Programme züchten - Evolution als Optimierungsverfahren

Heiko Spindler

Freiberuflicher IT-Berater, Architekt, Autor und Coach

Agenda

- Was ist Evolution?
- Simulieren von Evolution
- Ein erstes Beispiel
- Programme züchten
- Fazit

Missverständnis über Evolution

- Langsam
- Mutationen sind extrem zerstörerisch
- Evolution kann nichts „Neues“ erzeugen, sondern nur Vorhandenes variieren
  - Wie können komplizierte Organe (z. B. menschliches Auge oder Gehirn) entstehen?
- Evolution ist nicht zielgerichtet: Versuch & Irrtum
- Evolution gibt es nur in der Natur

Evolution der Evolutionstheorie

Da Vinci (1452-1519)

- Ahnung der Bedeutung von Fossilien

Georges Baron de Cuvier (1769-1832)

- Arten entstehen und verschwinden durch Naturkatastrophen

Jean Baptiste de Lamarck (1809)

- Erste Abstammungstheorie vererbbare Veränderungen

Charles R. Darwin (1859)
"On the Origin of Species by Means of Natural Selection (Die Entstehung der Arten durch natürliche Zuchtwahl)"

Beobachtungen

- Es gibt einen Überschuss an Individuen
- Lebewesen sind nicht identisch

➔ Ein großer Teil der Lebewesen stirbt ohne Nachkommen

➔ Es gibt einen Selektionsdruck

Individuen, die mit den Lebensbedingungen gut zurechtkommen, haben eine größere Überlebenschance und erzeugen mehr Nachkommen.

DNA: Deoxyribonucleic acid

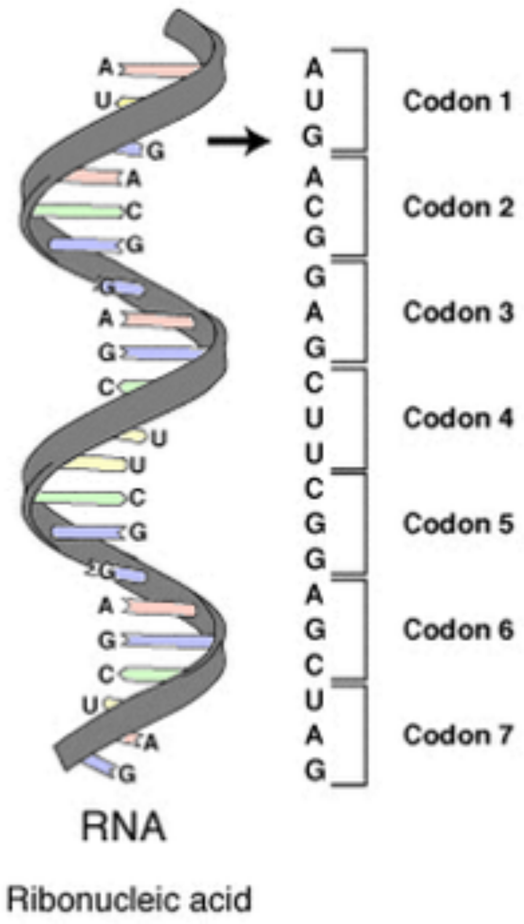

Helix mit Sequenzen der 4 Basen:

Adenin (A), Guanin (G),
Cytosil (C), Thymin (T)/Urazil (U)

Jeweils 3 Basen zusammen beschreiben ein Codon (64 Worte, alle außer 3 beschreiben eine Aminosäure)

Aminosäuren bilden die Bausteine für die Proteine (Eiweiße) zusammensetzen.

Evolutionsfaktoren

- Natürliche Selektion
- Veränderung
  - Mutation: Austauschen von Basen (z. B. durch UV-Licht)
  - Sexuelle Rekombination: Crossover von DNS-Teilen zwischen den Eltern

Allgemein:

- Veränderung + Selektion = Evolution

NOKIA
Connecting People

Know our past. Create the future...

