

都鳥: メモリキャッシュによる ライブマイグレーションの高速化


第30回仮想化実装技術勉強会

2011年12月19日

穂山空道 (東大 情報理工 創造情報 M2)


背景: VMの動的再配置によるクラウド効率化(1/2)

- Dynamic VM Consolidation[1]
 - 低負荷 → 共有サーバに集約し電力削減
 - 高負荷 → 分散配置し性能保障




背景: VMの動的再配置によるクラウド効率化(1/2)

- Dynamic VM Consolidation[1]
 - 低負荷 → 共有サーバに集約し電力削減
 - 高負荷 → 分散配置し性能保障



背景: VMの動的再配置によるクラウド効率化(2/2)

- Memory Buddies[2]
 - メモリの似たVMを集約しメモリ共有→メモリ使用量削減




- SnowBird[3]
 - VMがデスクトップ、計算ノード、データベース間を移動→アプリケーション実行時間削減

[2] Interactive Resource-Intensive Application Made Easy, *Middleware2007*, Largar-Cavilla et al.
[3] Memory Buddies: Exploiting Page Sharing for Smart Collocation in Virtualized Data Centers, *VEE2009*, Wood et al.


Pre-copy Live Migration [4]

- 全メモリをコピーした後、実行ホストを移動
 - コピー中に更新されたメモリ → 再コピー
 - コピー量が十分減少 → VMを停止し残りをコピー




Pre-copy Live Migration [4]

- **全メモリをコピー**した後、実行ホストを移動
 - コピー中に更新されたメモリ → 再コピー
 - コピー量が十分減少 → VMを停止し残りをコピー




Pre-copy Live Migration [4]

- **全メモリをコピー**した後、実行ホストを移動
 - コピー中に更新されたメモリ → 再コピー
 - コピー量が十分減少 → VMを停止し残りをコピー




Pre-copy Live Migration [4]

- **全メモリをコピー**した後、実行ホストを移動
 - コピー中に更新されたメモリ → 再コピー
 - コピー量が十分減少 → VMを停止し残りをコピー



Post-copy Live Migration [5][6]

- 実行ホストを移動した後、**全メモリをコピー**
 - ページフォールトによるon-demandなコピー
 - バックグラウンドでのコピー




[5] SnowFlock: Rapid Virtual Machine Cloning for Cloud Computing, *EuroSys2008*, Largar-Cavilla *et al.*

[6] Enabling Instantaneous Relocation of Virtual Machines with a Lightweight VMM Extension, *CCGrid2010*, Hirofuchi *et al.*

Post-copy Live Migration [5][6]

- 実行ホストを移動した後、**全メモリをコピー**
 - ページフォールトによるon-demandなコピー
 - バックグラウンドでのコピー




[5] SnowFlock: Rapid Virtual Machine Cloning for Cloud Computing, *EuroSys2008*, Largar-Cavilla *et al.*

[6] Enabling Instantaneous Relocation of Virtual Machines with a Lightweight VMM Extension, *CCGrid2010*, Hirofuchi *et al.*

Post-copy Live Migration [5][6]

- 実行ホストを移動した後、**全メモリをコピー**
 - ページフォールトによるon-demandなコピー
 - バックグラウンドでのコピー




[5] SnowFlock: Rapid Virtual Machine Cloning for Cloud Computing, *EuroSys2008*, Largar-Cavilla *et al.*

[6] Enabling Instantaneous Relocation of Virtual Machines with a Lightweight VMM Extension, *CCGrid2010*, Hirofuchi *et al.*

Post-copy Live Migration [5][6]

- 実行ホストを移動した後、**全メモリをコピー**
 - ページフォールトによるon-demandなコピー
 - バックグラウンドでのコピー




[5] SnowFlock: Rapid Virtual Machine Cloning for Cloud Computing, *EuroSys2008*, Largar-Cavilla et al.

[6] Enabling Instantaneous Relocation of Virtual Machines with a Lightweight VMM Extension, *CCGrid2010*, Hirofuchi et al.

Post-copy Live Migration [5][6]

- 実行ホストを移動した後、**全メモリをコピー**
 - ページフォールトによるon-demandなコピー
 - バックグラウンドでのコピー



[5] SnowFlock: Rapid Virtual Machine Cloning for Cloud Computing, *EuroSys2008*, Largar-Cavilla et al.

[6] Enabling Instantaneous Relocation of Virtual Machines with a Lightweight VMM Extension, *CCGrid2010*, Hirofuchi et al.

