

環境適応型スケジューリング実現方式の検討 A Dynamic Scheduling Scheme for the Grid

井上 悠佑[†]
Yusuke INOUE

小板 隆浩[‡]
Takahiro KOITA

福田 晃[†]
Akira FUKUDA

1. はじめに

InterProScan は、EBI[1] (European Bioinformatics Institute) が開発したゲノムアプリケーションである。InterProScan は、複数の解析処理を同時におこなうので、単一の解析処理では得られない解析結果が得られることが多く、有用なゲノムアプリケーションとして広く利用されている。しかし、複数の解析処理を同時に実行するため、単一の解析処理に比べ非常に多くの処理能力が必要とされる。Grid 環境のような大規模な処理環境で InterProScan を実行した場合、多数の計算機の処理能力を十分に利用できないため、応答時間の大幅な増加が予想される。

しかし、Grid 環境で InterProScan を効率良く実行することができれば、応答時間を短縮することができると考えられる。Grid 環境で InterProScan を効率良く実行するには、アプリケーションや計算機の情報を考慮し、適切に解析処理を割り当てるスケジューリング機能が重要である。我々はこれまで、InterProScan が Grid 環境の多数の計算機を有効に利用できるスケジューリング機能を実装し、実 Grid 環境における有効性を評価してきた。これまでの評価結果から、我々の実装したスケジューリング機能は、環境内の負荷などの状況によって有効な方式が異なることが分かった。

本研究では、我々がこれまで実装してきたスケジューリング機能を、Grid 環境の状況に応じて有効な方式に切り替える環境適応型スケジューリングの検討をおこなう。本稿では、我々が実装してきたスケジューリング機能の概要と、環境適応型スケジューリング実現のための方策について検討する。環境適応型スケジューリングの実現により、実 Grid 環境である OBIGrid[2] (Open Bioinformatics Grid) での効率の良い InterProScan の実行を目指す。

2. InterProScan

InterProScan は、既存の解析ツールやデータベースを複数組み合わせで解析をおこなう統合ゲノムアプリケーションである。InterProScan はたんぱく質シーケンスの解析を、解析ツールとデータベース・解析命令を記述したスクリプトなどで実行する。InterProScan の各解析処理はそれぞれ独立しており、全ての解析処理が終了する

と解析結果は1つにまとめられ TXT 形式・XML 形式・HTML 形式などで出力される。図1に InterProScan の構成を示す。




図1: InterProScan の構成

以後、本稿では InterProScan を構成するアプリケーションを解析処理と呼ぶ。InterProScan は複数の解析処理をおこなうことで、複数の解析結果を出力し、解析結果を比較することができる。

既存の InterProScan には、各解析処理を同時に実行するためのスケジューリング機能が実装されている。このスケジューリング機能による解析処理の割り当ては、インストール時に、1つの解析処理に対して1台の計算機を固定的に指定し、以後変更しない。

つまり、InterProScan は10種類の解析処理から構成されており、1つの解析処理を1台の計算機に割り当てても最大10台の計算機しか利用できないため、多数の計算機があっても有効に利用できないという問題点がある。

3. スケジューリング機能

我々は、これまで Fixed 方式、Random 方式、Load 方式、Adaptive 方式のスケジューリング機能 [3]、ジョブマネージャ [4] を実装した。各スケジューリング機能の概要について述べる。

Fixed 方式は、InterProScan に実装されている既存のスケジューリング機能である。Fixed 方式は、インストール時に解析処理を実行する計算機を指定する。Grid 環境の状況がどんなに変化しても、Fixed 方式では、特定の計算機に固定的に解析処理を割り当てる。Random 方式は、Grid 環境全ての計算機を対象に各解析処理をランダムに割り当てる。

Load 方式は、予め各計算機での InterProScan の実行時間を調べ、計算機の実行時間と CPU 使用率をもとに計算機の処理能力を調べる。計算機の処理能力から各計算機の予想応答時間を算出し、最も予想応答時間が短い