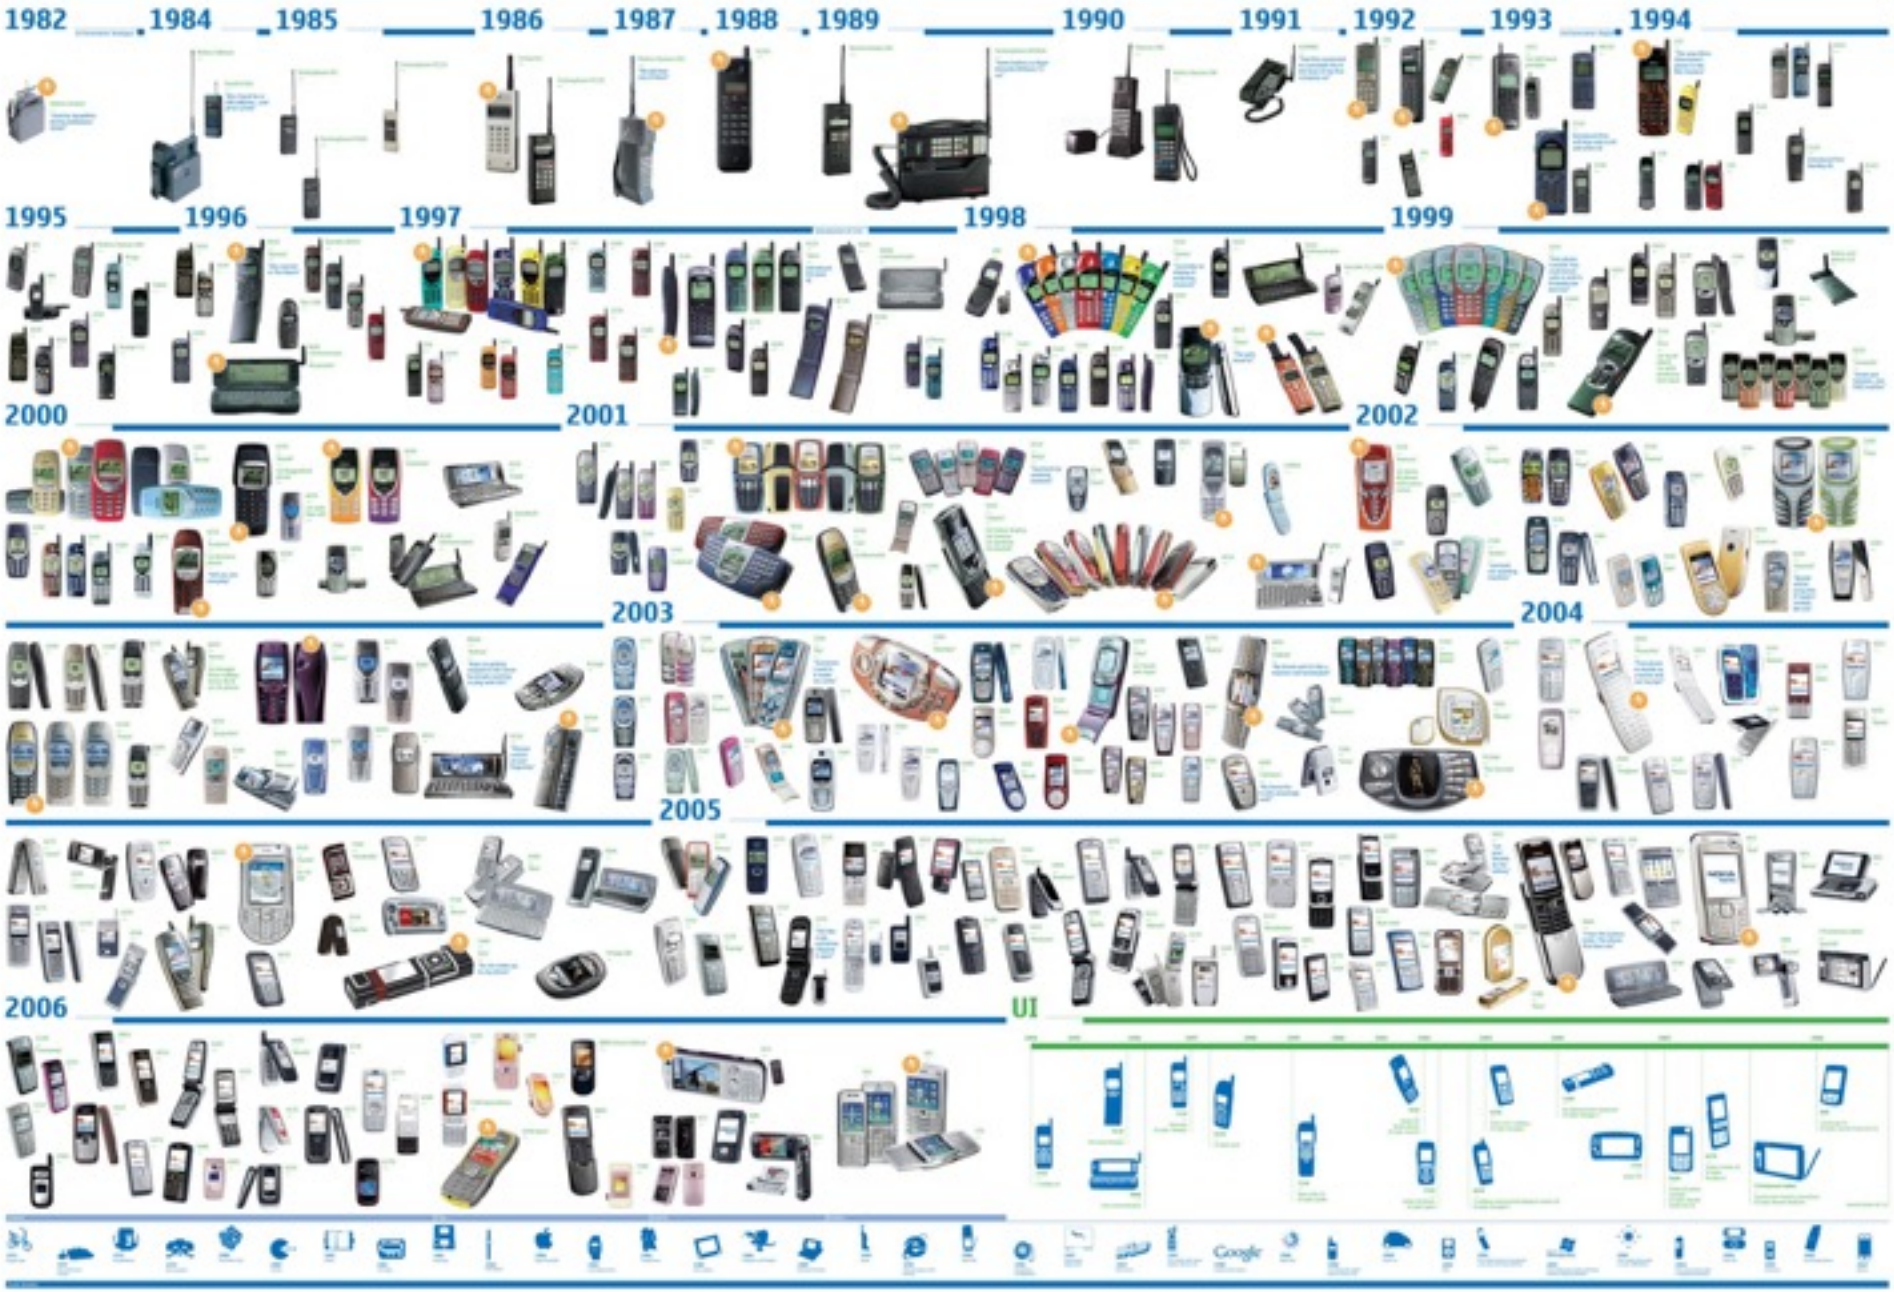

Andere Formen von Evolution

- Lebewesen und Arten
- Technische Produkte (z. B. Computer, Autos)
- Mode und Geschmäcker (z. B. Musik, Kleidung, etc.)
- Verhaltensweisen (z. B. Familie vs. Karriere)
- Standards (z. B. JAVA, USB, …)
- Unternehmen
- …

➔ alle Systeme, die die Evolutionsfaktoren erfüllen

Biologische versus künstliche Evolution

Biologisch	Künstlich	Beispiel TSP
Lebewesen	Lösungsversuch	
Gen/Eigenschaft	Teilelement der Lösung	
Leben eines Lebewesens	Simulation und Bewertung eines Lösungsversuchs	
Mutation oder Rekombination von Genen	Mutation oder Rekombination der Elemente in einer Lösung	

Biologische versus künstliche Evolution

Biologisch	Künstlich	Beispiel TSP
Lebewesen	Lösungsversuch	Eine Rundreise
Gen/Eigenschaft	Teilelement der Lösung	Ort X als 2. Stopp besuchen
Leben eines Lebewesens	Simulation und Bewertung eines Lösungsversuchs	Berechnen der Gesamtlänge der Rundreise
Mutation oder Rekombination von Genen	Mutation oder Rekombination der Elemente in einer Lösung	Vertauschen der Reihenfolge der Orte

