Lezione E11

Scheduler per job interrompibili

Sistemi operativi open-source, embedded e real-time

21 novembre 2017

Marco Cesati

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

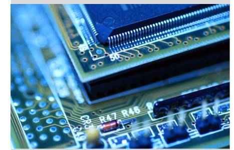

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Di cosa parliamo in questa lezione?

In questa lezione scriviamo il codice dello scheduler per job interrompibili

1. Il cambio di contesto
2. Creazione di un nuovo task
3. Scheduler (prima versione)
4. Modifiche alla funzione `_irq_handler()`
5. La funzione `_irq_schedule()`
6. La funzione `_sys_schedule()`
7. Scheduler (seconda versione)

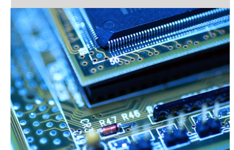

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

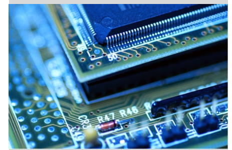

Contesto prima dell'esecuzione di _bsp_irq( )

- La CPU è in modalità SYSTEM
- I registri AAPCS-clobbered del flusso di esecuzione interrotto salvati sullo stack sono `r0`–`r3`, `r12`, `r14` (=`lr`)
- Nel registro `r12` è caricato l'indirizzo del gestore di medio livello dell'interruzione `_bsp_irq()`

	r0	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10	r11	r12	sp r13	lr r14	pc r15	cpsr	spsr
SYS	N-32	Q	C	D	E	F	G	H	I	J	K	L	Ω	N-32	#	#	*	////
IRQ														A	B			Q
STK	(A)	B	C	D	M	O	P+4	Q	X	Y	Z							

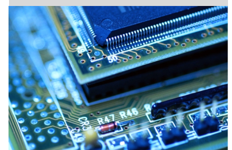

Contesto dopo la terminazione di _bsp_irq( )

- La CPU è in modalità SYSTEM
- In cima allo stack vi sono i valori di alcuni registri del flusso di esecuzione da recuperare:
    - Registri AAPCS-clobbered `r0`–`r3`, `r12`, `r14` (=`lr`)
    - Registro `r15` (=`pc`), ossia l'indirizzo dell'istruzione successiva del flusso di esecuzione da recuperare
    - Registro `cpsr`

	r0	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10	r11	r12	sp r13	lr r14	pc r15	cpsr	spsr
SYS	?	?	?	?	E	F	G	H	I	J	K	L	?	N-32	?	#	*	////
IRQ														?	?			?
STK	(A)	B	C	D	M	O	P+4	Q	X	Y	Z							

Cambio di contesto

- Ogni job ha un proprio stack
- I valori dei registri `r0–r3`, `r12`, `r14`, `r15` e `cpsr` sono salvati sul proprio stack
- È necessario salvare altrove i valori dei registri `r4–r11` e `r13` (=`sp`)
  - Salvataggio nel descrittore del task!
- Effettuare il cambio di contesto significa modificare `sp` in modo che faccia riferimento allo stack di un task differente
- Il cambio di contesto viene effettuato subito dopo la terminazione di `_bsp_irq()`
  - Le istruzioni macchina seguenti in `_irq_handler()` recuperano il contesto di un flusso di esecuzione (job) diverso da quello interrotto

Il cambio di contesto avviene solo se si sta per tornare all'esecuzione di un job (attenzione alle interruzioni annidate)

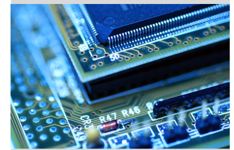

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Stack specifico per ogni task

- Gli stack sono allocati nella sezione `.bss` in un unico vettore
  - È necessario evitare di inizializzare a zero gli stack, altrimenti viene riscritto l'indirizzo di ritorno di `fill_bss()`
  - Utilizziamo una sottosezione chiamata `.bss.stack`
- Ogni stack ha lunghezza predefinita
- Ogni stack è allineato a pagine di memoria
- Gli stack crescono per indirizzi decrescenti

```
#define STACK_SIZE 4096
char stacks[MAX_NUM_TASKS*STACK_SIZE]
  __attribute__((aligned (STACK_SIZE)))
  __attribute__((section (.bss.stack)));
const char *stack0_top =
  stacks + MAX_NUM_TASKS*STACK_SIZE;
```

