

2 レベル保護リング環境での VMM 構築

青柳 信吾 追川 修一
筑波大学

小規模組み込み機器用の CPU の多くはカーネル用とユーザプロセス用の 2 レベルの保護リングしか持たない。しかし、現在研究されている VMM は 3 レベルの保護リング環境用のものが多く、組み込み機器に移植することが困難である。本論文では 2 レベルの保護リング環境における、ページング機構を利用した仮想保護リングによる、仮想マシン環境の構築について述べる。

Building VMM on 2-Level Ring Architecture

Shingo Aoyagi Shuichi Oikawa
University of Tsukuba

Most of the currently available embedded processors provide only two protection levels, privileged and unprivileged, at most. On the other hand, the researches and developments of VMMs are currently conducted mainly using the Intel IA-32 processor architecture, which provides four protection levels; thus, porting such VMMs to embedded processors requires significant effort and costs. This paper describes our VMM that requires only two protection levels but does not sacrifice the protection among the VMM, the guest OS kernel, and its user processes by “virtual protection ring”.

1 はじめに

今日、組み込み機器のハードウェアは非常に複雑化し、これまでワークステーションなど高機能な環境でしか実行できなかった複雑なプログラムなどが組み込み機器上で実行できるようになった。しかし一方で、組み込み機器は生活、社会の中に存在するため、このようなシステムがソフトウェアのバグなどにより異常動作を起こした場合にはワークステーションの暴走以上に脅威となる。そこで近年では、これまで行ってきたハードウェア上で直接 OS を実行する環境からハードウェア上に仮想マシンを構築し仮想マシン内で OS を実行する環境へ変化している。このような環境ではアプリケーションや OS などのソフトウェア資源が暴走した場合でもハードウェアに危機的な影響が出る前に仮想マシンにより処理を中断することができ、安全性を高める手法として広い分野での利用が求められている。

現在実用化されている仮想マシンモニタ (VMM) は、Intel IA-32 など複雑なプロセッサ上で実行するものが多く、このような VMM は、プロセッサが VMM を実行するために十分な保護リング機能が提供しているものとして設計、実装されている。しかし、通常、小規模な組み込み機器用のプロセッサでは、OS カーネルとユーザプロセスを実行するのに必要最低限の保護リングのみしか提供しておらず、2 レベルの保護リングであることが多い。そのため IA-32 などの上に構築された多数の保護リングを使用する仮想マシンは、小規模な組み込み機器環境への移植は困難であり、移植するためにプロセッサの保護リング機能を変更するなど多額の開発コストがかかる。

そこで本研究は、2 レベルの保護リング環境に仮想マシン環境を構築し、保護リングレベルが限定さ

れている場合での VMM のソフトウェアアーキテクチャを提案する。本研究の VMM アーキテクチャにより、これまでに PC 用として設計された仮想マシンを小規模な組み込み機器環境へ移植することを可能にする。

本研究では実験環境として IA-32 アーキテクチャの CPU の環境を用意した。IA-32 アーキテクチャでは 4 レベルの保護リングを提供する。本研究は 2 レベルの保護リング環境での VMM 実行を目的としているため、IA-32 が提供する保護リングのうち 2 個のリングのみを使う。またこの環境では、Xen など多くの 3 レベル保護リングを用いる VMM が実現されており、これらと性能を比較することでリング数の違いによる性能への影響を考察することも目的とする。ゲスト OS としては、組み込み機器で広く使われている Linux を選択した。

本研究では 2 レベルの保護リング環境用の VMM を構築する手法として、ページング機能を利用した仮想保護リング機構を作成した。仮想保護リングは非特権モードで実行するゲスト OS カーネルとユーザプロセス間の保護を提供する機能である。仮想保護リング機構により、本研究では 2 レベルの保護リング環境内で VMM を構築し、VMM 上にて Linux Kernel 2.6.17 とユーザプロセスとして Busybox を実行できることを確認した。