Prozess: Simulierte Evolution

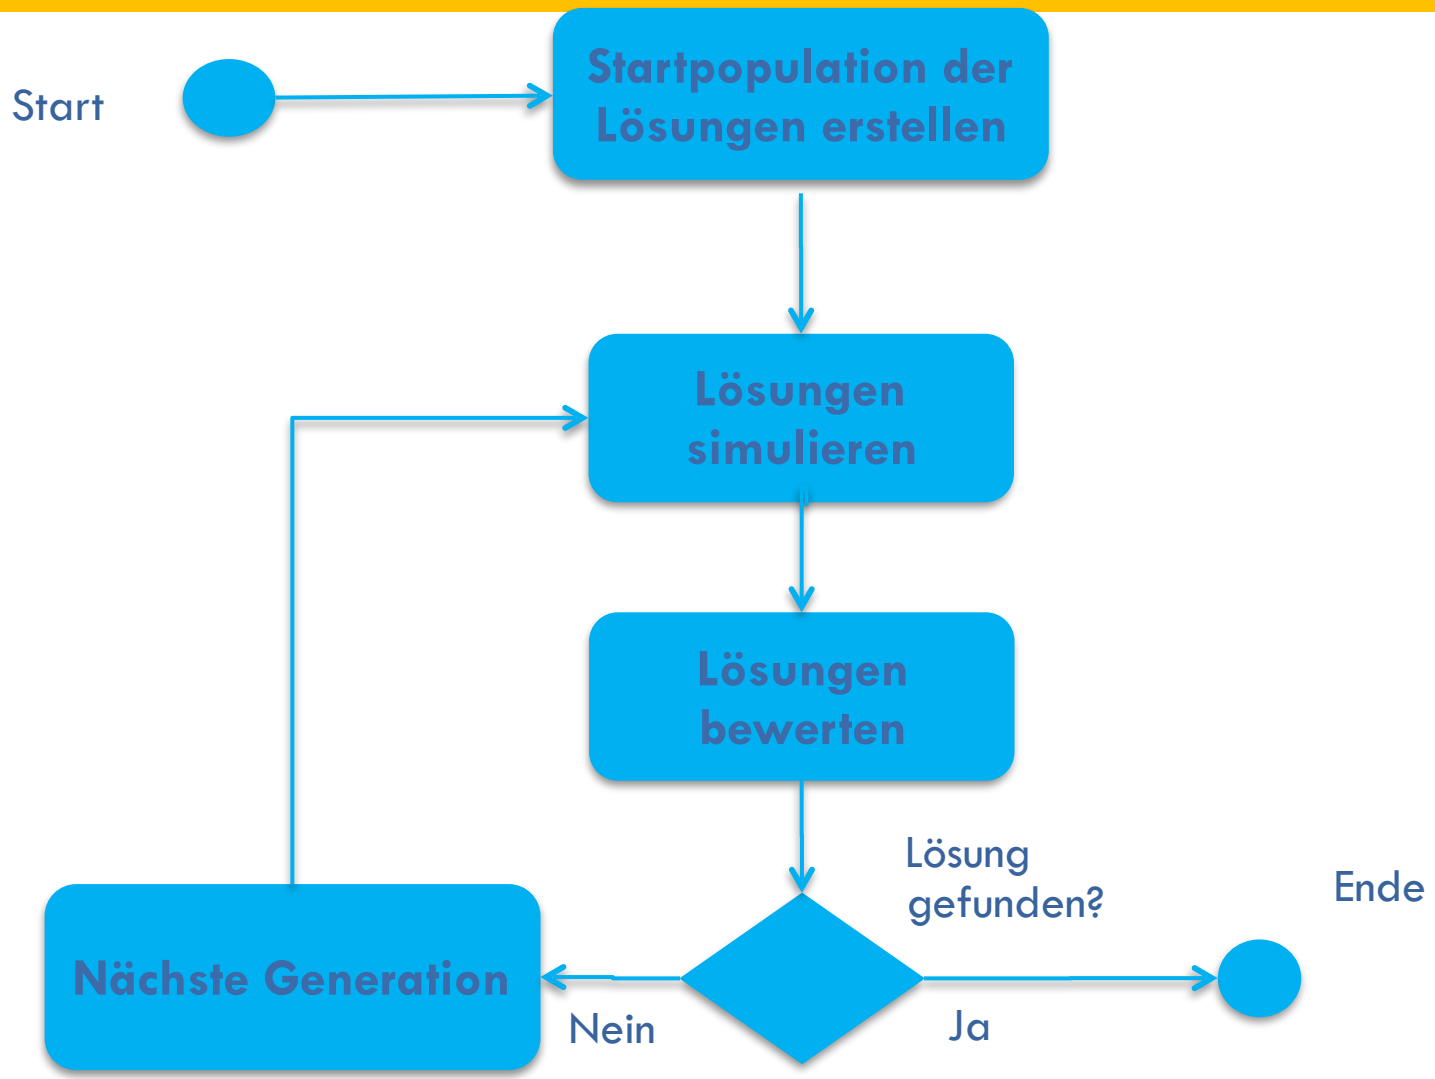

Veränderungen des Erbgutes

- Grundsätzlich zerstörerisch …
- … aber bringt Neues in die Population ein

Typen genetischer Operationen:

- Kopieren eines Lösungsversuchs
- Kombinieren von 2 Lösungsversuchen
- …

Mutation

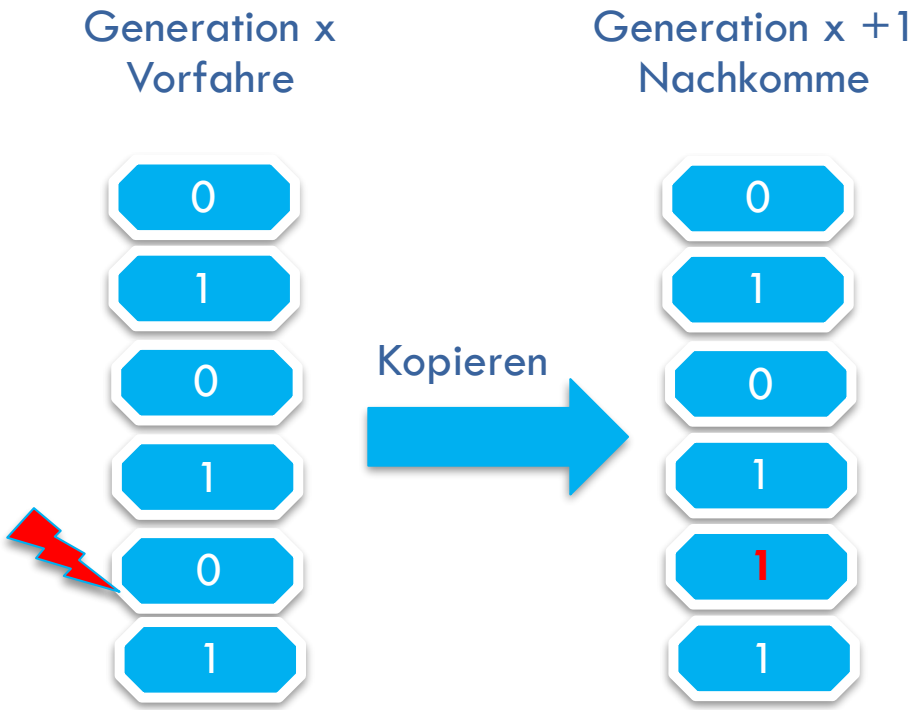

- An einer zufälligen Stelle im Erbgut wird ein Gen auf einen anderen Wert (Allel) verändert.

