

モデル予測制御によるハイブリッドクラウド環境での ビジネスクリティカルシステムの計算資源配置の一検討

小川祐紀雄[†] 長谷川 剛^{††} 村田 正幸^{†††}

[†] 室蘭工業大学 情報メディア教育センター 〒 050-8585 北海道室蘭市水元町 27-1

^{††} 大阪大学 サイバーメディアセンター 〒 560-0043 大阪府豊中市待兼山町 1-32

^{†††} 大阪大学 大学院情報科学研究科 〒 565-0871 大阪府吹田市山田丘 1-5

E-mail: [†]y-ogawa@mmm.muroran-it.ac.jp, ^{††}hasegawa@cmc.osaka-u.ac.jp, ^{†††}murata@ist.osaka-u.ac.jp

あらまし ビジネスクリティカルシステムに対して、プライベートおよびパブリックデータセンタの二センタ構成とし、平均的な処理要求に必要な計算資源をプライベートデータセンタに固定的に配備し、処理要求の増加時にはパブリックデータセンタの計算資源をオンデマンドに拡張することで、可用性や性能要件を満たしつつ計算資源の利用効率を高める。本稿では、モデル予測制御の適用により、計算資源の過度なスケールアウト/インを避けつつ目標利用率を保つ。まず、計算資源のコスト、障害耐性、操作量に着目した評価モデルを提案し、次いで、実ウェブシステムのトレースデータを用いて計算機シミュレーションを行う。リクエスト受信率予測誤差によりシステム利用率が頻繁にしきい値以上となるが、操作量を考慮することで制御回数が抑制され、結果として高利用率が緩和されることを示す。

キーワード ハイブリッドクラウド、モデル予測制御、計算資源、利用率

A Study of Computing Resource Allocation Based on Model Predictive Control for Business-Critical Systems in Hybrid Cloud Environment

Yukio OGAWA[†], Go HASEGAWA^{††}, and Masayuki MURATA^{†††}

[†] Center for Multimedia Aided Education, Muroran Institute of Technology

^{††} Cybermedia Center, Osaka University

^{†††} Graduate School of Information Science and Technology, Osaka University

E-mail: [†]y-ogawa@mmm.muroran-it.ac.jp, ^{††}hasegawa@cmc.osaka-u.ac.jp, ^{†††}murata@ist.osaka-u.ac.jp

Abstract In this report, business-critical application systems are constructed from computing resources provided by both private and public data centers. A private data center provides fixed resources for processing average workloads, whereas a public data center supplies on-demand resources for handling peak workloads. This system architecture enables us to satisfy application system requirements such as availability and performance as well as to maximize the resource utilization. This report presents a model predictive control approach for maintaining a target system utilization without too often scaling-out/in computing resources in such a hybrid cloud environment. We first formulated a cost function regarding the deployment of physical and virtual servers as well as fault tolerance and operation of them. We then conducted numerical simulations. The results indicate that, although an application system often experiences high utilization level above a threshold because of prediction errors, counting the operational cost reduces the frequency of scaling-out/in the resources, resulting in alleviating the high utilization.

Key words hybrid cloud, model predictive control, computing resources, utilization

1. はじめに

信頼性や安定性能を重視したオンプレミス型のビジネスクリティカルなアプリケーションシステムでは、ピークトラヒック

を処理できる計算資源を配備することが多いため、計算資源の平均的な利用率は低下する [1]。これに対して、プライベートデータセンタと IaaS (Infrastructure as a service) 型パブリックデータセンタを組み合わせた二センタ構成とし、プライベ

トデータセンタには平均的な需要量を処理する計算資源を固定的に配備し、処理要求が増加した時にはパブリックデータセンタの計算資源をオンデマンドに拡張させることで、処理性能を保ちつつ計算資源の利用効率を高めることが可能になる [2]。本稿の目的は、上記のハイブリッドクラウド環境において、サービス性能や可用性を守りつつコストを削減する計算資源の最適配備に向け、解析モデルの構築と評価を行うことである。

