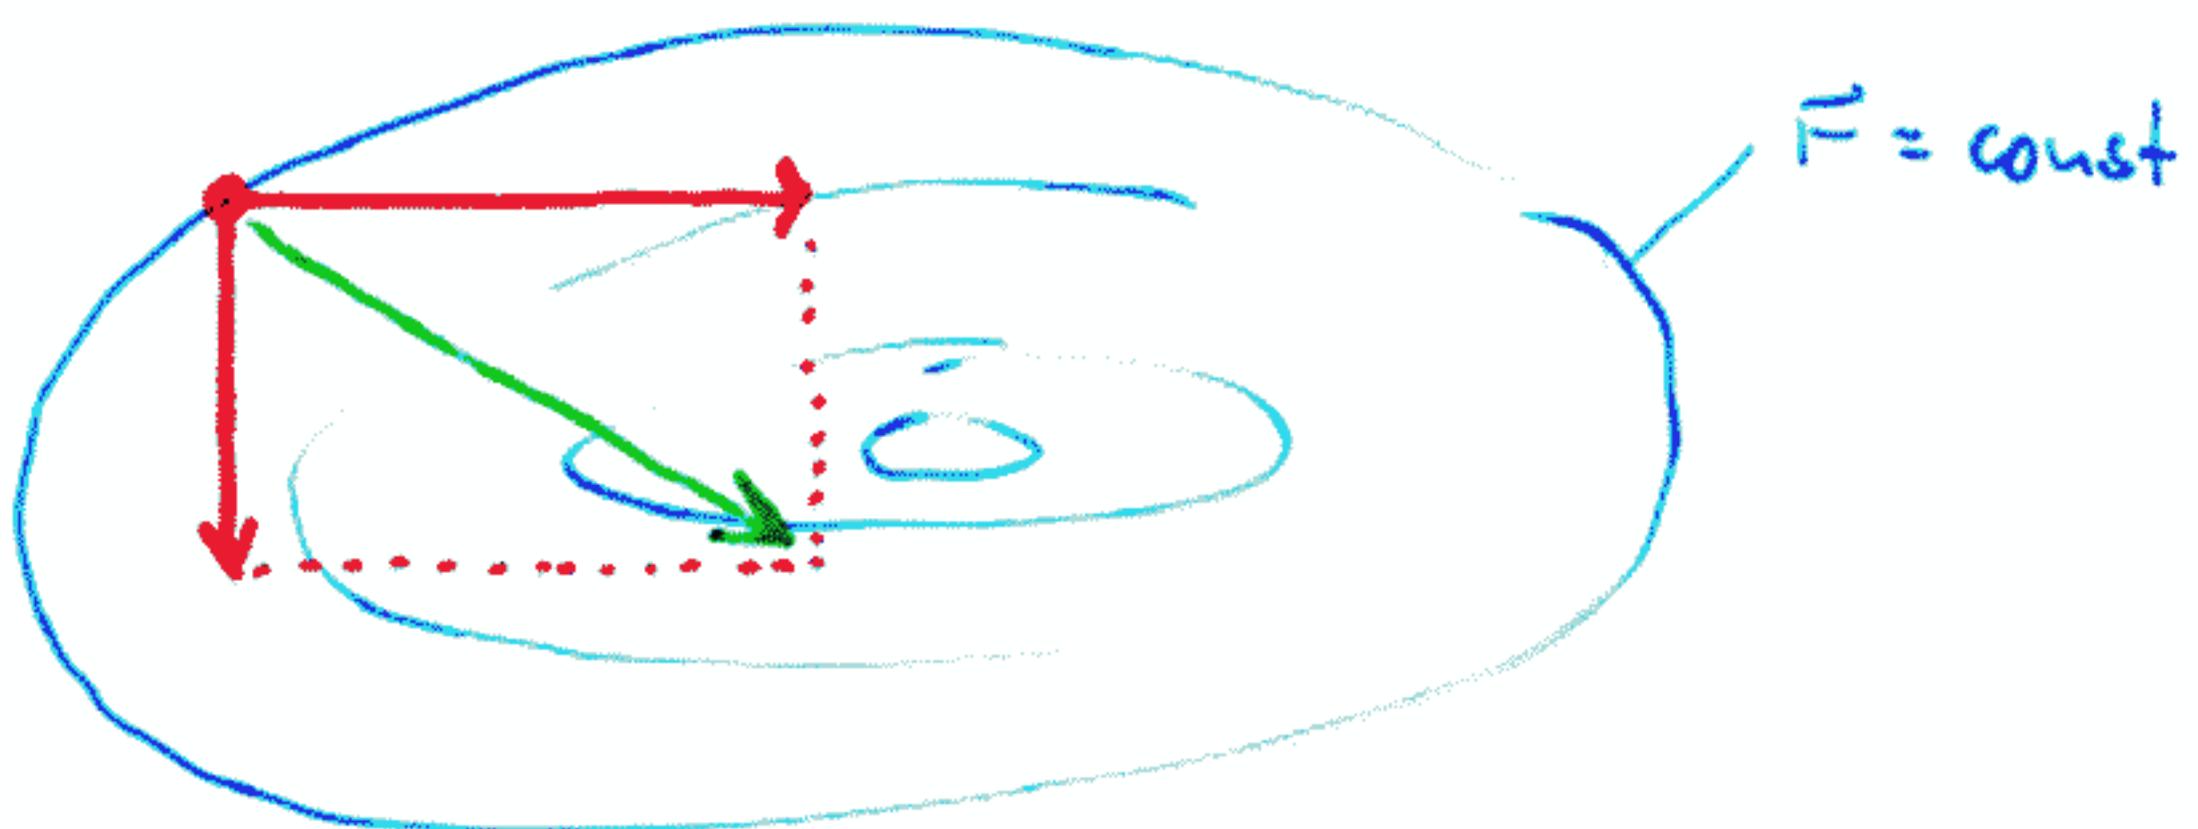
Kritik am Schema-Theorem

- Approximationen im Beweis gültig für $\lambda \rightarrow \infty$
- in endlicher Population kommen nicht alle Schemata vor
- bei exponentiellem Wachstum in endlichen Pop. sterben andere Schemata vollständig aus
- Crossover und Mutation nur destruktiv?
- Wachstum wäre nur dann exponentiell, wenn Wachstumsrate const.
(das ist aber nicht der Fall; sie geht gegen Null)
- „Zusammenfügen“ brauchbarer Bruchstücke setzt Dekomponierbarkeit voraus
(i.a. müssen sich Variablen gleichzeitig ändern)