2 アーキテクチャ

2.1 IA-32 アーキテクチャ

これまでに研究されている VMM は、IA-32 環境用に設計されたものが多い。今後組み込み機器に VMM

を移植する場合には IA-32 上で実行されている VMM に変更を加えて実現することが予想される。

IA-32 アーキテクチャとは、Intel Pentium シリーズ用の CPU アーキテクチャである [4]。IA-32 CPU はシステム上に複雑な OS を実行させることを目標としており、4 レベルの保護リング、ページング機構、セグメント機構、割り込み機構などを提供している。

IA-32 では CPU が発行する命令のうち、システム全体の挙動に影響を及ぼす命令を特権命令と呼び、その他の命令を非特権命令と呼ぶ。CPU の実行時には、特権処理を行えるかどうかの指定が可能で、この状態をモードと呼ぶ。保護リング機構はモードと関連し、最も特権の高いリング (リング 0) では CPU の特権状態やハードウェア全体の操作が可能である。これ以外の状態を非特権モードと呼ぶ。非特権モードでは特権命令の発行ができないもの、システム全体に影響するレジスタの一部を読み出すことが可能である。

IA-32 CPU で割り込みが発生すると、発生要因ごとにあらかじめ設定した処理が呼び出される。割り込み要因と呼び出される関数の対応を指定する配列を割り込みベクタと呼ぶ。割り込みベクタには予約済みのベクタ (0~19) とユーザ定義ベクタ (32~255) がある。予約済みのベクタには、0 による除算やページフォルト、一般保護例外などマップされており、ユーザ定義ベクタにはタイマ割り込みやソフトウェア割り込みを使ったシステムコールなどを割り込みコントローラ (PIC) によって配置することができる。

また IA-32 では CPU によって CPU 独自の命令を提供しているものもある。最近の Linux ではこれら CPU 依存の命令を利用することも多く、VMM 設計の際にはこれらの命令を仮想化する必要がある。

2.2 Linux

本研究では、構築した VMM 環境の実用性評価のため、VMM 上にゲスト OS を実行することでテストを行う。ゲスト OS には組み込み機器や PC など幅広い分野で使われている Linux を選択した。Linux は IA-32 環境をはじめ、PowerPC、ARM など多くのアーキテクチャ上に移植されている。

IA-32 環境で実行する Linux は、IA-32 の持つページング機構を用いて 4GB の仮想メモリ空間を作り、この中で実行する。また、Linux は IA-32 が提供する保護リング機構のうち 2 つのレベルを使いカーネルとユーザプロセス間の保護を確立する (図 1-(a))。通常はカーネルをレベル 0、ユーザプロセスをレベル 3 で実行する。これにより、カーネルがハードウェア全体を管理、各プロセスに対して適切にリソースを配分することができる

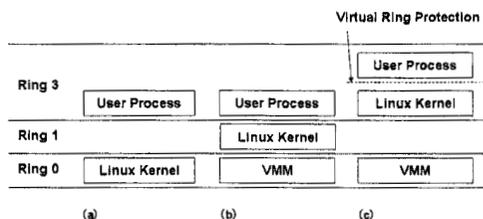


図 1: 保護リング上の OS と VMM

2.3 3 レベルリングでの VMM

IA-32 上に VMM を構築する場合、OS が使用していない保護リングを利用する方法が一般的である。この場合、VMM とゲスト OS は CPU の保護リング内に図 1-(b) のように配置される。ゲスト OS カーネルのソースコードの一部に変更を加え、ゲスト OS カーネルをリング 1 で実行する。ハードウェアの電源をいれると、まず VMM がリング 0 で起動する。次にカーネルを呼び出してゲスト OS の初期化を行い、最後にユーザプロセスが生成される。ゲスト OS カーネルはリング 1 で実行しており特権命令を発行することができないため、これを VMM に依頼し処理する。また、ゲスト OS カーネルはユーザよりも特権の高いリングで実行しているため、VMM が無い状態で実行している場合と同様にユーザプロセスを管理することができる。このような VM 内で実行する OS をゲスト OS と呼ぶ。

