

Wirtualizacja sprzętowa

(czyli tej prezentacji – nie ma!)

Dominika Pawlik, Michał Gołębiowski, Kamil Kawka

20 listopada 2008

Co to jest?

Jest to sposób ukrycia części związanych z architekturą zasobów sprzętowych, aby można było wygodniej z nich korzystać.

Wirtualizuje się praktycznie wszystkie warstwy w komputerze:

- 1 wirtualne sieci
- 2 wirtualne urządzenia
- 3 **wirtualna maszyna**
- 4 wirtualna pamięć
- 5 wirtualny system plików

Co to jest?


Jest to sposób ukrycia części związanych z architekturą zasobów sprzętowych, aby można było wygodniej z nich korzystać.

Wirtualizuje się praktycznie wszystkie warstwy w komputerze:

- 1 wirtualne sieci
- 2 wirtualne urządzenia
- 3 **wirtualna maszyna**
- 4 wirtualna pamięć
- 5 wirtualny system plików


Jak to działa

(„Niektórzy mówią, że nas oko łodzi”)




Jak to działa

(„Niektórzy mówią, że nas oko łudzi
I że nic nie ma ...”)



Jak to działa

(„Niektórzy mówią, że nas oko łodzi
I że nic nie ma, tylko się wydaje”)



A do czego służy?

- 1 serwery – zwykle obciążenie serwera to mniej niż 15%, więc czemu na jednej maszynie nie postawić wielu serwerów?
- 2 uruchamianie programów na inną architekturę
- 3 korzystanie z paru systemów operacyjnych
- 4 tworzenie snapshotów
- 5 testowanie niebezpiecznych programów
- 6 testowanie zmian w systemie operacyjnym

A do czego służy?

- 1 serwery – zwykle obciążenie serwera to mniej niż 15%, więc czemu na jednej maszynie nie postawić wielu serwerów?
- 2 uruchamianie programów na inną architekturę
- 3 korzystanie z paru systemów operacyjnych
- 4 tworzenie snapshotów
- 5 testowanie niebezpiecznych programów
- 6 testowanie zmian w systemie operacyjnym

A do czego służy?

- 1 serwery – zwykle obciążenie serwera to mniej niż 15%, więc czemu na jednej maszynie nie postawić wielu serwerów?
- 2 uruchamianie programów na inną architekturę
- 3 korzystanie z paru systemów operacyjnych
- 4 tworzenie snapshotów
- 5 testowanie niebezpiecznych programów
- 6 testowanie zmian w systemie operacyjnym

A do czego służy?

- 1 serwery – zwykle obciążenie serwera to mniej niż 15%, więc czemu na jednej maszynie nie postawić wielu serwerów?
- 2 uruchamianie programów na inną architekturę
- 3 korzystanie z paru systemów operacyjnych
- 4 tworzenie snapshotów
- 5 testowanie niebezpiecznych programów
- 6 testowanie zmian w systemie operacyjnym

A do czego służy?

- 1 serwery – zwykle obciążenie serwera to mniej niż 15%, więc czemu na jednej maszynie nie postawić wielu serwerów?
- 2 uruchamianie programów na inną architekturę
- 3 korzystanie z paru systemów operacyjnych
- 4 tworzenie snapshotów
- 5 testowanie niebezpiecznych programów
- 6 testowanie zmian w systemie operacyjnym

A do czego służy?

- 1 serwery – zwykle obciążenie serwera to mniej niż 15%, więc czemu na jednej maszynie nie postawić wielu serwerów?
- 2 uruchamianie programów na inną architekturę
- 3 korzystanie z paru systemów operacyjnych
- 4 tworzenie snapshotów
- 5 testowanie niebezpiecznych programów
- 6 testowanie zmian w systemie operacyjnym

Wady

1. większe zużycie zasobów
2. spadek wydajności
3. mniejsza wygoda
4. problemy z licencjami na oprogramowanie (np. Microsoft)

Wady

- 1 większe zużycie zasobów
- 2 spadek wydajności
- 3 mniejsza wygoda
- 4 problemy z licencjami na oprogramowanie (np. Microsoft)

Wady

- 1 większe zużycie zasobów
- 2 spadek wydajności
- 3 mniejsza wygoda
- 4 problemy z licencjami na oprogramowanie (np. Microsoft)

Zagrożenia

- SubVirt, Samuel T. King et al, University of Michigan and Microsoft Research
- BluePill, Joanna Rutkowska, COSEINC 3 września 2006



BluePill

- zaprojektowany przez Joannę Rutkowską w 2006
- teoretycznie umożliwia całkowite i niewykrywalne przejęcie kontroli nad systemem ofiary
- kiedy system połknie niebieską tabletkę:
Blue Pill przechwytuje system w locie i ładuje go do swojej VM. Użytkownik ofiary pracuje bez straty wydajności i bez możliwości wykrycia Blue Pill
- prototypowa implementacja z opublikowanymi źródłami

Jak groźne są takie wirusy?

Zagrożenie ze strony rootkitów wykorzystujących VM jest na tyle realne, że jeden z autorów SubVirta przez jakiś czas wykorzystywał komputer, o którym nie wiedział, że jest zarażony prototypowym rootkitem.