Nur noch ‚Hardliner‘ verteidigen das Schema-Theorem

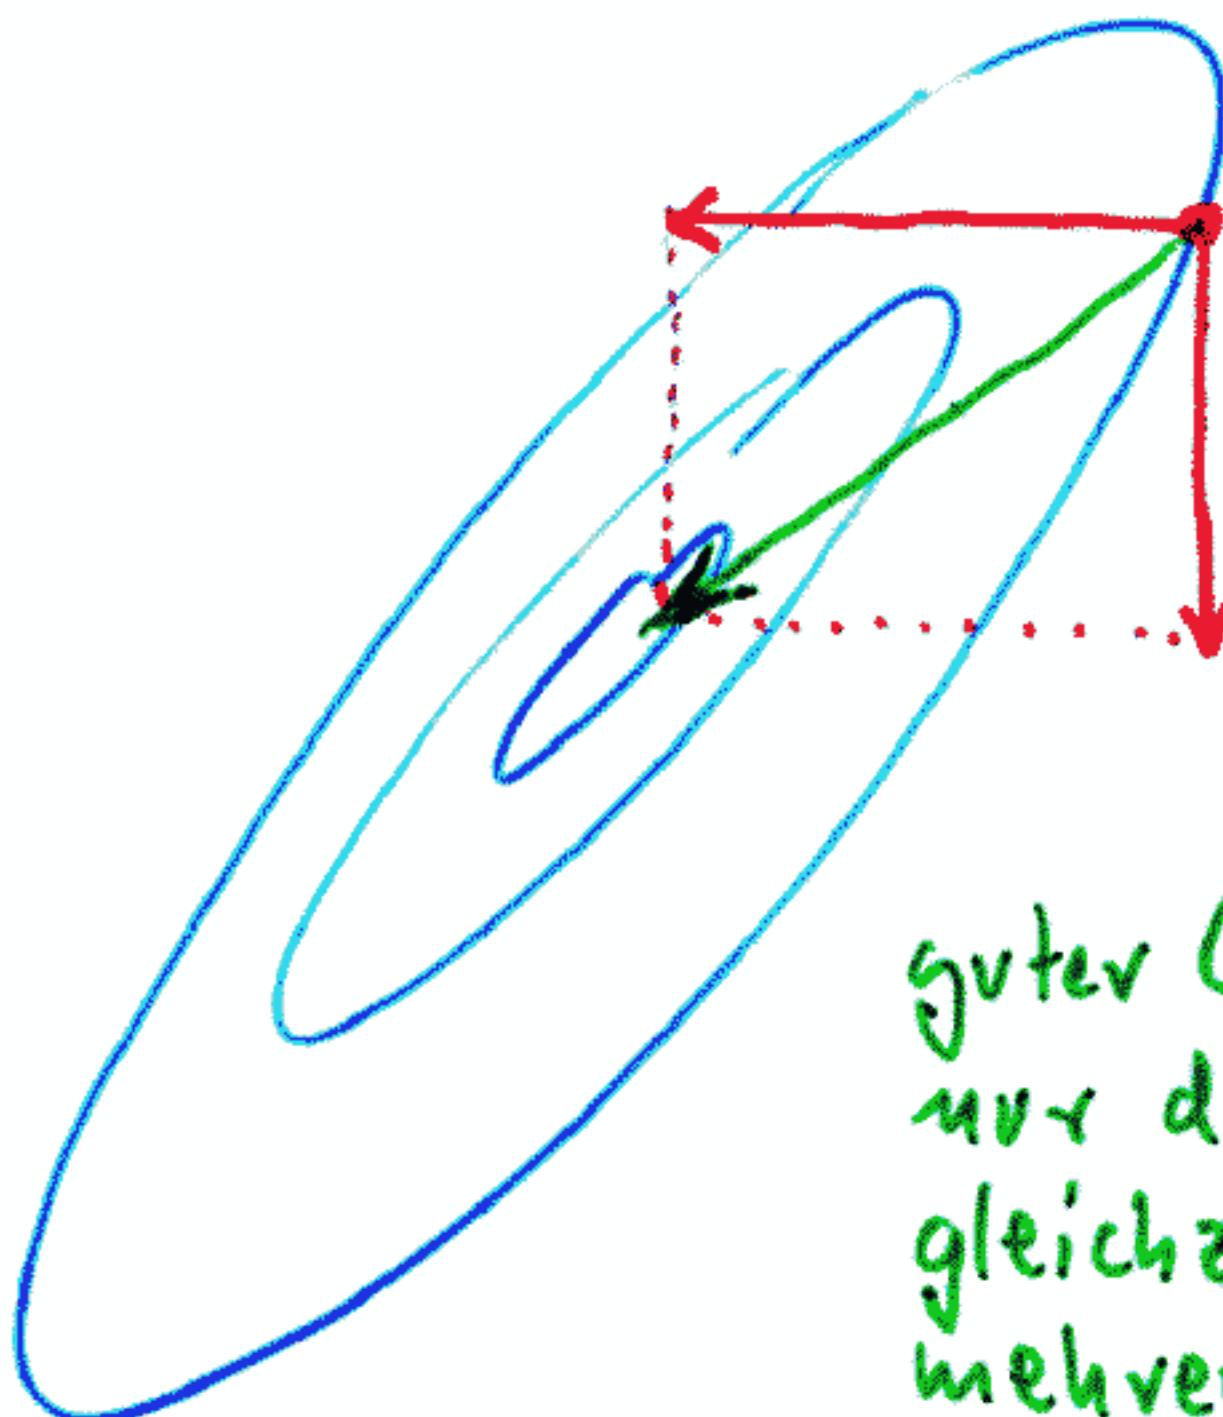
Kritik an der building block Hypothese

Fall 1



guter GesamtSchritt = Zusammensetzung
verbessernder Einzelschritte

Fall 2



guter GesamtSchritt
nur durch koordinierte
gleichzeitige Änderungen
mehrerer Variablen
(Teile des Bitstrings)

bb Hypothese gilt für separable Zielfunktion

Gigs: deceptive problems
(täuschend, betrügerisch)

implicit parallelism

jeder Schema testet gleichzeitig die
Bruchbarkeit einer ganzen Hyperebene

es werden aber nur gerade vorhanden Instanzen,
keine Schemata (summatisch) bewertet

Schema-Theorem geht von ∞ großer Pop. aus;
darin enthalten ist dann aber bereits
global optimale Lösung;
diese muß sich nur noch durchsetzen!

Alle „optimalen“ Bits sind schon in relativ
kleiner Population vorhanden
sie brauchen „nur noch“ richtig zusammengestellt
zu werden (\rightarrow Prinzip der Rekombination)

? Wahrscheinlichkeit, daß zufällige Startpopulation alle korrekten Bits der optimalen Lösung enthält

