


Real Time QEMU

Professional Service

Tatuhiko Oshima

■ QEMUは、複数のサービススレッドを生成し並行処理。

- ◆ main thread メインスレッド すべてのIOとイベントを管理
- ◆ vcpu thread ゲストOSを実行 smpで指定した数だけ生成
- ◆ paio thread ディスクIOを行うスレッド linuxのAIOを使用
- ◆ vnc thread configur時に指定すると生成する
VNCの描画処理を行う




- 総てはデフォルト固定で、無制御状態
 - ◆ スケジュール TS
 - ◆ 優先度 0
 - ◆ CPUアフィニティ 総てのスレッドは同じマスク




- 総てのリクエストは、mainスレッドが制御
- ゲストOSから発行されたディスクIOは、カーネルのAIOコールで処理される

- 空いているCPUでQEMUスレッドは実行される
- プロセスに割り付けが可能でも実行CPUは移動




- カーネルスレッドのスケジュールも必要
- キャッシュがフラッシュするので、ジッター大
- mainスレッドがスケジュールされないイベントリターンは配信されない

- プロセス単位で、公平なスケジュールを期待しているが....



- スケジュールは、スレッド単位なので、要求の多いQEMUスレッド(AIO)がスケジュールされてしまう



- Cgroup制御を行っても、Guest2のIO要求の数は減らせない(Guest1はDISKIOを使用していない)
→ プロセス単位の動的優先処理が必要

- カーネル側はRedHawkの基本機能を利用
→カーネルの変更はしない
 - ◆ RedHawkリアルタイムカーネル機能
 - Memory lock
 - Real time scheduling & priority
 - User code Preempt lock (Only RedHawk)
 - Shield CPU(Only RedHawk)
- QEMU側のみリアルタイム化する
- バージョンアップに備えて基本的な構造は変えない

■ リアルタイム化

◆ QEMUスレッド別の制御データ

■ スケジュール

SCHED_FIFO, SCHED_RR, SCHED_OTHER

■ 優先度 0(TS) or 1～99(RR or FIFO)

■ Nice値 -19～+20(TS or RR)

値でタイムクオンタムが異なる

→ 連続実行可能なCPU時間

■ CPUアフィニティ

◆ メモリロック

◆ プリエンプション禁止（QEMU連続実行を保証）


■ ハードウェア模擬部分のレイテンシ確保には必須

■ 模擬デバイスのモディファイ

- ◆ ivshmem
- ◆ Guest-Hostの通信(再起動通知、負荷率取得など)
 - ivshmemを利用して、guest側から再起動通知を行う。
 - RT-QEMU側では、再起動通知期間中、Guestの優先度を強制的にTSに設定する。
- ◆ Guest間の通信

■ 新規模擬デバイス(vrfmem)

- ◆ リフレクティブメモリ(5565)模擬デバイス
- ◆ 実デバイスとリンクし異なるホストにまたがるHost-Guest間通信を可能



■ VNC部高速化

- ◆ スレッド生成(標準搭載:configure vnc_thread="yes")
- ◆ mainスレッドで実行される、画面差分処理の高速化
 - memcmp() → sse2_memcmp()
 - memcpy() → sse2_memcpy()
- ◆ mainスレッドで実行される、画面差分処理の並列化
 - for (y=0;y<SIZE;y++) を2分割し高速化

- オプション -rtに続く最初の xxxx 4 文字はスレッドを現し、その後の _yyyyは機能を現す

- ◆ vcpu 仮想CPU
- ◆ main 管理スレッド
- ◆ paio 非同期IOスレッド
- ◆ vncm vnc メイン側スレッド (注1)
- ◆ vnscs vnc スレーブ側スレッド(注2)

- 注1 : vnc高速化スレッドパラメータ、無指定の場合には、ループ分割しない

- 注2 : configureで指定されるオリジナルスレッドパラメータ

その後の文字で、以下を現す。


- ◆ xxxx_sched スケジュール、
- ◆ xxxx_prio 優先度
- ◆ xxxx_nice nice値

- -rt vcpu_bias=3,4 -rt vcpu_sched=fifo,fifo -rt vcpu_prio=1,1 -rt vcpu_nice=0,0
- -rt main_bias=5 -rt main_sched=fifo -rt main_prio=1 -rt main_nice=0
- -rt paio_bias=6 -rt paio_sched=rr -rt paio_prio=1 -rt paio_nice=19
- -rt vnics_bias=7 -rt vnics_sched=rr -rt vnics_prio=1 -rt vnics_nice=19
- -rt vncm_bias=7 -rt vncm_sched=rr -rt vncm_prio=1 -rt vncm_nice=19

-20	800ms	-10	600ms	0	100ms	10	48ms
-19	780ms	-9	580ms	1	92ms	11	44ms
-18	760ms	-8	560ms	2	88ms	12	40ms
-17	740ms	-7	540ms	3	84ms	13	32ms
-16	720ms	-6	520ms	4	80ms	14	28ms
-15	700ms	-5	500ms	5	72ms	15	24ms
-14	680ms	-4	480ms	6	68ms	16	20ms
-13	660ms	-3	460ms	7	64ms	17	12ms
-12	640ms	-2	440ms	8	60ms	18	8ms
-11	620ms	-1	420ms	9	52ms	19	4ms

nice値テーブル


- スレッド別に割り付けが可能



- スレッド別にスケジュール&優先度を設定
- スレッド別にnice値を設定可能(タイムクオンタム)


■ 完全分離型 FIFO (最も高速に応答)

◆ サービスの応答性を重視




■ 完全共有型 RR (Nice値でサービス時間を制御)

◆ サービスの公平性を重視



- スレッド制御の効果を試験
ホスト側で同一CPUに負荷を与え、guest側でcyclic testを行う (stress --cpu 8 --io 4 --vm 2 --vm-bytes 128)
 - ◆ org:スレッドアフィニティなし優先度あり
 - ◆ mod:スレッドアフィニティあり優先度あり




■ 完全共有型の試験


同一コアにGuest1とGuest2を公平に割り付け
外部システムからGuest1にPINGを500回行う

- ◆ Normal test: Guest1, Guest2とも無負荷
- ◆ Load test : stress -cpu2 をGuest2で実行し、Guest2のCPU負荷100%×2にする

→総てのスレッドは、固定優先度1のクオンタム4ms(RR,1,NICE 19)



■ ネットワークIOレイテンシ (500回のpingの応答時間)




■ Pingの応答時間に大きな変化は無い。

■ 完全共有型の試験


同一コアにGuest1とGuest2を公平に割り付け
外部システムからGuest1にPINGを500回行う

- ◆ Normal test: Guest1, Guest2とも無負荷
- ◆ Load test : Guest2をrebootする

→総てのスレッドは、固定優先度1のクオンタム4ms(RR,1,NICE 19)




■ ネットワークIOレイテンシ（500回のpingの応答時間）



- Pingの応答時間は、4ms以下(nice19の設定)
- Pingの応答時間が大きく遅い箇所は、Guestネットワークの構成時 1 回だけ

Windows7 & DPC Latency Checker



オリジナル版



RealTime QEMU

■ RT-QEMUの特徴

- ◆ RedHawk Realtime Linuxカーネルの機能を利用し、QEMUのみのモディファイでリアルタイム化。
- ◆ カーネルのバージョンアップに迅速に対応可能。
- ◆ Guest側カーネルの変更も無い
- ◆ 十分な応答性を確保
- ◆ 用途に応じて、細かなチューニングが可能