Live Migrationの問題点

- 全メモリを転送する
 - VMのメモリサイズは小さい(一般に数GB)
 - 長いマイグレーション時間(メモリサイズ/帯域幅)




1. マイグレーション中はアプリケーションパフォーマンス↓
(workloadによって8%~30% [7])
2. サーバ集約時に複数のマイグレーション受け入れが同時に起こりやすくなる [8]

[7] Live Migration of Multiple Virtual Machines with Resource Reservation in Cloud Computing Environments, *IEEE CLOUD 2011*, Ye et al.

[8] Performance Modeling of Concurrent Live Migration Operations in Cloud Computing Systems using PRISM Probabilistic Model Checker, *IEEE CLOUD 2011*, Kikuchi et al.

Memory Reusing: 着想

- VMの全メモリをコピーすることはコスト大（特に積極的な再配置環境下）
 - ポイント: VMが動的再配置されるとき、VMは一度実行されたホストに戻ってくる可能性
- ⇒ 更新されていないメモリページを再利用！




Memory Reusing: 着想

- VMの全メモリをコピーすることはコスト大（特に積極的な再配置環境下）


– ポイント: VMが動的再配置されるとき、VMは一度実行されたホストに戻ってくる可能性

➡ 更新されていないメモリページを再利用！



Memory Reusing: 着想

- VMの全メモリをコピーすることはコスト大（特に積極的な再配置環境下）
 - ポイント: VMが動的再配置されるとき、VMは一度実行されたホストに戻ってくる可能性
- ⇒ 更新されていないメモリページを再利用！




Memory Reusing: 着想

- VMの全メモリをコピーすることはコスト大（特に積極的な再配置環境下）

– ポイント: VMが動的再配置されるとき、VMは一度実行されたホストに戻ってくる可能性

➡ 更新されていないメモリページを再利用！



Memory Reusing: アルゴリズム

1. メモリページの世代
 - VMの起動時に0初期化
 - マイグレーション毎に更新ページの世代を+1
2. VMの移動時、移動元にメモリをキャッシュ
3. VMが戻ってくる時、キャッシュの世代と最新の世代を比較
 - 世代が同じページ → 再利用
 - 世代が違うページ → ネットワーク越しにコピー

実装: 都鳥




- QEMU 0.13.0, KVMを利用
 - 変更前: 全メモリページを転送
 - 変更後: 更新されたページのみ転送(pre, post両方式に対応)
- 世代管理サーバを開発
 - 既存VMMへの変更を少なく
- 詳細
 - 世代は4バイト符号なし整数(実用上十分)
 - ホストはIPアドレスで区別
 - VMはuuidで区別

} (VM, host)の組が、hostにある
VMのメモリキャッシュを表す


都鳥の動作: 最初のマイグレーション

0. VMが動作中



都鳥の動作: 最初のマイグレーション

1. VMを停止



都鳥の動作: 最初のマイグレーション

1. VMを停止




2. 世代をインクリメント

$(VM, A) = [0, 1, 1, 1, 0, 0]$
 $(VM, B) = [*, *, *, *, *, *]$


世代管理サーバ

ホストA → ホストB


都鳥の動作: 最初のマイグレーション




都鳥の動作: 戻るマイグレーション




都鳥の動作: 戻るマイグレーション




都鳥の動作: 戻るマイグレーション




都鳥の動作: 戻るマイグレーション




都鳥の動作: 戻るマイグレーション



都鳥の動作: 戻るマイグレーション



都鳥の動作: 戻るマイグレーション



実験: 目的と環境

- マイクロベンチマーク (pre)
 - ページ書き込み速度と再利用率の関係
 - (Xeon X5460, 8GB memory, GibEthernet , QEMU 0.13.0, Linux 2.6.32, KVM 2.6.32)×3
- アプリケーションベンチマーク (pre/post)
 - Webサーバワークロードをシミュレート
 - (Phenom II X4 955, 4GB memory, QEMU 0.13.0, Linux 2.6.32, KVM 2.6.38)×1
KVMのバグのため

ゲストはともにUbuntu 10.10 server, 1GB memory

マイクロベンチマーク(1/2)

1. ホストAで500MBのランダムデータを用意
2. ホストAからホストBへマイグレーション
3. データを更新(三種類の速度)
 - 200 pages/s, 1000 pages/s, 5000 pages/s
4. 30秒後にホストBからホストAに戻る