オンデマンドでの計算資源の配備は、クラウドコンピューティングの特長の一つであり広く研究されている [3,4]。サービスレベルの変化を検知した時点で、あるいは、検知してから制御するまでの間に、計算資源の過不足が問題となる場合は、プロアクティブな制御が必要になる。この手法では、計算資源への誤差を含む需要予測に基づき、応答時間や利用可能 CPU 量などのサービスレベルやシステム要件を満たしながら、全体コストなど最適化するための計算資源の割り当てが行われる。ハイブリッドクラウド環境を対象とした場合、仮想サーバの利用率が一定以下になるように制約を設けながら全体コストを最小化する仮想サーバ割り当て手法 [5]、計算資源の必要量を確保しながら仮想サーバのコストを最小化するプロビジョニング [6]、ビデオストリーミングについてデータのキャッシュやレプリケーション負荷を最小化し利用効率を高めるデータ分散処理手法 [7] が提案されている。このような計算資源の最適配置では、従来、代表的パブリッククラウドの課金時間間隔 [8] にあわせて時間単位の制御が行われてきた。しかし、分単位での従量課金が提供されるようになってきたことから [9,10]、今後は、計算資源の利用効率向上に向けてより短周期で制御を行うと考えられる。そのため、サービスレベルと計算資源の利用状態の関係に加え、短周期で計算資源を制御することのオーバーヘッドを考慮する必要がある。需要予測に基づき計算資源を調整する場合、短周期の需要変動や予測誤差が発生すると頻繁に制御を行う結果となり、仮想サーバの過度の起動や停止を発生させ、課金体系によってはコスト増となる。そこで、計算資源の制御量や予測誤差の影響を逐次反映するために、本稿ではモデル予測制御 [11] を適用する。

計算資源配備へのモデル予測制御の適用例として、応答時間偏差と仮想サーバ数や制御回数を考慮した仮想サーバのオートスケール手法 [12,13]、キューイング遅延とサーバの電力消費や制御回数を考慮したサーバクラスタのプロビジョニング手法 [14] などが提案されている。ここでは、システム性能と制御回数との関係が示されているが、ビジネスクリティカルシステムへ適用する場合、性能面に加え可用性を考慮する必要がある。また、ビジネスクリティカルシステムでは、他事業者のシステムによる擾乱を排除するため、一サービス事業者で物理サーバを専有することが多く、また、パブリックデータセンタから物理サーバも提供されるようになったが [15]、物理サーバは仮想サーバよりさらに資源配備に時間を要する。一般に、仮想サーバの配備には数分以上、物理サーバの配備には数 10 分以上のリードタイムが必要と考えられるが、このようなリードタイムの影響について従来研究では考慮されていない。

本稿では、従来はプライベートデータセンタで構築されてい

たビジネスクリティカルシステムをハイブリッドクラウド環境へ拡張するため解析モデルを構築し、モデル予測制御に伴う予測誤差の影響を評価する。まず、システム形態と制御フローを示したあと、モデル予測制御を適用するための評価関数、制約条件を示す。複数の実システムのトレースデータを用いて、提案モデルの評価を行い、予測誤差がある状況でもモデル予測制御により割り当てが最適化され得ることを示す。

以下、2. 章ではハイブリッドクラウドシステムの構成と制御フローを説明する。3. 章において計算資源割り当て評価モデルを提案し、4. 章で評価結果を説明する。最後に 5. 章で本稿のまとめと今後の課題を述べる。

2. ハイブリッドクラウドシステムの概要

本稿では、ビジネスクリティカルシステムをプライベートおよびパブリックデータセンタの二センタに分散して配置する構成とし、そのうちパブリックデータセンタでは需要量に合わせて計算資源量をオンデマンドで調整する (図 1)。パブリックデータセンタにおいても、プライベートデータセンタと同様、一サービス事業者が物理サーバを専有する。ただし、プライベートデータセンタにおける物理サーバ台数は固定、パブリックデータセンタにおける物理サーバ台数は可変とする。一方、仮想サーバ台数は両センタともに可変とする。各データセンタにおけるロードバランス、ファイアウォール、データベースは固定的に利用するため、以降では計算資源として物理サーバおよび仮想サーバを対象とする。各アプリケーションシステムは、プライベートデータセンタおよびパブリックデータセンタに仮想サーバを一台ずつ配備した状態を最小構成とし、需要増加に応じてプライベートデータセンタの物理サーバに対して、さらにパブリックデータセンタの物理サーバに対して、仮想サーバを順に割り当てる。需要の減少時は逆の順とする。

