

類似性を考慮した反復的マルチプルアライメント

広沢 誠¹、石川 幹人¹、星田 昌紀²

7 D-6

1: (財)新世代コンピュータ技術開発機構 2: 松下電器産業株式会社

1はじめに

タンパク質配列のマルチプルアライメントの問題は、組合せ最適化問題と捉えることができ、実用的規模の問題では、大量の計算量を必要とする。生物学者が手作業でアライメントをする場合も、大変な労力が必要であり、高品質で高速な自動アライメントシステムが望まれている。

一昨年、反復改善法[Berger 91]という、新しい視点からのアライメント手法が提案された。この方法も従来法[Feng 87, Barton 90]と同様に、要素技術にダイナミックプログラミング[Needleman 70]を用いているが、それを反復的に適用することにより、アライメントを徐々に改善していくというものである。しかしながら、反復改善法は、3、4本の配列のアライメントを作成する場合には、有効であるが多数の配列のアライメントを作る場合には計算量が大きくなるので実用的ではない。

我々は反復改善法を基に実用的なアライメントアルゴリズムを開発してきた。まず、我々は、並列反復改善法[星田 92]を開発し、さらに、これを基にツリーベース並列反復改善法[石川 92]を開発してきた。これらは、並列コンピュータ向きのアルゴリズムである。ツリーベース並列反復改善法は、それがベースとする並列反復改善法より品質の良いアライメントを作り出しが、計算量が大きいという問題点がある。我々は、ベースとする並列反復改善法を配列間の類似性を考慮し改良することにより、ツリーベース並列反復改善法の計算量を削減する方式を開発したので、発表する。

以下、まず、並列反復改善法、ツリーベース並列反復改善法の説明をしてから、新ツリーベース並列反復改善法の説明をする。最後に、以前のツリーベース並列反復改善法と新ツリーベース並列反復改善法の比較をする。

2並列反復改善法

並列反復改善法[星田 92]は、配列グループ間に、ダイナミックプログラミング(DP)を反復的に適用することにより、アライメントを徐々に改善する(図1)。まず、何らかの方法で初期状態となるアライメントを作成する。

これらN本の配列を、何らかの基準によって2つのグループに分割し、分割された2つのグループ間に、2次元DPを適用し、アライメントを作ることができる。このアライメントの評価値は、前の状態の得点より改善しているか、悪くとも同じ得点である。

さて、この分割法は $2^{N-1} - 1$ 通りあるので、可能な全ての分割方法に対してDPを行ない、一番良い評価値を持つアライメントを次のサイクルの初期状態するという過程を繰り返すことにより、徐々にアライメントを改善していくことが可能である。評価値に収束がみられたら、その時点の状態を最終アライメントとする。

しかしながら、 $2^{N-1} - 1$ 通りの分割方法を全て行なうと、配列の本数が多い時には、計算量が膨大になり現実的ではな

い。例えば、ICO Tの256台の並列計算機で各分割に対するDPを並列に行なうと 9 本($2^9 - 1 = 255$)までの配列しか扱うことができないそこで、我々は、効果的な分割法をのみを採用することにした(限定分割法)。

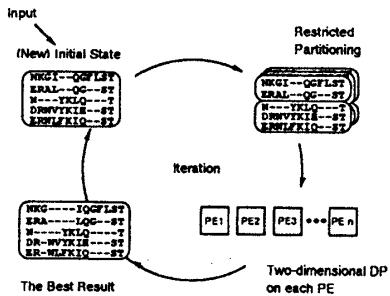


図1: 並列反復改善法

我々は、実験を行った結果を分析するなかで、N本の配列がある場合は、1本とN-1本、および、2本とN-2本という分割が主に改善に寄与し、 $N/2$ 本と $N/2$ 本というような分割は、あまり改善に寄与しないことを見い出した。例えば、1本とN-1本および2本とN-2本という分割法だけを行うとすると、22本の配列についてのグループ間DPが、一度に実行可能である($_{22}C_1 + _{22}C_2 = 22 + 231 = 253$)。また、1本とN-1本というような分割法だけを行うとすると256本までの配列を扱える。以上の考察に基づき、我々は、前回は1本限定分割、1、2本限定分割を採用することになった。

