Lezione R14

Linux in ambito real-time

Sistemi operativi open-source, embedded e real-time

12 dicembre 2017

Marco Cesati

Dipartimento di Ingegneria Civile e Ingegneria Informatica
Università degli Studi di Roma Tor Vergata

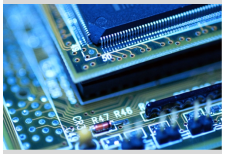

Di cosa parliamo in questa lezione?

In questa lezione si descrivono le soluzioni tecniche che consentono l'impiego di Linux in ambiti hard real-time

1. Utilizzo di Linux in ambito real-time
2. Approcci mono-kernel e dual-kernel
3. Sistemi real-time partizionati
4. RTAI
5. La patch PREEMPT_RT

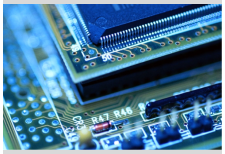

Linux come RTOS

È possibile considerare Linux come un sistema operativo real-time? ***Dipende...***

Linux **non** è un sistema **hard** real-time: è progettato per massimizzare il throughput delle applicazioni e minimizzare i tempi medi di risposta

Comunque Linux ha numerose caratteristiche che lo rendono conveniente per un utilizzo in ambienti real-time:

- Buona gestione di tempo e timer (*high resolution timer*)
- Gestione "separata" delle interruzioni
- Schedulazione e gestione delle priorità dei task
- Supporto alle politiche di accesso alle risorse condivise
- Interrompibilità dei task anche in kernel mode

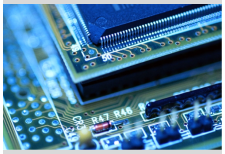

Linux come RTOS (2)

- Possibilità di creare facilmente task in kernel mode, con cambi di contesto rapidi e gestione della memoria con un unico spazio di indirizzamento
- Supporto alla memoria virtuale e protezione della memoria per i task user mode (cambio di contesto lento)
- Possibilità di configurazione a grana fine
- Kernel monolitico, ma codice completamente disponibile, modificabile e modulare per ottenere occupazione della memoria (footprint) ridotta
- È il sistema operativo con il maggior numero di architetture supportate
- È il sistema operativo con il maggior numero di driver di periferiche disponibili
- Comunità di sviluppo, supporto e testing molto attive

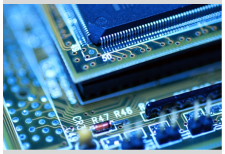

Limiti di Linux come hard RTOS

Il limite principale di Linux per il suo uso in ambito hard real-time è nella predicibilità temporale di kernel e applicazioni:

- Il kernel non è completamente interrompibile
- Le interruzioni sono disabilitate nelle sezioni critiche, sia nelle chiamate di sistema che nella gestione secondaria (ISR) di numerose interruzioni
- Le ISR possono avere una durata non predicibile
- La gestione delle interruzioni non fa uso di meccanismi di priorità
- La latenza di schedulazione dei task è elevata, soprattutto a causa del costo dei cambi di contesto

Si può rimediare a tutti questi limiti?

Non è semplice, ma effettivamente è possibile modificare il kernel Linux in modo da renderlo sostanzialmente predicibile

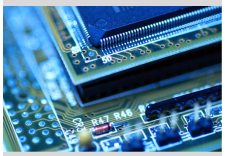

Linux come embedded RTOS

Il kernel Linux è monolitico, ha senso considerarlo per i sistemi embedded?

Sì, dato che è possibile configurare il kernel in modo da ridurre drasticamente la sua dimensione