次に、計算資源の制御フローについて説明する。本稿では、計算資源の構成変更を行う制御時間区間をタイムスロットと呼ぶ。モデル予測制御 [11] では、図 2 に示すように、現在時刻から数タイムスロットを予測区間 (prediction horizon) として計算資源への需要予測を行い、利用率などの指標値が予測区間において最適化されるよう計算資源の配置を推定する。計算資源の制御については、一般的なモデル予測制御の場合は 1 タイムスロット先の制御を行うが、本稿では、仮想サーバおよび物理サーバの配備までのリードタイムを考慮して、複数タイムスロット先の制御を行う。具体的には、計算資源配備計画のための計算時間、プライベートデータセンタにおける仮想サーバの起動や設定に必要な時間、パブリックデータセンタからの物理サーバ提供時間 [15] および仮想サーバの起動や設定の時間、仮想サーバ起動後の他システムとの接続確立時間などを考慮して、タイムスロットの大きさを 10 分とし、仮想サーバおよび物理サーバの配備までのリードタイムを、それぞれ 10 分および 20 分とする。つまり、現在時刻において 2 タイムスロット先の仮想サーバの配備および 3 タイムスロット先の物理サーバの配備を決定する。各タイムスロットにおいては、制御の結果発生した新たな誤差を加味して同様の制御を繰り返す。

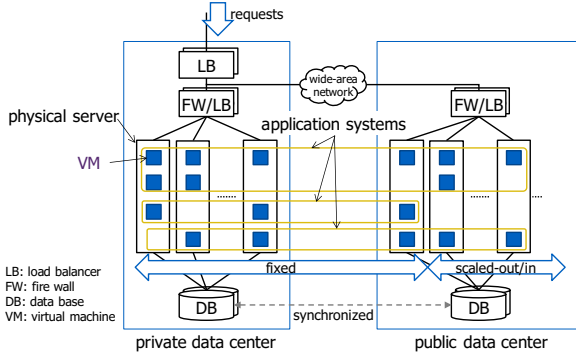


図1 ハイブリッドクラウドシステムの概要

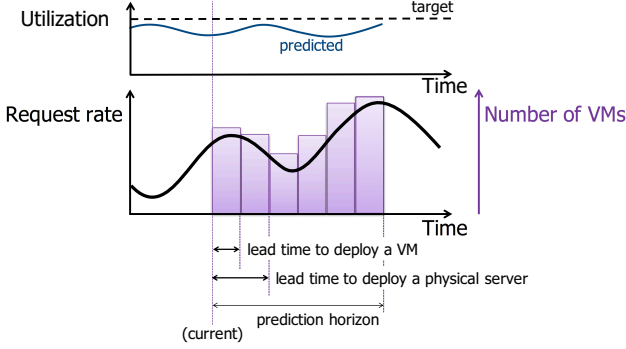


図2 モデル予測制御の概要

3. 計算資源配備のモデル

3.1 変数および定数の定義

タイムスロット $t (t = 1, 2, \dots, T)$ における物理サーバや仮想サーバの状態を記述するための定数や変数を以下に定める。

- M_{pr} : プライベートデータセンタの物理サーバ台数 (定数)。
- $M_{pb}(t)$: パブリックデータセンタの物理サーバ台数 (変数)。
- n_{vm} : 物理サーバ一台あたりの仮想サーバ台数 (定数)。
- $n_{ij}(t)$: 物理サーバ $i (i = 1, \dots, M_{pr} + M_{pb}(t))$ において、アプリケーションシステム $j (j = 1, \dots, K)$ を構成する仮想サーバの割り当て台数 (変数)。($n_{ij}(t) \geq 1 (i = 1, M_{pr} + 1), n_{ij}(t) \geq 0$ (otherwise))
- $\lambda_j(t)$: アプリケーションシステム j が処理するリクエスト受信率 (リクエスト数/秒) (変数)。予測値は $\hat{\lambda}_i(t)$ とする。
- μ_j : 仮想サーバのアプリケーションシステム j に対する処理性能 (リクエスト数/秒) (定数)。プライベートデータセンタおよびパブリックデータセンタで同一とする。
- C_j : アプリケーションシステム j における仮想サーバの利用率しきい値 (定数)。
- d_j : アプリケーションシステム j の 1 リクエストあたりのデータ量 (定数)。

次に、プライベートデータセンタにおけるコスト算出のための定数を以下に定義する。

- c_{pr} : 物理サーバのタイムスロットあたりのリース費用。
- p_{ps} : 物理サーバあたりの消費電力。

- c_{ec} : タイムスロットあたりの電力料金。
- e : エネルギー比例係数 [16]。

さらに、パブリックデータセンタにおけるコスト算出のための定数を以下に定義する。

- c_{pb} : 物理サーバのタイムスロットあたりの利用コスト。
- c_{tr} : 単位データ量あたりのデータ転送コスト。

3.2 評価関数

タイムスロット t における全体コストを、計算資源配備に関するコスト ($R(t)$)、障害発生時のサービス性能低下により失われるコスト ($\alpha F(t)$)、計算資源の操作に関するコスト ($\beta O(t)$) の合計値で表す。この全体コストをタイムスロット $t+1$ からタイムスロット $t+h$ の区間において最小化することを目的とする。なお、 h は定数である。

