

負荷履歴を用いた Kubernetes における アダプティブスケジューリング

蕪木 貴央†

藤田 悟‡

法政大学大学院情報科学研究科†

法政大学情報科学部‡

1. はじめに

近年、アプリケーションの仮想化技術のひとつとして、コンテナ技術が注目を集めている。コンテナとは、ハードウェアを仮想化する従来の仮想マシン(VM)とは違い、OSの仮想化を行う事でアプリケーションを分離する仕組みであり、VMと比べて軽量、かつ、起動が高速である事が特徴である。

コンテナをクラスタ上で運用するためには、コンテナオーケストレータと呼ばれるプログラムを用いる。このオーケストレータとしては Kubernetes, Docker Swarm, Apache Mesos 等が開発されているが、本研究は Kubernetes を対象とした。

Kubernetes のスケジューラは、CPU、メモリ、ストレージの状態をスケジュール時に確認し、それぞれのリソース使用量が少ない（または多い）ノードに優先的にスケジュールする、後述の Worst-Fit あるいは Best-Fit に相当する処理を行う。加えて、現実の運用では、必ずしもビン、即ちクラスタのノードの削減が最適とは限らず、Quality of Service (QoS)が優先される事も多い。

そこで本研究では、Kubernetes のスケジューラを拡張し、ネットワークの実行履歴を用いてコンテナ間の通信量を考慮するスケジューリング方式を提案し、その効果を実験で評価する。

2. 関連研究

仮想マシンやコンテナをクラスタに効率良くスケジュールする基本方式として、ビンパッキング問題が知られている。ビンパッキング問題は、大きさの異なるアイテムをビンと呼ばれる容器に詰め込み、そのビンの数を最小にすることを問う NP 困難問題である。Kubernetes で用いられる Worst-Fit や Best-Fit は、Ullman によって初めて証明された[1]。

ビンパッキングに限らず、VM やクラウドコン

ピューティング環境で用いるアルゴリズムとして、エネルギー効率や QoS などの異なる観点から様々な手法が提案されている [2]。ネットワークに焦点を当て、木構造を用いてビンパッキングを改良した研究としては[3]がある。

Kubernetes の最小管理単位は ポッドと呼ばれ、単一あるいは複数のコンテナで構成される。Kubernetes のスケジューラの研究として、このポッドをグループ化してスケジュールする手法 [4] や Quota と呼ばれる制約システムを改良する手法[5]が提案されてきた。

3. 負荷履歴を用いたスケジューリング

3.1. 基本設計

本研究では、Kubernetes による高可用なクラスタリソースの管理機能に注目し、分散環境で重要となる通信量の最適化が可能なスケジューリング方式を提案する。既に述べたように、Kubernetes の最小管理単位はポッドである。Kubernetes 上のアプリケーションは、複数のポッドで構成され、ポッド間には様々な通信が発生する。各ポッドは、高可用性のために複数のノード（クラスタを構成する VM または物理マシン）上に分散配置されて実行されることになるが、ポッド間の依存性の違いから、相互の通信が多いポッドが異なるノードに配置されると、期待性能を達成できなくなる。ポッド間の通信量については、実行環境依存であり、事前に想定することが難しい。そこで、本研究では、サービスの運用開始前に、仮運用期間を設定し、ポッド間の通信量を負荷履歴として蓄積し、本運用の際に、この負荷履歴を利用してポッドの最適配置を行うスケジューラを研究開発した。

3.2. 通信の測定と保存

通信量履歴の取得にあたっては、Kubernetes のネットワークを定義する Container Network Interface の監視を行うプログラムを自作した。すなわち、各ポッドの持つプライベートアドレスを割り出し、そのアドレスの通信量を監視することで、ポッド間の通信量を把握した。また、取得し

Adaptive Scheduling Based on Historical Resource Usage in Kubernetes

† Takao Kaburaki, Graduate School of Computer and Information Sciences, Hosei University

‡ Satoru Fujita, Faculty of Computer and Information Sciences, Hosei University

たデータは、時系列データベースである Prometheus に保存した。

3.3. スケジューラ

スケジューラは、Prometheus に保存されている履歴の 30 分平均値を利用して、ポッドのスケジュールを行う。スケジュール対象のポッドが追加された時、スケジューラはそのポッドの履歴を参照して 0 から 100 の整数でスコアリングを行い、通信量が多いポッドが配置されているノードに優先的にポッドが配置されるようにする。

4. 実験

4.1. 実験環境

実験は、Kubernetes クラスタに、先述のネットワーク監視ツールを追加した環境で行う。Kubernetes クラスタは、6 台の Raspberry Pi 4B (4GB) によって高可用構成で作成する。抽出したデータの収集、保存、処理を行うデータベースには、時系列データベースの 1 つである Prometheus を用いる。Prometheus 実行用に、更に 1 台の Raspberry Pi 4B を利用する。

4.2. 実験

実験には、ネットワークのスループットを測定するツールである iperf を用いる。1 つの iperf クライアントは 1 つの iperf サーバに接続し、通信を行う事で、スループットを測定する。本研究では、iperf サーバ 1 つを含むポッドを 10 個、それらのいずれかのサーバと通信する iperf クライアントを 1 つ以上含むポッドを 10 個用いて、スループットを測定する。この時ポッドに含まれる iperf クライアントは、実験 A で 1 つ、実験 B で 3 つである(図 1)。

実験では、最初に 45 分間ポッドを動作させ、その後クライアントのポッドを一旦削除し、リスケジュールを行う。リスケジュール前後においてそれぞれ 45 分間稼働させた時点で、各ポッドが実行されているノードと、全体のスループットの 30 分平均を確認し、本手法のスケジューラによる変化を調べる。

4.3. 実験結果

各クライアントは、それぞれ最も通信量が多いポッドと同一のノードに配置されることが確認できた。その結果、スループットの 30 分平均のグラフ(図 2)より、実験 A, B 共に、リスケジュール後に全体のスループットが向上したことが確認できた。

5. おわりに

本研究によって、ネットワークの状況を考慮することで、QoS が改善される可能性がある事が分かった。一方で、CPU やメモリ等、その他のリソースについても履歴を用いて、最適なリソースを選択しながらスケジュールを行うといったことが考えられるため、今後の課題としたい。




図 1. 実験 B の構成




図 2. 実験 A, B それぞれのリスケジュール適用前後のスループット

参考文献

- [1] J.D. Ullman. The performance of a memory allocation algorithm. Technical Report 100, Princeton University, Princeton, NJ, 1971.
- [2] Usmani, Z. and Singh, S., 2016. A Survey of Virtual Machine Placement Techniques in a Cloud Data Center. *Procedia Computer Science*, 78, pp.491-498.
- [3] Dong, J., Wang, H. and Cheng, S., 2015. Energy-performance tradeoffs in IaaS cloud with virtual machine scheduling. *China Communications*, 12(2), pp.155-166.
- [4] GitHub. 2021. *Kubernetes-Sigs/Scheduler-Plugins*. [online] Available at: <<https://github.com/kubernetes-sigs/scheduler-plugins/tree/master/kep/2-lightweight-coscheduling>> [Accessed 6 January 2021].
- [5] GitHub. 2021. *Kubernetes-Sigs/Scheduler-Plugins*. [online] Available at: <<https://github.com/kubernetes-sigs/scheduler-plugins/tree/master/kep/61-Trimaran-real-load-aware-scheduling>> [Accessed 6 January 2021].