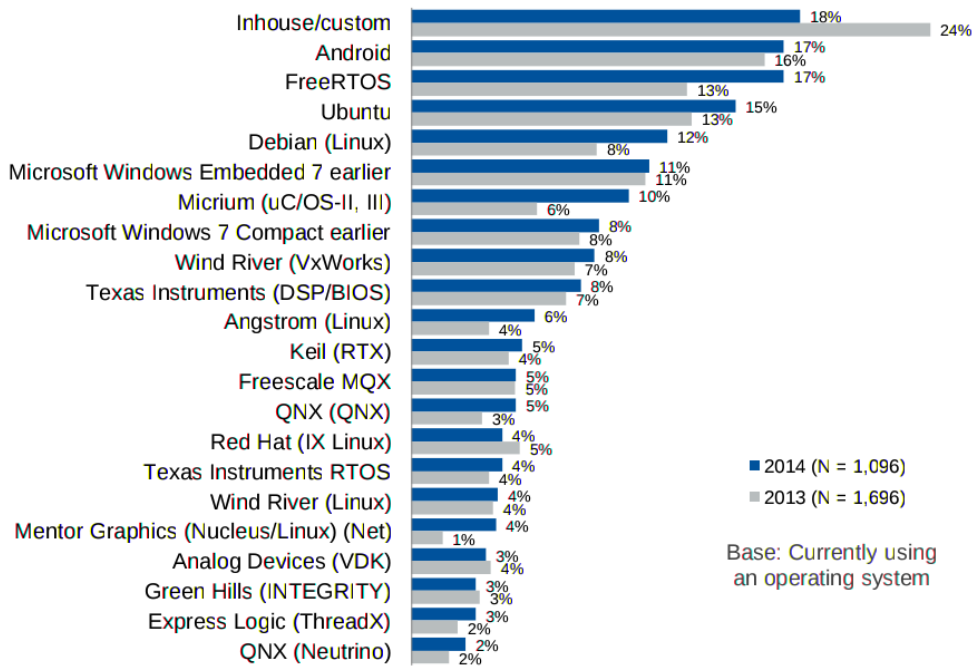

Fonte: www.embedded.com

Linux in ambito real-time
Marco Cesati

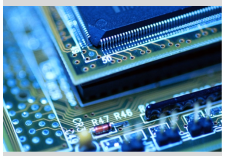

Schema della lezione
Linux e real-time
Mono- e dual-kernel
Sistemi partizionati
RTAI e ADEOS
Linux PREEMPT_RT

Limiti di Linux come hard RTOS

Il limite principale di Linux per il suo uso in ambito hard real-time è nella predicibilità temporale di kernel e applicazioni

Nel meccanismo di gestione delle interruzioni:

- Interruzioni senza priorità
- Molte ISR hanno sezioni critiche con interruzioni disabilitate
- Le ISR possono avere una durata non predicibile

Altri possibili problemi:

- Clock e timer non sufficientemente precisi
- Elevata latenza di schedulazione dei task, soprattutto a causa del costo dei cambi di contesto
- Kernel non completamente interrompibile

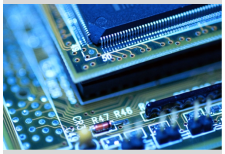

Gestione delle interruzioni in Linux

Un gran numero di problemi legati all'uso di Linux in ambito real-time è dovuto alla gestione delle interruzioni

- Le interruzioni hanno priorità più elevata dei processi
- Si utilizza una gestione "separata", con tre livelli:
- La prima parte della gestione (*top half*) si compone di interrupt handler e la parte immediata dell'ISR
  - L'interrupt handler salva e recupera il contesto interrotto e dà conferma della ricezione dell'interruzione
  - La parte immediata dell'ISR interagisce con la periferica H/W ed eventualmente "prenota" la successiva esecuzione del bottom half
- La seconda parte della gestione (*bottom half*)
  - svolge operazioni lunghe generalmente interrompibili
  - è costituita da una procedura da eseguire quando nessun altro top half è in esecuzione, quindi:
    - immediatamente prima di tornare ad eseguire un processo
    - oppure per mezzo di un kernel thread

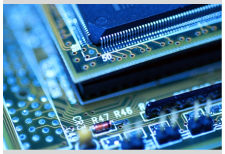

Problemi nella gestione delle interruzioni

- Le interruzioni sono in generale interrompibili da altre interruzioni
- È un problema perché le interruzioni non hanno priorità

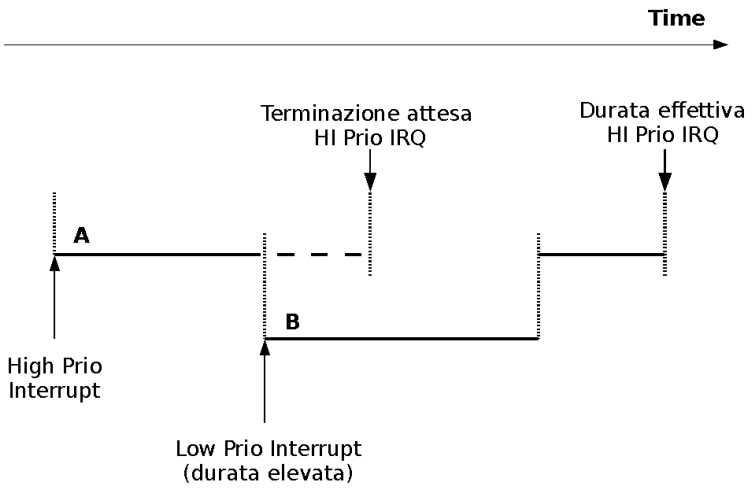

Disabilitare l'interrompibilità delle interruzioni non è una buona soluzione $\Longrightarrow$ **le interruzioni non sono predicibili**

