


Modulo 5 : La Virtualizzazione Tramite Hardware





Obiettivi

- Descrivere dispositivo denominato PR/SM
- Definire le caratteristiche di funzionamento del PR/SM
- Descrivere le modalita' di condivisione delle CPU e di dispositivi di I/O

Premessa

La Virtualizzazione di Risorse Informatiche tramite Hardware e' una caratteristica specifica dei Sistemi IBM ed in particolare dei Sistemi Centrali caratterizzati dalla z/Architecture .


IL Processor Resource & Systems Management (PR/SM) introdotto da IBM nel 1986 sui calcolatori IBM 3090 della famiglia S/370 e poi riportato come un dispositivo standard sulle piu' recenti Famiglie S/390, ES9000, zSeries e zSystems.

Si tratta di un **Firmware microcodificato** e non modificabile dall'utente

Per l'efficienza e le caratteristiche e' stato riproposto con le dovute modifiche anche su altre Famiglie di elaboratori con diversa architettura (RISC) detti pSeries dove viene chiamato **Micro-Partitioning**


Il PR/SM rimane ad oggi una caratteristica **Unica** ed Univoca dei Sistemi Centrali **IBM** e non e' stato ancora eguagliato in efficienza e funzioni da nessuna altra implementazione.

le tecniche di Partizionamento piu' comuni per approdare a passi successivi al modello PR/SM che ne rappresenta la implementazione piu' avanzata e che possiede altresì caratteristiche di Virtualizzazione.




Il Design dei Chips influisce sulle capacità di Virtualizzazione

Replicated Server Chip Design




- Carichi di lavoro misti e contemporanei stressano l'uso della cache, richiedendo un numero alto di context switches
- Working sets potrebbero essere troppo grandi per le dimensioni della cache
- La velocità di un processore "Fast" non è pienamente sfruttata a causa dei continui "cache misses"

Consolidated Server Chip Design




- La cache System Z è in grado di contenere più working sets e di dimensioni maggiori
- La velocità del Processore è ottimizzata in relazione alle dimensioni e all'uso della cache

Considerazioni sulla Scalabilità: Context Switching



- Virtualizzazione, - per definizione, comprende il “context switching”
- Il Tempo richiesto per eseguire un “context switching”, è un indicatore del memory time




Approcci alla Server Virtualization

Partizionamento Fisico	Firmware su "metallo"	Firmware su SW
<p>Server suddiviso in frazioni, in ognuna delle quali gira un OS</p>	<p>Firmware fornisce la condivisione a "grana fine" di tutte le risorse</p>	<p>Firmware usa I servizi del OS per la condivisione delle risorse</p>
<p>Physical partitioning S/370 SI-to-PP and PP-to-SI, Sun Domains, HP nPars</p> <p>Logical partitioning pSeries LPAR, HP (PA) vPars</p>	<p>System z PR/SM and z/VM POWER Hypervisor VMware ESX Server Xen Hypervisor</p>	<p>VMware GSX Microsoft Virtual Server HP Integrity VM User Mode Linux</p>

Outlook:

- "Firmware su Metallo" diventerà la soluzione dominante per i servers (alta efficienza e disponibilità)
- "Firmware su SW" utilizzato per workstation per clients,
- "Hardware partitioning" è ormai un approccio superato

Partizionamento Fisico - PPAR




Partizionamento fisico PPAR

Si tratta di una **tecnica** usata da HP , SUN ed IBM solo nei Sistemi di Architettura **INTEL**

- Le Partizioni Fisiche sono in genere correlate con la struttura fisica della macchina e poco modificabili.