本論文では、ゲスト OS に対して、実機上で実行される OS をネイティブ OS と呼ぶ。

3 2 レベルリング内での VMM の実現方法

組み込み機器用の CPU では 2 レベルのみの保護リングを提供するものが多く、2.3 で紹介した 3 レベルの保護リングを使う手法では VMM を構築することができない。そこで、本研究ではゲスト OS カーネルとユーザプロセスをリング 3、VMM をリング 0 で配置することで、2 レベルの保護リング環境で実行できる VMM を実現する。この場合、ゲスト OS カーネルとユーザプロセスは、同じ特権のリングで実行されるため、3 レベルの保護リング環境のように VMM が特にゲスト OS カーネル、ユーザプロセス間の保護を行わない方法ではユーザプロセスからカーネル空間へのアクセスが可能となってしまう、ネイティブ Linux でのカーネル、ユーザプロセスの階層構造を保つことができない。

そのため、このような VMM 環境では VMM がゲスト OS カーネルとユーザプロセス間に何らかの方法を使って保護を構築しなければならない。本研究

では VMM がゲスト OS のカーネルとユーザプロセス間に仮想保護リングを提供する (図 1-c). 仮想保護リングは VMM によって管理され, ユーザプロセスからカーネルが持つメモリ領域へのアクセスを禁止する. またこの機構はゲスト OS カーネルからユーザプロセスのメモリ領域へのアクセスを可能にし, ネイティブ Linux 内での階層構造を保つことができる.

本研究では仮想保護リングの実現方法として IA-32 が提供するページング機構を用いる. ページング機構は仮想メモリを提供するための機能であり, 保護リングが 2 レベルのみの CPU であってもページング機構が提供されていることが多い. 例えばこのようなプロセッサとしては SH-4 がある. SH-4 は組み込み機器用のプロセッサであり, ページング機構とソフトウェア制御の TLB により柔軟な仮想メモリ管理が行える. しかし, 保護リングは 2 レベルであり, カーネルとユーザプロセスが実行される [5].

VMM 環境において, ページング機構はシステム全体の実行に関連する機能であるため VMM が管理する. 3 レベルの保護リング環境では, ゲスト OS カーネルが用意したページテーブルを VMM が受け取り, VMM がチェックした後, ページテーブルを CPU に設定する. 本研究では仮想保護リングを提供するため, VMM は VMM 内にページテーブルを 2 種類管理する. VMM はゲスト OS カーネルから指定されたページテーブルを VMM へコピーする際に, 特権モードで参照できる範囲のカーネルモードページテーブルと, 非特権モードで参照できる範囲のユーザモードページテーブルを生成する. ゲスト OS カーネル実行中にはカーネルモードページテーブルを, ユーザプロセスが実行中にはユーザモードページテーブルを使用する設定にすることで, ゲスト OS カーネルからはゲスト OS 全体が, ユーザプロセスからはユーザプロセスのみの領域が参照できる. (図 2)

また仮想保護リングの環境では, ユーザプロセスとゲスト OS カーネルが切り替わる際にページテーブルを切り替える必要がある. これはネイティブ Linux には無い処理のため VMM によって処理される必要がある. そのため VMM はカーネルモードとユーザモードの切り替えを検出しなければならない. 検出方法については次章で詳細を述べる.

4 実装

3 章では, 2 レベルの保護リング環境上に VMM を構築する手法の概要について述べた. 本章では, 本研究で構築した VMM の実装の詳細と, 2 レベルの保護リング環境に VMM を実現するためのテクニックを紹介する.

