



SAPIENZA
UNIVERSITÀ DI ROMA

Sistemi di calcolo

Capitolo 5: Come si ottimizza un programma?

Corso di Laurea in Ingegneria Informatica e Automatica



Quali parti di un programma ottimizzare?

Cruciale identificare le parti critiche (se ci sono)

- 1) Studiare l'impatto che l'ottimizzazione di una parte ha sulle prestazioni del tutto
- 2) Identificare i colli di bottiglia (hot spot) in cui si concentra il grosso del lavoro, usando tool chiamati performance profiler.

More computing sins are committed in the name of efficiency (without necessarily achieving it) than any other single reason - including blind stupidity. (Bill Wulf) [motto del corso!]



Metriche di prestazioni

- Latenza: tempo richiesto per il completamento di una operazione
- Throughput: numero di operazioni completate nell'unità di tempo
- Spazio: memoria richiesta da un programma
- Energia: consumo energetico del sistema che esegue il programma



Scala degli eventi in un sistema di calcolo

Evento ²⁰	Latenza effettiva	Latenza riscalata
Ciclo di clock	0.4 nsec	1 sec
Accesso cache L1	0.9 nsec	2 sec
Accesso cache L2	2.8 nsec	7 sec
Accesso cache L3	28 nsec	1 min
Accesso RAM DDR3 DIMM	100 nsec	4 min
Accesso disco SSD	50-150 μ sec	1.5-4 giorni
Accesso disco a rotazione	1-10 msec	1-9 mesi
Invio pacchetto Internet continentale/intercontinentale	65-141 msec	5-11 anni



Speedup

$$\text{Speedup} = \frac{\text{Tempo programma non ottimizzato}}{\text{Tempo programma ottimizzato}}$$

Es. speedup 2x vuole dire che il programma ottimizzato richiede la metà del tempo di quello non ottimizzato.



Legge di Amdahl

La legge di Amdahl determina lo speedup complessivo di un programma a fronte dell'ottimizzazione di una sua parte:

$$\text{Speedup} = \frac{1}{\frac{\alpha}{k} + 1 - \alpha}$$

α = frazione del programma ottimizzata

k = speedup ottenuto su quella frazione



Legge di Amdahl: esempi

Es 1 $\alpha = 0.5$, $K = 2x$

$$\text{speedup} = \frac{1}{\frac{0.5}{2} + 1 - 0.5} = 1.33x$$

Es 2 $\alpha = 0.9$, $K = 6x$

$$\text{speedup} = \frac{1}{\frac{0.9}{6} + 1 - 0.9} = 4x$$



Legge di Amdahl: dimostrazione

Supponiamo di dividere un programma in due parti:

A: parte da ottimizzare B: rimanente

Si ha $T_A = \alpha T$ e $T_B = (1-\alpha)T$, dove T è il tempo totale richiesto dal programma. Si immagini ora di ottimizzare A ottenendo speedup K per la versione ottimizzata A' . Si ha:

$$\text{Speedup} = \frac{T}{T'} = \frac{T}{\underbrace{T_A' + T_B}_{\rightarrow T_A/K}} = \frac{T}{\frac{T_A}{K} + (1-\alpha)T} = \frac{T}{\frac{\alpha T}{K} + (1-\alpha)T}$$



Profilazione delle prestazioni

La profilazione delle prestazioni serve per identificare i colli di bottiglia, che meritano di essere ottimizzati.

Metodi di profilazione

Manuale, instrumentando il codice con chiamate a funzioni di misurazione del tempo

Automatico, usando dei tool (profilers) che calcolano il tempo speso nelle varie parti del programma (es. funzioni)



Profilazione manuale

Lo schema generale per profilare una porzione di codice è il seguente:

```
double start = misura_tempo();  
// porzione di codice da misurare  
// ...  
double elapsed = misura_tempo() - start;  
printf("Tempo richiesto: %f\n", elapsed);
```

instrumentazione

Si noti che `misura_tempo()` calcola il tempo attuale rispetto a un punto di riferimento dato.



Codice di misurazione manuale del tempo

```
#include <time.h> // misura-tempo() clock_gettime (misura nanosecondi)
double get_real_time_msec() {
    struct timespec ts;
    Tempo reale clock_gettime(CLOCK_MONOTONIC, &ts);
    return ts.tv_sec*1E03 + ts.tv_nsec*1E-06;
}
```

```
#include <sys/resource.h> // getrusage (misura microsecondi)
double get_user_time_msec() {
    struct rusage ru;
    getrusage(RUSAGE_SELF, &ru);
    return ru.ru_otime.tv_sec*1E03 + ru.ru_otime.tv_usec*1E-03;
}
```

misura-tempo()
tempo speso attivamente dal processo sulla CPU (tempo utente)
tempo utente



Codice di misurazione manuale del tempo

```
#include <sys/resource.h> // getrusage (misura microsecondi)
double get_system_time_msec() {
    struct rusage ru;
    getrusage(RUSAGE_SELF, &ru);
    return ru.ru_stime.tv_sec*1E03 + ru.ru_stime.tv_usec*1E-03;
}
```

tempo

speso attivamente sulla CPU in modalità supervisor

system

DEMO 5.1-profiling/E1-profile-sorting



Latenza e risoluzione funzioni misurazione tempo

Latenza: tempo richiesto dalla funzione di misurazione del tempo

Risoluzione: minimo intervallo misurabile

Entrambe devono essere $\ll$ della porzione da misurare (almeno un ordine di grandezza)

Se la porzione da misurare è troppo piccola si può pensare di ripeterla più volte, misurare il tempo totale e ottenere il tempo medio dividendo per il num. di ripetizioni

attenzione agli effetti dovuti alla cache!