Le risorse non sono condivise e/o virtualizzate

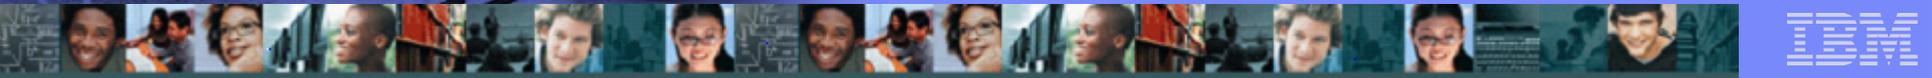
Console




Partizionamento Logico a risorse dedicate- LPAR


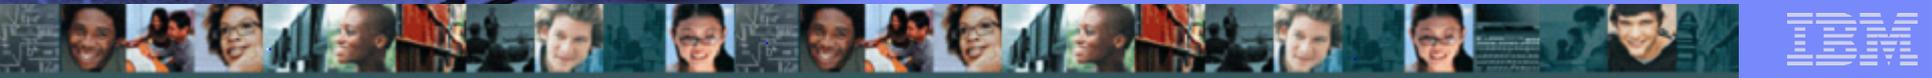
Si tratta di una tecnica usata da IBM nei Sistemi RISC con P4


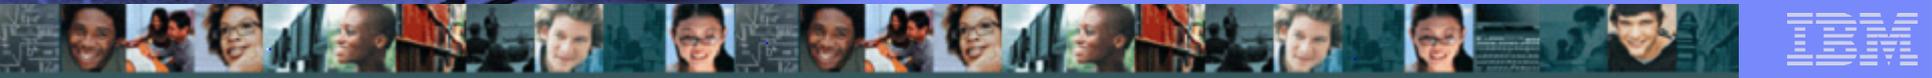


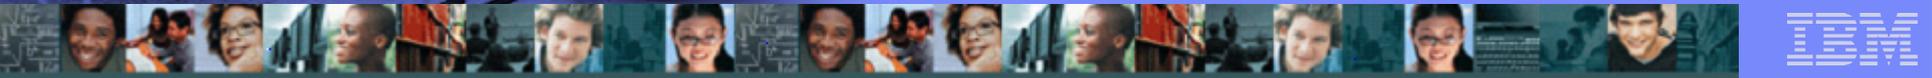


Partizionamento Logico Dinamico – Dyn LPAR







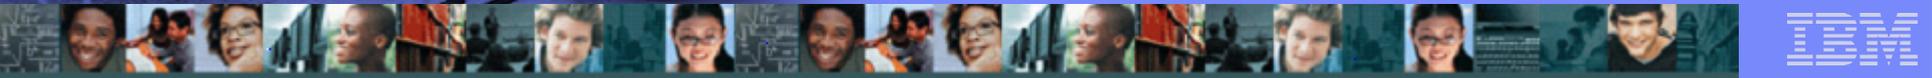


Caratteristiche del PR/SM

- Livelli Multipli di Virtualizzazione
- Completa Condivisione di Tutte le risorse
- Supporta Diversi Sistemi Operativi
- Partizioni Logiche con differenti TOD
- Allocazione Dinamica delle Risorse
- Eventuali Risorse Dedicare
- Capping
- Intelligent Resource Director

Numero di LPAR :		
3.	Z900	= 15
4.	Z800	= 15
5.	Z890-110	= 15
6.	Z890	= 30
7.	Z990	= 30
8.	Z9-109	= 60

Un Sistema con un solo processore su **z9-109** puo' avere **60 LPAR** , quindi la granularita' minima di una LPAR e' di un **sessantesimo di processore**.



Vocabolario

❑ LP – Logical processor

- Processore logico , che verrà dispacciato su un processore fisico

❑ PP – Physical Processor

- Processore fisico, uno dei processori presenti in macchina sul quale verranno eseguiti i LP