Scheduler per job interrompibili

Marco Cesati

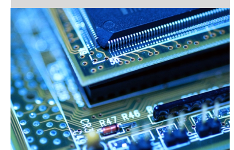

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Il descrittore del task

```
struct task {
    int valid;
    unsigned long releasetime;
    int released;
    int period;
    int priority;
    job_t job;
    void *arg;
    const char *name;
    unsigned long sp;
    unsigned long regs[8];
};
```

- La variabile `current` contiene l'indirizzo del task in esecuzione
- Se nessun job è eseguibile, `current` punta al descrittore del task con TID 0 (idle task)

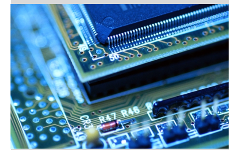

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione _switch_to()

```
void __attribute__((naked))
_switch_to(struct task *to)
{
    irq_disable();
    save_regs(current->regs);
    load_regs(to->regs);
    switch_stacks(current, to);
    current = to;
    irq_enable();
    naked_return();
}
```


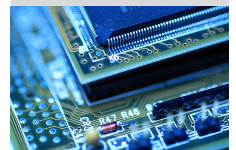

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Funzioni “naked”

- L’attributo `naked` è una estensione del compilatore **gcc** per l’architettura ARM
- Forza il compilatore a non emettere codice per il prologo e l’epilogo della funzione
- Nessuna istruzione generata automaticamente per salvare il contenuto di registri sullo stack
- Tuttavia non viene nemmeno emessa l’istruzione di “return” per terminare la funzione
  - È necessario generare esplicitamente l’istruzione di “return”

```
#define naked_return() \
    __asm__ __volatile__("bx lr");
```


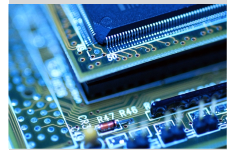

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler( )
_irq_schedule( )
_sys_schedule( )
Scheduler (2^a vers.)

Salvataggio e ripristino dei registri r4–r11

Per salvare il contenuto dei registri `r4–r11`:

```
#define save_regs(regs) \
    __asm__ __volatile__("stmia %0,{r4-r11}" \
                : : "r" (regs) : "memory");
```

Per ripristinare il contenuto degli stessi registri:

```
#define load_regs(regs) \
    __asm__ __volatile__("ldmia %0,{r4-r11}" \
          : : "r" (regs) : "r4", "r5", "r6", \
     "r7", "r8", "r9", "r10", "r11", "memory");
```

Scheduler per job interrompibili

Marco Cesati

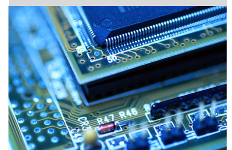

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler( )
_irq_schedule( )
_sys_schedule( )
Scheduler (2^a vers.)

La macro switch_stacks

La macro `switch_stacks` salva e ripristina il contenuto del registro `r13` (=`sp`)

```
#define switch_stacks(from, to) \
    __asm__ __volatile__("str sp,%0\n\t" \
                         "ldr sp,%1\n\t" \
            : "m" ((from)->sp), "m" ((to)->sp) \
                                  "sp", "memory");
```


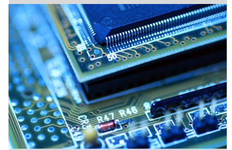

Schema della lezione

Cambio di contesto

Creazione di un task

Scheduler (1^a vers.)

_irq_handler()

_irq_schedule()

_sys_schedule()

Scheduler (2^a vers.)

Inizializzazione del contesto di un nuovo task

- Determinare la posizione dello stack del task
- Definire l'entry point del job
  - Non coincide con la funzione da eseguire nel job
- Inizializzare il contesto salvato nel descrittore del task
- Inizializzare lo stack del task
  - Deve avere la stessa struttura dello stack di un job interrotto da una interruzione

STK	**r0**	r1	r2	r3	r12	lr	pc	spsr
	N	+4	+8	+12	+16	+20	+24	+28

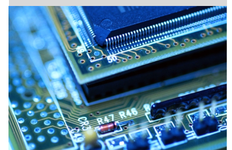

Schema della lezione

Cambio di contesto

Creazione di un task

Scheduler (1^a vers.)