Objective: minimize

$$\sum_{\tau=t+1}^{t+h} (R(\tau) + \alpha F(\tau) + \beta O(\tau)) \quad (1)$$

上記目的関数の α と β は、障害時のサービス性能低下量 ($F(t)$) と計算資源の操作量 ($O(t)$) を、それぞれコストに換算する時の重み付けのための定数である。計算資源コストとの比較においてどの程度の影響を持つ可能性があるかを考慮して定める。各項の詳細は以降で説明するが、計算資源コストを下げるために仮想サーバを物理サーバ上に高密度に配置すると障害によるサービス性能低下量が大きくなるため、 $R(\tau)$ と $F(\tau)$ はトレードオフ関係にある。また、オーバプロビジョニングによる計算資源コストの増加を防ぐためには仮想サーバを高頻度に操作する必要があり、 $R(\tau)$ と $O(\tau)$ もトレードオフ関係にある。

3.2.1 計算資源配備に関するコスト

物理サーバおよび仮想サーバの配備に関するコスト ($R(\tau)$) は、プライベートデータセンタでのコスト ($R_{pr}(\tau)$) とパブリックデータセンタでのコスト ($R_{pb}(\tau)$) の和とする。

$$R(\tau) = R_{pr}(\tau) + R_{pb}(\tau) \quad (2)$$

a) プライベートデータセンタの計算資源コスト

プライベートデータセンタの計算資源コストは、物理サーバの調達コストと稼働時の電力コストの合計とする。電力コストは、エネルギー比例特性 [16] を仮定して定める。

$$R_{pr}(\tau) = c_{pr} M_{pr} + c_{ec} p_{ps} \left((1-e) \sum_{i=1}^{M_{pr}} \left[\frac{\sum_{j=1}^K n_{ij}(\tau)}{n_{vm}} \right] + e \sum_{i=1}^{M_{pr}} \sum_{j=1}^K \frac{n_{ij}(\tau)}{n_{vm}} \right) \quad (3)$$

上式右辺第二項の電力コストは、物理サーバの稼働に必要な固定的な電力と、仮想サーバ稼働台数に比例する電力からなる。

b) パブリックデータセンタの計算資源コスト

パブリックデータセンタの計算資源コストは、物理サーバの利用コストとデータの転送コストの合計とする。データ転送コストに関して、リクエスト数はアプリケーションシステムにお

いて全仮想サーバに均等に分散されることを前提とする。

$$R_{pb}(\tau) = c_{pb}M_{pb}(\tau) + c_{tr} \sum_{j=1}^K \frac{d_j \hat{\lambda}_j \delta \sum_{i=M_{pr}+1}^{M_{pr}+M_{pb}(\tau)} n_{ij}(\tau)}{\sum_{i=1}^{M_{pr}+M_{pb}(\tau)} n_{ij}(\tau)} \quad (4)$$

上記の δ はタイムスロットの時間幅である。なお、プライベートデータセンタとパブリックデータセンタ間の広域ネットワークのコストは、ハイブリッドクラウド環境以外のアプリケーションと共有し、かつ、定額料金と仮定して計上していない。

3.2.2 障害によるサービス性能の低下量

物理機器の多重障害の発生頻度は単一障害に比較して極めて小さいため、単一障害を対象とする。物理サーバ単体の障害は、割り当てられている複数仮想サーバの多重障害となって現れ、一つのアプリケーションシステムにおいて複数の仮想サーバが同時に障害になると、サービス回復時間が長期化するリスクがある。そこで、便宜的にサービス回復時間は同時に障害となる仮想サーバ数の二乗に比例すると仮定し [17]、障害によるサービス性能の低下量を下記式で定義する。

$$F(\tau) = \sum_{j=1}^K \gamma_j \sum_{i=1}^{M_{pr}+M_{pb}(\tau)} n_{ij}(\tau)^2 \quad (5)$$

上式において、 γ_j はアプリケーションシステム j の重み付けのための定数である。式 (5) は、一つのアプリケーションシステムにおいて、仮想サーバが割り当てられている物理サーバ数が少ないほど、また、仮想サーバが分散して物理サーバに割り当てられ同時に障害となる数が少ないほど、サービス低下量は小さくなることを表す。