L Länge des Bitstrings

λ Zahl der Individuen

$$\text{gesuchte Wahrsch. : } w = 1 - L 2^{-\lambda}$$

$$\text{Bsp. } L = 1000$$

$$\lambda = 50$$

$$w \approx 0.999999999999 = 1 - 10^{-12}$$

Leider gehen korrekte Bits oft zwischendurch verloren. \rightsquigarrow Mutationen, um sie wiederzugewinnen

aber

Mutation ist sog. Hintergrundoperator

$$CGA : p_m = 10^{-3}$$

Rekombination (Crossover) ist Hauptoperator

$$CGA : p_c = 0.6$$

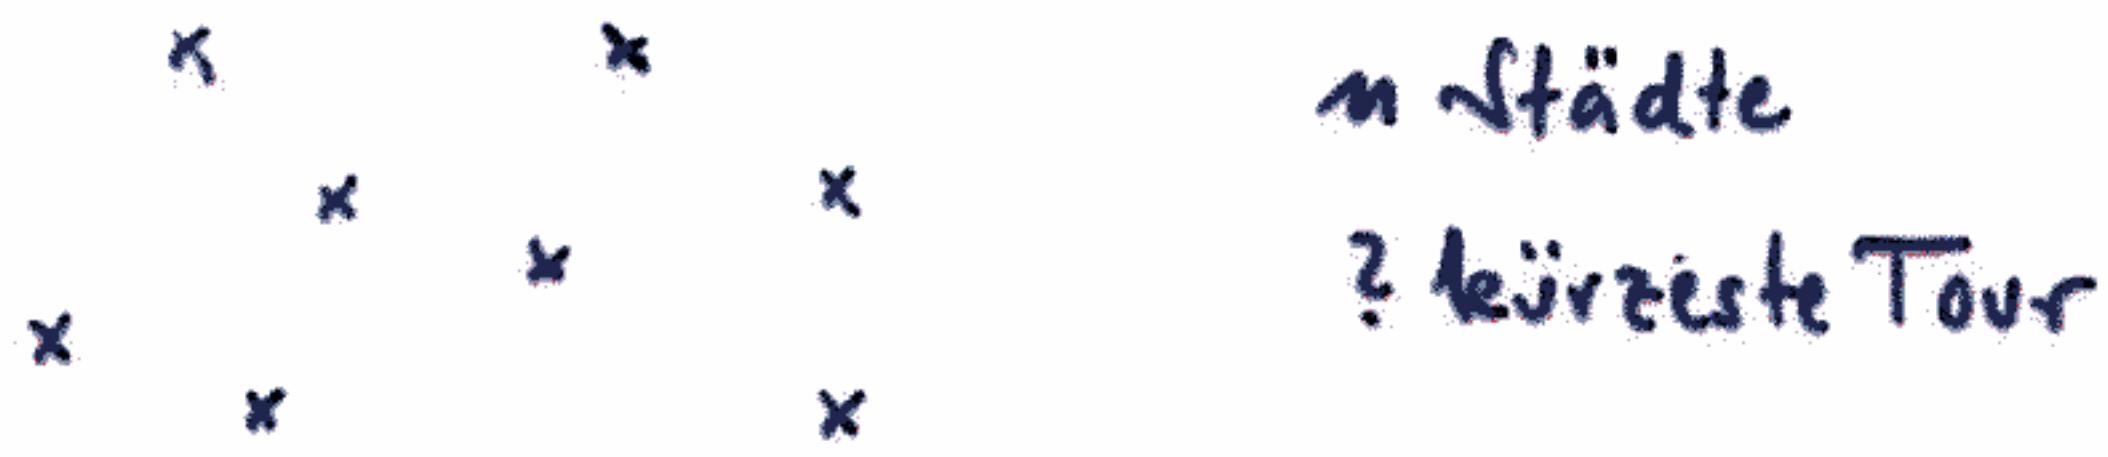
Selektion: heute meist rangbasiert

\rightsquigarrow geringere Abh. von Gradient

oder tournament selection

Beispiel : TSP

Travelling Salesperson Problem
man



lange Zeit Paradebeispiel für Brauchbarkeit der GAs:
liefern relativ schnell gute Näherungslösungen

spezialisierte deterministische Strat. versus
spezialisierte GA

Frage der Modellierung

Datenstruktur für Individuen/Instanzen

z.B. Städte durchnummieren 1, 2, ..., n

gesucht: Permutation Π

z.B. Adjazenzmatrix

gesucht: Belegung mit Nullen u. Einsen
(je eine Eins pro Zeile u. Spalte)