_irq_handler()

_irq_schedule()

_sys_schedule()

Scheduler (2^a vers.)

La funzione init_task_context( )

```
void init_task_context(struct task *t,
                                int ntask) {
    int i;
    unsigned long *sp = (unsigned long *)
         (stack0_top-ntask*STACK_SIZE);
    *(--sp) = SYS_MODE | NO_FIQ;   // spsr
    *(--sp) = (unsigned long)
              task_entry_point;   // RET
    *(--sp) = 0ul;                 // lr
    *(--sp) = 0ul;                 // r12
    *(--sp) = 0ul;                 // r3
    *(--sp) = 0ul;                 // r2
    *(--sp) = 0ul;                 // r1
    *(--sp) = (unsigned long) t;   // r0
    t->sp = (unsigned long) sp;
    for (i = 0; i < 8; ++i)
        t->regs[i] = 0ul; /* r4-r11 */
}
```


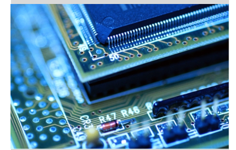

Schema della lezione

Cambio di contesto

Creazione di un task

Scheduler (1^a vers.)

_irq_handler( )

_irq_schedule( )

_sys_schedule( )

Scheduler (2^a vers.)

La funzione init_task_context( )

- I registri `pc` e `r0` vengono configurati in maniera da saltare alla funzione `task_entry_point()` passando come argomento il puntatore al descrittore del task nel registro `r0`
- I registri da `r1` ad `r12` (compresi `r4`-`r11`) assumeranno valore 0
- Il registro `lr` viene impostato a 0 in quanto come si vedrà la funzione `task_entry_point()` e' senza ritorno.
- Il registro `spsr` dev'essere impostato in maniera che la modalità di esecuzione sia SYSTEM e gli IRQ siano abilitati.

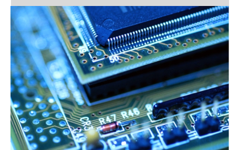

Schema della lezione

Cambio di contesto

Creazione di un task

Scheduler (1^a vers.)

_irq_handler( )

_irq_schedule( )

_sys_schedule( )

Scheduler (2^a vers.)

La funzione task_entry_point()

`task_entry_point()` è il punto di ingresso di ogni task

L'argomento (in `r0`) è l'indirizzo del descrittore di task

```
void __attribute__((naked))
task_entry_point(struct task *t)
{
   for (;;) {
      if (!t->valid || !t->released)
         panic0();
      irq_enable();
      t->job(t->arg);
      irq_disable();
      --t->released;
      _sys_schedule();
   }
}
```


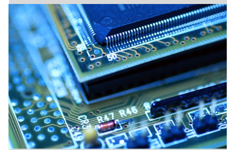

Schema della lezione

Cambio di contesto

Creazione di un task

Scheduler (1^a vers.)

_irq_handler()

_irq_schedule()

_sys_schedule()

Scheduler (2^a vers.)

La funzione task_entry_point() (2)

- Esegue un ciclo senza fine
  - Una iterazione per ciascun rilascio di un job del task
- La funzione del job è eseguita con interruzioni abilitate
- Per il resto il ciclo è eseguito con interruzioni disabilitate
- Quando un job termina si decrementa `t->released`
  - È il numero di job del task rilasciati e non completati
- La funzione `_sys_schedule()` seleziona un nuovo task da eseguire quando un job del task termina
  - È eseguita nel contesto di esecuzione dei job
  - La funzione "ritornerà" solo quando questo task verrà nuovamente selezionato dallo scheduler per l'esecuzione

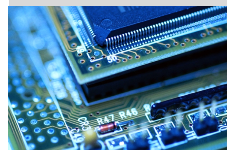

Schema della lezione

Cambio di contesto

Creazione di un task

Scheduler (1^a vers.)

_irq_handler()

_irq_schedule()

_sys_schedule()

Scheduler (2^a vers.)