I kolejne zyski

Honeypot – pułapka na wirusy:

<http://www.citi.umich.edu/u/provos/papers/honeyd.pdf>

Emulacja Pełna

Emulacja – program komputerowy emuluje działanie jednego systemu operacyjnego.

Symuluje: pamięć, procesor, urządzenie I/O, zegar, ...

Emulacja API – emulujemy tylko bibliotekę systemową.

Emulacja Pełna

Emulacja – program komputerowy emuluje działanie jednego systemu operacyjnego.

Symuluje: pamięć, procesor, urządzenie I/O, zegar, ...

Emulacja API – emulujemy tylko bibliotekę systemową.

Porównanie

☺	Zalety	Wady
Emulacja	- nie trzeba instalować SO - emuluje dowolną architekturę - przenośna	wolna – 20% wydajności natywnej
Emulacja API	- nie trzeba instalować SO - średnio szybkie (60%) :)	- tylko aplikacje na architekturę gospodarza - średnio szybkie (60%) :)

Parawirtualizacja

- **system operacyjny gościa wie, że jest wirtualizowany**
- dostosowuje swój sposób korzystania z zasobów systemowych, np. z pamięci; na przykład zamiast `syscall` wywołuje `hypercall`
- szybka: ponad 95% wydajności gospodarza
- trzeba jednak zmienić system operacyjny, zatem nie można jej wykorzystywać do wprowadzania zmian w jądrze

Parawirtualizacja

- system operacyjny gościa wie, że jest wirtualizowany
- dostosowuje swój sposób korzystania z zasobów systemowych, np. z pamięci; na przykład zamiast `syscall` wywołuje `hypercall`
- szybka: ponad 95% wydajności gospodarza
- trzeba jednak zmienić system operacyjny, zatem nie można jej wykorzystywać do wprowadzania zmian w jądrze

Parawirtualizacja

- system operacyjny gościa wie, że jest wirtualizowany
- dostosowuje swój sposób korzystania z zasobów systemowych, np. z pamięci; na przykład zamiast `syscall` wywołuje `hypercall`
- szybka: ponad 95% wydajności gospodarza
- trzeba jednak zmienić system operacyjny, zatem nie można jej wykorzystywać do wprowadzania zmian w jądrze

Parawirtualizacja

- system operacyjny gościa wie, że jest wirtualizowany
- dostosowuje swój sposób korzystania z zasobów systemowych, np. z pamięci; na przykład zamiast `syscall` wywołuje `hypercall`
- szybka: ponad 95% wydajności gospodarza
- trzeba jednak zmienić system operacyjny, zatem nie można jej wykorzystywać do wprowadzania zmian w jądrze

Parawirtualizacja

- system operacyjny gościa wie, że jest wirtualizowany
- dostosowuje swój sposób korzystania z zasobów systemowych, np. z pamięci; na przykład zamiast `syscall` wywołuje `hypercall`
- szybka: ponad 95% wydajności gospodarza
- trzeba jednak zmienić system operacyjny, zatem nie można jej wykorzystywać do wprowadzania zmian w jądrze

Wirtualizacja OS

Uruchamiamy system operacyjny gościa pod systemem operacyjnym gospodarza. Chcielibyśmy, żeby działało:

- 1 szybko
- 2 identycznie
- 3 i aby gość niczego nie wiedział (w szczególności by kontrolował zasoby)

Wirtualizacja OS

Uruchamiamy system operacyjny gościa pod systemem operacyjnym gospodarza. Chcielibyśmy, żeby działało:

- 1 szybko
- 2 identycznie
- 3 i aby gość niczego nie wiedział (w szczególności by kontrolował zasoby)

Wirtualizacja OS

Uruchamiamy system operacyjny gościa pod systemem operacyjnym gospodarza. Chcielibyśmy, żeby działało:

- 1 szybko
- 2 identycznie
- 3 i aby gość niczego nie wiedział (w szczególności by kontrolował zasoby)

Wirtualizacja OS

Uruchamiamy system operacyjny gościa pod systemem operacyjnym gospodarza. Chcielibyśmy, żeby działało:

- 1 szybko
- 2 identycznie
- 3 i aby gość niczego nie wiedział (w szczególności by kontrolował zasoby)

W idealnym-wirtualnym świecie (,,W koszyczku jabłuszko ...”)

- każda instrukcja zmieniająca zasoby systemowe lub zależna od konfiguracji sprzętu (wrażliwie) wywołuje przerwanie sprzętowe
- kryterium Popka-Golberga mówi, że jeśli tak jest, to można skonstruować wirtualną maszynę
- w x86 tak nie jest – i to jest problem

W idealnym-wirtualnym świecie (,,W koszyczku jabłuszko ...”)

- każda instrukcja zmieniająca zasoby systemowe lub zależna od konfiguracji sprzętu (wrażliwie) wywołuje przerwanie sprzętowe
- **kryterium Popka-Golberga** mówi, że jeśli tak jest, to można skonstruować wirtualną maszynę
- w x86 tak nie jest – i to jest problem

W idealnym-wirtualnym świecie (,,W koszyczku jabłuszko ...”)

- każda instrukcja zmieniająca zasoby systemowe lub zależna od konfiguracji sprzętu (wrażliwie) wywołuje przerwanie sprzętowe
- **kryterium Popka-Golberga** mówi, że jeśli tak jest, to można skonstruować wirtualną maszynę
- w x86 tak nie jest – i to jest problem

Opis problemu

(„W jabłuszku robaczek ...”)