Crossover

Partiell zuordnendes Crossover (PMX):

$$\begin{array}{l}
 A = (9 \ 8 \ 4 \ | \ 5 \ 6 \ 7 \ | \ 1 \ 3 \ 2 \ 10) \\
 \quad \quad \quad \downarrow \downarrow \downarrow \\
 B = (8 \ \underbrace{7 \ 1}_{10} \ | \ 2 \ 3 \ 10 \ | \ 9 \ \underbrace{5 \ 4}_{2} \ \underbrace{6 \ 3}_{3}) \\
 \quad \quad \quad \downarrow \\
 \hat{A} = (9 \ 8 \ 4 \ | \ 2 \ 3 \ 10 \ | \ 1 \ 6 \ 5 \ 7) \\
 \hat{B} = (8 \ 10 \ 1 \ | \ 5 \ 6 \ 7 \ | \ 9 \ 2 \ 4 \ 3)
 \end{array}$$

Erhält *absolute* Stadtpositionen.

Ordnungs-Crossover (OX):

$$\begin{array}{l}
 A = (9 \ 8 \ 4 \ | \ 5 \ 6 \ 7 \ | \ 1 \ 3 \ \underline{2} \ 10) \\
 \quad \quad \quad \downarrow \downarrow \downarrow \\
 B = (8 \ \underline{7} \ 1 \ | \ 2 \ 3 \ 10 \ | \ 9 \ \underline{5} \ 4 \ \underline{6}) \\
 \quad \quad \quad \downarrow \\
 A' = (9 \ 8 \ 4 \ | \ 5 \ 6 \ 7 \ | \ 1 \leftarrow \leftarrow \leftarrow) \\
 B' = (8 \leftarrow 1 \ | \ 2 \ 3 \ 10 \ | \ 9 \leftarrow 4 \leftarrow) \\
 \quad \quad \quad \downarrow \\
 A'' = (5 \ 6 \ 7 \ | \ - \ - \ - \ | \ 1 \ 9 \ 8 \ 4) \\
 B'' = (2 \ 3 \ 10 \ | \ - \ - \ - \ | \ 9 \ 4 \ 8 \ 1) \\
 \quad \quad \quad \downarrow \\
 \hat{A} = (5 \ 6 \ 7 \ | \ 2 \ 3 \ 10 \ | \ 1 \ 9 \ 8 \ 4) \\
 \hat{B} = (2 \ 3 \ 10 \ | \ 5 \ 6 \ 7 \ | \ 9 \ 4 \ 8 \ 1)
 \end{array}$$

Erhält *relative* Stadtpositionen.

Zyklus-Crossover (CX):

$$\begin{aligned}
 C &= (\underline{9} \ 8 \ 2 \ \underline{1} \ 7 \ \underline{4} \ 5 \ 10 \ \underline{6} \ 3 \) \\
 D &= (\underline{1} \ 2 \ 3 \ \underline{4} \ 5 \ \underline{6} \ 7 \ 8 \ \underline{9} \ 10 \) \\
 &\quad \downarrow \\
 C' &= (9 \ - \ - \ 1 \ - \ 4 \ - \ - \ 6 \ - \) \\
 &\quad \uparrow \uparrow \uparrow \uparrow \uparrow \uparrow \uparrow \\
 D' &= (1 \ - \ - \ 4 \ - \ 6 \ - \ - \ 9 \ - \) \\
 &\quad \downarrow \\
 \hat{C} &= (9 \ 2 \ 3 \ 1 \ 5 \ 4 \ 7 \ 8 \ 6 \ 10 \) \\
 \hat{D} &= (1 \ 8 \ 2 \ 4 \ 7 \ 6 \ 5 \ 10 \ 9 \ 3 \)
 \end{aligned}$$

Garantiert, daß jede Stadt positionstreu entweder von Elter 1 oder Elter 2 übernommen wird.

Fazit zur TSP-Rekombination:

⇒ Kreativität bei der Operatorentwicklung ist nötig !

- Kaum theoretische Hinweise.
- Experimentell:
OX ca. 11% besser als PX,
OX ca. 15% besser als CX.
- Literatur: Oliver, Smith, Holland 1987.

Mutation / Inversion

Paaraustausch-Mutation:

$$A = (9 \ 8 \ 4 \ 5 \ 6 \ 7 \ 1 \ 3 \ 2 \ 10)$$

↓

$$\hat{A} = (9 \ 8 \ 3 \ 5 \ 6 \ 7 \ 1 \ 4 \ 2 \ 10)$$

Gute Näherungslösungen ($n = 50, 100$) (Fogel 1988).

Inversion:

$$A = (9 \ | \ 8 \ 4 \ 5 \ 6 \ 7 \ | \ 1 \ 3 \ 2 \ 10)$$

↓

$$\hat{A} = (9 \ | \ 7 \ 6 \ 5 \ 4 \ 8 \ | \ 1 \ 3 \ 2 \ 10)$$

(Enspricht einem 2-er Kantenaustausch; wie in Lin's 2-opt Heuristik).