❑ LPAR

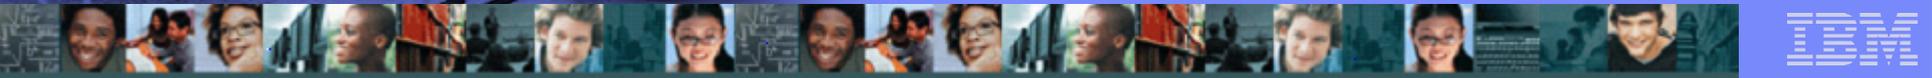
- Partizione Logica

❑ Weight

- Peso assegnato alla partizione logica

❑ Share

- Percentuale di allocazione della macchina fisica



Definizioni

■ **Processori Logici Dedicati**

- Assegnati ad un Processore Fisico (PP)
- Ad uso esclusivo di una LPAR
- LPAR con PP dedicati sottraggono elementi dal Pool dei processori disponibili
- LPAR con PP dedicati INACTIVE dona i suoi PP al Pool
- LPAR con PP dedicati configurati OFFLINE dona i suoi PP al Pool

■ **Processori Logici Shared (LP)**



- Assegnati ad un Pool di Processori Fisici
- $Share\% = \text{Peso (Weight) del LPAR} / \text{Peso delle LPAR "Active"}$
- E' possibile superare lo Share% se le altre LPAR non usano la loro allocazione
- Hard Capping non permette di superare lo Share%
- Soft Capping (WLC) non permette di superare la Capacità Definita (MSU)

Dispatching – PR/SM System z9

La struttura Multi-Book dei System z9 e dei z990 Trex, ha caratteristiche diverse per l'accesso alla Memoria

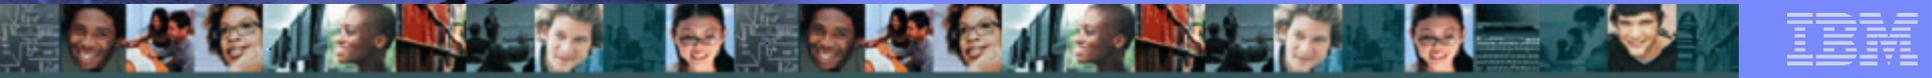
- Accesso alla Cache L2 da parte di PP di Books differenti
 - 2 x Book, 32MB x Book, Processor Cache

Accesso



Il PR/SM dei System z9 è concepito per garantire la migliore Performance ad un LPAR ...

- Assicurando la migliore allocazione possibile della memoria e dei processori al momento dell'attivazione
 - Tentativo di allocare tutta la memoria di un LPAR sullo stesso Book
 - Per le LPAR con PP dedicati, tentativo di allocare i processori sullo stesso Book della memoria
- Assicurando il "miglior Dispatching" possibile di un LP sul "miglior" PP
 - Ricerca del PP sullo stesso Book dell'ultimo dispatch
 - Ricerca del PP sullo stesso Book di dove risiede la memoria della LPAR (Primary Affinity Mask)






Le fonti di OVERHEAD

❑ L'overhead è costituito da 3 componenti principali:

- il tempo speso dal PR/SM per una specifica LPAR (LPAR Mgmt)
 - setup di un LP della LPAR per il dispatching su un PP
 - emulazioni chieste dal Sistema Operativo
 - cambio del TOD

- il tempo speso dal PR/SM per tutte le LPAR (*Physcal*)
 - ricerca di un LP da dispacciare


- Cache L1 miss (allungamento del TCB time)
 - le caches L1 servono più di un LP
 - I System z9 hanno migliorato ulteriormente tale effetto



Wait Complete

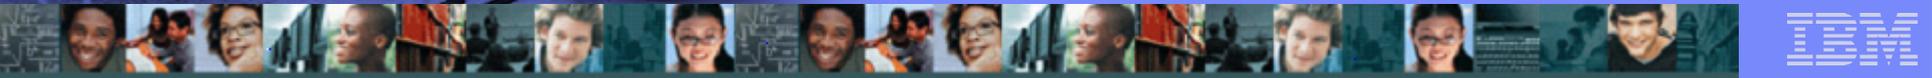
Event Driven WC=NO

- Se un LP è in Wait State non aspetta la fine del Time Slice per cedere il PP ad un altro LP



Time Driven WC=YES

- Se un LP è in Wait State, attende la fine del Time Slice per cedere il PP ad un altro LP