3.2.3 計算資源の操作量

計算資源の操作量は、タイムスロット τ に起動停止される物理サーバ数、および、新規割り当て、マイグレーション、削除される仮想サーバ数の総和とする。

$$O(\tau) = \left(\sum_{i=1}^{M_{pr}} \left[\frac{\sum_{j=1}^K n_{ij}(\tau)}{n_{vm}} \right] - \sum_{i=1}^{M_{pr}} \left[\frac{\sum_{j=1}^K n_{ij}(\tau-1)}{n_{vm}} \right] \right) + (M_{pb}(\tau) - M_{pb}(\tau-1)) + \sum_{i=1}^{M_{pr}+M_{pb}(\tau)} \sum_{j=1}^K |n_{ij}(\tau) - n_{ij}(\tau-1)| \quad (6)$$

上式右辺第一項はプライベートデータセンタにおける物理サーバの操作量、第二項はパブリックデータセンタにおける物理サーバの操作量、第三項は仮想サーバの操作量である。

3.3 制約条件

時刻 τ における制約条件として以下を定める。

Subject to:

$$\sum_{k=1}^K n_{ij}(\tau) \leq n_{vm} \quad (\forall i \in \{1, \dots, M_{pr} + M_{pb}(\tau)\}) \quad (7)$$

$$\frac{\hat{\lambda}_j(\tau)}{\mu_j \sum_{i=1}^{M_{pr}+M_{pb}(\tau)} n_{ij}(\tau)} \leq C_j \quad (\forall j \in \{1, \dots, K\}) \quad (8)$$

制約 (7) は、一つの物理サーバにおける仮想サーバ数の合計が定数 n_{vm} 以下であることを示す。制約 (8) は、一つのアプリケーションシステムの利用率が定数 C_j 以下であることを示す。

3.4 リクエスト受信率の予測

本節では、タイムスロット t における各サービスのリクエスト受信率 $\lambda_j(t)$ を x_t と表記する。 h タイムスロット先の予測値 \hat{x}_{t+h} の予測には、季節変動(周期性)を考慮した ARIMA(自己回帰和分移動平均)モデル [18] を適用する。ラグ演算子 B を $Bx_t = x_{t-1}$ と定義して、 $y_t = (1-B)^d(1-B^s)^D x_t$ と変換し、 x_t に対し d 階差分演算および D 階季節差分演算を行い定常化した時系列 y_t を定める。 s は周期変動の期間である。系列 y_t は、過去のデータと誤差の多項式として次のように表される

$$y_t = \sum_{v=1}^p \phi_v B^v y_t + (1 + \sum_{w=1}^q \theta_w B^w) \epsilon_t \quad (9)$$

右辺第一項は p 次自己回帰過程、第二項は q 次移動平均過程を表し、 ϕ_v, θ_w は係数である。 ϵ_t は誤差項であり、 $\epsilon_t \sim N(0, \sigma^2)$ に従う白色雑音である。モデルの次数や係数は、過去 k 個の観測値 y_{t-k+1}, \dots, y_t に対し、最尤推定および赤池情報量基準 (AIC) を適用することにより求める。タイムスロット t における 1 タイムスロット先のタイムスロット $t+1$ の予測値 \hat{y}_{t+1} は、式 (9) において t を $t+1$ と置き換え、誤差項予測値 $\hat{\epsilon}_{t+1} = 0$ とし、観測された値および誤差を代入することで計算できる。 y_{t+1} の分布は $N(\hat{y}_{t+1}, \sigma^2)$ に従う。また、 y_{t+h} を $y_{t+h} = \sum_{u=0}^{\infty} \psi_u \epsilon_{t+h-u}$ (ψ_u は観測値より算出されるパラメータ。 $\psi_0 = 1$) と表した時、 y_{t+h} の分布は、 $N(\hat{y}_{t+h}, \sigma^2 \sum_{u=0}^{h-1} \psi_u^2)$ に従う。

4. 評価

目的関数 (1) は、物理サーバ i に関して最適性の原理が成立するため、仮想サーバの割り当て台数 $n_{ij}(\tau)$ の算出に動的計画法 [19] を用いる。また、計算時間を考慮し、目的関数 (1) において $h = 4$ と設定した。

4.1 条件設定

a) データセット

評価では、次の三つの実アプリケーションシステムのそれぞれ約 3 ヶ月間のトレースデータを用いた。各データの初期時刻を時刻 0 として一致させてシミュレーション用データとした。