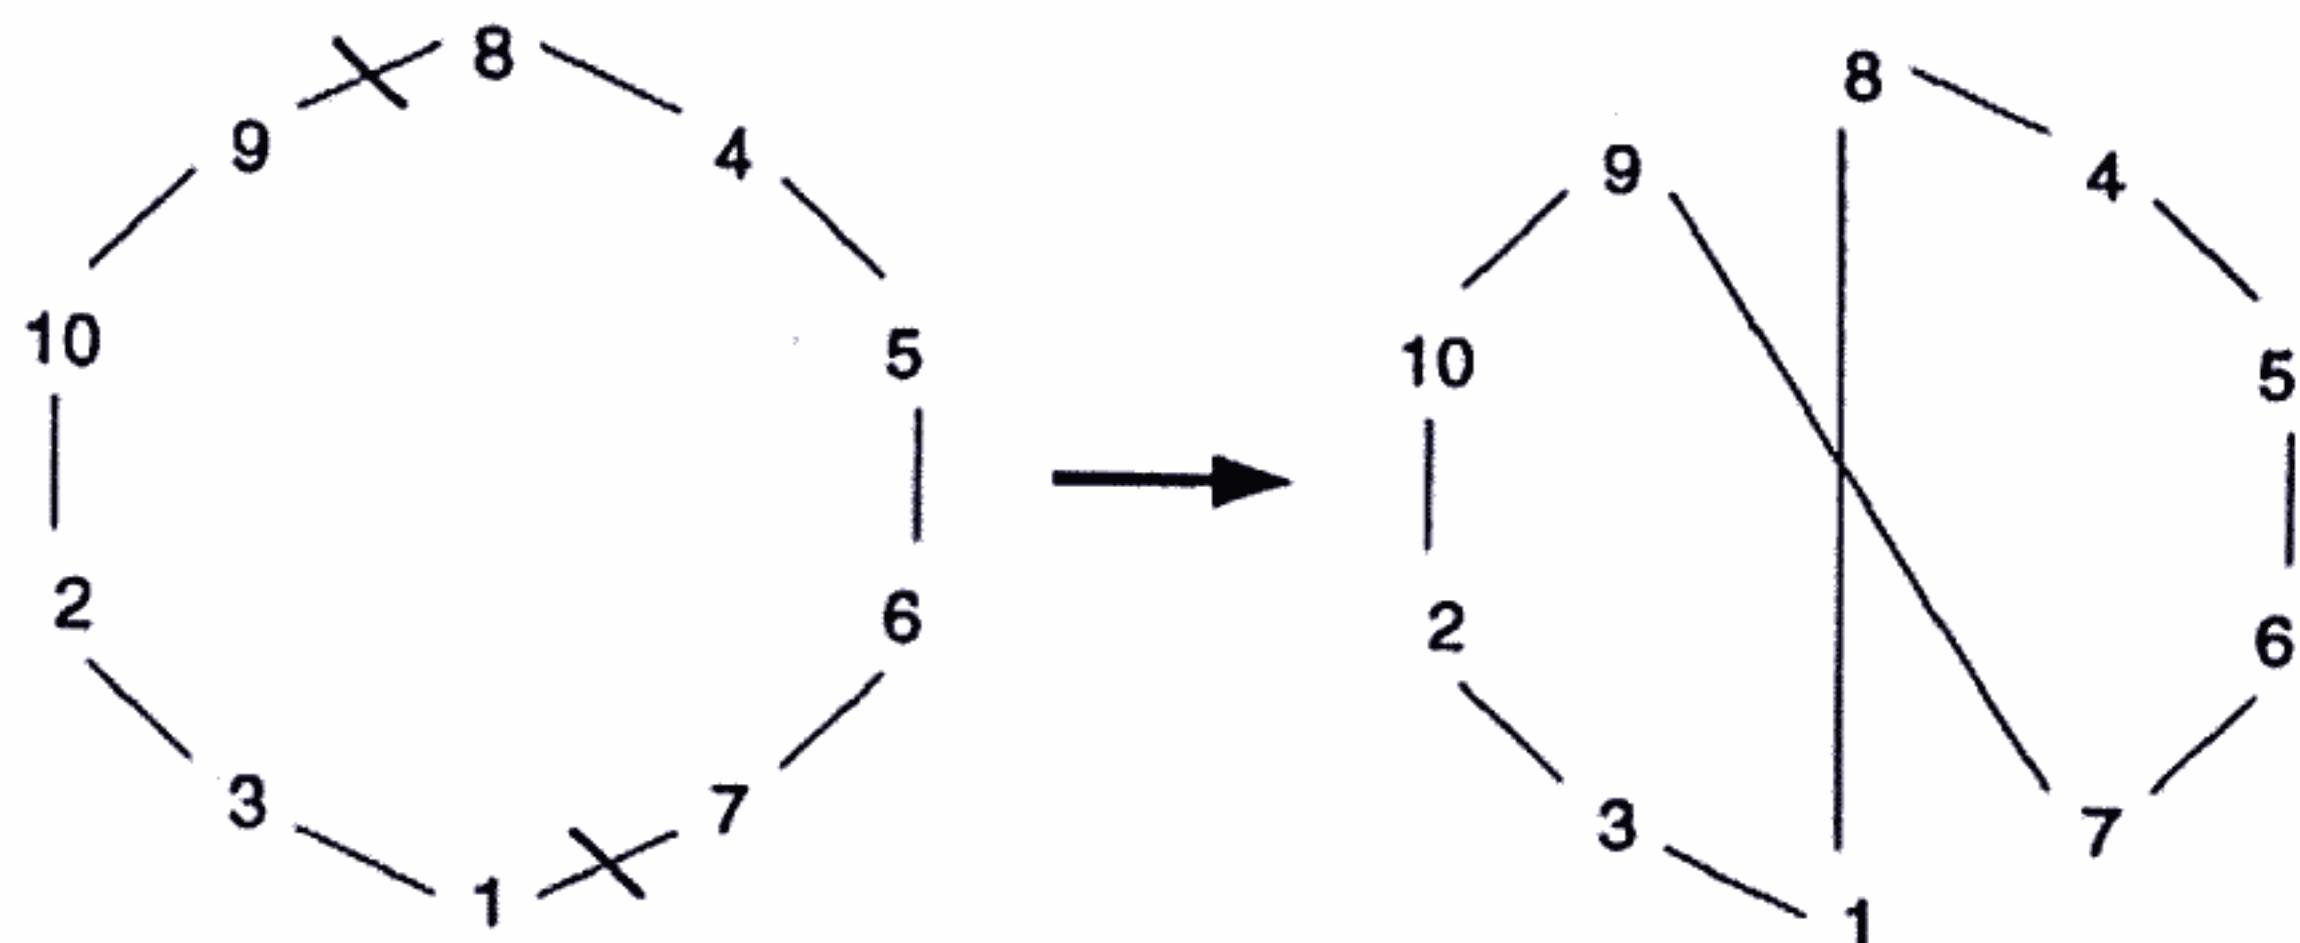


Abbildung 12: 2-er Kantenaustausch durch Inversion.

etwas Theorie (hier GA)

- GA (kanonisch) konvergiert nicht, sondern fluktuiert um einen Fixpunkt (hoffentlich ein lokales Optimum); J. Holland beharrt: GA ist keine Optimierungsmethode.
- ‚Premature convergence‘ besagt ebendies.
- Laut Fischer-Eigen Modell kann ein cGA nicht einmal ein Optimum halten, wenn die Mutationsrate zu groß ist und/oder die Bitstrings zu lang.
- Hollands Schema-Theorem ist nicht konstruktiv, es behandelt **beide** Variationsmechanismen (Crossover und Mutation) als nur schädlich, gilt für unendlich große Populationen und wird oft falsch interpretiert („exponentielles Wachstum guter Schemata niedriger Ordnung und geringer Länge“).
- Die Building-Block Hypothese gilt nur für **separable** Fitness-Funktionen.
- Ein ‚elitist‘ GA (bisher beste Lösung bleibt) konvergiert aber.
Im linearen Fall: $O(n \log n)$ Schritte benötigt (z.B. ‚counting ones‘ Problem).
In schlimmsten Fall („epistasis“): $O(n^n)$ Schritte benötigt.