La funzione create_task()

`create_task()` deve “saltare” il task 0 (idle task)

```
int create_task(job_t job, void *arg,
        int period, int delay,
        int priority, const char *name)
{
   int i;
   struct task *t;
   for (i=1 ;i<MAX_NUM_TASKS; ++i)
      if (!taskset[i].valid)
         break;
[...]
   t->releasetime = ticks + delay;
   t->released = 0;
   init_task_context(t, i);
   __memory_barrier();
   irq_disable();
[...]
}
```


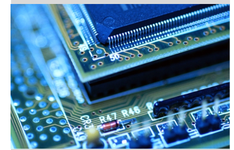

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Lo scheduler dei job

Costituito da diverse procedure:

- La funzione `check_periodic_tasks()`
  - Eseguita ad ogni tick in contesto interruzione
  - Controlla i rilasci dei job dei task periodici
- La funzione `schedule()`:
  - Eseguita nel contesto dei job
  - Scansiona il vettore di task per selezionare il job rilasciato di priorità massima

Chi invoca lo scheduler:

- La funzione Assembly `_irq_handler()`:
  - Alla conclusione della gestione dell’interruzione, esegue se necessario `schedule()`
- La funzione Assembly `_sys_schedule()`:
  - Invoca `schedule()` alla terminazione di un job

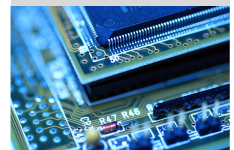

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione check_periodic_tasks()

```
void check_periodic_tasks(void) {
  unsigned long now = ticks;
  struct task *f;
  int i;
  for (i=0,f=taskset+1;i<num_tasks;++f) {
    if (f - taskset > MAX_NUM_TASKS)
       panic0();
    if (!f->valid)
       continue;
    if(time_after_eq(now,f->releasetime)){
       ++f->released;
       f->releasetime += f->period;
       trigger_schedule = 1;
       ++globalreleases;
    }
    ++i;
  }
}
```


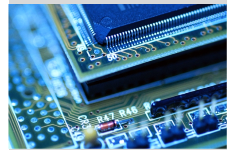

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione schedule() – 1^a versione

`schedule()` restituisce l'indirizzo del descrittore del task da eseguire, oppure `NULL` se il task corrente è già il migliore

```
struct task *schedule(void)
{
   struct task *best;
   unsigned long oldreleases;
   do {
      oldreleases = globalreleases;
      best = select_best_task();
   } while (oldreleases!=globalreleases);
   trigger_schedule = 0;
   return (best!=current ? best : NULL);
}
```

Scheduler per job interrompibili

Marco Cesati

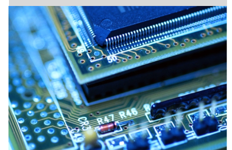

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione select_best_task()

```
static inline
struct task *select_best_task(void) {
    int maxprio, i;
    struct task *best, *f;
    maxprio = MININT;
    best  = &taskset[0];
    for (i=0,f=taskset+1;i<num_tasks;++f) {
        if (f - taskset > MAX_NUM_TASKS)
            panic0();
        if (!f->valid)
            continue;
        ++i;
        if (f->released > 0 &&
             f->priority > maxprio)
            maxprio = f->priority, best = f;
    }
    return best;
}
```


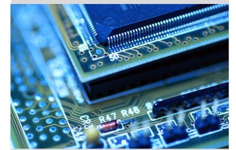

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Modifica alla funzione _irq_handler() (1)

`_irq_handler()` deve consentire di invocare `schedule()` se necessario

```
[...]
  bx       r12 /* call to _bsp_irq() */
  msr      cpsr_c,#(SYS_MODE|NO_INT)
: Nuove istruzioni :
  mov      r0,sp
  add      sp,sp,#(8*4)
  msr      cpsr_c,#(IRQ_MODE|NO_INT)
  mov      sp,r0
  ldr      r0,[sp,#(7*4)]
  msr      spsr_cxsf,r0
  ldmfd    sp,{r0-r3,r12,lr}^
  nop
  ldr      lr,[sp,#(6*4)]
  movs     pc,lr
```

Scheduler per job interrompibili

Marco Cesati

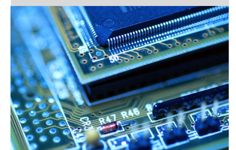

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Modifica alla funzione _irq_handler() (2)