Dispatching – L'influenza del LPAR Weight) - Priorità...2/2

❑ Formule usate dal LIC

- Calcolo delle % fisica relativa a quella LPAR
- Calcolo del numero di PP relativi a quella LPAR
- Calcolo della % di PP per ogni LP

$$WEIGHT(LPARx)\% = 100 * \frac{WEIGHT(LPARx)}{\sum WEIGHT_LPAR_Actives}$$

$$TARGET(LPARx) = WEIGHT(LPARx) * (\#Non_DED_PP)$$

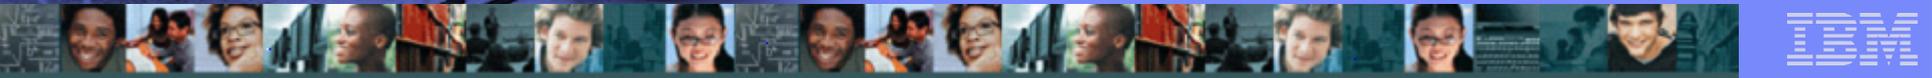
$$TARGET(LPx)\% = \frac{TARGET(LPARx)}{\#LP_dans_LPARx}$$

❑ Se Target(LPx)% < Current


- La LP utilizza più risorse di quello che le è stato garantito e la **Priorità Diminuisce** all'interno della Ready_Q

❑ Se Target(LPx)% > Current

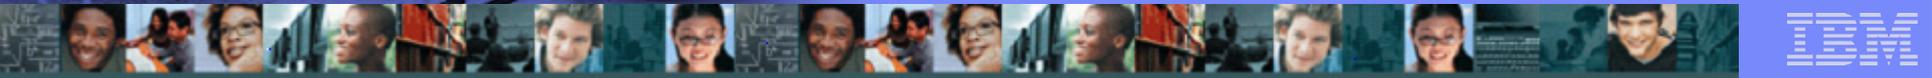
- La LP utilizza meno risorse "garantite" e la **Priorità Aumenta** all'interno della coda



Effetto MP



Fonte : Charyl Watson Research



Cos'è “Effetto MP” ?


Tempo speso nel "hardware" per le operazioni di coordinamento tra i vari Processori, azioni largamente “invisibili” al sistema operativo. Questo fenomeno accade ogni qualvolta un Processore accede o potrà accedere , nell'immediato (*instruction pipeline look-ahead*) qualsiasi risorsa hardware , la quale potrebbe essere, simultaneamente, aggiornata da un altro processo in corso.

Esempi di tale risorse sono:

- > bytes in real storage,
- > entries in a translation look-aside buffer,
- > data in high-speed buffer (HSB or L1) cache,
- > istruzioni in high-speed cache,
- > istruzioni in pipelines di altri processori