3ツリーベース並列反復改善法

ツリーベース並列反復改善法[石川 92]では、恣意的な初期状態を用いるのではなく、前もって配列群の中で、どの配列とどの配列が近い関係にあるかを調べてツリーを作り、そのツリーに従って、徐々に配列の本数を増やしながら反復改善を行っていく方式である。このため、初期状態に依存しないアライメントが得られる。

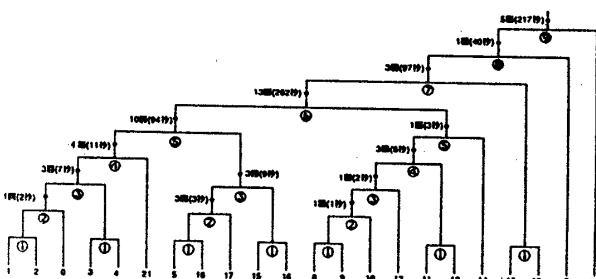


図2: ツリーベース並列反復改善法

この方法の手順を具体的に述べると、次のようになる。まず、配列の全てのペアについてDPを行い、そのスコアを求める。そして、そのスコアを配列間の類似性と考え、良く似た配列から順に結線したツリーを作成する。これが前処理であり、例えば図4に示すようなツリーが得られる。このツリー

に従って、類似している配列から順に 2 次元 DP を使い配列を組み合わせ、アライメントしていく。ただし、2 次元 DP を行った結果が配列 3 本以上のアライメントになるときは、そのあと収束するまで並列反復改善を行い、その時点のアライメントを確実なものとする。図 2 の黒い丸で示される点は、並列反復改善を行った個所を表している。それぞれ、1.2 本限定で、何サイクル並列反復改善を行って、何秒かかったかを、「回、秒」で示している。

4 ツリーベース並列反復改善法の改良

我々は、1.2 本限定のツリーベース並列反復改善法と 1 本限定のツリーベース並列反復改善法の比較検討を 256 個のプロセッサを持つ並列計算機を用いて行なった。実験は、kinase というグループのタンパク質（30 種）から、それぞれ類似性の比較的高い部分配列（80 文字分）を取り出した配列群（30 本）から、ランダムに選び出した 22 本に対して、それぞれの実験を 30 回行った。プロセッサは分割数の数だけ用いた。つまり、1.2 本限定では 255 個、1 本限定では 22 個のプロセッサを用いた。その結果、多くの場合において 1.2 本限定が 1 本限定より良い結果を出した。また、計算時間は双方とも同様であった（図 3 を参照）。

1.2 本限定の問題点は分割数が配列の本数の 2 乗で増えるために、プロセッサの数が（分割数に比較して）少ないので並列計算機、または、逐次計算機を用いて計算する場合には、計算時間が長くなることである。そこで、我々は分割数が 1 本限定と同程度であり、しかも、1.2 本限定と同様に効果的な分割方法である tree 依存分割を考案した。

図 2 を流用して tree 依存分割の説明をする。tree 依存分割では、ツリーベース並列反復改善法において、アライメントに配列が加えられていくたびに系統樹を描き、類似性を考慮した分割方法を行なう。具体的には、系統樹のサブツリーを構成する配列と、そうでない配列に分割する。 n 本の配列には、 $2n - 3$ 本のサブツリーがあるので、 $2n - 3$ 個の分割法がある。図 2 におけるサブツリーは、例えば、{1}, {2}, {1,2}, {0}, {1,2,0}, {3}, {4}, {3,4}, {1,2,0,3,4}, {21} {1,2,0,3,4,21}, ..., である。tree 依存分割は、全ての 1 本限定分割を含んでる。また、配列の類似度が高い 2 つの配列に対する 1.2 本限定分割も含んでいる。