Instrukcje, których nie lubimy

W architekturze x86 jest ich aż 17. Na przykład:

- SGDT, SIDT, SLDT – czytanie rejestrów
- SMSW – korzystanie ze stanu procesora
- PUSH, POP – zależne od trybu pracy (poziomu ochrony)
- POPF – a nawet zmienianie flag w EFLAGS
- ...

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze zmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze samozmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu


- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze samozmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)

Rozwiązanie problemu

- zarządca przechwytuje instrukcje wrażliwe
- trzeba rekompilować kod, ale to trwa i trwa , ...
- a utrudniają nam to jeszcze instrukcje skoku. I zostaje jeszcze samozmieniający się kod
- Zatem stosujemy flagi (i wcale nas to nie bawi)


Ring – co to takiego?

- 1 *Ringi* ochronne – hierarchiczny system ochronny
- 2 Ringi określają uprawnienia dostępu do poszczególnych zasobów. Im niższy numer Ringu, tym większe uprawnienia
- 3 np. Ring zerowy: jądro systemu



Ring – co to takiego?

- 1 *Ringi* ochronne – hierarchiczny system ochronny
- 2 Ringi określają uprawnienia dostępu do poszczególnych zasobów. Im niższy numer Ringu, tym większe uprawnienia
- 3 np. Ring zerowy: jądro systemu



Ring – co to takiego?

Ringi zapewniają separację zasobów, pozwalającą na ochronę przed:

- błędami krytycznymi – niewiele procesów ma uprawnienia pozwalające na uszkodzenie podstawowej funkcjonalności OS-u
- złośliwym oprogramowaniem – program spyware uruchomiony w Ringu 3 nie będzie miał dostępu do kamery internetowej, wymagającej Ringu 1

Ring – co to takiego?

Ringi zapewniają separację zasobów, pozwalającą na ochronę przed:

- błędami krytycznymi – niewiele procesów ma uprawnienia pozwalające na uszkodzenie podstawowej funkcjonalności OS-u
- złośliwym oprogramowaniem – program spyware uruchomiony w Ringu 3 nie będzie miał dostępu do kamery internetowej, wymagającej Ringu 1

Ring – co to takiego?

Ringi zapewniają separację zasobów, pozwalającą na ochronę przed:

- błędami krytycznymi – niewiele procesów ma uprawnienia pozwalające na uszkodzenie podstawowej funkcjonalności OS-u
- złośliwym oprogramowaniem – program spyware uruchomiony w Ringu 3 nie będzie miał dostępu do kamery internetowej, wymagającej Ringu 1

Co z wirtualizacją? Ring -1

- 1 jądro systemu wymaga do działania Ringu 0
- 2 nie chcemy, by systemy odpalane na wirtualnej maszynie miały pełny dostęp do systemu-hosta
- 3 stworzenie Ringu -1 – superuprzywilejowanego trybu, który może być używany wyłącznie przez maszynę wirtualną
- 4 Ring -1 zapewnia obsługę instrukcji zmieniających zasoby, które nie wywołują przerw sprzętowych (była o nich mowa wcześniej)

Co z wirtualizacją? Ring -1


- 1 jądro systemu wymaga do działania Ringu 0
- 2 nie chcemy, by systemy odpalane na wirtualnej maszynie miały pełny dostęp do systemu-hosta
- 3 stworzenie Ringu -1 – superuprzywilejowanego trybu, który może być używany wyłącznie przez maszynę wirtualną
- 4 Ring -1 zapewnia obsługę instrukcji zmieniających zasoby, które nie wywołują przerw sprzętowych (była o nich mowa wcześniej)

Co z wirtualizacją? Ring -1

- 1 jądro systemu wymaga do działania Ringu 0
- 2 nie chcemy, by systemy odpalane na wirtualnej maszynie miały pełny dostęp do systemu-hosta
- 3 stworzenie Ringu -1 – superuprzywilejowanego trybu, który może być używany wyłącznie przez maszynę wirtualną
- 4 Ring -1 zapewnia obsługę instrukcji zmieniających zasoby, które nie wywołują przerw sprzętowych (była o nich mowa wcześniej)

Stronicowanie na komputerze niewirtualizowanym

Zwykły system operacyjny, translacja adresu liniowego do fizycznego z użyciem *page walkera*:



TLB – translation look-aside buffer

Translacja adresu jest bardzo obciążającą operacją, gdyż *page walker* musi odczytywać pamięć wiele razy

- rozwiązanie: tablica ostatnich translacji (TLB – translation look-aside buffer)
- procesor najpierw sprawdza, czy żądana translacja nie znajduje się w TLB; dopiero w przeciwnym wypadku przeprowadza ją od początku

TLB – translation look-aside buffer

Translacja adresu jest bardzo obciążającą operacją, gdyż *page walker* musi odczytywać pamięć wiele razy

- rozwiązanie: tablica ostatnich translacji (TLB – translation look-aside buffer)
- procesor najpierw sprawdza, czy żądana translacja nie znajduje się w TLB; dopiero w przeciwnym wypadku przeprowadza ją od początku

TLB – translation look-aside buffer

System operacyjny musi współpracować z procesorem w celu utrzymania spójności TLB, np.:

- po przełączeniu kontekstu możemy stracić uprawnienia dotyczące jakiegoś fragmentu pamięci – system operacyjny musi zażądać od CPU usunięcia odpowiedniego wpisu w TLB
- dodatkowy narzut przy użyciu wielu procesorów (SMP – symmetric multiprocessing – współdzielenie pamięci przez wiele procesorów) – jeśli tablica jest współdzielona, CPU musi usunąć odpowiedni wpis z TLB wszystkich procesorów

TLB – translation look-aside buffer

System operacyjny musi współpracować z procesorem w celu utrzymania spójności TLB, np.:

- po przełączeniu kontekstu możemy stracić uprawnienia dotyczące jakiegoś fragmentu pamięci – system operacyjny musi zażądać od CPU usunięcia odpowiedniego wpisu w TLB
- dodatkowy narzut przy użyciu wielu procesorów (SMP – symmetric multiprocessing – współdzielenie pamięci przez wiele procesorów) – jeśli tablica jest współdzielona, CPU musi usunąć odpowiedni wpis z TLB wszystkich procesorów

TLB – translation look-aside buffer

System operacyjny musi współpracować z procesorem w celu utrzymania spójności TLB, np.:

- po przełączeniu kontekstu możemy stracić uprawnienia dotyczące jakiegoś fragmentu pamięci – system operacyjny musi zażądać od CPU usunięcia odpowiedniego wpisu w TLB
- dodatkowy narzut przy użyciu wielu procesorów (SMP – symmetric multiprocessing – współdzielenie pamięci przez wiele procesorów) – jeśli tablica jest współdzielona, CPU musi usunąć odpowiedni wpis z TLB wszystkich procesorów

Obsługa translacji adresów gościa

Zakładamy, że stosujemy pełną wirtualizację (gość nie wie, że jest wirtualizowany).

- nadzorca musi kontrolować translacje adresów wykonywane przez gościa
- dodatkowy poziom translacji (translacja adresu „fizycznego” gościa do adresu fizycznego systemu)
- powoduje to dodatkowe obciążenie nadzorcy

Obsługa translacji adresów gościa

Zakładamy, że stosujemy pełną wirtualizację (gość nie wie, że jest wirtualizowany).

- nadzorca musi kontrolować translacje adresów wykonywane przez gościa
- dodatkowy poziom translacji (translacja adresu „fizycznego” gościa do adresu fizycznego systemu)
- powoduje to dodatkowe obciążenie nadzorczy

Obsługa translacji adresów gościa

Zakładamy, że stosujemy pełną wirtualizację (gość nie wie, że jest wirtualizowany).

- nadzorca musi kontrolować translacje adresów wykonywane przez gościa
- dodatkowy poziom translacji (translacja adresu „fizycznego” gościa do adresu fizycznego systemu)
- powoduje to dodatkowe obciążenie nadzorcy

Shadow page tables (sPT)

- 1 nadzorca żąda od CPU używania *shadow page table* (sPT) do przeprowadzania translacji adresów
- 2 sPT tłumaczy liniowy adres gościa na fizyczny adres systemu
- 3 nadzorca musi utrzymywać sPT w stanie spójnym
- 4 jedna z metod – nałożenie ochrony przed zapisem na całą pamięć gościa
 - każda próba dostępu gościa do jego tablicy stron (gPT) wywołuje błąd ochrony pamięci, przechwytywany przez CPU i przekazujący obsługę do nadzorcy
 - nadzorca wykonuje żądanie gościa i poprawia sPT
 - analogiczna obsługa w przypadku usuwania translacji przez gościa

Shadow page tables (sPT)

- 1 nadzorca żąda od CPU używania *shadow page table* (sPT) do przeprowadzania translacji adresów
- 2 sPT tłumaczy liniowy adres gościa na fizyczny adres systemu
- 3 nadzorca musi utrzymywać sPT w stanie spójnym
- 4 jedna z metod – nałożenie ochrony przed zapisem na całą pamięć gościa
 - każda próba dostępu gościa do jego tablicy stron (gPT) wywołuje błąd ochrony pamięci, przechwytywany przez CPU i przekazujący obsługę do nadzorcy
 - nadzorca wykonuje żądanie gościa i poprawia sPT
 - analogiczna obsługa w przypadku usuwania translacji przez gościa

Shadow page tables (sPT)

- 1 nadzorca żąda od CPU używania *shadow page table* (sPT) do przeprowadzania translacji adresów
- 2 sPT tłumaczy liniowy adres gościa na fizyczny adres systemu
- 3 nadzorca musi utrzymywać sPT w stanie spójnym
- 4 jedna z metod – nałożenie ochrony przed zapisem na całą pamięć gościa
 - każda próba dostępu gościa do jego tablicy stron (gPT) wywołuje błąd ochrony pamięci, przechwytywany przez CPU i przekazujący obsługę do nadzorcy
 - nadzorca wykonuje żądanie gościa i poprawia sPT
 - analogiczna obsługa w przypadku usuwania translacji przez gościa

Shadow page tables (sPT)