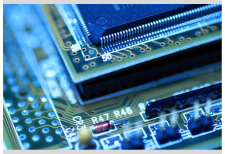

Gestione del tempo in Linux

- Linux è in grado di supportare i principali dispositivi hardware (clock device) per la gestione del tempo
- In genere ogni architettura offre diversi dispositivi hardware per la gestione del tempo
- In Linux ogni "orologio" hardware è visto come un dispositivo virtuale chiamato *clock source*
- Il tempo interno del sistema è mantenuto in nanosecondi (e non più in *jiffies* = numero di occorrenze del clock tick)
- Linux supporta i timer tradizionali di Unix, con bassa precisione e basati sul clock tick
- Linux supporta anche timer ad alta risoluzione, o hrtimer, indipendenti dal clock tick e con risoluzione nominale nell'ordine del nanosecondo
- La risoluzione effettiva degli hrtimer è comunque dell'ordine del microsecondo

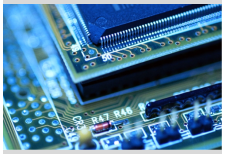

Problemi nella gestione del tempo

Cosa limita la precisione degli hrtimer in Linux?

- Attivare un hrtimer significa programmare un dispositivo hardware in modo che esso generi una interruzione dopo un determinato intervallo di tempo
- Se le interruzioni sono disabilitate per intervalli di tempo troppo lunghi, Linux non può rilevare la scadenza dell'hrtimer con sufficiente precisione
- Poiché le interruzioni non hanno priorità, la gestione dell'interruzione associata all'hrtimer può essere interrotta da un flusso di altre interruzioni
- Il kernel non è sempre interrompibile, quindi l'applicazione real-time che ha programmato l'hrtimer potrebbe non essere posta in esecuzione in tempo utile
- Poiché il costo del cambio di contesto è elevato, la lunghezza minima dell'intervallo effettivamente programmabile in un hrtimer è eccessiva

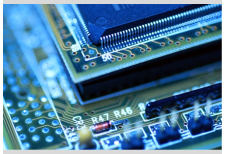

Schedulazione in Linux

Lo scheduler di Linux è un programma modulare:

- Basato sul concetto di *classi di schedulazione*, ossia una gerarchia di moduli che implementano differenti politiche di gestione dei processi
- Lo scheduler generale si limita ad interrogare le classi di schedulazione in ordine di priorità, chiedendo processi da porre in esecuzione
- Le politiche di schedulazione real-time sono definite in classi di schedulazione con priorità massima
- In generale tutte le classi di schedulazione:
  - supportano i sistemi multiprocessore (SMP)
  - hanno overhead essenzialmente indipendente dal numero di processi attivi nel sistema

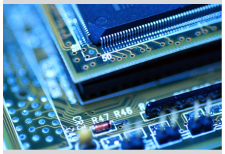

Politiche di schedulazione real-time

La classe di schedulazione real-time di *default* implementa uno scheduler con processi interrompibili a priorità fissa:

- la schedulazione dei processi real-time è (quasi) completamente distinta rispetto ai processi non real-time
- sono implementate una politica FIFO ed una Round-Robin per i processi di pari priorità
- lo scheduler è basato su una singola coda di processi eseguibili per ciascun processore con 100 livelli di priorità
- consente di implementare algoritmi a priorità fissa come RM o DM

Esiste un **meccanismo di sicurezza** per evitare che un processo real-time che non rilascia mai la CPU blocchi il sistema

Il meccanismo di sicurezza è modificabile o disabilitabile con i file "virtuali" `/proc/sys/kernel/sched_rt_period_us` e `/proc/sys/kernel/sched_rt_runtime_us`

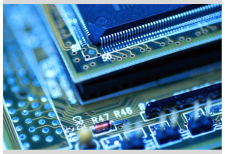

La classe di schedulazione Deadline

In Linux 3.14 (2014) è stata introdotta la nuova classe di schedulazione real-time Deadline:

- `SCHED_DEADLINE`, con priorità intermedia tra quelle real-time (`SCHED_RR`, `SCHED_FIFO`) e `SCHED_NORMAL`
- sviluppata principalmente da Dario Faggioli e Juri Lelli (Scuola Superiore S. Anna di Pisa) dal 2009 al 2014
- sostanzialmente introduce una schedulazione con priorità dinamica a livello di task: EDF

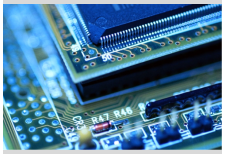

La classe di schedulazione Deadline (2)

- Ad ogni task Deadline sono associati i parametri (e, p, d) (in microsecondi):
  - e è il tempo di esecuzione del task
  - p è il periodo
  - d è la deadline relativa
- I task sono schedulati secondo l'algoritmo EDF

Come vengono calcolate le scadenze assolute?