EP 1962

finite-state
automaton
for prediction

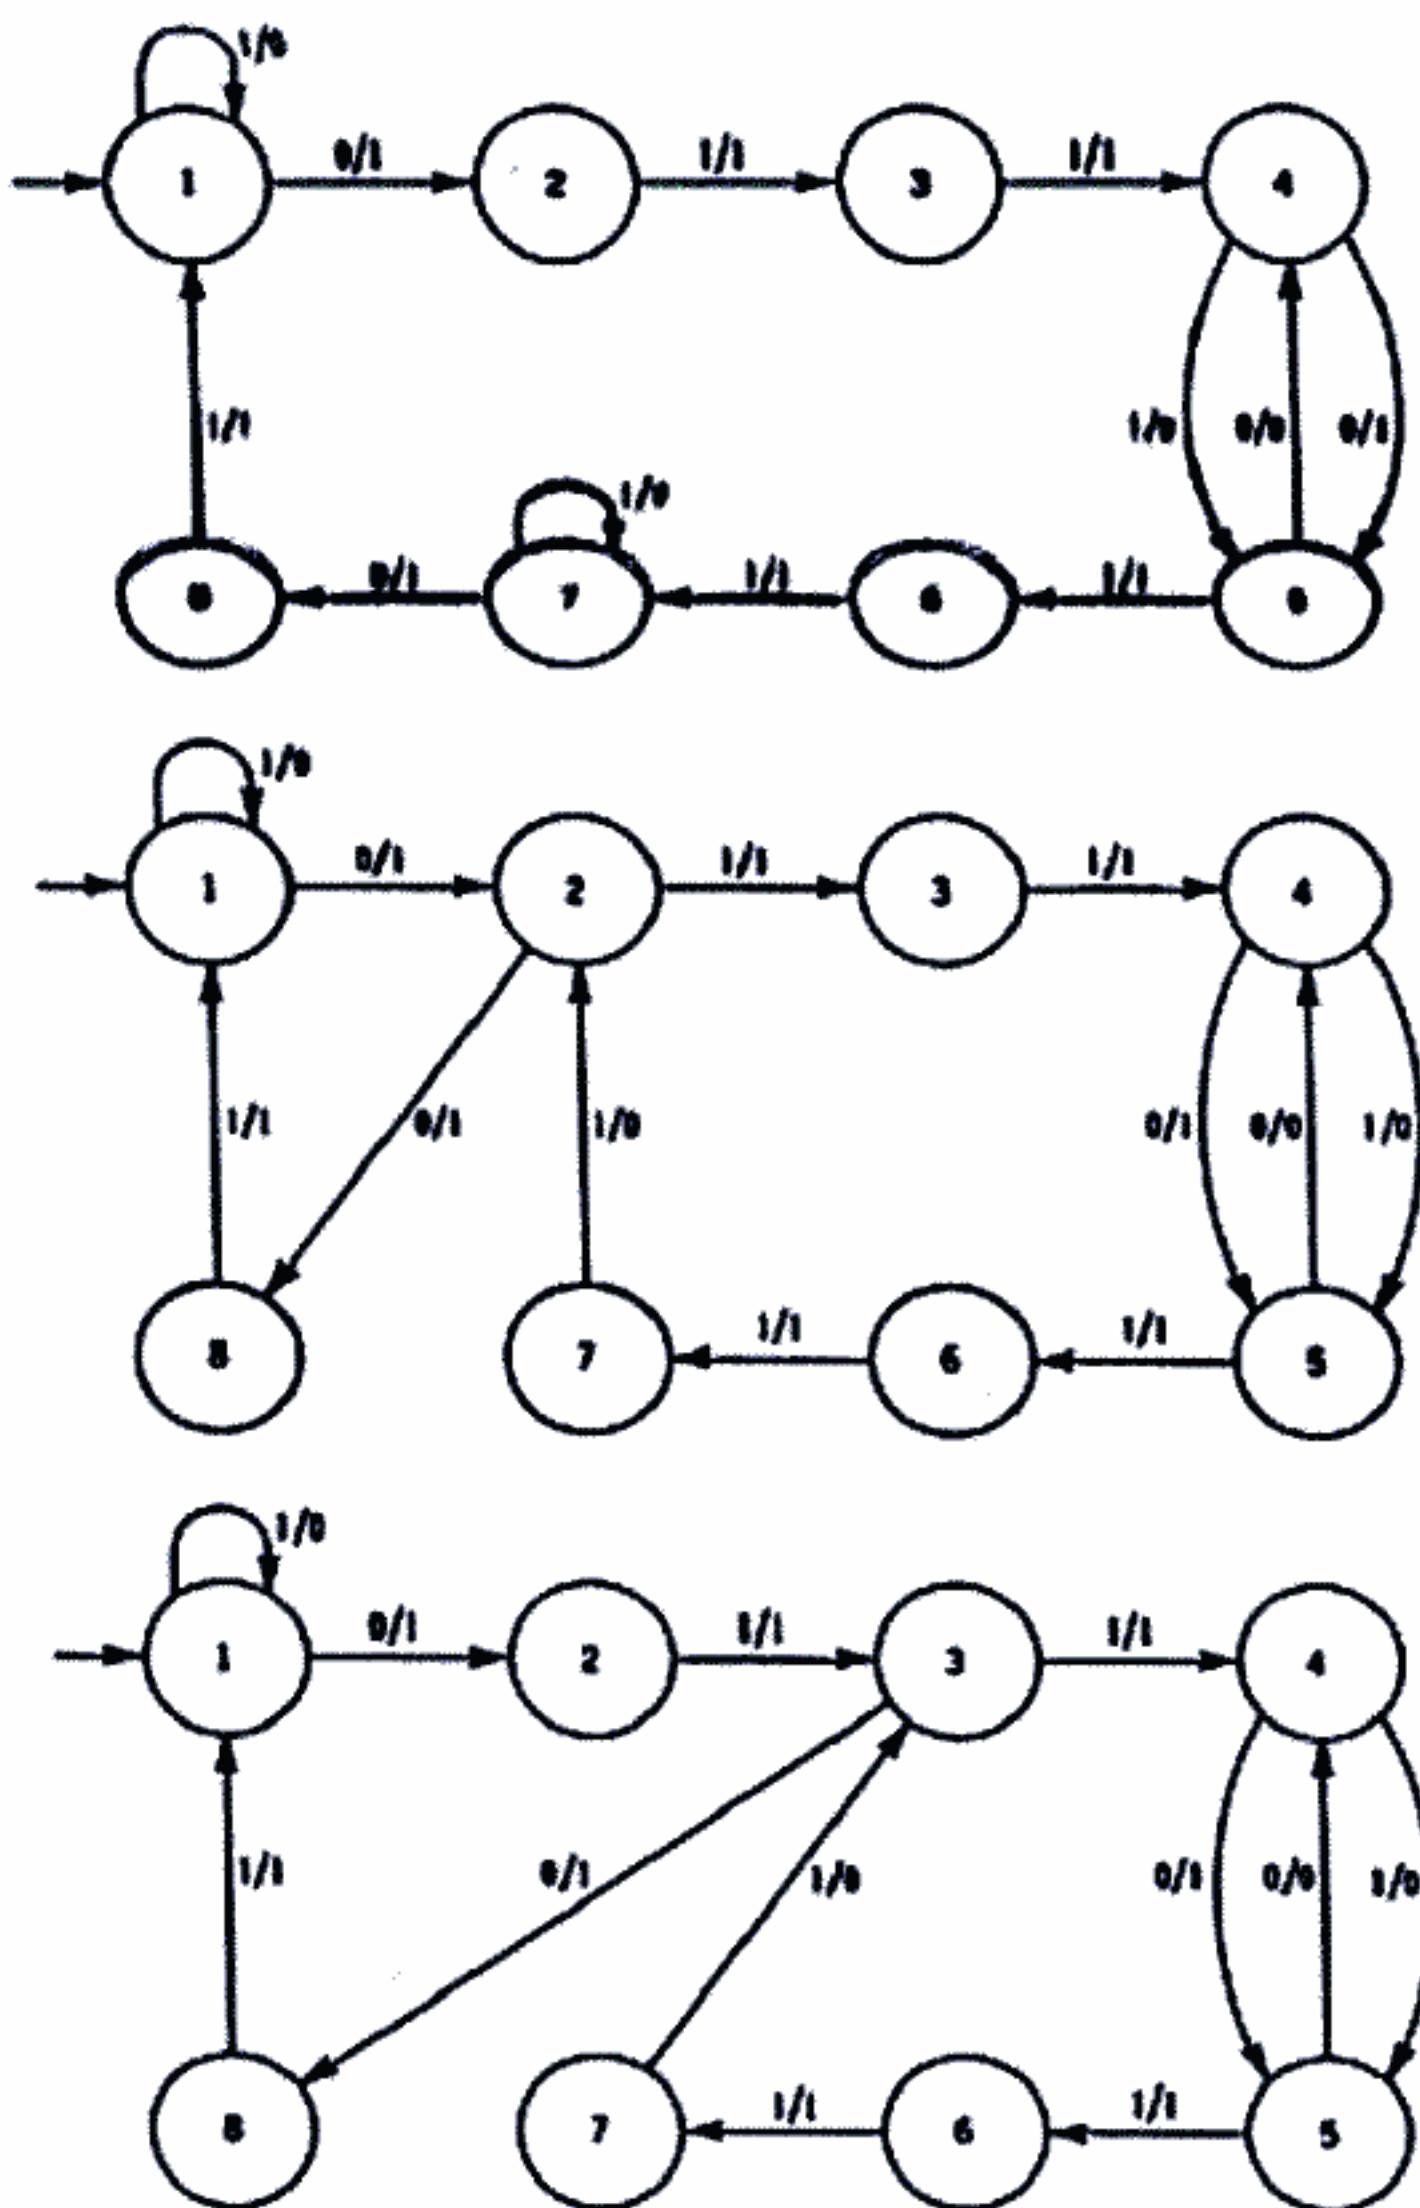


Fig. 3.4. Three different eight-state machines which perfectly predict 101110011101 cyclic environment.