- 1 nadzorca żąda od CPU używania *shadow page table* (sPT) do przeprowadzania translacji adresów
- 2 sPT tłumaczy liniowy adres gościa na fizyczny adres systemu
- 3 nadzorca musi utrzymywać sPT w stanie spójnym
- 4 jedna z metod – nałożenie ochrony przed zapisem na całą pamięć gościa
 - każda próba dostępu gościa do jego tablicy stron (gPT) wywołuje błąd ochrony pamięci, przechwytywany przez CPU i przekazujący obsługę do nadzorcy
 - nadzorca wykonuje żądanie gościa i poprawia sPT
 - analogiczna obsługa w przypadku usuwania translacji przez gościa

Inne rozwiązanie (Virtual TLB)

- nie uaktualniamy sPT po każdej modyfikacji gPT przez gościa – zezwalamy na chwilową niespójność
- jeśli gość odwoła się do adresu, którego obsługa nie znajduje się w sPT, zostaje wywołany błąd ochrony pamięci
- nadzorca czyta całą tablicę gPT i wstawia brakujące translacje do sPT, przywracając spójność; następnie obsługuje żądanie gościa
- analogicznie dla usuwania

Inne rozwiązanie (Virtual TLB)

- nie uaktualniamy sPT po każdej modyfikacji gPT przez gościa – zezwalamy na chwilową niespójność
- jeśli gość odwoła się do adresu, którego obsługa nie znajduje się w sPT, zostaje wywołany błąd ochrony pamięci
- nadzorca czyta całą tablicę gPT i wstawia brakujące translacje do sPT, przywracając spójność; następnie obsługuje żądanie gościa
- analogicznie dla usuwania

Inne rozwiązanie (Virtual TLB)

- nie uaktualniamy sPT po każdej modyfikacji gPT przez gościa – zezwalamy na chwilową niespójność
- jeśli gość odwoła się do adresu, którego obsługa nie znajduje się w sPT, zostaje wywołany błąd ochrony pamięci
- nadzorca czyta całą tablicę gPT i wstawia brakujące translacje do sPT, przywracając spójność; następnie obsługuje żądanie gościa
- analogicznie dla usuwania

Wady takich rozwiązań

- 1 duża ilość błędów ochrony pamięci, których obsługa jest bardzo kosztowna
- 2 trudno odróżnić faktyczne błędy ochrony pamięci gościa od spowodowanych przez zaprezentowane rozwiązania wirtualizacyjne
- 3 każde przełączenie kontekstu wymaga poprawienia sPT – spory narzut
- 4 dodatkowe problemy dla gości z SMP – gPT może być współdzielona przez wiele procesorów. Nadzorca może:
 - dla każdego procesora utrzymywać osobną instancję sPT – spory dodatkowy narzut przy poprawianiu sPT
 - utrzymywać współdzieloną sPT dla wielu wirtualnych procesorów – duże koszty synchronizacji

Wady takich rozwiązań

- 1 duża ilość błędów ochrony pamięci, których obsługa jest bardzo kosztowna
- 2 trudno odróżnić faktyczne błędy ochrony pamięci gościa od spowodowanych przez zaprezentowane rozwiązania wirtualizacyjne
- 3 każde przełączenie kontekstu wymaga poprawienia sPT – spory narzut
- 4 dodatkowe problemy dla gości z SMP – gPT może być współdzielona przez wiele procesorów. Nadzorca może:
 - dla każdego procesora utrzymywać osobną instancję sPT – spory dodatkowy narzut przy poprawianiu sPT
 - utrzymywać współdzieloną sPT dla wielu wirtualnych procesorów – duże koszty synchronizacji

Wady takich rozwiązań

- 1 duża ilość błędów ochrony pamięci, których obsługa jest bardzo kosztowna
- 2 trudno odróżnić faktyczne błędy ochrony pamięci gościa od spowodowanych przez zaprezentowane rozwiązania wirtualizacyjne
- 3 każde przełączenie kontekstu wymaga poprawienia sPT – spory narzut
- 4 dodatkowe problemy dla gości z SMP – gPT może być współdzielona przez wiele procesorów. Nadzorca może:
 - dla każdego procesora utrzymywać osobną instancję sPT – spory dodatkowy narzut przy poprawianiu sPT
 - utrzymywać współdzieloną sPT dla wielu wirtualnych procesorów – duże koszty synchronizacji

Wady takich rozwiązań

- 1 duża ilość błędów ochrony pamięci, których obsługa jest bardzo kosztowna
- 2 trudno odróżnić faktyczne błędy ochrony pamięci gościa od spowodowanych przez zaprezentowane rozwiązania wirtualizacyjne
- 3 każde przełączenie kontekstu wymaga poprawienia sPT – spory narzut
- 4 dodatkowe problemy dla gości z SMP – gPT może być współdzielona przez wiele procesorów. Nadzorca może:
 - dla każdego procesora utrzymywać osobną instancję sPT – spory dodatkowy narzut przy poprawianiu sPT
 - utrzymywać współdzieloną sPT dla wielu wirtualnych procesorów – duże koszty synchronizacji

Wady takich rozwiązań

- 1 duża ilość błędów ochrony pamięci, których obsługa jest bardzo kosztowna
- 2 trudno odróżnić faktyczne błędy ochrony pamięci gościa od spowodowanych przez zaprezentowane rozwiązania wirtualizacyjne
- 3 każde przełączenie kontekstu wymaga poprawienia sPT – spory narzut
- 4 dodatkowe problemy dla gości z SMP – gPT może być współdzielona przez wiele procesorów. Nadzorca może:
 - dla każdego procesora utrzymywać osobną instancję sPT – spory dodatkowy narzut przy poprawianiu sPT
 - utrzymywać współdzieloną sPT dla wielu wirtualnych procesorów – duże koszty synchronizacji