Inversion

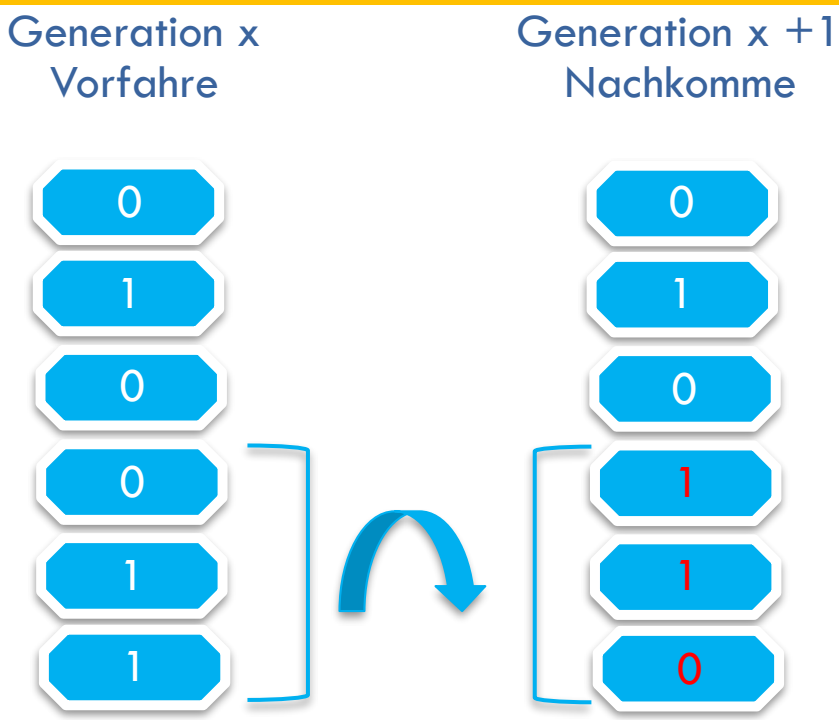

- Die Reihenfolge von Teilen des Erbgutes verändert sich.

Rekombination

- Zwei Lösungsversuche paaren sich
- Schnelles Verbreiten guter Lösungen oder Teillösungen in der Population
- Grundsätzlich zerstörerische Wirkung
- Gegensatz: Neue Lösungsansätze zulassen vs. schnelle Konvergenz auf eine Lösungsidee

Rekombination und Cross-Over

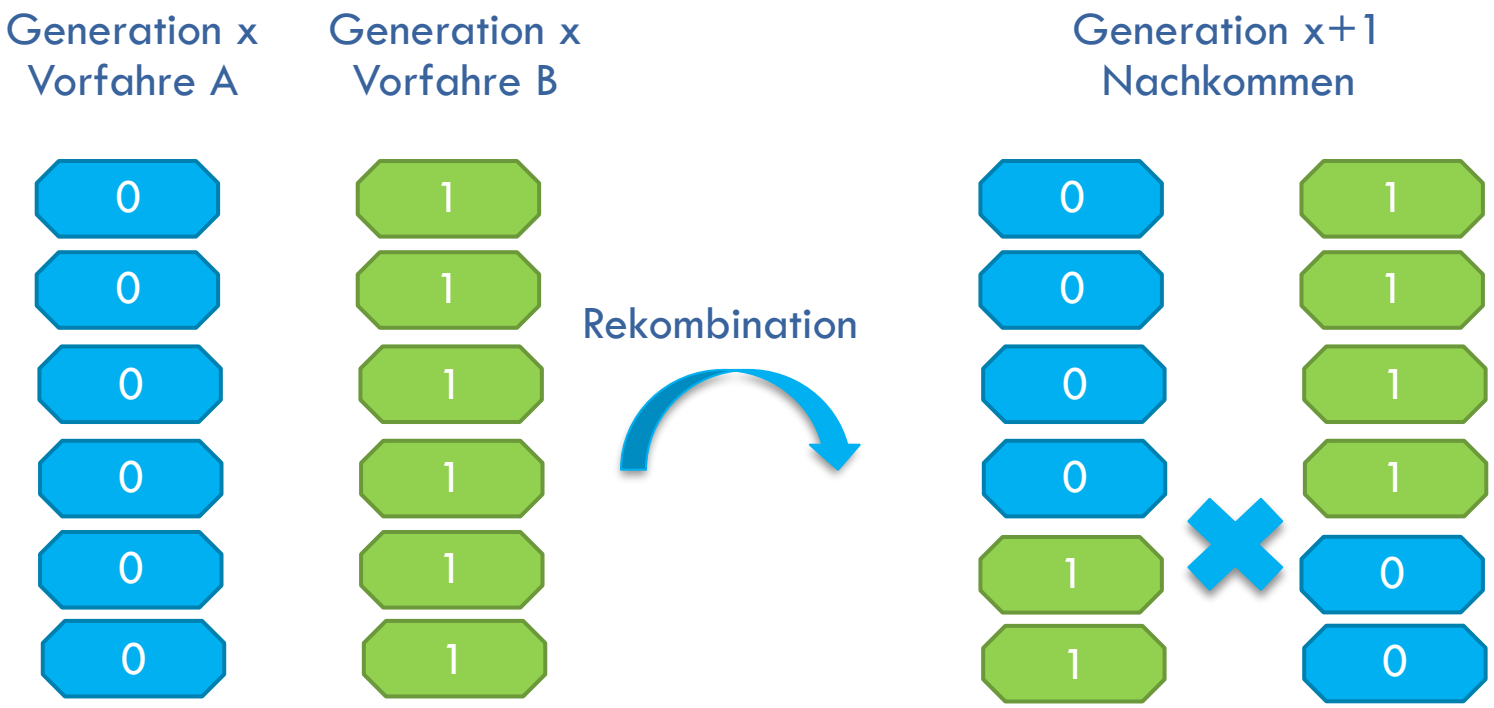

Zielfunktion für die Bewertung der Lösungsversuche

- Abbildung des Lösungsversuches auf eine Zahl
- Je höher die Zahl, desto besser ist der Lösungsversuch
- Sollte möglichst einfach sein

Simulierte Evolution anwenden

1. Abbildung der Gene für die Lösungen
2. Definieren der Bewertungsfunktion
3. Definieren der genetischen Operatoren
4. Selektion von guten Lösungen
5. Implementieren des Ablaufs

JGAP

- Framework für die Implementierung von Optimierungen mit Hilfe von simulierter Evolution
- Java und Open Source
- Link: http://jgap.sourceforge.net/

- Aufgaben
  - Bildet den grundlegenden Algorithmus ab
  - Datenstrukturen für die Abbildung von Genen mit unterschiedlichen Datentypen
  - Bildet die genetischen Operatoren ab (Mutation, Rekombination, …)
  - Interface für Bewertungsfunktion

Beispiel: Welche Wörter sind hier versteckt?

```
STIFTUER
TISCHUND
URBTHFAM
NAEIAESI
DDAGSLEN
EIMEEDLU
IOELEN_T
S_RKATZE
```