- キャンパスウェブ: 3 万人規模の大学における大学ウェブサイトへの HTTP リクエストログ (2014 年 4 月 1 日~2014 年 6 月 26 日) (7.8KB/リクエスト)
- ビデオウェブ: 国内大規模ネットワークのゲートウェイにおけるビデオサイトへの HTTP リクエストログ (2015 年 9 月 12 日~2015 年 12 月 7 日) (10.3MB/リクエスト [20])
- ワールドカップウェブ: 1998 年ワールドカップウェブサイトへの HTTP リクエストログ [21] (1998 年 5 月 1 日~1998 年 7 月 26 日) (4.1KB/リクエスト)

各項目の文末は、1 リクエストあたりの平均データ量 (d_j) である。キャンパスウェブとワールドカップウェブは実測値であり、ビデオウェブは文献 [20] を参考にした。

b) 物理サーバおよび仮想サーバの配備に関する定数

- プライベートデータセンタにおける物理サーバの台数 (M_{pr}) は5台とし、物理サーバ一台あたりの仮想サーバ台数 (n_{vm}) は4台とした。

- 各ウェブシステムにおける仮想サーバの処理性能 (μ_j) は、リクエスト受信率中央値の1/4とした。つまり、キャンパスウェブでは0.5リクエスト/秒、ビデオウェブでは0.2リクエスト/秒、ワールドカップウェブで156リクエスト/秒とした。

- 仮想サーバの利用率しきい値 (C_j) は、全てのウェブシステムで0.5とした。

c) 全体コスト算出のための定数

タイムスロットの大きさを前述のように10分とし、下記のように各定数はタイムスロットあたりの値として定めた。

- プライベートデータセンタにおいて、物理サーバ (CPU:1ソケット4コア、メモリ:32GB) のリース期間を3年とし、セットアップ工数など含むコストはハードウェアコストの2倍として算出した。つまり、 $c_{pr} = 379,411 [22] \times 2$ 円/台・3年 = 4.8円/台・タイムスロットとした。

- プライベートデータセンタの電力料金 (c_{ec}) は、18.12円/kWh [23] = 3×10^{-3} 円/W・タイムスロットとし、物理サーバあたりの電力 (p_{ps}) は350W [22]、エネルギー比例係数 (e) は0.6とした [16]。

- パブリックデータセンタから、プライベートデータセンタと同様の性能の物理サーバインスタンスを選択した。為替レートを1ドル=103.58円とし、 $c_{pb} = 0.717$ ドル/台・時 [15] = 12円/台・タイムスロットとした。

- パブリックデータセンタにおけるデータ転送コストは、0.09ドル/GB [15] = 9.3×10^{-9} 円/Bとした。

- 障害によるサービス性能の低下量 (式 (5)) における重み付けのための定数 γ_j は全て1とした。

4.2 評価結果

a) リクエスト受信率予測値

各アプリケーションシステムのリクエスト受信率 ($\lambda_j(t)$) の季節変動周期を1週間とし、リクエスト受信率に対し対数変換を行った上で、各タイムスロットにおいて前3週間分のデータを用いて (p, q) 値を求め予測値 ($\hat{\lambda}_j(t)$) を算出した。ARIMAモデルの選択では、 $0 \leq p \leq 5, 0 \leq q \leq 5$ の範囲からAICを最小とする (p, q) を選んだ [18]。図3に、予測誤差としてMAPE (Mean Absolute Percentage Error) = $\frac{1}{T} \sum_{t=1}^T \frac{|\lambda_j(t) - \hat{\lambda}_j(t)|}{\lambda_j(t)}$ を示す。予測誤差が大きいことからキャンパスウェブシステムに着目し、ある1日におけるリクエスト受信率の実測値と3タイムスロット先までの予測値を図4に示した。なお、リクエスト受信率は、仮想サーバの処理性能を単位とした値として示している。リクエスト受信率が大きくなるほど予測値の誤差は大きくなり、また、1タイムスロット先、2タイムスロット先、3タイムスロット先の順に、僅かであるが予測誤差は大きくなる。

b) システム利用率

図4に対応するキャンパスウェブシステムの利用率を図5に示す。システム利用率では、予測誤差の無い場合 (*ideal*)、物理・仮想サーバの配備までのリードタイムが無い場合 (*no lead*




図3 リクエスト受信率予測誤差

time)、提案手法 (物理サーバ配備のリードタイム:3タイムスロット、仮想サーバ配備のリードタイム:2タイムスロット) で目的関数 (1) において ($\alpha = 0, \beta = 0$) とした場合、および、($\alpha = 0, \beta = 1$) とした場合を示している。