- Si utilizza l'algoritmo CBS
  - Il tempo di esecuzione è il budget
- Lo stato corrente di un task e' descritto da una deadline assoluta e dal tempo di esecuzione residuo
- Ogni task della classe `SCHED_DEADLINE` è analogo a un server CBS!

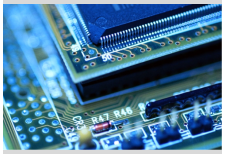

La classe di schedulazione Deadline (3)

Perché non è stato implementato l'algoritmo EDF puro?

Perché nel mondo reale i task possono avere comportamenti scorretti (ad es., eseguire più del tempo previsto)

Nell'implementazione `SCHED_DEADLINE`:

- Ogni task richiede allo scheduler di "riservare" e μs ogni p μs per la sua esecuzione
- Alla sua invocazione, lo scheduler aggiorna le scadenze e sceglie secondo l'algoritmo EDF
- Quando un task termina il proprio budget esso viene sospeso fino alla deadline usata per la schedulazione

Schedulazione EDF con isolamento temporale dei task

Non è una implementazione canonica di un server CBS!

Ref: *Documentation/scheduler/sched-deadline.txt*

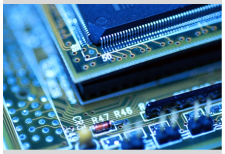

Problemi della schedulazione

Problema # 1

Un processo real-time ad alta priorità può comunque essere interrotto e quindi rallentato dai gestori delle interruzioni

Problema # 2

Linux implementa meccanismi di *bilanciamento del carico* sui sistemi multiprocessore

Bilanciamento del carico:

- Lo scheduler cerca di ripartire uniformemente il carico fra i processori effettuando migrazioni dei processi
- L'effetto di ciascuna migrazione è valutato solo in relazione al carico generato, e **non** considera le priorità
- La migrazione diminuisce la predicibilità di esecuzione ed aumenta la latenza a causa dei cambi di contesto aggiuntivi e della invalidazione delle memorie cache

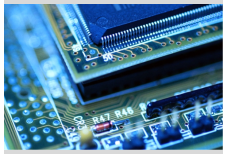

Il meccanismo di affinità della CPU

Il problema della non predicibilità dovuta al bilanciamento del carico è facilmente risolvibile: come?

Questo problema si presenta esclusivamente nei sistemi multiprocessore con schedulazione globale dei task

In Linux esiste un meccanismo che permette di definire l'affinità dei processi verso le CPU del sistema:

- Ogni processo possiede una "bitmap" che specifica i processori sui quali esso può essere eseguito
- La bitmap è ereditata dai figli del processo
- La bitmap è impostata mediante la chiamata di sistema `sched_setaffinity()`
- Da linea comando si può utilizzare il programma `taskset`

Con il meccanismo di affinità delle CPU si può realizzare un sistema statico in cui non si ha mai bilanciamento del carico

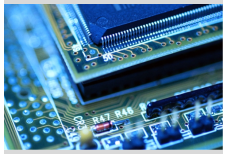

Come usare Linux in ambito hard real-time

Quali soluzioni tecniche possono consentire l'utilizzo di Linux in ambito hard real-time?

Esistono due strade possibili, radicalmente differenti:

1. Approccio mono-kernel: modificare radicalmente il kernel Linux per eliminare tutte le cause di impredicibilità del suo comportamento

2. Approccio dual-kernel: apportare il minor numero possibile di variazioni al codice di Linux, ma impedire l'accesso diretto ai dispositivi hardware tramite l'inserimento di uno strato di software intermedio tra il kernel e l'hardware

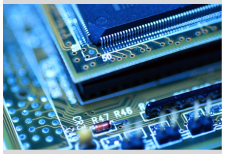

Approccio mono-kernel

Utilizzando l'approccio mono-kernel il codice sorgente del kernel Linux è modificato in modo molto complesso allo scopo di:

- ottenere la quasi completa interrompibilità del kernel
- consentire una gestione predicibile delle interruzioni
- proteggere i processi real-time dall'esecuzione dei gestori delle interruzioni
- implementare meccanismi di priority inheritance

Esempi di approcci mono-kernel applicati a Linux:

- MontaVista Hard Hat Linux (commerciale)
- TimeSys Linux (commerciale)
- Linux con patch PREEMPT_RT (open-source)