Non si deve invocare `schedule()` se il flusso interrotto non appartiene a nessun job (ad es. interruzione annidata)

Introduciamo la variabile globale `irq_level` che tiene traccia del livello di annidamento raggiunto

```
unsigned long irq_level = 0ul;
void _bsp_irq(void) {
   u32 irqno;
   isr_t isr;
   ++irq_level;
   for (;;) {
      if (iomem(...) == 0 && ...) {
         --irq_level;
         return;
      }
      [...]
   }
}
```


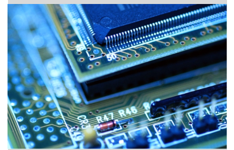

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Modifica alla funzione _irq_handler() (3)

Non si deve invocare `schedule()` se

- `irq_level` è diverso da zero
- `trigger_schedule` è uguale a zero

```
    msr     cpsr_c,#(SYS_MODE|NO_INT)
    ldr     r0,=irq_level
    ldr     r0,[r0]
    tst     r0,r0
    bne     .Lrestore
    ldr     r0,=trigger_schedule
    ldr     r0,[r0]
    tst     r0,r0
    beq     .Lrestore
[...]
.Lrestore:
    mov   r0,sp
```

Scheduler per job interrompibili

Marco Cesati

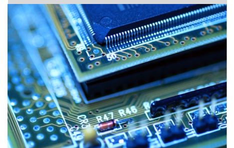

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione _irq_schedule() (1)

- Il valore restituito da `schedule()` è nel registro `r0`
- Se `r0` è nullo non occorre effettuare un cambio di contesto

```
_irq_schedule:
    ldr     r12,=schedule
    blx     r12
    tst     r0,r0
    beq     .Lrestore
    ldr     r12,=_switch_to
    blx     r12
    cpsid   if
.Lrestore:
[...]
```

Al termine di `_switch_to`:

- `sp` punta ora alla cima dello stack del task che deve essere eseguito
- Le interruzioni sono abilitate: forzare la disabilitazione attraverso **`cpsid`**

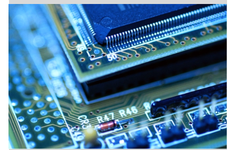

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione _sys_schedule() (1)

- Invocata al termine di un job
  - Lo stack non contiene i valori salvati da `_irq_handler()`
- È necessario salvare i registri AAPCS-clobbered sullo stack
  - ...ma non è possibile utilizzare i registri della modalità IRQ

```
_sys_schedule:
    str     lr,[sp,#-(4*2)]!
    mrs     lr,cpsr
    str     lr,[sp,#4]
    ldr     lr,[sp]
[...]
```

- Il valore di ritorno in `lr` viene salvato sullo stack
  - Punta all'interno del ciclo in `task_entry_point()`
  - `sp` viene aggiornato in modo da lasciare una posizione libera sotto la cima
- `cpsr` viene salvato sullo stack nella posizione libera
- `lr` viene recuperato dallo stack (la cima non è modificata)

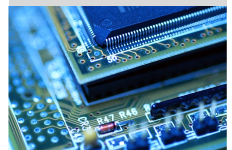

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione _sys_schedule() (2)

- Si salvano sullo stack i registri `r0–r3`, `r12` e `lr`
- Dopo il salvataggio la struttura dei valori sullo stack è esattamente identica a quella che si ha in seguito ad una interruzione
- La procedura termina eseguendo un salto entro la funzione `_irq_schedule()`

```
[...]
  ldr     lr,[sp]
  stmfd   sp!,{r0-r3,r12,lr}
  b       _irq_schedule
```


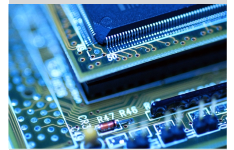

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Correzione della funzione _switch_to()

Poiché `_switch_to()` può essere invocata con le interruzioni già disabilitate, non è corretto ri-abilitarle al termine: è necessario ripristinare lo stato precedente.