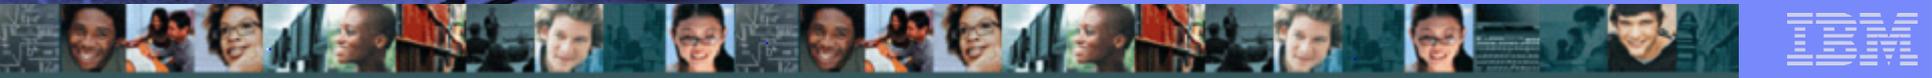
IBM System z CPU Virtualization

HiperSockets & Virtual Networking and Switching





Virtualizzazione Multi-dimensionale

- HW: **PR/SM (LPAR's)** & SW: **zVM (VM's)**
- Shared or Dedicated pools di "CPU's"
- **Shared Pools:**
- **Any Logical CPU runs on any physical CPU**
- **Dispatching dei logical CPU's è ottimizzato sulla base della locazione di memoria della LPAR & dispatch history**
- **Garanzia della capacità di LPAR = Weight**
- Capped and uncapped LPAR's
- **Time and Event Driven dispatching....**
- Event driven dispatching aumenta la reattività (metodo preferito)
- **Time-slices – nell'ordine dei 5-10ms – per ridurre i costi di gestione**
- Cicli di CPU non utilizzati da un LPAR sono "donati" ad altre LPAR's, e...
- **Logical CP's sono ordinati per priorità sulla base del rapporto "Relative Weights/Logical CP"**
- Low-priority LPAR's danno la precedenza alle LPAR con alta priorità
- **zVM ha algoritmi di schedulazione per ottimizzare la reattività ed il throughput**
- Le risorse Fisiche e Virtuali (CPU, I/O e memoria) possono essere "regolate" dinamicamente sia all'interno sia tra le LPAR's




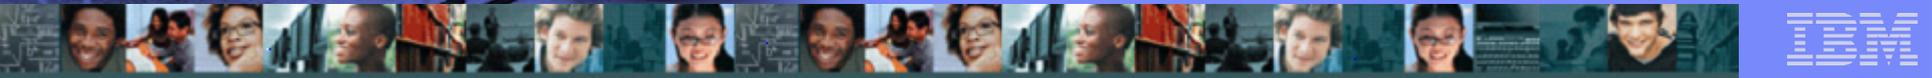
Livelli Multipli di Virtualizzazione HW + SW






Completa Condizione delle Risorse – CPU/ICF/zAAP

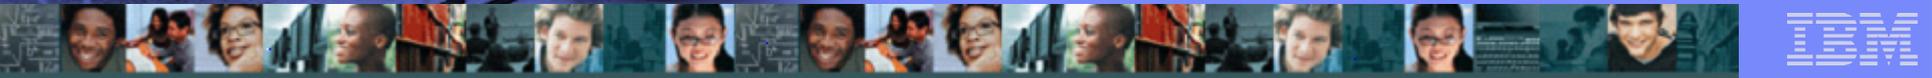




Completa Condivisione delle Risorse – CPU / IFL

I Processori di tipo IFL possono essere usati solo per LINUX o per LINUX Virtualizzato da z/VM





Gestione delle CPU Condivise – Dispatching e Peso e Capping

A Ciascuna **Partizione Logica caratterizzata** da un nome possono essere assegnate **CPU dedicate o Condivise**.

Se le CPU sono **dedicate** ad una partizione Logica la **potenza di calcolo** della partizione e' data dalla potenza equivalente di un Sistema zSeries di quel dato modello con quel dato numero di CPU in tutto.

Nel caso in cui vengano assegnate **CPU condivise** esse prendono il nome di **CP Logici**.

Il Numero di **CP Logici** assegnati ad una partizione ne determina l'**importanza e la prioritá** di esecuzione in caso di contesa di risorse.

Per calcolare la **prioritá di esecuzione** e la capacita' elaborativa assegnate ad una partizione con CPU condivise occorre tenere conto:

- **Del Numero di CP Logici Assegnati**
- Di un parametro utente detto **Peso** (weight)
- Della presenza di **Capping**

Consideriamo un semplice Esempio:


Dato un Sistema z/Architecture con 6 Cpu Fisiche definiamo in esso TRE partizioni logiche con CPU condivise.

Siano le partizioni logiche denominate:

**VSEESA
ZOSTEST
ZVM**

Supponiamo di definire per esse i seguenti parametri:

LP Name	Logical CPs	Weight
VSEESA	1	300
ZOSTEST	6	100
ZVM	2	900



Gestione delle CPU Condivise – Dispatching e Peso

Calcoliamo il 100% della capacita del sistema sommando i pesi dichiarati :

$$300 + 100 + 900 = 1300$$

Esprimiamo ora **in percentuale** il valore di ogni LPAR in base ai **pesi** dichiarati

Tale numero rappresenta **la percentuale della potenza globale, SHARE%** assegnata ad ogni LPAR in assoluto


Per calcolare quale e' la **frazione di singolo processore** che sara' assegnata ad ogni LPAR in caso di contesa di risorse occorre dividere **le percentuali assolute per il numero di CP Logici**

