

Towards Energy-Aware Scheduling in Data Centers Using Machine Learning

著者： Josep Ll. Berral, et al.

出典： *The First Int'l Conf. on Energy-Efficient Computing and Networking*, pp. 215–224, Apr, 2010,

発表者： 高性能コンピューティング学講座 本多・近藤研究室 1053012 佐藤友貴

1 概要

近年のデータセンターの消費電力の増加にともない、データセンターの省電力化が重要視されている。本論文ではタスクを動的にスケジューリングする際に機械学習を利用することで最適なサーバへのタスクの割り当てを予測しつつ、稼働している多数のサーバを少数のサーバへ統合することで省電力化を図る手法を提案する。

2 SLA(Service Level Agreement)

まず、本論文での性能指標となる SLA (Service Level Agreement) について説明する。SLA はサービス合意水準の略で、タスクを実行する際に付与する条件である。例えば、サーバに到着したタスクを 10 秒以内に処理を完了させる、という条件がタスク実行時に付与される場合、10 秒以内にタスクの処理を完了できれば、SLA が満たされたことになる。

3 従来手法と提案手法

3.1 性能因子 R の定義

スケジューリングを行う上での基準とするために、性能因子 R を定義する。R はサーバがタスクを目標の実行時間で処理できるかの指標であり、目標の実行時間はユーザーが要求する実行時間 \times SLAfactor で求める。SLAfactor はユーザーが要求する実行時間に対する許容度を与えるための値である。例えば、ユーザーが要求する実行時間が 10 秒であり、SLAfactor が 1.2 であるとする、10 秒 \times 1.2=12 秒となり、目標の実行時間は 12 秒となる。R は各サーバでのタスク実行時間と目標実行時間を比較することで求め、実行時間が目標値以内であれば 100、目標をオーバーした場合はその割合に応じて 100 以下の値をとる。

3.2 スケジューリングとマイグレーション

まず、本論文の提案スケジューリング手法のベースとなる、Dynamic Backfilling について説明する。Dynamic Backfilling は Backfilling に対し、動的スケジューリングを加えたものである。Backfilling は、資源に余裕がある限り、1つのノードタスクを割り当てられるだけ割り当てる

手法であり、実行中のサーバの資源使用率を 100 %に近い状態にすることができる。また、なるべく少数のサーバで処理ができ、アイドルサーバ数を最大化できるため、それらサーバの電源をオフにすることで電力を削減できる。Dynamic Backfilling は Backfilling にタスクマイグレーションを追加したものである。タスクマイグレーションは、あるサーバの実行タスク数が閾値以下(本論文では 4 タスクと設定)になった場合に、他のサーバへタスクを移す。ここで、他の各サーバへタスクを移した場合の R の値の大小を比較し、最も R の値が大きくなるサーバへタスクをマイグレーションさせる。マイグレーションを行って実行するタスクがなくなったサーバは電源をオフにする(サーバ統合)。

3.3 機械学習の利用

Dynamic Backfilling は R の値が既知の場合は有効な手法であるが、各サーバ上でのタスク実行時間は一般的に既知ではないので、Dynamic Backfilling は現実的に利用可能な手法ではない。そこで本論文では R の値を機械学習によって予測し、予測された R の値を基にタスクマイグレーションを行う *Machine Learning DB* という手法を提案する。機械学習では、簡単に情報を得ることのできるサーバの CPU 使用率から R の値を予測する。あらかじめ R の値を求めておいたタスクセットを利用し、CPU 使用率と R との関係性を線形回帰分析によりモデル化する。




図 1: 機械学習の概略

図 1 は機械学習の概略を表したものである。手順は以下のようになる。

1. 特徴 (R、CPU 使用率) が既知のタスクセットを用意し、機械学習アルゴリズムを適用する

2. 機械学習アルゴリズム (本論文では線形回帰分析) に より、R と CPU 使用率の関係のモデル化を行う
3. 特徴が不明なタスクに対してモデル化で得られた数式から R を予測し、スケジューリングに利用する

4 評価方法

4.1 シミュレーションによる評価

提案手法はシミュレーションによって評価を行う。評価では提案手法と Dynamic Backfilling などの従来スケジューリング手法を比較する。なお、Dynamic Backfilling では R の値は既知として評価を行った。