Sostituire `irq_disable()` e `irq_enable()` con `irq_save()` e `irq_restore()`:

```
void __attribute__((naked))
_switch_to(struct task *to) {
    unsigned long flags;
    irq_save(flags);
    save_regs(current->regs);
    load_regs(to->regs);
    switch_stacks(current, to);
    current = to;
    irq_restore(flags);
    naked_return();
}
```


Scheduler per job interrompibili

Marco Cesati

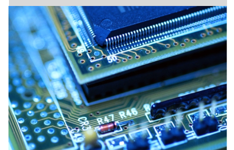

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Le macro irq_save( ) e irq_restore( )

Per salvare lo stato corrente del registro **cpsr** e disabilitare le interruzioni:

```
#define irq_save(flags) \
    __asm__ __volatile__("mrs %0,cpsr\n\t" \
                         "cpsid i\n\t" \
                : "=r" ((flags)) : : "memory");
```

Per ripristinare lo stato precedente di **cpsr** (la "c" consente di preservare i flag di condizione, eventualmente aggiornati):

```
#define irq_restore(flags) \
    __asm__ __volatile__("msr cpsr_c,%0" \
                    : : "r"((flags)) : "memory");
```

Scheduler per job interrompibili

Marco Cesati

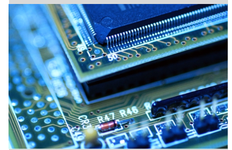

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1ª vers.)
_irq_handler( )
_irq_schedule( )
_sys_schedule( )
Scheduler (2ª vers.)

La nuova funzione _irq_schedule( )

- Alla luce delle modifiche a `_switch_to()`, non è più necessario forzare la disabilitazione delle interruzioni dopo l'invocazione:

```
_irq_schedule:
    ldr     r12,=schedule
    blx     r12
    tst     r0,r0
    beq     .Lrestore
    ldr     r12,=_switch_to
    blx     r12
    cpsid   if        (barrato)
.Lrestore:
[...]
```


Scheduler per job interrompibili

Marco Cesati

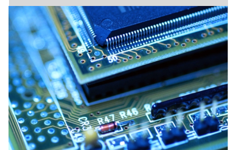

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1ª vers.)
_irq_handler( )
_irq_schedule( )
_sys_schedule( )
Scheduler (2ª vers.)

Analisi interrompibilità dello scheduler

- Adesso `schedule()` è sempre invocata con le interruzioni disabilitate, tuttavia tenerle disabilitate durante la scansione del vettore di task porterebbe a tempi di blocco eccessivi
- Scegliamo dunque di abilitarle durante la sola esecuzione della funzione `select_best_task()`

```
struct task *schedule(void) {
[...]
    do {
        oldreleases = globalreleases;
        irq_enable();
        best = select_best_task();
        irq_disable();
    } while (oldreleases!=globalreleases);
[...]
}
```


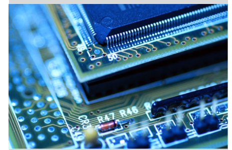

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

Race condition in schedule()

- Problema: adesso la funzione `schedule()` è rientrante
  - Ad esempio: quando un job termina viene invocata
  - Durante la sua esecuzione avviene una interruzione di tick
- Utilizziamo come meccanismo di sincronizzazione una variabile “sentinella” `do_not_enter`

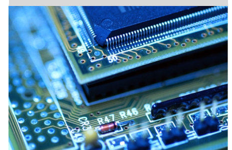

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler()
_irq_schedule()
_sys_schedule()
Scheduler (2^a vers.)

La funzione schedule( ) – versione finale

```
struct task *schedule(void) {
    static int do_not_enter = 0;
    struct task *best;
    unsigned long oldreleases;

    if (do_not_enter)
        return NULL;
    do_not_enter = 1;
    do {
        oldreleases = globalreleases;
        irq_enable();
        best = select_best_task();
        irq_disable();
    } while (oldreleases!=globalreleases);
    trigger_schedule = 0;
    do_not_enter = 0;
    return (best!=current ? best : NULL);
}
```


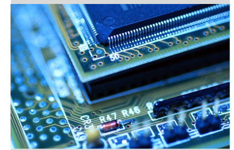

Schema della lezione
Cambio di contesto
Creazione di un task
Scheduler (1^a vers.)
_irq_handler( )
_irq_schedule( )
_sys_schedule( )
Scheduler (2^a vers.)