予測誤差の無い場合は、図4の実測値を用いて割り当てを行う。システム利用率は、タイムスロット10から50以外でほぼしきい値0.5となり、タイムスロット10から50でも他に比べ高くなる。リードタイムの無い場合は、図4の1タイムスロット先の予測値を用いて割り当てを行う。タイムスロット毎にリクエスト受信率が変動するためタイムスロット毎に割り当てが変更され、予測誤差のためシステム利用率が頻繁にしきい値0.5を大きく超える。提案手法では、3タイムスロット先予測値を用いて物理サーバを割り当て、2タイムスロット先予測値を用いて仮想サーバを割り当てる。($\alpha = 0, \beta = 0$) の場合は、リードタイムの無い場合と同様であり、予測誤差が大きくなる分だけ利用率しきい値からの偏差が大きくなる。

一方、提案手法で ($\alpha = 0, \beta = 1$) とした場合は、操作をオーバーヘッド (コスト) として考慮することになるので操作回数が減少する。これは、物理および仮想サーバ数の台数を減らさない方向に作用し、結果的に利用率しきい値を超える回数やしきい値からの偏差が緩和される。図6にタイムスロットあたりの計算資源配備に関するコスト ($R(t)$) および操作量に関するコスト ($O(t)$) 示すが、($\alpha = 0, \beta = 0$) に対して ($\alpha = 0, \beta = 1$) とした場合、操作量 ($O(t)$) が減少する。一方、操作量を考慮することは、システム利用率を低くする方向にも働くが、ほとんどのタイムスロットにおいて、物理サーバ台数の変更なしに仮想サーバの台数変更や移動を抑制することとして作用したため、計算資源配備に関するコストの増加は僅かであった。

また、提案手法において ($\alpha = 1, \beta = 0$) とし、障害によるサービス性能の低下 ($F(t)$) を考慮すると、($\alpha = 0, \beta = 0$) に比較し、物理サーバに対して仮想サーバが分散配置される。ただし、この設定では、仮想サーバの配置のみ変更され台数は変更されることが多く、($\alpha = 0, \beta = 0$) と比較して、システム利用率の変化や計算資源コストの増加はほとんど発生しなかった。

5. おわりに

本稿では、ビジネスクリティカルシステムを対象として、ハイブリッドクラウド環境における計算資源の最適配備のための解析モデルの構築と評価を行った。モデル予測制御を適用し、

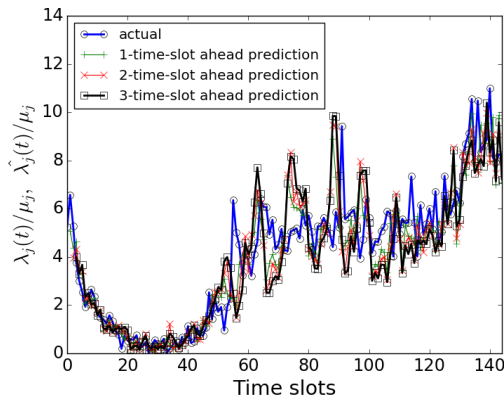


図4 キャンパスウェブシステムにおけるリクエスト受信率

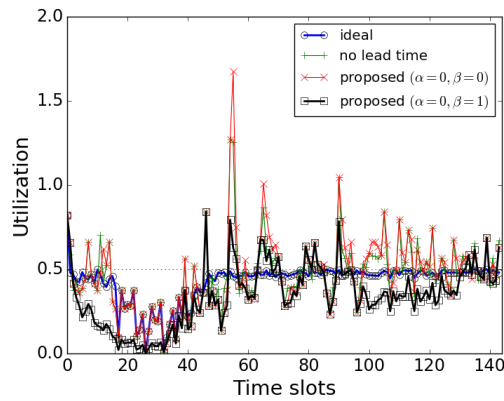


図5 キャンパスウェブシステムの利用率




図6 全体コスト

操作量をコストとして考慮することで、計算資源の制御回数が抑制され、結果的にリクエスト受信率の予測誤差に起因する高システム利用率が緩和されること、また、本稿の条件設定であれば、計算資源のコストはほぼ変化しないことを示した。今後の課題として、目的関数 (1) における重み付け定数 α 、 β や h を網羅的に変化させることにより、パレート最適となる状態を明示的に示すことが挙げられる。

文献

[1] M. Armbrust, A. Fox, R. Griffith, A.D. Joseph, R.H. Katz, A. Konwinski, G. Lee, D.A. Patterson, A. Rabkin, I. Stoica, and M. Zaharia, “Above the clouds: A berkeley view of

cloud computing,” Technical Report UCB/EECS-2009-28, University of California, Berkeley, Feb. 2009.