[†]九州大学, Kyushu University

[‡]同志社大学, Doshisha University

計算機に解析処理を割り当てる。

Adaptive方式は、計算機の処理能力に加え、解析処理の負荷も考慮してスケジューリングをおこなう。Adaptive方式は、各計算機の実行時間とCPU使用率をもとに各計算機の予想応答時間を算出し解析処理を割り当てる点は、Load方式と同じである。しかし、各解析処理の負荷や計算機の処理能力によって、解析処理を割り当てる計算機を優先的に決める点がLoad方式と異なる。

ジョブマネージャは、たんぱく質シーケンスを分散実行させず、1つの計算機に割り当てて逐次実行させる。ジョブマネージャにより、InterProScanの解析処理を1台の計算機で逐次実行させる場合、解析処理を分散実行することによる応答時間の短縮は望めない。しかし、オーバーヘッドは解析処理を分散実行するより小さい。

4. 性能評価と環境適応型スケジューリング

前章で述べたスケジューリング機能をOBIGridで評価した。各方式の有効性と検討すべき課題について述べる。評価方法としては、ランダムにInterProScanを生成し、Grid環境に投入し、応答時間を測定した。InterProScanを100個投入したときの平均応答時間と負荷率の関係を図2に示す。負荷率とは、Grid環境内のInterProScanの混雑度を表す指標である。負荷率100%は、もうそれ以上InterProScanを処理することができない状態を表す。




図2: 平均応答時間

評価結果から、負荷率が低いときはAdaptive方式のスケジューリング機能が、負荷率が高いときはジョブマネージャが、それぞれ最も短い応答時間となることを示した。Grid環境内に処理が少ない低負荷時は、空いている計算機が多いためInterProScanの分散実行が有効であり、処理が多い高負荷時は不用意に分散せず1つのInterProScanを1台の計算機で逐次実行することが有効である。つまり、Grid環境内の負荷に応じて方式を切り替える環境適応型スケジューリングが有効と考えられる。

しかし、実際にGrid環境内の負荷を正確に把握する

ことは難しく、何らかの指標を負荷の代替値として用いる必要がある。環境適応型スケジューリングを検討する場合、まず、何を指標にスケジューリング方式を切り替えるか決める必要がある。

指標の一つとしてたんぱく質シーケンス数があげられる。InterProScanでは、一般的にたんぱく質シーケンス数と必要な処理量は、ほぼ一定である。つまりシーケンス数が定まれば、ある程度実行時間が予測可能である。これまでの評価結果より、ある一定数以上のたんぱく質シーケンスを同時に解析する場合、全体としての分散実行の効果は小さくなる。シーケンス数とGrid環境内の計算機台数・処理能力が分かっているならば、どのスケジューリング機能を使うべきか判断することができると考えられる。

しかし、たんぱく質シーケンス数を指標にする場合、解析中のシーケンス数と各方式の応答時間の関係について予め評価する必要がある。同様の多数シーケンスセットに対して、繰り返し解析をおこなうような場合に対しては、最も適切な方式を常に選択できることが期待される。他ユーザの処理や計算機構成が頻繁に変わるような場合には、再び閾値を調査する必要がある。

5. まとめと今後の課題

ゲノムアプリケーションInterProScanを対象に、我々がこれまで実装してきたスケジューリング機能を、Grid環境の状況に応じて有効な方式に切り替える環境適応型スケジューリングの実現方法について検討した。基本的には、負荷状況に応じて方式切り替えることが有効であると考えられるが、負荷状況を知る指標の1つとしてたんぱく質シーケンス数をあげ検討した。

今後の課題としては、たんぱく質シーケンスを指標に用いる時の具体的な閾値の算出と、指標を取り入れ環境に応じてスケジューリングを変更する環境適応型スケジューリングの実現があげられる。

参考文献

- [1] EBI, <http://www.ebi.ac.uk/>.
- [2] OBIGrid, <http://www.obigrid.org/>.
- [3] Yusuke Inoue, Takahiro Koita, and Akira Fukuda, "Performance Evaluation of Scheduling Schemes for a Genomic Application on OBIGrid", Proc. The 2nd IASTED International Conference on Communications, Internet, & Information Technology (CIIT 2003), 2003.
- [4] 井上 悠佑, 小坂 隆浩, 福田 晃, 「Grid環境における簡易ジョブマネージャの試作と評価」, 第4回九州大学情報基盤センター研究集会, pp.49-56, 2003.