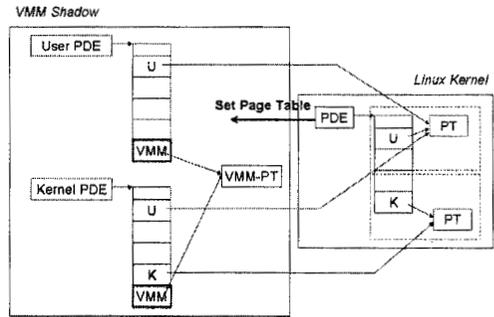


図 2: シャドウページテーブル

4.1 仮想アドレスマップ

VMM 環境において VMM からゲスト OS の仮想メモリの内容を参照したい場合には, VMM の仮想メモリ内にゲスト OS をすべてマップしてしまう方法が便利である. ネイティブ Linux は仮想メモリ 4GB 内にカーネルとユーザプロセスを配置するが, 今回は VMM からゲスト OS を簡単に参照するためにゲスト OS の Linux カーネルに修正を加え, Linux の仮想メモリを 3.95GB とし, 残りの領域を VMM 用メモリ空間として確保した.

4.2 セグメント機構の仮想化

IA-32 のセグメント機構は実行時に参照できる仮想アドレスの範囲を設定する機能である. ページング機構は, 各ページごとに U/S ビットを持ち, U/S ビットが 0 のページは特権モード時のみアクセスが可能となる機能を持っている. ネイティブ Linux ではページング機構の各ページの U/S ビットによってカーネルとユーザプロセス間のメモリ保護を提供する. そのため, ネイティブ Linux のセグメントは保護機構としては利用されず, 仮想アドレス全体にアクセスできるように設定される.

本システムでは仮想アドレス空間内に VMM とゲスト OS が混在しているが, ゲスト OS から VMM のアドレス領域へのメモリの読み書きは VMM 保護の観点から禁止されるべきである. そのため, 本システムではセグメント機構を利用する. VMM はゲスト OS 用の VMM のアドレス空間へのアクセスを制限するセグメントと VMM 用のすべてのアドレス空間へアクセス可能な 2 種類のセグメントを用意する. これを実行中に切り替えることで, VMM 実行中には仮想アドレス空間内の任意の場所へのアクセスが可能とし, ゲスト OS からは VMM のアドレスへのアクセスが禁止することができる.

本システムでは, VMM をリング 0, ゲスト OS をすべてリング 3 で実行する. そのため, ページテー

した場合であるため、VMM がなにかしらの対応を行う必要がある。しかし、現在は適切な対応策が決定していないため、(4)の要因による GP が発生すると VMM は発生時のレジスタ情報をダンプして停止する。

4.4.3 ページフォルトのハンドリング

ページフォルト (PF) もまた予約済みベクタで発生する例外である。PF の要因としては、3つの要因が考えられ、(1) ユーザモード中のカーネルメモリへのアクセス、(2) ゲスト OS ページテーブルがシャドウページテーブルへ反映されていない場合、(3) ゲスト OS が準備していないページでのページフォルトの場合、がある。(1) はユーザプロセスからゲスト OS のカーネル領域へアクセスのため GP であり、この場合には VMM はゲスト OS のカーネルへ GP を通知する。(2) は VMM がシャドウページテーブルを持つために発生する例外である。ゲスト OS から VMM へのページテーブル登録後、ゲスト OS カーネルがゲスト OS 内のページテーブルを変更した場合、シャドウページテーブルとゲスト OS ページテーブル間に矛盾が生じる。そのため、CPU に設定されているページテーブルはゲスト OS が指定した適切なページングを行うことができず PF が発生する。この例外の場合、ゲスト OS のページテーブルを読み込み、シャドウページテーブルを再構築し、ゲスト OS ページテーブルをシャドウページテーブルへ反映させた後、PF を発生させた命令へ戻し、実行を再開させる。ここで、この方法によるシャドウページテーブルの更新はゲスト OS の書き換えたページがシャドウページテーブル内に登録されていない場合のみ有効であり、ページがシャドウページテーブルに登録されている場合には PF が発生しないためシャドウページテーブルの更新が発生しない。これについては VMM がゲスト OS によるページテーブルの変更を検出する必要があるが、現在は未対策である。(3) はゲスト OS でハンドルされる例外のため、VMM はゲスト OS のハンドラを呼び出す。