DEMO 5.1-profiling/E2-*, E3-*



Profilazione automatica: gprof

Misura automaticamente tempo speso nelle varie funzioni

- 1) compilare programma con `gcc -Pg ... -O mioprogram`
- 2) eseguire il programma `mioprogram`. Questo genererà un report di profilazione chiamato `gmon.out`
- 3) visualizzare il report con `gprof mioprogram`


DEMO 5.1-profiling/E4-gprof



Aspetti chiave delle ottimizzazioni

Ottimizzare le prestazioni : ridurre la quantità di risorse richieste dall'esecuzione (es. tempo, spazio, energia)

(NB) attenzione a non compromettere la correttezza!





Importanza delle ottimizzazioni


Programmatore professionisti pensano innanzitutto a correttezza, manutenibilità, robustezza, portabilità, modularità, ecc. prima ancora delle prestazioni.

Perché occuparsi di prestazioni? Perché sono la "moneta" per comprare altre qualità del software che provocano riduzioni di prestazioni (es. modularità).

Con l'avvento delle architetture multi-core è diventato indispensabile che il programmatore si occupi di sfruttarle.



Legge di Moore: numero transistor x2 ogni 24 mesi



Original data up to the year 2010 collected and plotted by M. Horowitz, F. Labonte, O. Shacham, K. Olukotun, L. Hammond, and C. Batten
New plot and data collected for 2010-2017 by K. Rupp



Tecniche di ottimizzazioni prestazioni

Ridurre il "work" = numero di istruzioni eseguite

Ridurre il costo delle istruzioni eseguite (tempo richiesto dalle istruzioni)



Ottimizzazioni gcc

- O0: default, ok per debugging
- O1 (oppure -O): ottimizza, compilatore più lento di -O0
- O2: ottimizza ulteriormente, ancora più lento, non aumenta dimensione codice
- O3: ottimizza ancora di più, potrebbe aumentare la dimensione del codice generato
- Os: ottimizza per ridurre la dimensione del codice; attiva tutte le ottimizzazioni -O2 che non aumentano la dimensione del codice, più altre



Riduzione work: constant folding

Precalcola valori costanti:

C originale: test-cf.c	Constant folding (manualmente)
<pre>int f() { return 8+(14/2)*3; }</pre>	<pre>int f() { return 29; }</pre>

Incluso automaticamente in gcc-O1
Non va fatto manualmente dal programmatore

DEMO 5.2-work-opt/E1-const-fold



Riduzione work: constant propagation

Propaga valori costanti

C originale: test-cp.c	Constant propagation (manualmente)	Constant propagation + constant folding (manualmente)
<pre>int x; int f() { x = 8; return x-2; }</pre>	<pre>int x; int f() { x = 8; return 8-2; }</pre>	<pre>int x; int f() { x = 8; return 6; }</pre>

Non va fatto manualmente dal programmatore

DEMO 5.2-work-opt/E2-const-prop



Riduzione work: eliminazione sottoespressioni

Eliminazione sott-espressioni comuni

C originale: test-cse.c	Common subexpr. elimination (manualmente)
<pre>int expr(int x, int y) { return (x + y)*(x + y); }</pre>	<pre>int expr(int x, int y) { int z = x+y; return z*z; }</pre>

Non va fatto manualmente dal programmatore

DEMO 5.2-work-opt/E3-cse



Riduzione work: loop-invariant code motion (licm)

Evitare il ricalcolo di valori immutabili durante i loop

C originale: test1-licm.c	Loop-invariant code motion (manualmente)
<pre>int f(int x, int n) { int s = 1; for (; n>0; n--) s *= 7+x; return s; }</pre>	<pre>int f(int x, int n) { <i>int s=1; z=7+x;</i> <i>for (; n>0; n--) s *= z;</i> <i>return s;</i> }</pre>

Attenzione: potrebbe dovere essere effettuato dal programmatore

DEMO 5.2-work-opt/E4-licm, E5-licm



Riduzione work: loop unrolling

Riduzione del numero di iterazioni di un ciclo

C originale: test-lu.c	Loop unrolling di fattore 3 (manualmente)
<pre>int sum(int *v, int n) { int i, s = 0; for (i=0; i<n; ++i) s += v[i]; return s; }</pre>	<pre>int sum(int *v, int n) { int i, s = 0; for (i=0; i+2<n; s+=3){ s+=v[i]; s+=v[i+1]; s+=v[i+2]; } for (; i<n; i++) s+=v[i]; return s; }</pre>

NB) Alle volte viene effettuato dal compilatore.