ホストA



ホストB

マイクロベンチマーク(1/2)

1. ホストAで500MBのランダムデータを用意
2. ホストAからホストBへマイグレーション
3. データを更新(三種類の速度)
 - 200 pages/s, 1000 pages/s, 5000 pages/s
4. 30秒後にホストBからホストAに戻る



マイクロベンチマーク(1/2)

1. ホストAで500MBのランダムデータを用意
2. ホストAからホストBへマイグレーション
3. データを更新(三種類の速度)
 - 200 pages/s, 1000 pages/s, 5000 pages/s
4. 30秒後にホストBからホストAに戻る

メモリキャッシュ



ホストA



ホストB

マイクロベンチマーク(1/2)

1. ホストAで500MBのランダムデータを用意
2. ホストAからホストBへマイグレーション
3. データを更新(三種類の速度)
 - 200 pages/s, 1000 pages/s, 5000 pages/s
4. 30秒後にホストBからホストAに戻る



ホストA





帰り



ホストB


マイクロベンチマーク(2/2)



- 低速更新時: 転送量、移動時間共に9割以上の削減
- 高速更新時: 削減率が下がるものの5割ほど削減


アプリケーションベンチマーク(1/2)

1. 256KiB × 1024個の静的htmlをapacheで公開
2. 100接続/sで10周読み込み(約100秒)
3. 30秒後にA→B、さらに30秒後B→A




アプリケーションベンチマーク(1/2)

1. 256KiB × 1024個の静的htmlをapacheで公開
2. 100接続/sで10周読み込み(約100秒)
3. 30秒後にA→B、さらに30秒後B→A




アプリケーションベンチマーク(1/2)

1. 256KiB × 1024個の静的htmlをapacheで公開
2. 100接続/sで10周読み込み(約100秒)
3. 30秒後にA→B、さらに30秒後B→A




アプリケーションベンチマーク(1/2)

1. 256KiB × 1024個の静的htmlをapacheで公開
2. 100接続/sで10周読み込み(約100秒)
3. 30秒後にA→B、さらに30秒後B→A





アプリケーションベンチマーク(1/2)

1. 256KiB × 1024個の静的htmlをapacheで公開
2. 100接続/sで10周読み込み(約100秒)
3. 30秒後にA→B、さらに30秒後B→A



アプリケーションベンチマーク(2/2)



- 9割以上の削減
- ファイル読込はメモリを更新しない(手法の適用可能領域)

関連研究

- 単発のライブマイグレーションに関する研究
 - pre-copy型の繰り返しコピーで差分のみをrun-lengthで圧縮して転送 [9]
 - メモリではなく実行ログを転送→転送量削減 [10]
 - メモリページを特性によってクラスタリングしpost-copyにおけるプリフェッチ精度を向上 [11]
- 本研究は繰り返し発生するライブマイグレーションに着目した点が異なる

[9] Evaluation of Delta Compression Techniques for Efficient Live Migration of Large Virtual Machines, VEE2011, Svärd et al.

[10] Live Migration of Virtual Machine Based on Full System Trace and Replay, HPDC2009, Liu et al.

[11] Kaleidoscope: Cloud Micro-Elasticity via VM State Coloring, EuroSys2011, Bryant et al.

今後の課題

1. メモリキャッシュの効率的な管理

- 1GBのVMを実行したホスト → 当該VMのメモリキャッシュに1GBのRAMを消費
- 単純にはあるホストで更新されたページはその他のホストのキャッシュから解放可能(∴再利用できない)

2. 実環境での評価

- 負荷に応じたサーバ集約との統合評価
- ワークロード？(検討中)

結論

- 従来のライブマイグレーションでは全メモリを転送 → 多くの転送量, 長い転送時間
- VMの積極的な再配置による最適化では問題
- VMのメモリを再利用し上記を削減
 - 実装(都鳥)により有用性が示された
- 今後の課題
 - 効率的なキャッシュ管理
 - 実環境での評価

ComSys2011でのQ&A

- 提案手法のオーバーヘッドは？
 - メモリ書き込み監視によるオーバーヘッドは実用上十分小さい(NPBで確認)
 - 移動元・移動先・世代管理サーバ間で通信するが、(メモリサイズ÷4K)ビットと小さい
- キャッシュを先に転送しておくことは可能か？
 - 可能。負荷予測が必要なため現状out of scope
- どのようなワークロードに適用？
 - ファイルキャッシュが大きいとよく効く。具体的には現在検討中。