現在、以上に述べなかった予約済みベクタ例外が発生した場合、VMM はゲスト OS ハンドラを呼び出し例外処理を依託する。

4.4.4 ハイパーコール

VMM 環境ではゲスト OS から VMM を呼び出すためのハイパーコール (ハイパーバイザーコール) 機構を提供することが多い。ハイパーコール機構により、CPU には無い機能を VMM がゲスト OS へ仮想的に提供したり、1回の VMM 呼出で複数の特権処理を行うといった柔軟な仮想マシン環境を構築することができる。本システムもハイパーコール機構を用

意しており、ゲスト OS からのソフトウェア割込みにより発行することができる。ゲスト OS がソフトウェア割込みを特定のベクタに対して行った場合、VMM がこれをハイパーコールとして検出し、このときのレジスタの値を元に処理を決定し実行する。今回は 2 レベル保護リング環境でのハイパーコールのテストとして、IA-32 の特権命令 4 個 (lgdt, lldt, lidt, ltr) をハイパーコールによって実装した。また、これらの動作を確認するためにゲスト OS カーネルの該当する命令をハイパーコールに置き換えた。

4.5 IRET の検出

4.3 では 2 種類のページテーブルによる仮想保護リングを作成した。本節ではユーザモードとカーネルモードの切り替え時に行う際の仮想保護リングの特権移行と IRET のハンドリングについて紹介する。

本研究では、ユーザモードとカーネルモードの切り替えの際にページテーブルを切り替えることで仮想保護リングを提供する。ユーザモードからカーネルモードへの切り替えは通常割込みによって起こり、これは本システムにおいても同様である。この場合必ず VMM の割込みハンドラが呼び出されるため、モードの切り替えを簡単に検出することができる。しかし、IA-32 環境ではカーネルモードからユーザモードへの切り替えを VMM が検出するのは困難である。ネイティブ Linux では、このモード移行の際に IRET 命令を発行する。IRET 命令はある特権状態から特権の低い、もしくは特権の同じコードセグメントへジャンプするための命令である。現在の特権と移行後の特権を比較し、条件を満たす場合にはセグメントの切り替え、スタックの変更が自動で行われジャンプする。このような IRET 命令はカーネルからユーザプロセスへの移行や、割り込みハンドリング完了後、割り込み発生位置へのリターン処理に用いられる。ネイティブ Linux ではこの方法により特権モードの切り替えを行っているが、本システムでは特権モードを変更を VMM によるページテーブルの切り替えで実現しているため、ゲスト OS カーネルの IRET 発行時に必ず VMM が呼び出されなければならない。

そこで、本研究では VMM を呼び出す方法として、ゲスト OS カーネルのマクロ定義に変更を加えることで IRET 命令の発行時に例外を起こすことでこれを実現した。変更点としては、カーネルモード、ユーザモードとしてマクロ定義されたコードセグメントの値をそれぞれ VMM があらかじめ予約した不正なセグメント番号を含む、特権、非特権セグメントに変更する。これによりゲスト OS 実行中にゲスト OS カーネルがこのマクロ定義を元にセグメントの値を準備し IRET 命令を発行すると、宛先セグメントは不正なセグメントとなるため GP が発生する。GP は VMM によりハンドルされ、命令のデコード、ス

タックの解析を行い、原因となったセグメント値から宛先のコードセグメントがユーザセグメントなのかカーネルセグメントなのかを判別することができる。もし、宛先の特権モードがユーザモードの場合には、ユーザモードページテーブルを設定し仮想保護リングの特権を変更する。最後に、修正した宛先へジャンプすることで IRET のエミュレーションは完了となる。