5 結果

図 3 は kinase のデータに対するツリーベース並列反復改善法の結果を 1 本限定分割（22 個のプロセッサを使用）と、1.2 本限定分割（255 個のプロセッサを使用）とツリー依存分割（41 個のプロセッサを使用）の 3 方式について示した。相対スコアとは、3 つの異なる方法を行ったときの、スコアの平均値からの相対的な差を表している。これから次のことが分かった。

- tree 依存分割は 1 本限定に比較して、3 つの場合を除いて良いスコアを出している。
- 1.2 本限定は 1 本限定に比較して、4 つの場合を除いて良いスコアを出している。
- tree 依存分割と 1.2 本限定のスコアとスコアは、平均としては同様な値を与えている。1.2 本限定のスコアの方のスコアが大きい場合の方が若干多い。ただし、1 つの例において、1.2 本限定のスコアが極端にわるい場合がある。
- 1.2 本限定と 1 本限定の平均実行時間とはほとんど同じである。これに対して、tree 依存分割の平均実行

時間は他の 2 方式に比較して 2 割ほど長い。しかし、調査の結果サイクル数は他の 2 方式とほぼ同じであることがわかった。これは、1.2 本限定分割を構成している不均等な分割の DP に比べて、tree 依存分割に多少含まれている均等に近い分割（例えば、22 本を 10 本と 12 本の分割）においての DP の時間が長いためであると思われる。2、3 個均等に近い分割が含まれているため tree 依存分割のサイクルは長くなる（不均等分割に割り当てられたプロセッサは、自分の仕事が済んでも均等に近い分割に割り当てられたプロセッサの仕事が終了するまでアイドルとなる）。

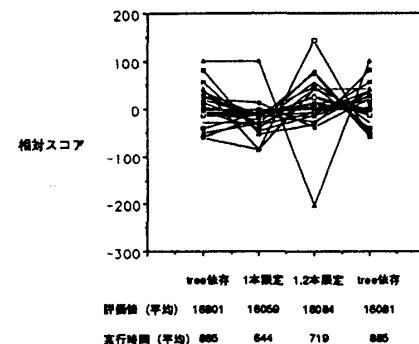


図 3: ツリーベース反復改善法の比較

これらの結果を検討すると、まず、tree 依存分割は 1 本限定に比較して優位であるということがわかる。また、tree 依存分割は 1.2 本限定とほぼ同様のスコアを出すのにもかかわらず、必要とするプロセッサが少ないので、並列計算機を使う場合において、配列の数が多い時、または、使用できるプロセッサの数が少ない時には、有利である。特に、逐次計算機を用いる場合には、均等に近い分割の DP の終了を他のプロセッサが待つアイドル時間がなくなるために、tree 依存分割は 1.2 本限定の速度比は、ほとんど分割数の比となる。したがって、分割比が大きくなる配列数が多い場合には tree 依存分割が優位である。

6まとめ

我々は、以前発表したツリーベース並列反復改善法を、tree 依存分割という方法をとることにより改良する方式を開発した。そして、この方式が以前の方式に対して優位であることを示した。

References

参考文献

- [Berger 91] M.P. Berger and P.J. Munson: CABIOS, 7, 1991, pp.479-484.
- [星田 92] 星田、石川、広沢、戸谷、十時: 情報処理学会情報学基礎研究会 27-2, 1992.
- [Needleman 70] S.B. Needleman and C.D. Wunsch: J. Mol. Biol. 48, 1970, pp.443-453.
- [Barton 90] J.G. Barton: Methods in Enzymology Volume 183 Academic Press, 1990, pp.403-428.
- [Feng 87] D. Feng and R.F. Doolittle: J. Mol. Evol., 25, 1987, pp.351-360.
- [石川 92] 石川、星田、広沢、戸谷、十時: 第 3 回ゲノム情報ワークショップ講演論文集, 1992, pp.263-266.