Wady takich rozwiązań

- 1 duża ilość błędów ochrony pamięci, których obsługa jest bardzo kosztowna
- 2 trudno odróżnić faktyczne błędy ochrony pamięci gościa od spowodowanych przez zaprezentowane rozwiązania wirtualizacyjne
- 3 każde przełączenie kontekstu wymaga poprawienia sPT – spory narzut
- 4 dodatkowe problemy dla gości z SMP – gPT może być współdzielona przez wiele procesorów. Nadzorca może:
 - dla każdego procesora utrzymywać osobną instancję sPT – spory dodatkowy narzut przy poprawianiu sPT
 - utrzymywać współdzieloną sPT dla wielu wirtualnych procesorów – duże koszty synchronizacji

Wady takich rozwiązań

Szacuje się, że obsługa sPT może pochłaniać aż do 75% całego obciążenia nadzorcy.

Nested page tables

- 1 dodatkowa tablica nPT (nested page table), obsługiwana sprzętowo
- 2 nPT tłumaczy „fizyczne” adresy gościa na fizyczne adresy systemu, gPT mapuje liniowy adres gościa do „fizycznego” adresu gościa
- 3 gość zachowuje całkowitą kontrolę nad swoimi tablicami stron

Nested page tables


- 1 dodatkowa tablica nPT (nested page table), obsługiwana sprzętowo
- 2 nPT tłumaczy „fizyczne” adresy gościa na fizyczne adresy systemu, gPT mapuje liniowy adres gościa do „fizycznego” adresu gościa
- 3 gość zachowuje całkowitą kontrolę nad swoimi tablicami stron

Nested page tables

- 1 dodatkowa tablica nPT (nested page table), obsługiwana sprzętowo
- 2 nPT tłumaczy „fizyczne” adresy gościa na fizyczne adresy systemu, gPT mapuje liniowy adres gościa do „fizycznego” adresu gościa
- 3 gość zachowuje całkowitą kontrolę nad swoimi tablicami stron


Praca *page walkera* przy użyciu nPT

Page walker wędruje jednocześnie po gPT i nPT, tłumacząc w ten sposób liniowy adres gościa na fizyczny adres systemu.



Praca *page walkera* przy użyciu nPT

Page walker wędruje jednocześnie po gPT i nPT, tłumacząc w ten sposób liniowy adres gościa na fizyczny adres systemu.



nPT a tablice TLB

1 Tryb gościa i tryb hosta:

- w trybie gościa TLB mapuje liniowe adresy gościa na fizyczne adresy systemu
- w trybie hosta TLB mapuje liniowe adresy hosta na fizyczne adresy systemu

2 Nested TLB – mapuje „fizyczne” adresy gościa na fizyczne adresy systemu

- **WAŻNE!**

nPT a tablice TLB

- 1 Tryb gościa i tryb hosta:
 - w trybie gościa TLB mapuje liniowe adresy gościa na fizyczne adresy systemu
 - w trybie hosta TLB mapuje liniowe adresy hosta na fizyczne adresy systemu
- 2 Nested TLB – mapuje „fizyczne” adresy gościa na fizyczne adresy systemu
 - **WAŻNE!**

nPT a tablice TLB

- 1 Tryb gościa i tryb hosta:
 - w trybie gościa TLB mapuje liniowe adresy gościa na fizyczne adresy systemu
 - w trybie hosta TLB mapuje liniowe adresy hosta na fizyczne adresy systemu
- 2 Nested TLB – mapuje „fizyczne” adresy gościa na fizyczne adresy systemu
 - **WAŻNE!**

nPT a tablice TLB


- 1 Tryb gościa i tryb hosta:
 - w trybie gościa TLB mapuje liniowe adresy gościa na fizyczne adresy systemu
 - w trybie hosta TLB mapuje liniowe adresy hosta na fizyczne adresy systemu
- 2 Nested TLB – mapuje „fizyczne” adresy gościa na fizyczne adresy systemu
 - **WAŻNE!**

nPT a tablice TLB

- 1 Tryb gościa i tryb hosta:
 - w trybie gościa TLB mapuje liniowe adresy gościa na fizyczne adresy systemu
 - w trybie hosta TLB mapuje liniowe adresy hosta na fizyczne adresy systemu
- 2 Nested TLB – mapuje „fizyczne” adresy gościa na fizyczne adresy systemu
 - **WAŻNE!**


Po co Nested TLB?

Przykład – 4-poziomowa tablica stron gościa. Każda kolejna iteracja wymaga przejścia przez *page walkera* tablicy nPT. W tym przypadku bez nPT mamy 4 odwołania do pamięci; jeśli zaś mamy nPT – do 24:



Parę testów


Wydajność z i bez użycia nested paging dla MS Terminal Services oraz SQL DB Hammer, uruchomione pod eksperymentalnym buildem VMware ESX:




Relative performance

Parę testów

Oracle 10G OLTP z i bez użycia nested paging, pod Red Hat Enterprise Linux uruchomionym pod Xen 3.1:



IOMMU



- IOMMU jest jednostką zarządzania pamięcią
- podobny do zwykłego MMU, który tłumaczy widoczne dla procesora adresy wirtualne na adresy fizyczne
- IOMMU zajmuje się tłumaczeniem widocznych dla urządzeń adresów wirtualnych na adresy fizyczne

Gdzie można znaleźć IOMMU?