[2] J. Barr, “Cloudbursting - hybrid application hosting,” <https://aws.amazon.com/jp/blogs/aws/cloudbursting/>, Aug. 2008. accessed June 9, 2016.

[3] A.R. Hummada, N.W. Paton, and R. Sakellariou, “Adaptation in cloud resource configuration: A survey,” *J. Cloud Comput.*, vol.5, no.1, pp.57:1–57:16, Dec. 2016.

[4] T. Lorida-Botran, J. Miguel-Alonso, and J.A. Lozano, “A review of auto-scaling techniques for elastic applications in cloud environments,” *J. Grid Comput.*, vol.12, no.4, pp.559–592, Dec. 2014.

[5] M. Bjorkqvist, L.Y. Chen, and W. Binder, “Cost-driven service provisioning in hybrid clouds,” *Proc. of 2012 5th IEEE SOCA*, pp.1–8, Dec. 2012.

[6] T. Guo, U. Sharma, P. Shenoy, T. Wood, and S. Sahu, “Cost-aware cloud bursting for enterprise applications,” *ACM Trans. Internet Technol.*, vol.13, no.3, pp.10:1–10:24, May 2014.

[7] H. Zhang, G. Jiang, K. Yoshihira, and H. Chen, “Proactive workload management in hybrid cloud computing,” *IEEE Trans. Netw. Service Manag.*, vol.11, no.1, pp.90–100, March 2014.

[8] Amazon Web Services, “Amazon EC2 Pricing,” <http://aws.amazon.com/ec2/pricing/>. accessed Sept. 15, 2016.

[9] Microsoft Azure, “Azure Pricing,” <https://azure.microsoft.com/en-us/pricing/>. accessed Sept. 15, 2016.

[10] Google Cloud Platform, “Google Compute Engine Pricing,” <https://cloud.google.com/compute/pricing>. accessed Sept. 15, 2016.

[11] J.M. Maciejowski, *Predictive control: with constraints*, Pearson education, 2002.

[12] N. Roy, A. Dubey, and A. Gokhale, “Efficient autoscaling in the cloud using predictive models for workload forecasting,” *Proc. of IEEE CLOUD*, pp.500–507, July 2011.

[13] H. Ghanbari, B. Simmons, M. Litoiu, C. Barna, and G. Iszlai, “Optimal autoscaling in a IaaS cloud,” *Proc. of Int. Conf. on Autonomic Computing*, pp.173–178, Sept. 2012.

[14] Q. Zhang, M.F. Zhani, S. Zhang, Q. Zhu, R. Boutaba, and J.L. Hellerstein, “Dynamic energy-aware capacity provisioning for cloud computing environments,” *Proc. of the 9th Int. Conf. on Autonomic Computing*, pp.145–154, Sept. 2012.

[15] SoftLayer Technologies, Inc., <http://www.softlayer.com>. accessed Oct. 11, 2016.

[16] D. Wong and M. Annavaram, “Knightshift: Scaling the energy proportionality wall through server-level heterogeneity,” *Proc. of IEEE/ACM Int. Symposium on Microarchitecture*, pp.119–130, Dec. 2012.

[17] P. Bodík, I. Menache, M. Chowdhury, P. Mani, D.A. Maltz, and I. Stoica, “Surviving failures in bandwidth-constrained datacenters,” *Proc. of the ACM SIGCOMM Conf.*, pp.431–442, Aug. 2012.

[18] R.J. Hyndman and G. Athanasopoulos, “Forecasting: principles and practice,” <https://www.otexts.org/book/fpp>. accessed May 10, 2015.

[19] S.S. Skiena, *The algorithm design manual: Second Edition*, Springer Science & Business Media, 1998.

[20] P. Gill, M. Arlitt, Z. Li, and A. Mahanti, “Youtube traffic characterization: A view from the edge,” *Proc. of ACM SIGCOMM Conf.*, pp.15–28, Jan. 2007.

[21] The Internet Traffic Archive, “1998 world cup web site access logs,” <http://ita.ee.lbl.gov/html/contrib/WorldCup.html>. accessed Nov. 19, 2014.

[22] Dell Inc., “PowerEdge R330,” <http://www.dell.com/jp/business/p/poweredge-r330/pd>. accessed Oct. 19, 2016.

[23] 北海道電力(株), <http://www.hepco.co.jp/business/price/unitprice/unitprice04.html>. accessed Oct. 19, 2016.