Lösung: Alle versteckten Worte

FELD x:5 y:2 vertikal
REGEN x:1 y:2 diagonal
BEAMER x:2 y:2 vertikal
TISCH x:0 y:1 horizontal
MINUTE x:7 y:2 vertikal
KATZE x:3 y:7 horizontal
HASE x:4 y:2 vertikal
STALL x:2 y:1 diagonal
IGEL x:3 y:3 vertikal

TUER x:4 y:0 horizontal
HUND x:4 y:1 horizontal
STIFT x:0 y:0 horizontal
SEE x:4 y:4 vertikal
NASE x:6 y:1 vertikal
EIS x:0 y:5 vertikal
STUNDE x:0 y:0 vertikal
RADIO x:1 y:2 vertikal

Aufgaben-Generator Buchstabenmatrix

- Erstellen einer Buchstabenmatrix, in der Wörter versteckt sind

- Ziele
  - Möglichst viele Worte verstecken
  - Worte können senkrecht, waagerecht und diagonal verlaufen
  - Worte dürfen sich überlagern und die gleichen Buchstaben nutzen
  - Kein Wort darf über den Rand hinaus gehen

```
STIFTUER
TISCHUND
URBTHFAM
NAEIAESI
DDAGSLEN
EIMEEDLU
IOELEN_T
S_RKATZE
```

Abbildung der Buchstabenmatrix
Klasse: Feld.java

```
public void reset()

public void putWord( String word, int
x, int y, DirectionEnum direction )

public boolean isWordUsed( String word)

public int getWordCount()

public int getViolations()

public int getLetters()

public int getMehrfach()
```

Buchstabenmatrix: Abbildung der Gene

- Insgesamt: 15 bis 25 Worte sollen versteckt werden
- In einer 8 mal 8 Buchstaben-Matrix

Position 1	Position 2	Position 3	Position 4
Wortindex: (0..20)	Position X: (0..7)	Position Y: (0..7)	Richtung: Horizontal (0), Vertikal (1), Diagonal (2)

Abbildung der Gene

```
Gene[] sampleGenes = new Gene[ MAX_GENES * ELEMENTS_PER_GENE ];
for (int i = 0; i <  MAX_GENES * ELEMENTS_PER_GENE;
        i = i +ELEMENTS_PER_GENE)
{
  sampleGenes[i]  =new IntegerGene(conf, 0, WORDS.length-1 );
  sampleGenes[i+1]=new IntegerGene(conf, 0, Field.MAX_WIDTH-1 );
  sampleGenes[i+2]=new IntegerGene(conf, 0, Field.MAX_HEIGHT-1 );
  sampleGenes[i+3]=new IntegerGene(conf,
1,DirectionEnum.values().length);
}
IChromosome sampleChromosome = new Chromosome(conf, sampleGenes);
conf.setSampleChromosome(sampleChromosome);
```

Fitnessfunktion – Höher, schneller, weiter

- Besser:
  - Mehr Worte
  - Mehr Buchstaben
  - Buchstaben werden mehrfach benutzt
- Fehler:
  - Wort steht über den Rand der Matrix hinaus
  - Wort überschreiben vorhanden Buchstaben

Fitnessfunktion

```
protected double evaluate(IChromosome a_subject) {
Field field = new Field();
for (int i=0; i<a_subject.size(); i=i+Crossword.ELEMENTS_PER_GENE) {
      Integer wordPos = (Integer)a_subject.getGene(i).getAllele();
      Integer xpos = (Integer)a_subject.getGene(i+1).getAllele();
      Integer ypos = (Integer)a_subject.getGene(i+2).getAllele();
      Integer direction = (Integer)a_subject.getGene(i+3).getAllele();
      DirectionEnum d = DirectionEnum.values()[direction-1];

      String word = Crossword.WORDS[wordPos];
      field.putWord( word, xpos, ypos, d);
  }
  int violations = field.getViolations()+1;
  int letters = field.getLetters()+1;
  int mehrfach = field.getMehrfach()+1;
  int wordCount = field.getWordCount()+1;

  return ((letters*wordCount*mehrfach) / (violations*violations)) ;
}
```

