

# Ein genetischer Algorithmus zur Proteinfaltung mit spezialisierten Operatoren

Michael Wachter  
25. Februar 2005

# Inhalt

## Einleitung

### Ein GA für die Proteinfaltung

- Repräsentation des Proteins

- Fitness-Funktion

- Variationsoperatoren

- Ergebnisse

### Verbesserung des GA

- Fitness-Funktion

- Neue Variationsoperatoren

- Ergebnisse

## Worum geht es bei der Proteinfaltung ?


- ▶ Primärstruktur des Proteins sagt nichts über die Anordnung im Raum.
- ▶ Funktion des Proteins ist abhängig von der Anordnung im Raum (Tertiärstruktur).
- ▶ Benutzung von evolutionären Algorithmen zur Bestimmung dieser Struktur.
- ▶ Ziel : Berechnen einer Struktur, die möglichst nahe an der natürlichen Struktur liegt.

Der Vortrag basiert auf Kapitel 8 „Application of Evolutionary Computation to Protein Folding“ von Steffen Schulze-Kremer aus dem Buch „Evolutionary Computation in Bioinformatics“

# Ein GA für die Proteinfaltung

- ▶ Verwendung eines genetischen Algorithmus zur Bestimmung der tertiären Struktur.
- ▶ Allerdings: keine Verwendung von Bitstrings, sondern Verwendung von realwertigen Zahlen.
- ▶ Vorteile :
  - ▶ Möglichkeit zur Verwendung anwendungsspezifischer Variationsoperatoren.
  - ▶ Einfach zu implementieren.
- ▶ Nachteile :
  - ▶ Mathematische Grundlage gilt streng genommen nur für Bitstrings.
  - ▶ Die Verwendung von Bitstrings ist schneller.
  - ▶ Die Zahlen müssen erst noch als Bitstrings codiert werden.

## Repräsentation des Proteins durch Torsionswinkel



**Abbildung:** Lysin mit den Winkeln  $\phi$ ,  $\psi$ , und  $\omega$  im Backbone und  $\lambda_1$ .. $\lambda_7$  im Rest.

# Fitness-Funktion

- ▶ Verwendung des Programms CHARMM zur Berechnung der Einzelenergien  $E_{bond}$ ,  $E_{phi}$ ,  $E_{tor}$ ,  $E_{impr}$ ,  $E_{vdW}$ ,  $E_{el}$ ,  $E_H$ ,  $E_{cphi}$
- ▶ Vernachlässigung der Energien  $E_{bond}$ ,  $E_{phi}$ ,  $E_{impr}$ , da sie beim Torsionswinkel-Ansatz konstant sind.
- ▶ Vernachlässigung der Energien  $E_H$  und  $E_{cphi}$  da das Protein im Vakuum betrachtet wird.
- ▶ Minimierung der Energie  $E_{ges} = E_{tor} + E_{vdW} + E_{el}$ .

## Bevorzugung kompakter Strukturen

Problem: Diese Fitness-Funktion führt nicht zu kompakten Strukturen.

- ▶ Einführung einer zusätzlichen Pseudo-Energie, die kleiner ist, je kugelförmiger die Struktur ist.

$$\text{erwarteter Durchmesser} = 8 \cdot \sqrt[3]{\text{Länge}}$$

$$E_{pe} = 4^{\text{aktueller Durchmesser} - \text{erwarteter Durchmesser}} \left[ \frac{\text{kcal}}{\text{mol}} \right]$$

- ▶ Verbesserte Energiefunktion:

$$E_{ges} = E_{tor} + E_{vdW} + E_{el} + E_{pe}$$

## Variationsoperatoren

- ▶ **MUTATE**  
Ein zufällig ausgewählter Torsionswinkel wird durch einen der 10 am häufigsten in der Natur vorkommenden ersetzt.
- ▶ **VARIATE**  
Ein Torsionswinkel wird mit einer gewissen Wahrscheinlichkeit um  $1^\circ$ ,  $5^\circ$  oder  $10^\circ$  verändert. Durch Parameter wird angegeben, wie hoch die Wahrscheinlichkeiten für diese Winkel sind und in welche Richtung diese gedreht werden.

# Variationsoperatoren

## ▶ CROSSOVER

Auswahl von 2 verschiedenen Crossover-Varianten mit gewissen Wahrscheinlichkeiten

- ▶ 2-Point Crossover - Die Torsionswinkel eines mehrere Residuen langen Teilstücks werden zwischen zwei Individuen vertauscht.
- ▶ Uniform Crossover - Es werden die Torsionswinkel zweier korrespondierender Residuen mit einer gewissen Wahrscheinlichkeit vertauscht.