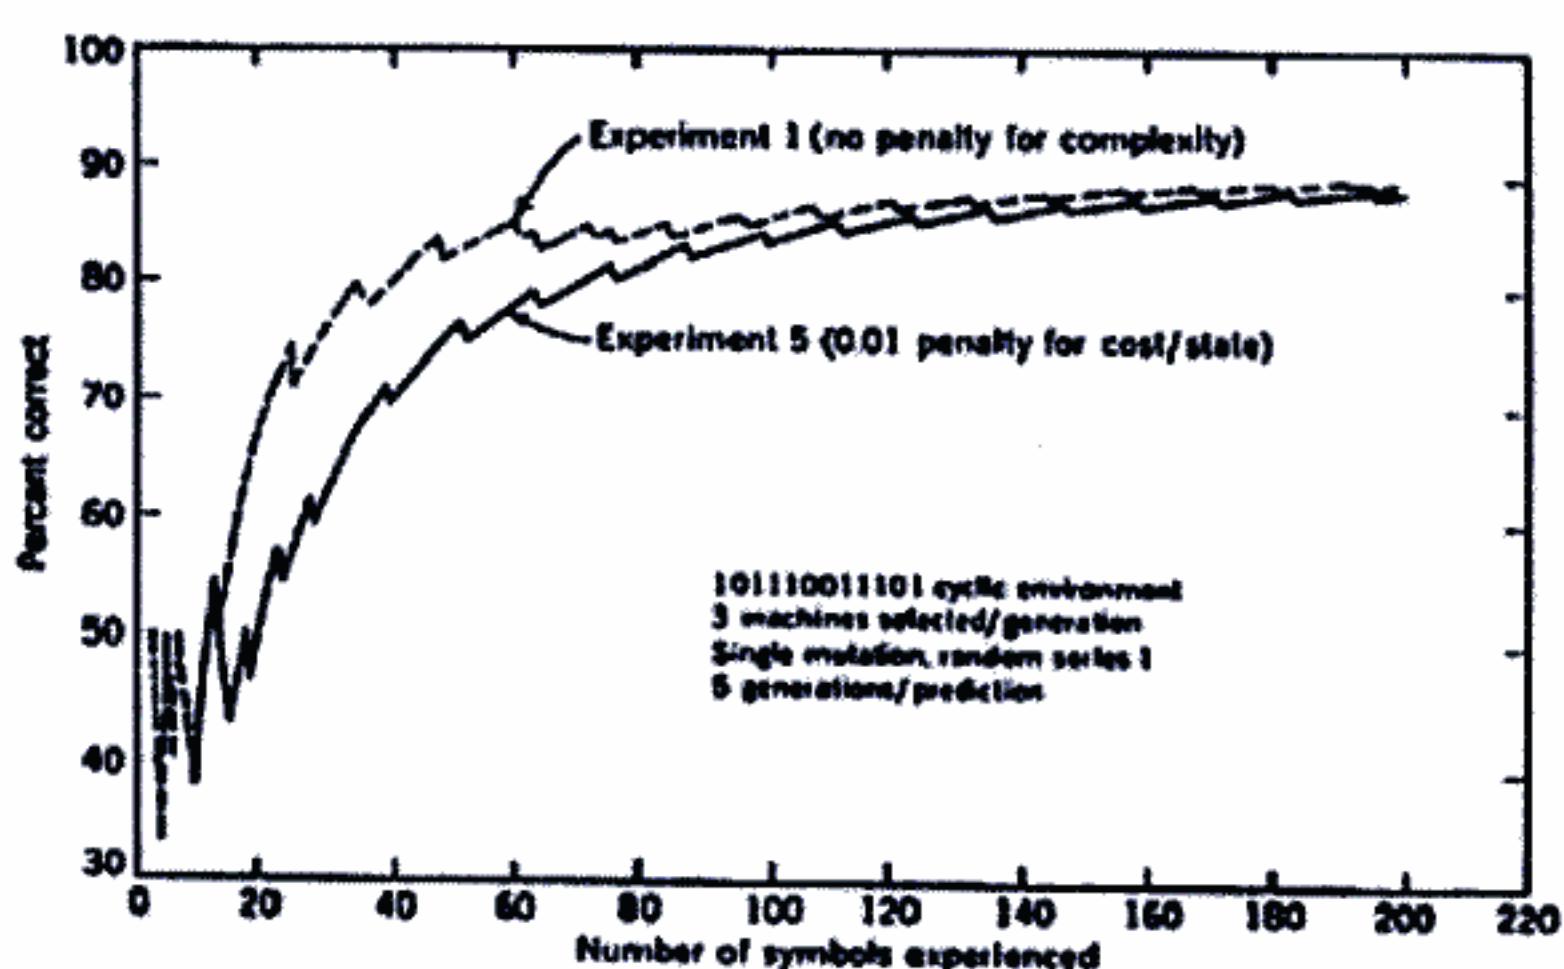


Fig. 3.2. A comparison of the prediction score with and without a penalty for complexity.