4.2 シミュレーション環境

シミュレーションは OMNeT++platform[1] を用いた。シミュレーションで稼働させるサーバは同一の性能のものを 400 台準備した。これらのサーバは状況に応じて電源を ON/OFF の切り替えが即座に可能であるとする。実行させるアプリケーションは特徴が異なるものを複数用意した。用いたアプリケーションは、GridWorkload, Service workload, Heterogeneous workload であり、消費電力や性能 (SLA 満足度) を評価する。

5 結果

3 種類の異なるアプリケーションを 1 週間に渡って連続で実行した。そのときの消費電力や CPU 使用率、SLA 満足度をグラフに示した。図 2、図 3 に実行結果のグラフを示す。

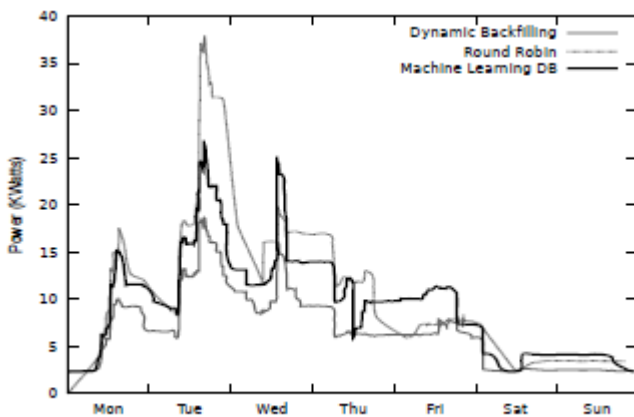


図 2: Grid workload を実行したときの消費電力

図 2 より、Grid workload を実行した場合、提案手法である Machine Learning DB は他の従来手法の Round Robin スケジューリングと比較して消費電力が低い、ベースである Dynamic Backfilling には及ばないことがわかる。どの手法も火曜日と水曜日の間の期間が電力を多く消費

しており、特に Round Robin で電力増大が顕著なのが分かる。この原因は、Round Robin では全サーバに順番にタスクを配置するため、稼働サーバの台数が他の手法よりも多くなるためである。

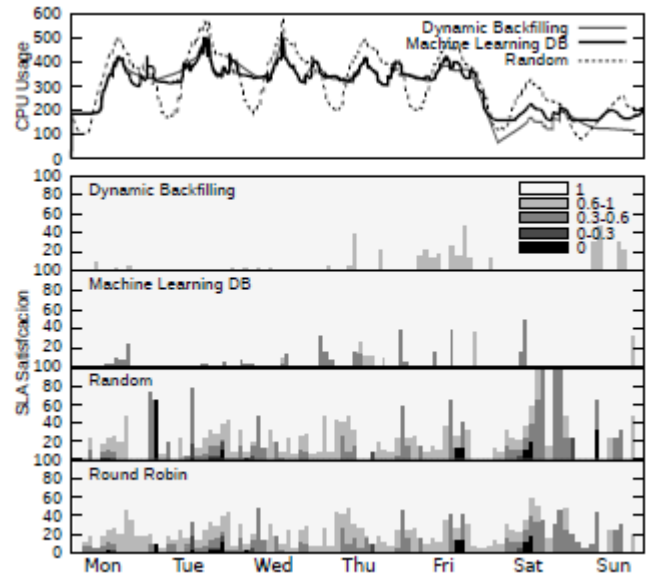


図 3: Heterogeneous workload を実行したときの CPU 使用率と SLA 満足度

図 3 は各手法を適用した場合の CPU 使用率や SLA 満足度を表している。SLA 満足度については棒グラフの数が少なく、また色が薄いほど SLA 満足度が高いことを表している。ランダムにスケジューリングを行った Random と Round Robin においては SLA 満足度が低い、Dynamic Backfilling と Machine learning DB (提案手法) では棒グラフが少なく、SLA 満足度が高いといえる。

6 結論

本論文では機械学習を利用した、動的スケジューリングとサーバ統合によるサーバの省電力化の手法を提案した。Dynamic Backfilling は実行時間や R の値が既知の場合は有効であるが、現実的には既知でないことが多く、実際の利用は難しい。一方で、提案手法では機械学習を用いることで現実的に利用することが可能であり、かつ性能や消費電力の面でも Dynamic Backfilling に匹敵するため、有効な手法であると考えられる。

参考文献

- [1] R. Nou, S. Kounev, F. Julia, and J. Torres. Automatic QoS control in enterprise Grid environments using online simulation. *J. Syst. Softw.*, 82(3):486502, 2009.