- AMD opublikował specyfikację dla IOMMU w architekturze HyperTransport
- Intel – IOMMU jako Virtualization Technology for Directed I/O, oznaczana jako VT-d
- Sun IOMMU – Device Virtual Memory Access (DVMA)
- IBM – The IBM Translation Control Entry (TCE) – Logical Partition Security in the IBM eServer pSeries 690

IOMMU – zalety

- można przydzielać duże obszary pamięci bez konieczności, aby były one ciągłe w pamięci fizycznej; pozwala to czasem uniknąć używania wektorowego I/O
- urządzenia, które nie są w stanie stworzyć dostatecznie dużych adresów, aby pokryć nimi całą pamięć fizyczną dzięki IOMMU mogą odwoływać się do całej pamięci
- ochrona pamięci: urządzenie nie może czytać lub pisać do pamięci, która nie została mu przydzielona
- w niektórych architekturach IOMMU może także przekierowywać sprzętowe przerwania w sposób podobny do standardowego przekierowywania adresów

IOMMU – wady

Wady IOMMU, w porównaniu do bezpośredniego fizycznego adresowania pamięci:

- pewne straty w wydajności z powodu translacji adresów i konieczności zarządzania nimi
- większe zużycie pamięci fizycznej z powodu dodania tablicy stron dla I/O

Zastosowania IOMMU poza wirtualizacją

The Graphics Address Remapping Table (GART) jest to zarządca pamięci wejścia/wyjścia (IOMMU) wykorzystywany przez karty graficzne używające złącz AGP i PCI Express. Dzięki niemu tekstury, wielokąty i inne potrzebne dane wczytywane są bezpośrednio z pamięci fizycznej komputera z wykorzystaniem DMA.


XEN

- monitor maszyn wirtualnych dla IA-32, x86, x86-64, IA-64 oraz PowerPC 97
- zarządza współpracą maszyn wirtualnych uruchomionych w jego środowisku
- Xen działa na zasadzie parawirtualizacji. – nie emuluje dokładnie istniejącego sprzętu, lecz pewne jego podobieństwo

XEN – trochę historii

- Xen rozwijany był przez grupę z Uniwersytetu Cambridge jako część projektu XenoServers
- z czasem Xen uzyskał status samodzielnego projektu
- dzięki bardzo dużej efektywności w porównaniu do innych programów służących do wirtualizacji powstał komercyjny projekt XenEnterprise

XEN – schemat działania




XEN – zastosowania

- konsolidacja serwerów: Xen umożliwia uruchomienie wielu serwerów równocześnie na jednej maszynie, zachowując efektywność oraz zapewniając pełną izolację



- jednoczesne uruchamianie wielu systemów operacyjnych
- testowanie jądra

Jak szybki jest XEN?



Linux (L), Xen/Linux (X), VMware (V), UML (U)

KVM – Kernel-based Virtual Machine

- komponent KVM pojawił się w jądrze Linuksa wraz z wersją 2.6.20 (luty 2007)
- wykorzystuje wirtualizację wspomaganą sprzętowo
- w pełni wirtualizowane rozwiązanie dla systemów Linux
- mały i względnie prosty (ok. 10000 linii kodu)

KVM

Podobieństwa i różnice w stosunku do:

- 1 VMware – bardzo złożony, komercyjny
- 2 Xen – korzysta z Linuxa tylko do obsługi I/O. Ma własne: scheduler, moduł zarządzania pamięcią. Działa bez sprzętowego wsparcia dla wirtualizacji

KVM


1 Ograniczenia

- wymaga procesora x86, który wspiera wirtualizację
- nie wykorzystuje maszyn wieloprocessorowych

2 Plany na przyszłość

- wsparcie dla parawirtualizacji
- obsługa Power PC
- obsługa IA-64
- obsługa starszych platform takich jak Windows 95 i 98 SE
- obsługa maszyn wieloprocessorowych

KVM – wydajność



<http://www.phoronix.com>

Co mierzyliśmy

Na systemie gospodarza, pod KVM oraz VMware mierzyliśmy czasy działania następujących programów:

- jednego procesu znajdującego liczby pierwsze
- dwóch procesów znajdujących liczby pierwsze
- jednego procesu liczącego silnię, korzystającego z architektury 64 bitowej
- dla wielu procesów czekających na siebie
- popularnego programu użytkowego: `make bzImage`

Co mierzyliśmy

Na systemie gospodarza, pod KVM oraz VMware mierzyliśmy czasy działania następujących programów:

- jednego procesu znajdującego liczby pierwsze
- dwóch procesów znajdujących liczby pierwsze
- jednego procesu liczącego silnię, korzystającego z architektury 64 bitowej
- dla wielu procesów czekających na siebie
- popularnego programu użytkowego: `make bzImage`

Co mierzyliśmy

Na systemie gospodarza, pod KVM oraz VMware mierzyliśmy czasy działania następujących programów:

- jednego procesu znajdujacego liczby pierwsze
- dwóch procesów znajdujacych liczby pierwsze
- jednego procesu liczacego silnie, korzystajacego z architektury 64 bitowej
- dla wielu procesów czekajacych na siebie
- popularnego programu uzytkowego: `make bzImage`

Co mierzyliśmy

Na systemie gospodarza, pod KVM oraz VMware mierzyliśmy czasy działania następujących programów:

- jednego procesu znajdujacego liczby pierwsze
- dwóch procesów znajdujących liczby pierwsze
- jednego procesu liczącego silnię, korzystającego z architektury 64 bitowej
- dla wielu procesów czekających na siebie
- popularnego programu użytkowego: `make bzImage`

Co mierzyliśmy

Na systemie gospodarza, pod KVM oraz VMware mierzyliśmy czasy działania następujących programów:

- jednego procesu znajdujacego liczby pierwsze
- dwóch procesów znajdujących liczby pierwsze
- jednego procesu liczącego silnię, korzystającego z architektury 64 bitowej
- dla wielu procesów czekających na siebie
- popularnego programu użytkowego: `make bzImage`

Metodologia

- test były powtarzane 20 razy
- obliczaliśmy czas minimalny, maksymalny, średnią, wariancję
- w systemie w tym czasie nie działały inne programy użytkownika
- każda z wirtualnych maszyn miała do dyspozycji 10 GB przestrzeni dyskowej oraz 1 GB pamięci operacyjnej, zaś gospodarz pracował na procesorze 2-rdzeniowym AMD64
- wyniki zależne od liczby procesów obrazujemy na wykresach o skali logarytmicznej

Metodologia

- test były powtarzane 20 razy
- obliczaliśmy czas minimalny, maksymalny, średnią, wariancję
- w systemie w tym czasie nie działały inne programy użytkownika
- każda z wirtualnych maszyn miała do dyspozycji 10 GB przestrzeni dyskowej oraz 1 GB pamięci operacyjnej, zaś gospodarz pracował na procesorze 2-rdzeniowym AMD64
- wyniki zależne od liczby procesów obrazujemy na wykresach o skali logarytmicznej

Metodologia

- test były powtarzane 20 razy
- obliczaliśmy czas minimalny, maksymalny, średnią, wariancję
- w systemie w tym czasie nie działały inne programy użytkownika
- każda z wirtualnych maszyn miała do dyspozycji 10 GB przestrzeni dyskowej oraz 1 GB pamięci operacyjnej, zaś gospodarz pracował na procesorze 2-rdzeniowym AMD64
- wyniki zależne od liczby procesów obrazujemy na wykresach o skali logarytmicznej

Metodologia

- test były powtarzane 20 razy
- obliczaliśmy czas minimalny, maksymalny, średnią, wariancję
- w systemie w tym czasie nie działały inne programy użytkownika
- każda z wirtualnych maszyn miała do dyspozycji 10 GB przestrzeni dyskowej oraz 1 GB pamięci operacyjnej, zaś gospodarz pracował na procesorze 2-rdzeniowym AMD64
- wyniki zależne od liczby procesów obrazujemy na wykresach o skali logarytmicznej

Metodologia

- test były powtarzane 20 razy
- obliczaliśmy czas minimalny, maksymalny, średnią, wariancję
- w systemie w tym czasie nie działały inne programy użytkownika
- każda z wirtualnych maszyn miała do dyspozycji 10 GB przestrzeni dyskowej oraz 1 GB pamięci operacyjnej, zaś gospodarz pracował na procesorze 2-rdzeniowym AMD64
- wyniki zależne od liczby procesów obrazujemy na wykresach o skali logarytmicznej

VMware i zegarek

(„Niektórzy mówią, że nas oko łudzi
I że nic nie ma, tylko się wydaje”)

- VMware nie umie mierzyć czasu
- zatem czas mierzyliśmy stoperem ;)
- niestety, nie ma wyników dla testów o krótkich czasach, a czasy maksymalne i minimalne nie są wiarygodne

VMware i zegarek

(„Niektórzy mówią, że nas oko ludzi
I że nic nie ma, tylko się wydaje”)


- VMware nie umie mierzyć czasu
- zatem czas mierzyliśmy stoperem ;)
- niestety, nie ma wyników dla testów o krótkich czasach, a czasy maksymalne i minimalne nie są wiarygodne

VMware i zegarek


(„Niektórzy mówią, że nas oko ludzi
I że nic nie ma, tylko się wydaje”)

- VMware nie umie mierzyć czasu
- zatem czas mierzyliśmy stoperem ;)
- niestety, nie ma wyników dla testów o krótkich czasach, a czasy maksymalne i minimalne nie są wiarygodne

Liczby pierwsze i silnia




Dużo procesów – KVM



Dużo procesów – ilorazy



Deser



Gdzie szukać wirtualizatora?

Kilka przydatnych linków:

- Virtualbox – <http://www.virtualbox.org/>
- Virtual PC – <http://www.microsoft.com/windows/products/winfamily/virtualpc/default.mspx>
- Qemu – <http://bellard.org/qemu/>
- KVM – <http://kvm.qumranet.com/kvmwiki>
- Lguest – <http://lguest.ozlabs.org/>
- Xen – <http://www.xen.org/>
- VMware – <http://www.vmware.com/>