

Progetto SOL – Corso A e B – a.a. 23/24

Docente Massimo Torquati

massimo.torquati@unipi.it

Si chiede di realizzare un programma C multi-processo e multi-threaded, denominato *farm2*, che implementa lo schema di comunicazione tra processi e thread mostrato in Figura 1.

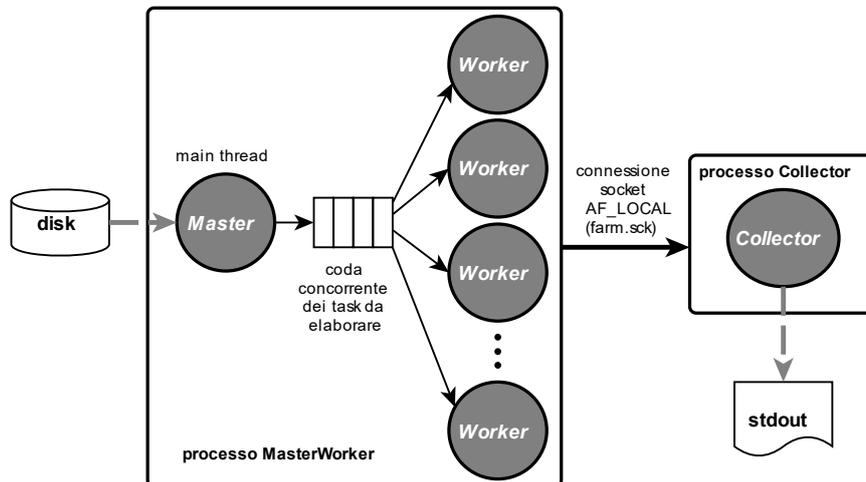


Figura 1 Architettura logica di connessione tra i processi *MasterWorker* e *Collector*

farm2 è un programma composto da due processi, il primo denominato *MasterWorker* ed il secondo denominato *Collector*. *MasterWorker*, è un processo multi-threaded composto da un thread *Master* e da ‘*n*’ thread *Worker*. **Il numero di thread Worker può variare dinamicamente nel corso dell’esecuzione.** Il valore iniziale del numero dei Worker viene settato utilizzando l’argomento opzionale ‘-n’ (vedere nel seguito). Il programma prende come argomenti una lista (eventualmente vuota se viene passata l’opzione ‘-d’) di file binari contenenti numeri interi lunghi ed un certo numero di argomenti opzionali (le opzioni sono ‘-n’, ‘-q’, ‘-t’, ‘-d’). Il processo *Collector* viene generato dal processo *MasterWorker*. I due processi comunicano **esclusivamente** attraverso una o più connessioni socket AF_LOCAL (AF_UNIX). Il processo *Collector* fa da processo server per le connessioni socket. Il socket file, denominato “*farm2.sck*” ed associato alla/alle connessione AF_LOCAL, deve essere creato all’interno della directory del progetto e deve essere cancellato alla terminazione del programma.

Il processo *MasterWorker* legge gli argomenti passati alla funzione *main* uno alla volta, verificando che siano file regolari. Se viene passata l’opzione ‘-d’ che prevede come argomento un nome di directory, viene navigata la directory passata come argomento e considerati tutti i file e le directory al suo interno.

Il nome del generico file di input (unitamente ad altre eventuali informazioni) viene inviato ad uno dei thread *Worker* del pool tramite una coda concorrente condivisa (denominata “coda concorrente dei task da elaborare” in Figura 1). Il generico thread *Worker* si occupa di leggere dal disco il contenuto dell’intero file il cui nome ha ricevuto in input, e di effettuare un calcolo sugli elementi letti. Il risultato del calcolo, unitamente al nome del file, viene quindi inviato dal *Worker* al processo *Collector* tramite la/le connessione/i socket precedentemente stabilita/e. Il processo *Collector* attende di ricevere tutti i risultati dai *Worker*, ed al termine della sua esecuzione, stamperà **sempre** i valori ricevuti sullo standard output, ordinando la stampa, in modo crescente rispetto al risultato (risultato1<=risultato2<=risultato3, ...):

```
risultato1  filepath1
risultato2  filepath2
risultato3  filepath3
```

La stampa dei risultati da parte del *Collector* avviene più di una volta se il tempo di esecuzione del *Collector* è maggiore ad un secondo. Infatti, il processo *Collector* stampa in modo ordinato sullo standard output i risultati parziali ricevuti fino a quel momento **dopo ogni secondo di esecuzione** (al termine, prima di uscire, effettuerà comunque la stampa di tutti i risultati ottenuti).