5 結果

本研究では、IA-32 アーキテクチャの Pentium 4 XE マシン上で VMware Workstation 5.5.1 を実行し実験環境を構築した。VMware は仮想マシンとして、ホスト環境と同種類の CPU と 512MB のメモリを提供する。以上の仮想マシン内で、本研究で構築した VMM とゲスト OS の Linux 2.6.17, シェル環境を提供する Busybox を実行する。Linux 2.6.17 には 4 章に示した変更点を加えた。

仮想マシン上で grub を使いネットワーク経由でブートした結果、VMM の起動、ゲストの Linux カーネルの起動、シェルの起動が確認できた。また、シェル内でコマンドを実行したところネイティブ Linux 同様の結果が得られ、正常に処理されていることが確認できた。現在はゲスト OS のカーネル、ユーザプロセス間の保護に関するテスト及び速度性能に関する評価は行っていないため、今後の研究課題とする。

6 関連研究

Disco は MIPS 用の VMM である [1]。MIPS は 3 レベルの保護リング機構、ページング機構とソフトウェア TLB 制御を持ち、SH4 とのアーキテクチャ的な差は主に保護リングレベルのみである。そのため本論文の手法を用いることで簡単に移植することができ、本手法は大変有用であると考えられる。

ソフトウェアによる 2 レベルの保護リング環境内での VMM 構築方法としては、x86-64 環境用の Xen がある [2]。この手法も本研究同様の 2 種類のページテーブルを使う手法が提案されているが、詳細、実行結果等は不明である。

また、2 レベルの保護リング環境で複数の OS 環境を実行する方法としては、マイクロカーネルによる方法がある [3]。しかし、この方法の場合はネイティブ OS を参考にし OS サーバやエミュレーションライブラリを構築する必要があり、ソフトウェアの設計実装コストが非常に高い。本研究では、ゲスト OS への変更はほとんど無いため移植コストは低く、OS レベルのバグを増やすことなくシステムを構築することができる。

7 おわりに

本研究では、2 レベルの保護リング環境にページング機能を利用した仮想保護リングにより VMM を実行する方法を提案した。本研究は、特権リング上で VMM を実行し、1 つの非特権リング内でカーネルとユーザプロセスを実行する。これには、ゲスト OS 1 つに対し VMM が仮想保護リング用にシャドウページテーブルを複数用意することで、カーネルとユーザプロセス間に保護機能を実現した。現在はシステムではゲスト OS 1 つに対してページテーブルを 2 種類作成しているが、さらに VMM 内で複数のページテーブルを用意することで複数レベルの仮想保護リングを提供でき、今後もさまざまな用途に利用可能な手法であると考えられる。

また、本研究では仮想保護リングを実現するために同じ特権モード内で実行されるカーネルとユーザプロセス間の切り替えを行う IRET の検出を行った。これは Linux のマクロ定義の変更と VMM の割込み処理部のみの変更によって実現することができた。

以上の方法で構築した VMM は 2 レベルの保護リングのアーキテクチャ内で動作し、VMM が構築した仮想マシン内で Linux および Busybox が実行できることを確認した。

参考文献

- [1] Edouard Bugnion, Scott Devine, Kinshuk Govil, and Mendel Rosenblum : “Disco: Running Commodity Operating Systems on Scalable Multiprocessors”, ACM TOCS, 15(4) 1997.
- [2] Ian Pratt, Keir Fraser, Steven Hand, Christian Limpach, Andrew Warfield : “Xen 3.0 and the Art of Virtualization”, Ottawa Linux Symposium, 2005.
- [3] Jochen Liedtke : “Toward Real μ -kernels”, Communications of the ACM, 39 (9), pp. 70-77, 1996.
- [4] Intel Corporation: “Intel 64 and IA-32 Architectures Software Developer’s Manuals”, Intel Corporation, 2006.
- [5] ルネサステクノロジ: “SH-4 ソフトウェアマニュアル Rev.6.00”, ルネサステクノロジ, 2006.