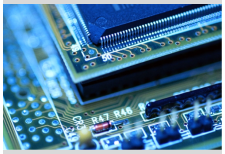

Approccio dual-kernel

Utilizzando l'approccio dual-kernel il kernel di Linux deve essere modificato in modo limitato ed in punti ben localizzati:

- L'obiettivo **non** è aumentare la predicibilità di Linux
- L'obiettivo è invece aumentare la predicibilità di un RTOS o applicazione RT in esecuzione insieme a Linux
- La chiave di volta dell'approccio dual-kernel è l'introduzione di uno strato intermedio tra l'hardware ed i sistemi operativi

Esempi di approcci dual-kernel applicabili a Linux:

- RTAI (open-source)
- Xenomai (open-source)
- RT-Linux (open-source)
- (fin troppi RTOS commerciali da citare. . .)

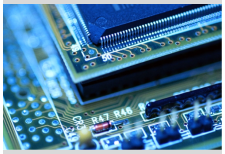

Esempio di sistema con dual-kernel

- Due SO a priorità differente sullo stesso hardware
- Un RTOS a priorità maggiore esegue i processi real-time
- Linux è attivo solo quando non vi sono processi real-time eseguibili
- Lo strato intermedio intercetta e consegna le interruzioni a Linux solo quando questo è in esecuzione

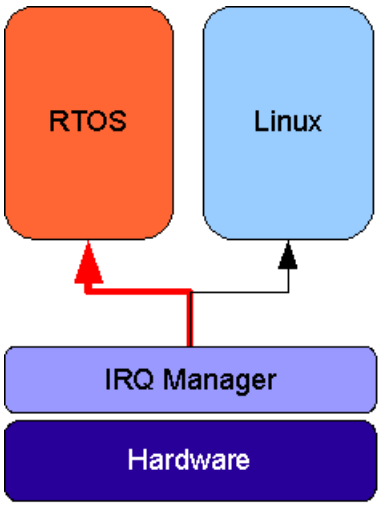

- Lo strato intermedio sostituisce sempre la gestione iniziale delle interruzioni di Linux
- È necessario quindi modificare la gestione iniziale delle interruzioni di Linux
- È possibile attivare il RTOS dopo l'inizializzazione di Linux

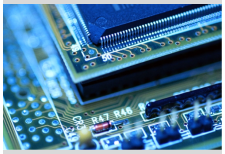

Vantaggi dell'approccio mono-kernel in Linux

Quali sono i vantaggi dell'approccio mono-kernel in Linux rispetto al dual-kernel?

- Le applicazioni real-time sono essenzialmente normali applicazioni POSIX o Linux
- L'applicazione real-time può utilizzare direttamente lo stack di rete e le comunicazioni tra processi implementate dal kernel Linux
- L'ambiente di sviluppo è molto flessibile ed efficiente
- Il progettista del sistema real-time può utilizzare il vasto insieme di driver di periferiche di Linux
- Le modifiche per adattare Linux all'ambito real-time sono gradualmente incorporate nel kernel standard
  $\Rightarrow$ le prestazioni del kernel standard tendono a migliorare

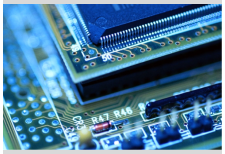

Vantaggi dell'approccio dual-kernel

Quali sono i vantaggi dell'approccio dual-kernel in Linux rispetto al mono-kernel?

- Le prestazioni delle applicazioni real-time non dipendono dal kernel Linux e sono quindi drasticamente migliori rispetto a quelle ottenibili con un mono-kernel
- È possibile utilizzare un RTOS specifico diverso da Linux, ovvero realizzare l'applicazione real-time senza supporto da alcun RTOS
- Il processo di certificazione del sistema real-time è limitato allo strato intermedio di astrazione dell'hardware ed ai componenti software real-time
- Non è necessario effettuare modifiche radicali e pervasive del kernel Linux, quindi è facile aggiornare il progetto del sistema real-time passando a nuove versioni del kernel
- Molti tipi di certificazioni richiedono in ogni caso un "partizionamento" spaziale e temporale del sistema

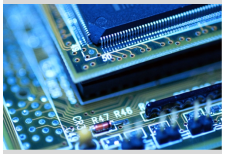

Partizionamento spaziale di un sistema

- Molti sistemi real-time debbono essere partizionati in modo spaziale
- Ciò è richiesto da diversi standard di certificazione, ad esempio l'ARINC 653 utilizzato in ambito avionico
- Il *partizionamento spaziale* del sistema è un meccanismo che consente di condividere le risorse del sistema tra più SO o applicazioni in modo che ciascuno di essi non possa interferire con il funzionamento degli altri
- Ad esempio, ciascuna partizione del sistema può essere associata ad una determinata porzione di RAM