DEMO 5.2-work-opt/E6-unroll

Serve se n
non è multiplo
di 3



Riduzione work: function inlining

Rimpiazza chiamata col corpo della funzione invocata

C originale: test-inl.c	Function inlining (manualmente)
<pre>int sqr(int x) { return x*x; } void f(int* v, int n) { int i; for (i=0; i<n; i++) v[i] = sqr(i); }</pre>	<pre>void f(int* v, int n) { int i; for (i=0; i<n; i++) v[i] = i*i; }</pre>

Effettuata in automatico dal compilatore con -O3.
Evitare di farla manualmente perché riduce modularità!

DEMO 5.2-work-opt/E7-inlining



Riduzione costo: register allocation

Tempo di accesso a registri $\ll$ Tempo accesso memoria
 $\Rightarrow$ compilatori tendono a allocare variabili in registri

C originale: test-ra.c	Senza alloc. registri (-O0)	Con alloc. registri (-O1)
<pre>void f(int n) { while (n--) g(); }</pre>	<pre>f: jmp L3 ciclo L4: call g L3: movl 4(%esp), %eax leal -1(%eax), %edx movl %edx, 4(%esp) testl %eax, %eax jne L4 ret</pre>	<pre>f: pushl %ebx movl 8(%esp), %ebx testl %ebx, %ebx je L3 L5: call g subl \$1, %ebx jne L5 L3: popl %ebx ret ciclo</pre>

DEMO 5.3-cost-opt/E1-reg-alloc



Riduzione costo: strength reduction

L'operator strength reduction consiste nel rimpiazzare un'operazione con una equivalente ma meno costosa:

Es.

$$X * 4 \rightarrow X \ll 2$$

$$X * 2 \rightarrow X + X \text{ o } X \ll 1$$

$$X * 17 \rightarrow X * 16 + X = X \ll 4 + X$$

$$X / 8 \rightarrow X \gg 3$$

NB: le operazioni di shift e somma sono molto più veloci di multipl. e divisione

DEMO 5.3-cost-opt/E2-strength-red



Riduzione costo: strength reduction

Rimpiazzare prodotti con somme ripetute
Effettuato dal compilatore con -O1

C originale: test-sr1.c	Strength reduction (manualmente)
<pre>void f(int* v, int n, int k) { int i; for (i=0; i<n; i++) v[i] = i*k; }</pre>	<pre>void f(int* v, int n, int k) { int i, c=0; for (i=0; i<n; i++) { v[i] = c; c += k; } }</pre>

DEMO 5.3-cost-opt/E3-strength-red2



Riduzione costo: allineamento dati in memoria

Vincolo accessi a memoria CPU: un oggetto di dimensioni s byte deve iniziare ad un indirizzo x multiplo di s , vale a dire $x \bmod s = 0$.

Motivazione:

modello di memoria programmatore:




modello di memoria CPU




una CPU a 32 bit
carica un intero
oggetto di 4 byte
alla volta se allineato
a indirizzo multiplo di
4 byte



Riduzione costo: allineamento dati in memoria



Es. struct S {
char x;
int y;
short z;
};



Alignamento corretto assumendo che a si multiplo di 4 byte.

(NB) padding = spazio sprecato



Riduzione costo: allineamento dati in memoria

L'allineamento migliora le prestazioni?

DEMO 5.3-cost-opt/E4-alignment

Sì, ma solo su architetture datate
Alcune CPU tuttavia generano un'eccezione
in caso di accesso non allineato




Riduzione costo: altre ottimizzazioni

Nel resto del corso vedremo altre ottimizzazioni del costo delle istruzioni legate ad aspetti hardware come i sistemi di memoria cache.



Riduzione spazio: ordinamento campi struct

```
struct S {  
    char a;  
    int b;  
    short c;  
    char d;  
    int e;  
    char f;  
};
```






Riduzione spazio: ordinamento campi struct

Si può ridurre lo spazio di una struct mettendo per primi i campi più grandi:

```
struct S {  
    int b;  
    int e;  
    short c;  
    char a;  
    char d;  
    char f;  
};
```



Il padding finale serve a garantire che in un array di strutture il primo campo sia allineato correttamente.



Riduzione spazio: eliminazione codice irraggiungibile

Dead code elimination: rimozione istruzioni non raggiungibili

C originale: test-dce.c	Dead code elimination (manualmente)
<pre>void f() { if (0) return 10; return 20; }</pre> <i>irraggiungibile</i> (with arrow pointing to the crossed-out line)	<pre>void f() { return 20; }</pre>

Un altro modo per ridurre la grandezza (footprint) del codice è compilare con -O5

DEMO 5.4-space-opt/E1-dead-code



Lezioni imparate

- 1) Ottimizzare solo i colli di bottiglia
(usare un profiler per identificarli)
- 2) Attenzione a mantenere la correttezza!
- 3) Molte ottimizzazioni sono fatte direttamente
dal compilatore (è utile disassemblare
il codice per capire le ottimizzazioni fatte)