Beispiel eines Optimierungslaufs

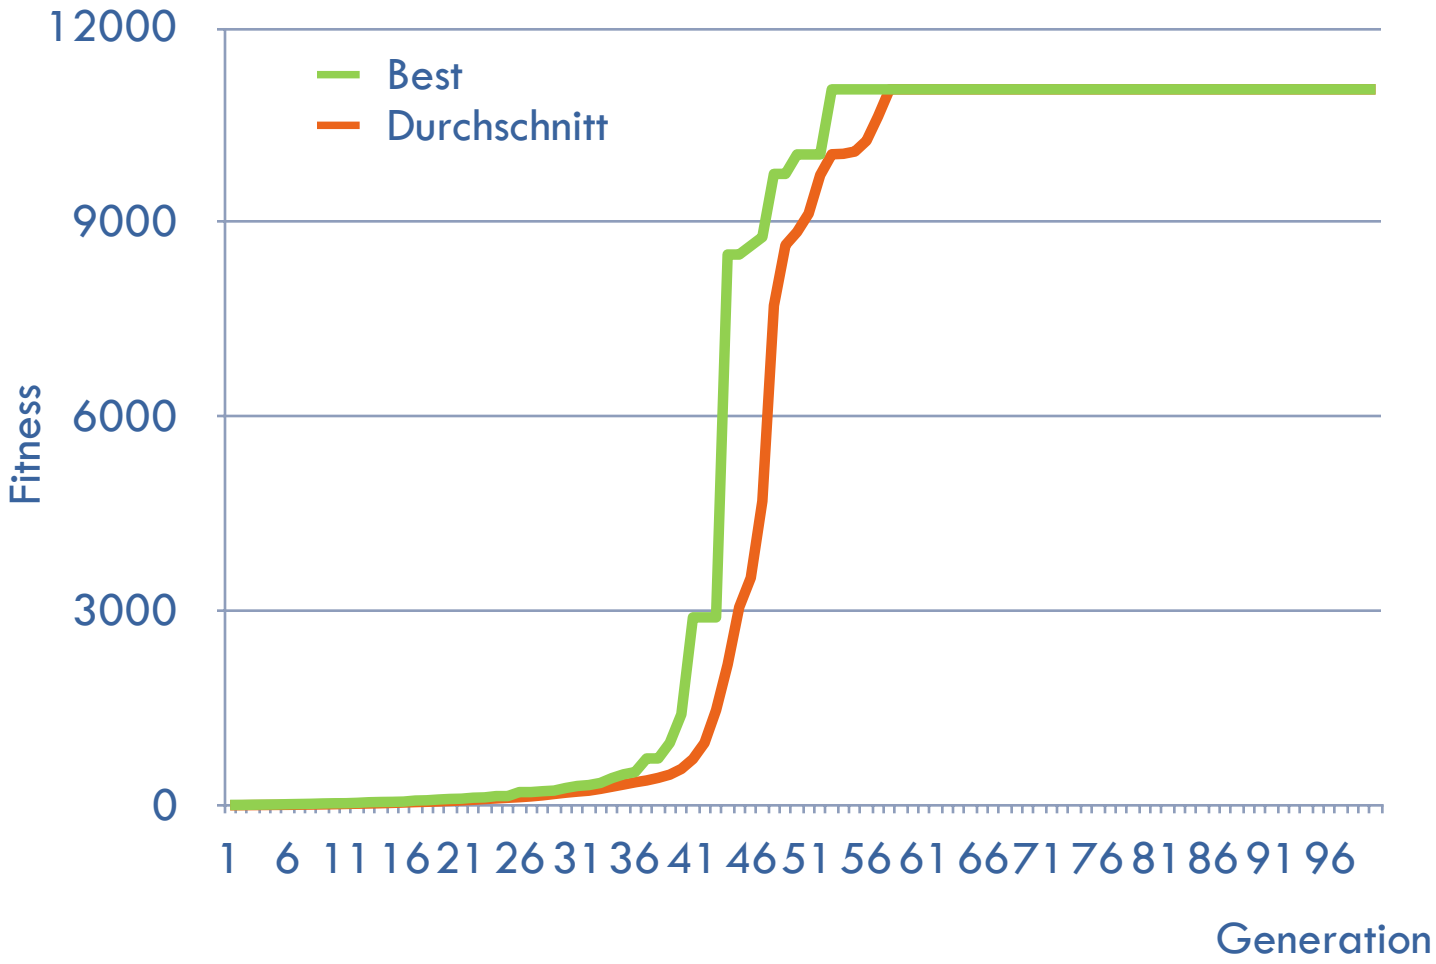

Betrachtungen des Suchraums

Mögliche Anzahl der Lösungen:

= (Ausprägungen der Gene) hoch (Anzahl Gene)

Rechnung für die Wortmatrix:

= (Anzahl Wort * Positionen x * Positionen y * Richtung) hoch (Anzahl Gene)

$= (20 * 8 * 8 * 3)^{20} = 3840^{20} = 4{,}86*10^{71}$

Ziel: Programme züchten

- Geht das?

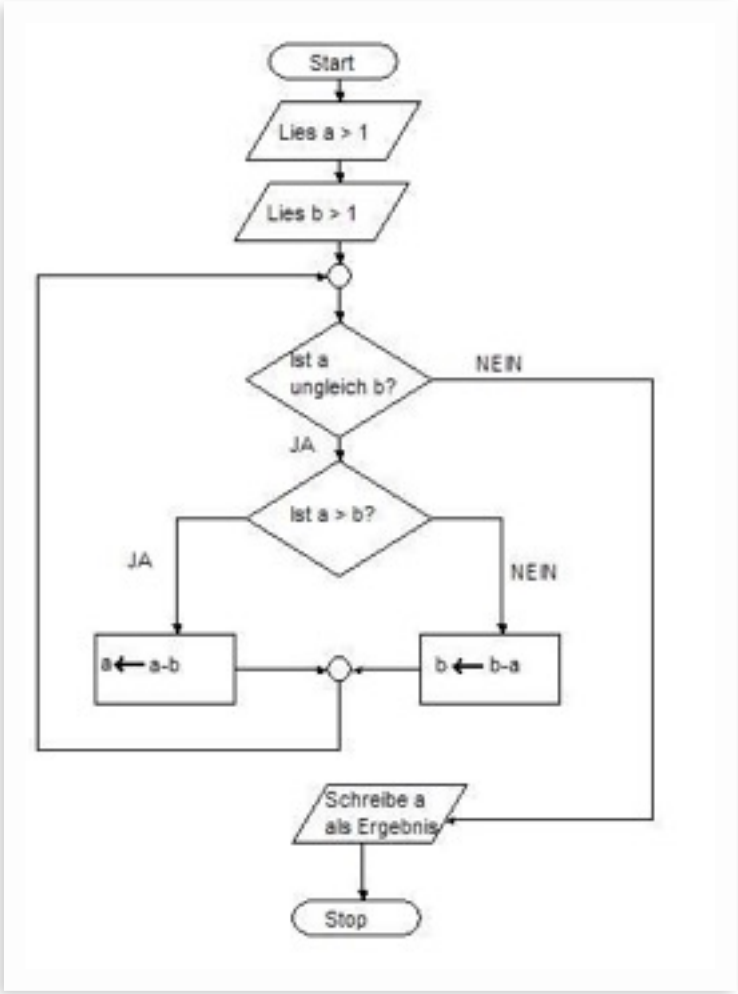

Beispiel: Programme züchten

- Aufgabe:
  - Ein Roboter soll alle Zelle eines Feldes markieren.
  - Das Feld besteht aus 9 mal 9 Zellen.
  - Manche Zellen enthalten Hindernisse.
  - Der Roboter hat einen Speicher für 30 Befehle.

Befehle

Befehl	Bemerkung
Move <links, rechts, hoch, runter>	Bewegen um eine Zelle
Set	Markiert die aktuelle Zelle
Nop	„No Operation“
Goto <Speicherplatz>	Ausführung wird mit dem Befehl an <Speicherplatz> fortgesetzt.
If <links, rechts, hoch, runter> = <frei, markiert, Wand> **Goto <Speicherplatz>**	Bedingter Sprung, wenn das untersuchte Feld im abgefragten Zustand ist.

Abbildung Gene

Befehle werden als 4 Integer-Werte abgelegt:

Nicht benötigte Parameter werden ignoriert.

Beispiel:

- Goto-Befehlscode + 1. Parameter mit Zieladresse

Fitnessfunktion

Fitnessfunktion

Priorität 1: „Löse die Aufgabe“

- Alle Felder markieren (Fitness zwischen 0 und 100) entspricht dem Prozentsatz markierter Felder.
- Effizienz spielt keine Rolle.

…

Fitnessfunktion

Priorität 1: „Löse die Aufgabe“

- Alle Felder markieren (Fitness zwischen 0 und 100) entspricht dem Prozentsatz markierter Felder.
- Effizienz spielt keine Rolle.

