

遺伝的アルゴリズムを取り入れたタンパク質配列解析

2R-4

戸谷 智之、石川 幹人、星田昌紀*、小長谷明彦**

(財)新世代コンピュータ技術開発機構、松下電器産業(株)*、NEC(株)**

1 はじめに

我々は、タンパク質配列の類似性を解析する手法のひとつであるマルチプルアライメントの問題の解決を目指して研究を行なってきた。昨年、並列反復改善法を用いたマルチプルアライメントシステムを開発し、従来以上に、高品質なアライメント結果を短時間のうちに獲得できることを可能にした。今回は、さらなる解の高品質化を目指し、並列反復改善法に遺伝的アルゴリズムを取り入れ、並列反復改善法の発展を試みた。それについて、報告を行なう。

2 並列反復改善法

並列反復改善法[1]は、Berger-Munsonの反復改善法のアイデアをもとにしている。これは、従来から行なわれてきた手法と比較して、高品質の解を得られる有効な方法であるが、 N 本の配列群に対して、 $2^N - 1$ 通りのグループ分割が考えられ、実用規模(数十本)のアライメントを得るには莫大な時間を要してしまい、現実的とは言えなかった。我々は、それを並列化し、さらに独自のヒューリスティクスを導入することで、実用規模の問題を短時間のうちに解き、高品質のアライメントを獲得できるシステムに発展させた。(図1)




図1：並列反復改善法

- (1) アライメントする配列群を2つのグループに分割する複数の組合せを生成する。
- (2) それぞれの分割組合せで、分割された2つのグループ間でのグループ間DPを行なうが、その処理を複数のプロセッサで並列に実行させる。

Parallel Iterative Aligner with Genetic Algorithm
 Tomoyuki Toya, Masato Ishikawa, Masaki Hoshida*,
 Akihiko Konagaya**
 ICOT, Matsushita Electric Industrial Co.*, NEC Co.**

(3) 各グループ間DPで得られた結果、アライメントの評価値として最も良いものを次のサイクルの配列群として、(1)の処理に戻る。

さらに、(1)の処理で、ヒューリスティクスを導入して、分割の場合の数を制限することで、計算時間の削減に成功した。それは、配列群を2つのグループに分割する際に、偏りをつけた分割の方が改善に効果があることが実験により確かめられたからであった。

このようにして、我々の並列反復改善法は、Berger-Munsonの手法をより実用的な規模の問題で、質の高い解を短時間のうちに解決できるように発展させたのであった。ただ、実験を繰り返していくうちに、問題によって、比較的質の良くないアライメントが得られることがあった。解空間上で、局所解につかまってしまったと考えられるが、我々は、その解決に遺伝的アルゴリズムを取り入れることを考えた。

3 遺伝的アルゴリズムとそれを取り入れた並列反復改善法

遺伝的アルゴリズム(Genetic Algorithm以下、GA)[2]は、生物の進化過程を発想のもとにした、組合せ問題の解決するための汎用の探索アルゴリズムである。GAは、適応度の高い個体が生き残ってい




図2：遺伝的アルゴリズム

くようく設計されたものであり、解空間上で複数の解(個体)の集団を操作の対象としている。GAでは、“mutation”、“crossover”、“selection”的3つのオペレーションが用いられる。図2のように、これらのオペレーションを組み合わせて行なわれるがGAである。我々は、このGAの発想をもとに、並列反復改善法を拡張することを考えた。従来の反復改善法では、

並列に実行を行なったグループ間 DP の結果で、最も良い解だけを選択することを行なってきた。つまり、山登り法を行なってきたと言える。しかし、それでは局所解につかまることもあるので、それを GA 的に発展させることで回避しようというものである。GA の適応度はアライメントの評価値に相当する。また、アライメントの解そのものを個体とした。我々は、GA における 3 つのオペレーションに相当するものを並列反復改善法では以下のように定義した。

mutation 個体の 1 部分を変化させるという意味で、解（配列群）の 1 本を抜きだし、その 1 本と抜かれた残りの配列群の間で DP によるアライメントを行なうこととした。GA の本来の mutation が持つ意味とは異なって、各個体を改善させるオペレーションとなっている。

crossover crossover は、2 つの個体間での解の混合と解釈できる。具体的には図 3 に示すようなオペレーションを行なう。選ばれた 2 つの個体（配列群）で、他の個体と“交換する配列”と“交換しない配列”をやはりランダムに決定する。そうして決定された“交換する配列”群を個体間で交換し、その後グループ間で DP を用いてアライメントする。




図 3: crossover

selection selection は、今ある個体群から、指定した割合で、適応度の高い個体を残し、適応度の低いものは捨てる操作を行う。捨てられた分の個体数だけ、生き残った個体間で crossover を実行し、全体の個体数は一定を保つようにしている。

4 GA 反復改善法の評価

我々は、並列論理型言語 KL1 を用いて、GA 反復改善法のアライメントシステムを構築し、並列計算機 PIM 上で並列実行させた。

図 4 は、従来の並列反復改善法の結果と GA 反復改善法の結果を比較するグラフである。問題は、いずれも 80 個のアミノ酸からなる 22 本の配列群であり、実用的な規模の問題である。

いずれも、256 プロセッサをもつ PIM 上で実行した。




図 4: 実験結果

並列反復改善法では、ヒューリスティクスとして、分割する際に、“1 本と残り”、もしくは“2 本と残り”になる分割のみに制限する手法を用いている。この場合、2 2 本の配列があるため、 $253(2_2 C_1 + 2_2 C_2)$ の分割ができるため、マスター プロセッサ 1 つを加えた、254 プロセッサでの並列実行ということになる。25 サイクル約 11 分で改善が見られなくなった時点で実行は終了し、得られた解の評価値は 13903 であった。

GA 反復改善法では、256 プロセッサ使用可能なので、全体の個体数を 255 として実行した。各世代の時間は 80 秒とし次の世代に生き残る個体を上位 90% とした。MAX とあるのは、各世代で最も高い評価値をプロットしたものである。AVE とあるのは、各世代での全個体の平均評価値をプロットしたものである。MAX を見ると、山登り法の場合とほぼ同じぐらいの時間で同レベルの解に達していることが分かるであろう。GA はさらに実行が続き、MAX の評価値は 15775、AVE も 15121 にまで達した。

5 まとめ

今回は、GA の発想をもとに並列反復改善法の発展させたマルチプルアライメントのシステムを実装し、より質の高いアライメント結果が得られたことを報告した。今後は、個体数、生存率、世代時間などの、パラメータと性能についての相関について、実験を行なっていきたいと考えている。

参考文献

- [1] 星田昌紀、石川幹人、広沢誠、戸谷智之、十時泰：“並列反復改善法によるタンパク質配列のアライメント”，情報処理学会第 27 回情報学基礎研究会，13-24, 1992.
- [2] Goldgberg,D.E.: “Genetic Algorithms in Search, Optimization, and Machine Learning”, Addison-Wesley Publishing Company, Inc., 1989.