Anwendung evolutionärer Algorithmen

Vorlesung 14:
Dynamische Umgebungen

Karsten Weicker
Universität Stuttgart
Institut für Informatik, Abteilung Formale Konzepte
Breitwiesenstr. 20–22, 70565 Stuttgart
E-Mail: Karsten.Weicker@informatik.uni-stuttgart.de

Dynamik und ihre Anforderungen

Arten von Dynamik:

- periodische und unperiodische Dynamik
- Transformation des Fitneßgebirges oder komplett neue Hügel in der Landschaft
- langsame, rasche und abrupte Veränderungen

Anforderungen:

- Finden eines Optimums trotz sich verändernder Fitneßlandschaft
- Verfolgung eines Optimums
- Finden eines neuen besseren Optimums

Probleme

- Optimierung im Dynamischen bedeutet eine Erhaltung der Anpassungsfähigkeit
- gewöhnliche EA konvergieren und verlieren damit ihre Anpassungsfähigkeit
  - problematisch insbesondere bei Verfolgung vorhandener und Auffindung neuer Optima
- andere Anforderungen werden an die Auswertung von und Erzeugung neuer Individuen gestellt
  - insbesondere beim Problem des Auffindens eines Optimums
  - bisher kaum untersucht

Ansätze

Reaktiv:

- Einsatz eines Standard-EA
- bei Änderungen in der Umgebung werden explizite Aktionen vorgenommen
- z.B. Erhöhung der Diversität, um ein neues Optimum zu finden

Erhalt der Adaptivität:

- Konvergenz wird grundsätzlich vermieden

Erinnerungsvermögen:

- zusätzlicher Speicher wird eingeführt, um gute frühere Lösungen zu behalten
- gut z.B. bei periodischen Veränderungen

Reaktiv: Hypermutation

Vorbild:

- einige biologische Zellen reagieren auf Streß durch Umweltbedingungen mit einer höheren Mutationsrate

Idee:

- durchschnittliche Performance wird beobachtet
- Falls diese abfällt: Mutationsrate wird hochgesetzt
- Ansteigend oder Stabil: geringe Mutationsrate
- Erhalt der Diversität

Ergebnisse:

- gute Ergebnisse in statischen und dynamischen Systemen (mit geringem Grad an Dynamik)

Reaktiv: Variable Local Search

Idee:

- ebenfalls die durchschnittliche Performance wird beobachtet
- falls diese abfällt tritt ein lokaler Tracking-Operator in Kraft

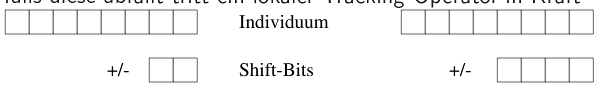

Ergebnisse:

- bessere Anpassung als Hypermutation da gradueller
- Anwendung auf zwei Industrieprojekte, bei denen optimale Kontrollparameter sich aufgrund von Variationen in den Arbeitsbedingungen verschieben.

Erhalt: Random Immigrants

Idee:

- Kritik an Hypermutation: sie wird nur bei beobachteter Verschlechterung angewandt – oft aber gleichbleibend schlecht, weil das Optimum nicht gefunden wird
- in einem Standard-GA wird nach der Erzeugung der Individuen durch Crossover und Mutation ein Hypermutation-Schritt eingeführt
- es wird ein Prozentsatz der Individuen durch völlig zufällige, neue Individuen ersetzt

Ergebnisse:

- auf bestimmten Testfunktionen wesentlich besser als Standard-GA und Hypermutation
- gute Ergebnisse mit 30

Kritik:

- schwierig auszubalancieren
- neue Individuen können sich oft nur schwer etablieren

Erhalt: Sharing und Niching

Idee:

- *Multi-Niche Crowding GA* soll implizit
  - Diversität erhalten
  - neue Gebiete erkunden unter Erhalt der gefundenen guten Lösungen
- Zwei Modifikationen des GA:
  - *Crowding Selektion* der Eltern: ein Elter wird zufällig gewählt, sein Partner als der phänotypisch ähnlichste aus einer zufällig gezogenen Gruppe an Individuen
  - *Worst among most similar replacement*: iterativ werden die neuen Individuen zugefügt. Die Individuen der alten Population werden gruppiert, in jeder Gruppe wird ein ähnlichstes Individuum zum neuen Individuum identifiziert, dasjenige mit der schlechtesten Fitneß wird ersetzt.

Ergebnisse:

- vielversprechende erste Ergebnisse
- neu entstehende Nischen werden sofort besetzt

Thermodynamischer GA

Vorbild:

- ähnlich wie bei SA: Minimierung der freien Energie $\langle E \rangle - HT$

Idee:

- Modifikation der Selektion: iterative Auswahl
- Auswahl von Individuum i (für Minimierung): Individuum I' mit minimalem $\bar{fit}(I_1, \ldots, I_{i-1}, I') - T \sum_{k=1}^{M} H_k(I_1, \ldots, I_{i-1}, I')$
- H_k mißt die Verschiedenheit des Gens k in den Individuen $H_k(I_1, \ldots, I_i) \;=\; -\left(\frac{num1}{i} \log \frac{num1}{i} + \frac{num0}{i} \log \frac{num0}{i}\right)$

Ergebnisse:

- Balance zwischen Minimierung der Fitneß und Erhalt der Diversität ist schwierig
- Möglichkeit: Anpassung der Temperatur T

Erinnerung: Diploidität

Vorbild:

- Natur erhält die Anpassungsfähigkeit durch einen doppelten Chromosomensatz
- rezessive Merkmale werden zwar weitervererbt, kommen evtl. allerdings erst wieder bei einer Veränderung der Umwelt zu einem positiven Einsatz

Idee:

- zusätzlich zu 0 und 1 wird eine rezessive 1 (i) eingeführt:

	0	i	1
0	0	0	1
i	0	1	1
1	1	1	1

- häufigeres Vorkommen von 1 wird durch eine Mutation ausgeglichen, mit $\Pr[0] = 0.5$, $\Pr[i] = 0.25$ und $\Pr[1] = 0.25$.