Priorität 2: „Lösen die Aufgabe gut“

- Jede Befehlsausführung kostet Energie. Ein neu markiertes Feld bringt etwas Energie.
- Je mehr Energie nach dem Markieren aller Zellen übrig ist desto effizienter ist der Algorithmus.
- Fitness = 100 + überschüssige Energie nach dem markieren aller Felder

Fitnessfunktion

```
public float calcFitness()
{
  float anzleer= feld.getNumberWithEntry(Feld.leer);
  float anzbelegt= feld.getNumberWithEntry(Feld.belegt);

  if (feld.aktFelderMarked >= (feld.MaxFelderToMark))
  {
    if (aktEnergie < 0) {
      return 100;
    } else {
      return ((100 + (aktEnergie)));
    }
  } else {
    return ((anzbelegt * 100) / (anzleer + anzbelegt));
  }
}
```

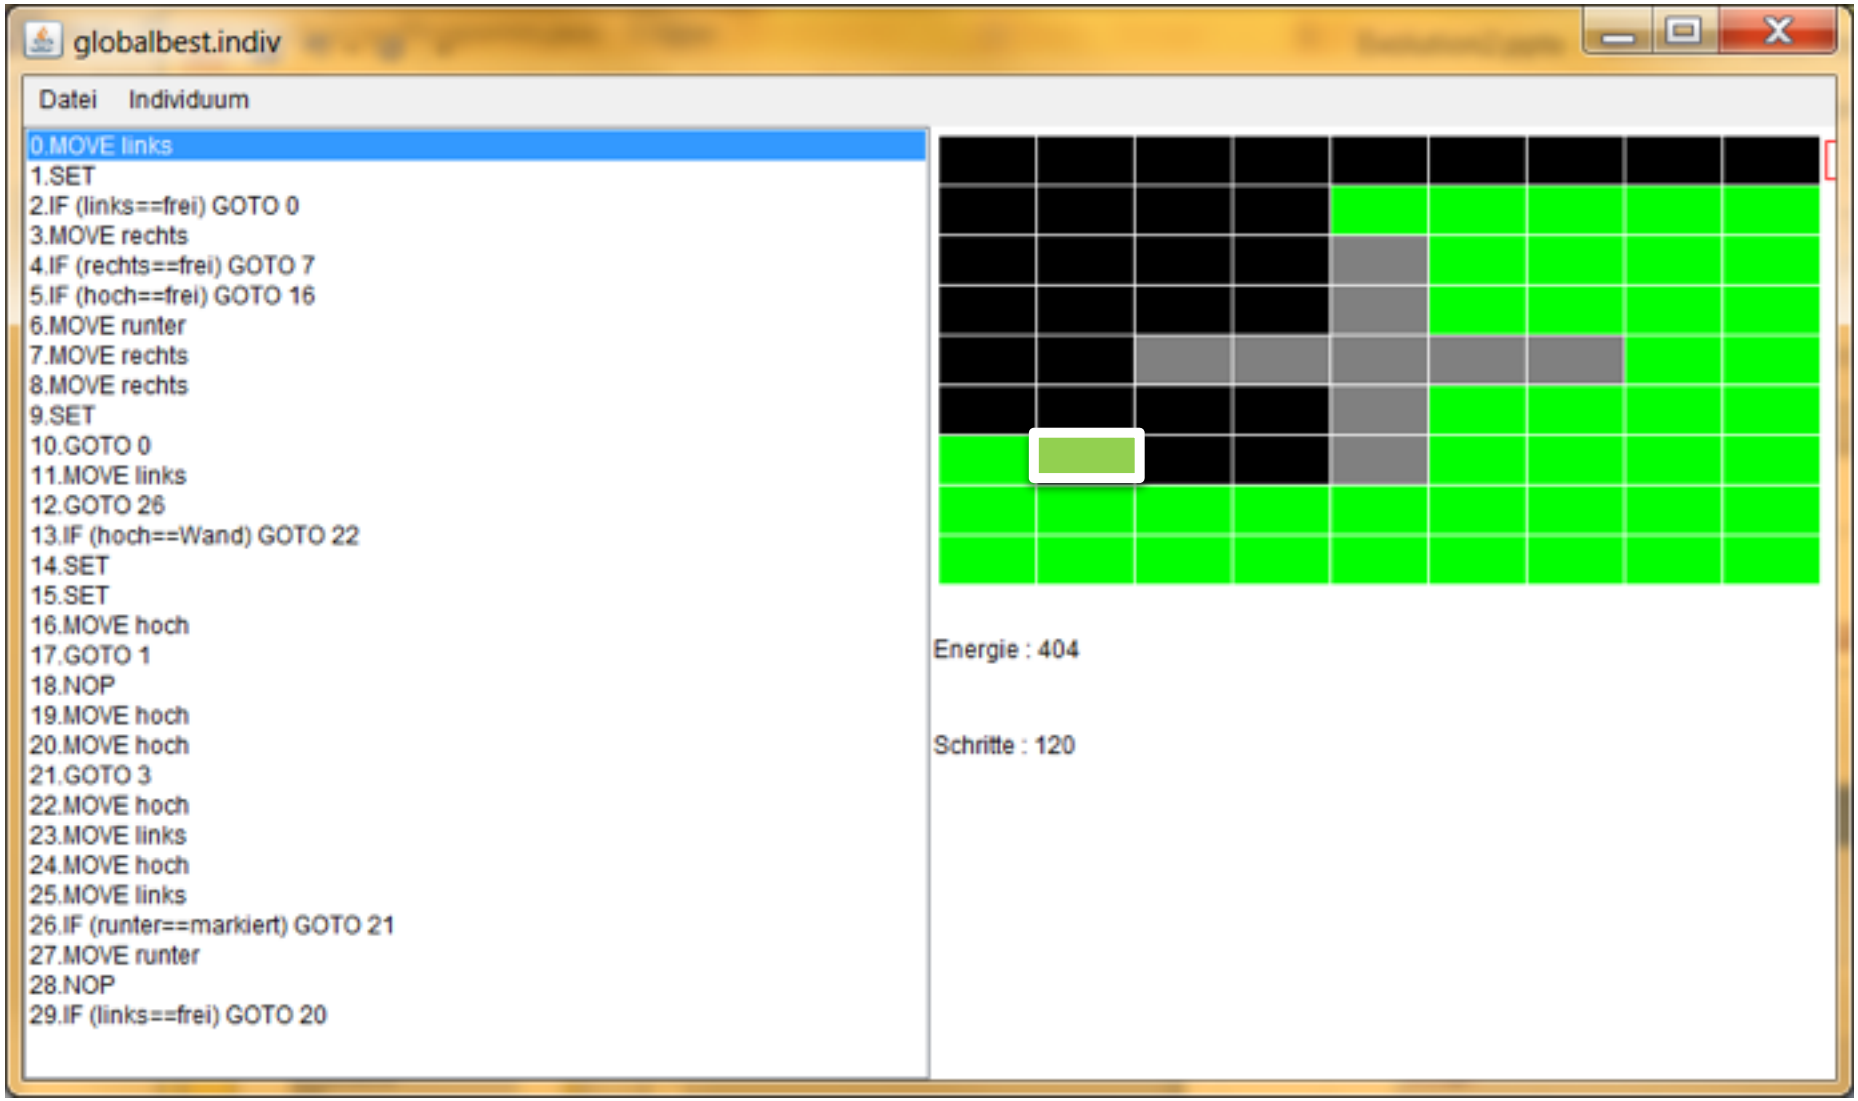
globalbest.indiv
Datei
Individuum
0.MOVE links
1.SET
2.IF (links==frei) GOTO 0
3.MOVE rechts
4.IF (rechts==frei) GOTO 7
5.IF (hoch==frei) GOTO 16
6.MOVE runter
7.MOVE rechts
8.MOVE rechts
9.SET
10.GOTO 0
11.MOVE links
12.GOTO 26
13.IF (hoch==Wand) GOTO 22
14.SET
15.SET
16.MOVE hoch
17.GOTO 1
18.NOP
19.MOVE hoch
20.MOVE hoch
21.GOTO 3
22.MOVE hoch
23.MOVE links
24.MOVE hoch
25.MOVE links
26.IF (runter==markiert) GOTO 21
27.MOVE runter
28.NOP
29.IF (links==frei) GOTO 20
Energie : 404
Schritte : 120