  $\Rightarrow$ richieste eccessive di memoria da parte di una applicazione in una partizione non possono influenzare i programmi nelle altre partizioni
- Generalmente il partizionamento spaziale è realizzato tramite un programma (*separation kernel*, o SK) che crea una astrazione dell'hardware per i programmi in esecuzione nelle partizioni

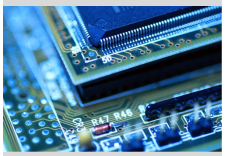

Partizionamento temporale di un sistema

- Anche il partizionamento temporale di un sistema è richiesto da diverse certificazioni come ARINC 653
- Il *partizionamento temporale* è analogo a quello spaziale, ma la risorsa suddivisa tra le varie partizioni è il tempo
- Tipicamente un separation kernel definisce una schedulazione ciclica delle partizioni
- I SO e le applicazioni in esecuzione in ciascuna partizione non possono influenzare i tempi d'esecuzione delle altre partizioni, né possono ritardare la loro schedulazione

In cosa differisce il partizionamento temporale di un RTOS dalla schedulazione dei processi di un sistema operativo generico?

- La schedulazione dei processi è essenzialmente un meccanismo software influenzabile da politiche di schedulazione, priorità dei processi, interruzioni, ...
- In una partizione di un sistema real-time può essere "contenuto" un intero SO e tutte le sue applicazioni

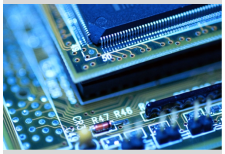

Esempio di sistema partizionato

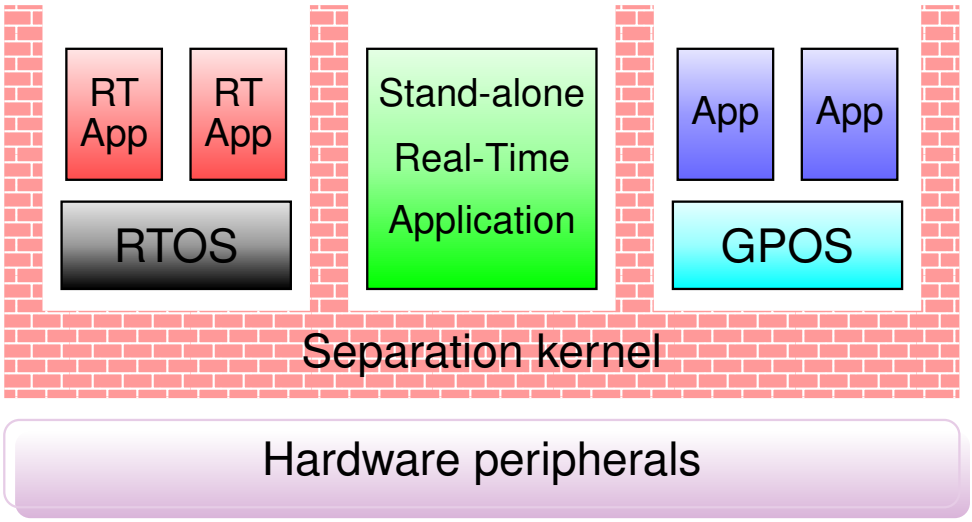

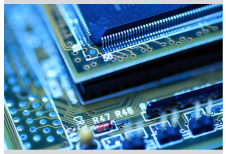

RTAI

RTAI (Real-Time Application Interface) è un RTOS hard real-time con approccio dual-kernel:

- Sviluppato nel Dipartimento di Ingegneria Aerospaziale del Politecnico di Milano (`www.rtai.org`)
- Nasce dall'esigenza di un RTOS a basso costo che consenta di utilizzare la FPU in kernel space
- Inizialmente basato su GNU-DOS, oggi su Linux
- L'ultima versione (4.1, marzo 2015) supporta le architetture x86, x86_64, PowerPC, ARM, M68K (Coldfire)

RTAI è costituito da:

- un *separation kernel* (generalmente una versione modificata di ADEOS)
- un modulo di Linux che costituisce il kernel del RTOS

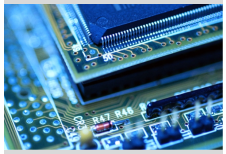

ADEOS

Il separation kernel di RTAI più utilizzato è in realtà un progetto indipendente (`home.gna.org/adeos`):

- ADEOS: Adaptive Domain Environment for Operating Systems
- è un nano-kernel che introduce uno strato di "virtualizzazione" tra le periferiche hardware e i sistemi operativi
- Le periferiche non sono pilotate direttamente da ADEOS, ma dai sistemi operativi
- ADEOS intercetta però le interruzioni generate dalle periferiche e le trasmette il più rapidamente possibile ai sistemi operativi
- Ogni sistema operativo è incluso in un proprio *dominio*