## Parameter der Variationsoperatoren

- ▶ Alle Parameter ändern sich linear zwischen dem Beginn und dem Abbruch des Algorithmus nach 1000 Generationen.

Parameter	Wert Beginn	Wert Ende
MUTATE	80	20
VARIATE	20	70
VARIATE 10	60	0
VARIATE 5	30	20
VARIATE 1	10	80
CROSSOVER	70	10
CROSSOVER (uniform)	90	10
CROSSOVER (2-point)	10	90

# Selektion

- ▶ Population von 10 Eltern und 10 Nachkommen.
- ▶ Die 10 besten Individuen überleben.

## Ergebnisse

- ▶ Test des Algorithmus mit Crambin.
- ▶ Vorteil: Relativ kurz.
- ▶ Resultat: Keine auch nur annähernde Ähnlichkeit mit der natürlichen Struktur.  
Der Algorithmus hat hier komplett versagt.

## Gründe für das Versagen

Der Wert für  $E_{el}$  ist deutlich niedriger als der der natürlichen Struktur.

Ursachen:

- ▶ Elektrostatische Zusammenhänge tragen sehr viel mehr zur Stabilisierung bei
- ▶ Crambin hat 6 teilweise geladene Residuen, die im Experiment nicht neutralisiert wurden
- ▶ Minimierung der Gesamtenergie ist am einfachsten über das elektrische Potential  $E_{el}$  möglich.

⇒ Der Algorithmus hat die Fitness-Funktion gut optimiert, diese ist allerdings zur Lösung des Problems nicht geeignet.

## Verbesserung der Fitness-Funktion

- ▶ Verwendung eines Fitness-Vektors aus verschiedenen Fitness-Komponenten.
- ▶ Möglichkeit der Gewichtung einzelner Fitness-Komponenten um bei Experimenten deren Einfluss ändern zu können.

$$\text{Fitness} = \begin{pmatrix} r.m.s \\ E_{tor} \\ E_{vdW} \\ E_{el} \\ E_{pe} \\ polar \\ hydro \\ scatter \\ solvent \\ Crippen \\ clash \end{pmatrix}$$

## Verschiedene Fitness-Komponenten

- ▶  $E_{tor}$ ,  $E_{vdW}$ ,  $E_{el}$ ,  $E_{pe}$  aus der ersten Fitness-Funktion
- ▶ r.m.s - Mittlere Abweichung der Struktur zu der natürlichen Struktur.
- ▶ polar - Wert, der Polare Residuen an der Oberfläche bevorzugt.
- ▶ hydro - Wert, der hydrophobe Residuen im Inneren bevorzugt.
- ▶ scatter - Mittlerer Abstand aller  $C_{\alpha}$  zum Schwerpunkt der Struktur.
- ▶ Crippen - Anzahl von Atompaaaren, die innerhalb einer gewissen Distanz miteinander interagieren.
- ▶ clash - Anzahl der Atompaaare, die näher als  $3,8\text{\AA}$  zusammenliegen.

## Verbesserung der Variationsoperatoren

- ▶ LOCAL-TWIST - Ein 3 Aminosäuren langes Teilstück des Proteins wird so verdreht, dass sich die Position der anderen Atome nicht ändert.
- ▶ MUTATE betrachtet nun die Winkel  $\phi$  und  $\psi$  als Paar und ersetzt dieses Paar durch eins der 10 am häufigsten in der Natur vorkommenden Paare.
- ▶ Bei bekannter Sekundärstruktur kann man die Winkel  $\phi$  und  $\psi$  weiter einschränken, was den Suchraum stark verkleinert.

## Tauglichkeit der Variationsoperatoren

- ▶ Ausschliessliche Nutzung des r.m.s-Wertes für die Fitness-Funktion.
- ▶ Mittlere Abweichung nach 10000 Generationen: 0,89 Å
- ▶ Da die Bindungslängen und die Bindungsgeometrie vernachlässigt wurden, kann nie eine genaue Übereinstimmung mit der natürlichen Struktur erreicht werden.

## Ergebnisse mit anderen Fitness-Komponenten

- ▶ Verwendung von  $E_{tor}$ ,  $E_{pe}$ ,  $E_{el}$ , polar, hydro, Crippen und Solvent - minimale r.m.s - Abweichung von 6,27Å.
- ▶ Änderung der Gewichtung führte bis zu Abweichungen von 6Å.
- ▶ Verwendung von Crippe, clash, hydro und scatter mit konstanten Winkel  $\omega$  und Beschränkung vom  $\phi$  und  $\psi$  durch die sekundäre Struktur führt zu r.m.s - Abweichungen von 4,36Å

⇒ Dieser Ansatz eines genetischen Algorithmus zur Proteinfaltung ist durchaus brauchbar.