Typischer Verlauf der Fitness

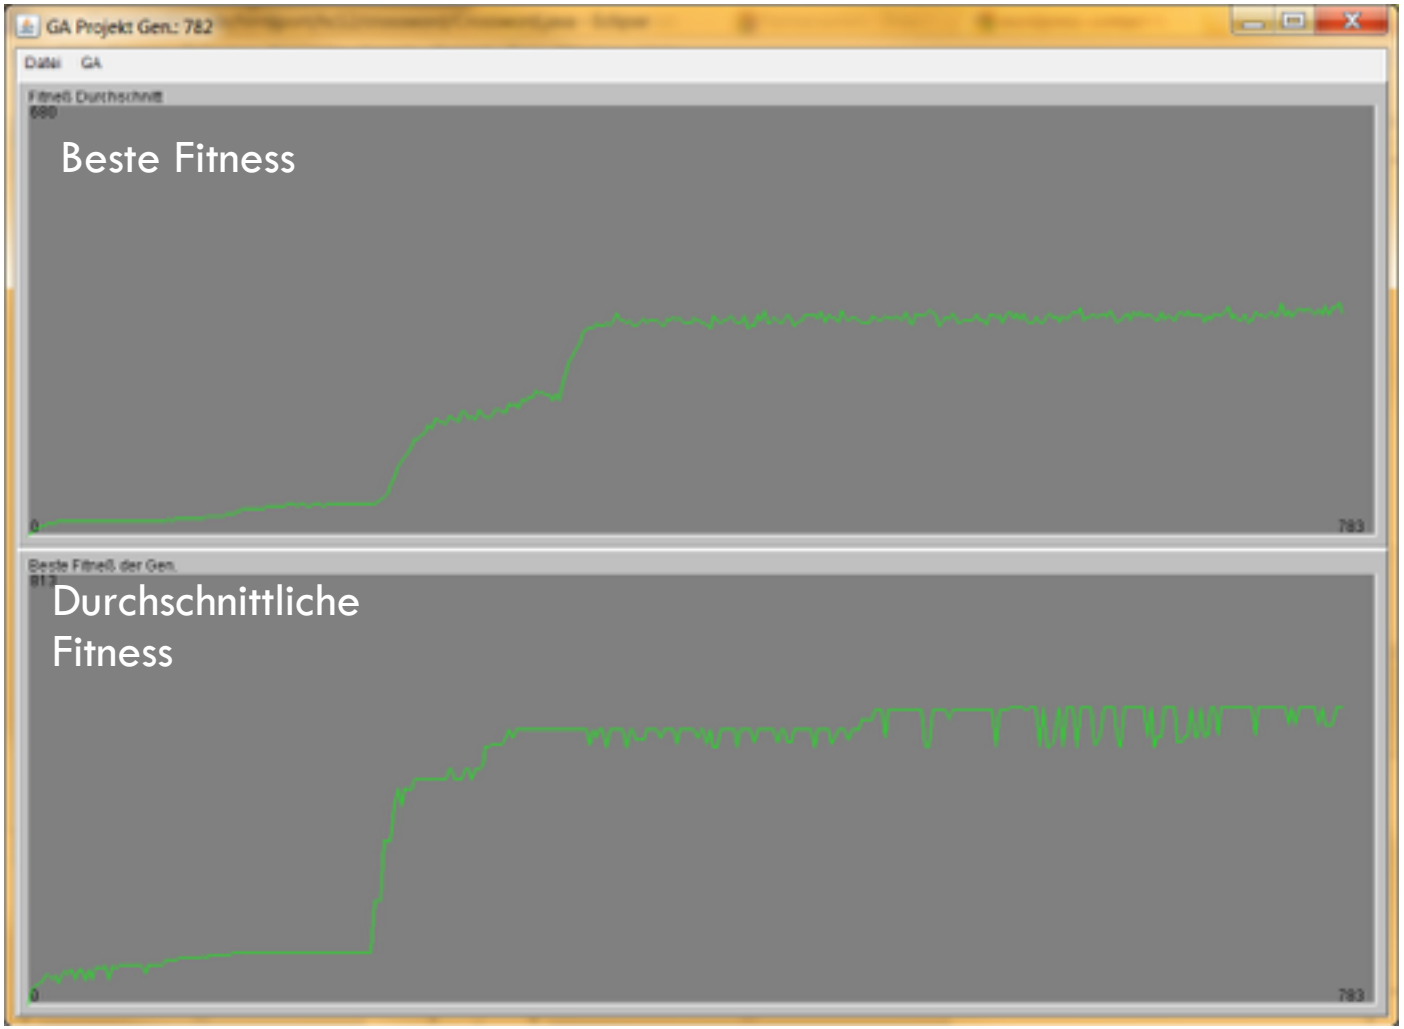

Berechnung des Lösungsraums

- Mögliche Lösungen: $396^{30} = 8{,}5*10^{77}$

Befehl	Anzahl der Ausprägungen
Move <links, rechts, hoch, runter>	4
Set	1
Nop	1
Goto <Speicherplatz>	30
If <links, rechts, hoch, runter> = <frei, markiert, Wand> Goto <Speicherplatz>	4*3*30 = 360

Parameter und ihre Auswirkungen 1

- Populationsgröße
  - Sinnvolle Werte: 40-500 Individuen
  - In einer großen Population kann sich eine nur leichte Verbesserung evtl. nicht durchsetzen und geht in der Menge unter.

- Rekombinationsrate
  - Hohe Rate: Prozess konvergiert sehr schnell.
  - Niedrige Rate: Gute Individuen (insbesondere nur leichte Verbesserungen) setzen sich evtl. nur langsam oder gar nicht durch

Parameter und ihre Auswirkungen 2

- Mutationsrate
  - Zu hoch bedeutet zu viel Zerstörung
  - Zu niedrig bedeutet zu wenig Kreativität und Neues
  - Gute Ergebnisse: 1% bis 5% Mutationsrate pro Gen
  - Idee: Anpassen der Mutationsrate:
    - Beispiel: Lange Phasen der Stagnation führen zum Ansteigen der Mutationsrate

Vorteile der Simulierten Evolution

- Grundlegende Prozess ist einfach
  - Generisch implementierbar
- Es ist kaum Wissen über einen Lösungsweg notwendig
  - Es reicht aus Lösungen zu simulieren und zu bewerten
- Ist für komplexe Probleme geeignet
- Gut parallelisierbar

VIELEN DANK!

Heiko Spindler

Freiberuflicher IT-Berater

Mail: hs@heikospindler.de

Mobil: 0162 432 56 90