Ergebnisse:

- Vergleich zu einem haploiden Standard-GA
- bessere Ergebnisse bezüglich eines zyklischen Rucksackproblems (Zyklus: 15 Generationen)

Erinnerung: Diploidität

Kritik:

- haploider GA ist nach jeweils 15 Generationen konvergiert während der diploide noch Individuen unterschiedlicher Fitneß enthält
  $\Rightarrow$ diploider GA kann sich leichter auf Neuerungen nach 15 Generationen einstellen, haploider braucht lange die verlorene Information wieder zu finden
- bei größeren Zykluszeiten ist der haploide überlegen

Verbesserungen:

- rezessive 0 (o) und 1 (i):

	0	o	1	i
0	00	00	1o/0i	0i
o	00	oo	0i	1o/0i
1	1o/0i	1o	11	11
i	0i	10/0i	11	ii

- bei einem drastischen Abfall der Fitneß eines Individuums (um $\geq 20\%$), werden die Dominanzwerte für alle Allele invertiert
  $11 \rightarrow ii$, $OO \rightarrow oo$, $1o \rightarrow 0i$, etc.

Erinnerung: Bewertung von Diploidität

- Diploidität mit einem rezessiven Gen:
  - scheint vor allem die Diversität größer zu halten
- Diploidität mit zwei rezessiven Genen:
  - Diversität kann noch besser erhalten werden
  - Dominanzwechselmechanismus kann die diploide Information nutzen
  - kann sehr gut zwischen oszillierenden Optima hin und her wechseln
  - allerdings können so nur zwei verschiedene Lösungen gemerkt werden
- Mehr als zwei Lösungen: Rucksackproblem mit zufälligen neuen Zielfunktionen
  - hier versagt die Diploidität mit zwei rezessiven Genen
  - sowohl haploider wie einfach diploider GA sind besser

Erinnerung: Fallbasierte Initialisierung

Idee:

- früheres Wissen wird in einer Datenbank abgelegt und kann bei der Initialisierung der Population bei ähnlichen Umständen wieder herangezogen werden
- wenn Veränderungen werden detektiert und dann der GA neu gestartet
- Initialisierung der Population:
  - 50% beste Lösungen unter ähnlichen Bedingungen aus Datenbank
  - 25% aus vorheriger Population
  - 12.5% gute bekannte Standardindividuen
  - 12.5% Individuen mit eher zufälligem Verhalten

Ergebnisse:

- erfolgreich angewandt für Verfolgungsstrategien in einer einfachen Umgebung
- GA arbeitet auf einem Simulationsmodell
- Umweltveränderungen müssen meßbar und unterscheidbar sein

Selbstanpassende Operatoren

- sich drehende Spirale
- Aufgabe: Auffinden des Optimiums
- Methode: Evolustionsstrategie
- Adaption:
  - uniform
  - separate
  - Kovarianzmatrix
  - Ringmutation

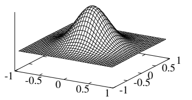

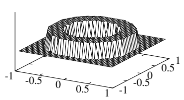

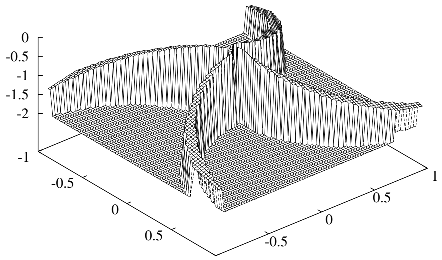

Selbstanpassende Operatoren

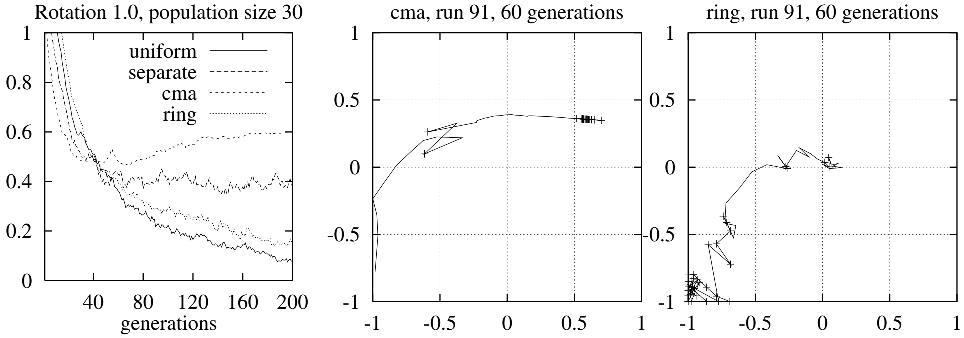

- Vermutung: andere Mutationsprinzipien bei dynamischen Problemen
- Andere Ergebnisse: Selbstadaptive Verfahren lassen sich leichter in die Irre führen als adaptive