Su tali valori e' ammessa una tolleranza del 3.4% circa

LP Name	Logical CPs	Weight
VSEESA	1	300
ZOSTEST	6	100
ZVM	2	900

VSEESA	$300/1300 = 23.1\%$
ZOSTEST	$100/1300 = 7.7\%$
ZVM	$900/1300 = 69.2\%$

VSEESA	$23.1/1 \text{ CP} = 23.1\%$
ZOSTEST	$7.7/6 \text{ CPs} = 1.3\%$
ZVM	$69.2/2 \text{ CPs} = 34.6\%$




Gestione delle CPU Condivise – Capping

Pur avendo definito dei pesi specifici per ogni LPAR nel caso in cui non vi sia contesa di risorse, **ogni LPAR verra' servita mediante la risorsa CPU al meglio possibile** : In tal modo tutta la potenza disponibile sara' usata indipendentemente dai Pesi definiti da qualsiasi LPAR ne faccia richiesta.

Nel Caso in cui si presentino **contese** il PR/SM si occupera' di gestirle mantenendo i pesi specifici dichiarati e garantendo ad ogni LPAR la potenza calcolata in base ai pesi con uno scarto del 3.4%

Si definisce **Capping la possibilita' di forzare il rispetto dei Pesi su una LPAR anche in presenza di risorse disponibili in eccesso**

In caso di Capping tutte le LPAR cosi' dichiarate avranno la potenza determinata dal loro peso.



Caratteristiche delle Partizioni Logiche







Figure 1-1. Characteristics of Logical Partitions




PR/SM Gestione dell' I/O – Multi Image Facility (MIF)



System Z - MIF I/O Virtualization

- Ogni I/O device ha un “subchannel”
- Il subchannel è il target di una I/O instruction e sovrintende al controllo del device ed al suo accesso
- **Ogni LPAR interagisce DIRETTAMENTE con gli I/O devices**



Gestione dell' I/O – Shared Devices & Logical Path




Figure 2-13. Physical Connectivity of Shared Device 190







Figure 2-14. Logical View of Shared Device 190




Virtual I/O – Hypersockets e Virtual LAN






Consolidamento di Sistemi con Basso utilizzo



Se uno o piu' sistemi consolidati presentano un basso utilizzo il risultato sara' un risparmio complessivo della potenza necessaria

Ma fino a quanto questo recupero di potenza potra' essere realizzato ?





Minima Potenza Gestibile – Analizziamo un Caso di Studio

Studio del comportamento del consolidamento di due Sistemi detti SysA e SysB dei quali uno fortemente utilizzato ed uno scarsamente utilizzato.


Ipotizziamo due tipi di Partizionatori logici:

- A** = in grado di suddividere il processore in due parti. (Minima Potenza $\frac{1}{2}$ Processore)
- B** = in grado di suddividere il processore in quattro parti. (Minima Potenza $\frac{1}{4}$ di Processore)







Minima potenza Gestibile – Partizionatore A (1/2 CPU)




Benche' la somma dei due carichi non superi la potenza di 120 , il partizionatore di tipo A capace di suddividere il processore in due parti non sara' in grado di soddisfare in ogni istante le richieste concorrenti delle due partizioni logiche.




Minima potenza Gestibile – Partizionatore A (1/2 CPU)



Per potere gestire i due carichi concorrenti col partizionatore A occorrera' disporre almeno di una potenza di 180 a fronte di una somma che non supera 120 .



Minima potenza Gestibile – Partizionatore B (1/4 CPU)



Il Partizionatore B capace di suddividere il processore in quattro parti invece riuscirà a gestire perfettamente il carico con una potenza di 120 ,

La potenza minima gestibile e' molto importante al fine di ottimizzare carichi di diverso ordine di grandezza :
Col PR/SM su z9-109 la potenza minima gestibile e' di un sessantesimo di CPU