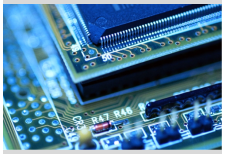

Architettura di ADEOS

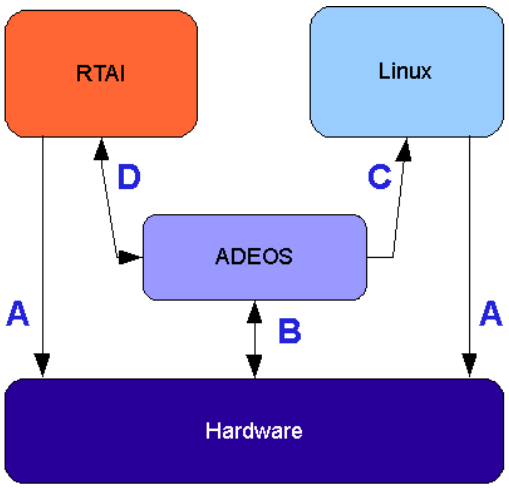

A : normale uso delle periferiche hardware

B : gestione iniziale delle interruzioni

C : dominio "parzialmente consapevole" di ADEOS (Linux)

D : dominio "consapevole" di ADEOS (RTAI)

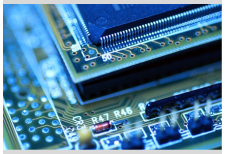

Gestione delle interruzioni con ADEOS

- In ADEOS ogni dominio è associato ad una priorità
- Ogni dominio è inserito in una catena di consegna delle interruzioni in relazione alla sua priorità

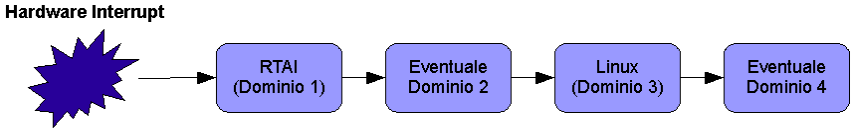

- Ogni singola interruzione è propagata da ADEOS lungo tutta la catena
- Ciascun dominio può accettare l'interruzione (normale gestione)
- oppure può bloccare l'interruzione (ad esempio disabilitando le interruzioni)
- oppure se è consapevole della presenza di ADEOS può ignorare l'interruzione e/o terminare la sua propagazione

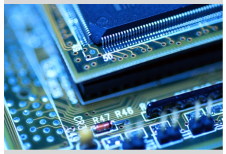

RTAI e ADEOS

- Sia ADEOS che RTAI sono implementati come moduli del kernel Linux
- ADEOS e RTAI possono essere attivati dopo l'inizializzazione di Linux
- RTAI è installato come dominio di massima priorità in ADEOS
- Linux diventa un dominio a priorità inferiore ad RTAI
- Al kernel Linux viene aggiunto il supporto per la gestione della catena di interruzioni di ADEOS

In realtà con RTAI si utilizza una versione modificata di ADEOS che consente una gestione più veloce delle interruzioni

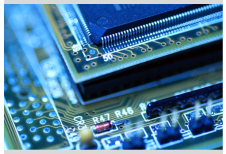

RTAI e ADEOS (2)

Gestione veloce di RTAI

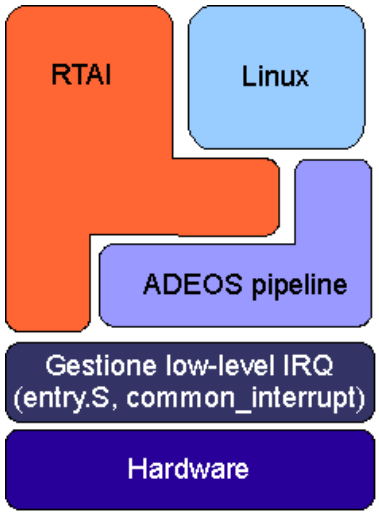

ADEOS standard (es. Xenomai)

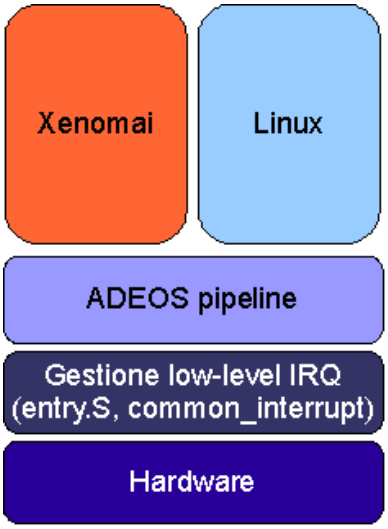

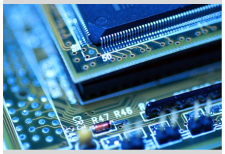

Schedulazione in RTAI

Lo scheduler di RTAI è sia *clock-driven* che *event-driven*:

Il meccanismo di schedulazione viene attivato:

- alla ricezione di una interruzione di timer
- all'uscita di una ISR
- alla sospensione spontanea di un task

In RTAI è possibile schedulare processi di Linux (*LXRT*):

- sono stati "promossi" hard real-time e sottratti allo scheduler di Linux
- **non** possono utilizzare chiamate di sistema di Linux

È "facile" realizzare una applicazione real-time che dialoga con il sistema Linux creando un programma multi-thread in cui alcuni thread sono assegnati ad RTAI ed altri a Linux!

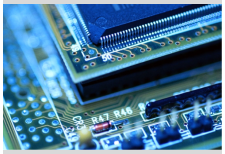

Schedulazione in RTAI (2)

In RTAI è anche possibile avere task “nativi”:

- Sono simili a kernel thread schedulati esclusivamente da RTAI
- Offrono un cambio di contesto molto veloce, ma non hanno protezione della memoria e dello spazio di indirizzamento
- Non è facile integrarli con le funzionalità del kernel Linux
- Generalmente vengono affiancati ad un task LXRT per la comunicazione con il kernel Linux

Nei sistemi multiprocessore:

- Ogni task è forzato ad eseguire su una sola CPU
- La CPU può essere determinata dall’utente o automaticamente da RTAI

RTAI supporta gli algoritmi di schedulazione FIFO, Round Robin, Rate Monotonic (RM) e Earliest Deadline First (EDF) e alcuni meccanismi di priority inheritance

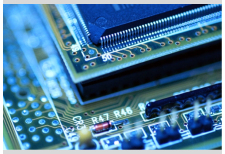

Linux PREEMPT_RT

Il principale progetto open-source per realizzare un RTOS mono-kernel basato su Linux è la patch PREEMPT_RT (`rt.wiki.kernel.org`)

- È la continuazione della patch MontaVista di Ingo Molnar per rendere il kernel pienamente interrompibile
- Il suo sviluppo procede di pari passo con quello del kernel Linux standard
- I suoi meccanismi vengono gradualmente inseriti all’interno del kernel standard
- Ha due obiettivi principali:
  - ridurre la dimensione delle sezioni non interrompibili del kernel
  - permettere l’esecuzione dei gestori delle interruzioni in un contesto schedulabile con priorità confrontabili con quelle dei processi

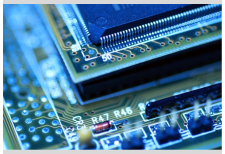

I meccanismi di PREEMPT_RT

L'idea fondamentale della patch PREEMPT_RT consiste nella sostituzione di alcuni meccanismi di sincronizzazione:

- Molte primitive del kernel standard disabilitano l'interrompibilità e iterano in un ciclo attendendo che una variabile di condizione cambi stato
- Queste primitive sono sostituite da *rt-mutex* che possono sospendere l'esecuzione del processo corrente
- Gli rt-mutex implementano un sofisticato protocollo di priority inheritance

Inoltre:

- l'operazione di acquisizione di uno spinlock può essere interrotta: disabilitare le interruzioni non basta!
- i gestori di interruzioni sono eseguiti all'interno di kernel thread

Alcuni tipi di interruzioni dalla durata breve e predicibile continuano ad essere eseguiti in modo "tradizionale"

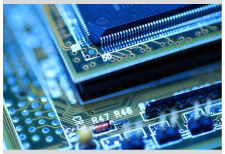

PREEMPT_RT e sistemi multiprocessori

Abbiamo visto che il modo migliore per garantire la predicibilità di un sistema multiprocessore consiste nel vincolare l'esecuzione di ciascun task ad uno specifico processore

Tuttavia la patch PREEMPT_RT cerca di mitigare gli effetti del bilanciamento del carico sulle CPU modificandone il funzionamento

- Il bilanciamento non può migrare un processo mentre esso è in esecuzione
- Il bilanciamento viene effettuato solo prima di mettere in esecuzione un processo o subito dopo la terminazione della sua esecuzione
- Il kernel cerca di non sovraccaricare un processore con processi di priorità elevata (i processi di priorità elevata sono distribuiti su più processori)
- Al risveglio di un processo ad alta priorità che dovrebbe interrompere il processo corrente si valuta euristicamente se è meglio migrarlo su un altro processore