Il calcolo che deve essere effettuato su ogni file è il seguente:

$$result = \sum_{i=0}^{N-1} (i * file[i])$$

dove N è il numero di interi lunghi (long) contenuti nel file, e *result* è l'intero lungo che dovrà essere inviato al *Collector*. Ad esempio, supponendo che il file "mydir/fileX.dat" passato in input come argomento del *main* abbia dimensione 24 bytes, con il seguente contenuto (si ricorda che gli interi lunghi – *long* – sono codificati con 8 bytes in sistemi Linux a 64bit):

```
3
2
4
```

il risultato calcolato dal *Worker* sarà:

$N=3$, $result = \sum_{i=0}^{3-1} [(i * file[i])] = (0 * 3 + 1 * 2 + 2 * 4) = 10$, quindi il processo *Collector* stamperà:

```
10 mydir/fileX.dat
```

Gli argomenti che opzionalmente possono essere passati al processo *MasterWorker* sono i seguenti:

- -n <nthread> specifica il numero di thread *Worker* del processo *MasterWorker* (valore di default 4)
- -q <qlen> specifica la lunghezza della coda concorrente tra il thread *Master* ed i thread *Worker* (valore di default 8)
- -d <directory-name> specifica una directory in cui sono contenuti file binari ed eventualmente altre directory contenente file binari qualora l'opzione venga ripetuta più volte; i file binari dovranno essere utilizzati come file di input per il calcolo;
- -t <delay> specifica un tempo **in millisecondi** che intercorre tra l'inserimento di due task consecutivi nella coda concorrente da parte del thread *Master* (valore di default 0). Usare la chiamata di libreria *usleep* o la system call *nanosleep* per implementare il ritardo.

Il processo *MasterWorker* deve gestire i segnali **SIGHUP, SIGINT, SIGQUIT, SIGTERM, SIGUSR1 e SIGUSR2**. Invece, il processo *Collector* deve mascherare tali segnali. Il segnale SIGPIPE deve essere ignorato da entrambi i processi. Alla ricezione dei segnali SIGHUP, SIGINT, SIGQUIT e SIGTERM il processo *MasterWorker* deve attendere che i *Worker* completino i task eventualmente presenti nella coda dei task da elaborare, non leggendo più eventuali altri file in input; quindi, deve terminare dopo aver atteso la terminazione dei *Workers* e del processo *Collector*. Alla ricezione del segnale SIGUSR1 il processo *MasterWorker* incrementa di una unità il numero di thread *Worker* nel pool (cioè viene creato un nuovo thread del pool), mentre alla ricezione del segnale SIGUSR2 *MasterWorker* decrementa di una unità il numero di thread *Worker* nel pool (cioè uno dei thread del pool termina). Prima di terminare, il processo *MasterWorker*, scrive (eventualmente sovrascrivendolo) nel file '**nworkeratexit.txt**' il numero di thread *Worker* presenti nel pool all'uscita, e cancella il socket file. Il processo *MasterWorker* e *Collector* non si inviano l'un l'altro segnali in modo esplicito.

Note

- La dimensione dei file in input non è limitata ad un valore massimo. Si supponga che la lunghezza del nome dei file (compreso il pathname) sia al massimo 255 caratteri.
- Il numero di file in input non è limitato ad un valore massimo.
- Il numero minimo di thread *Worker* nel pool è 1, non si deve invece assumere un limite superiore.

Materiale fornito per il progetto

Il materiale fornito è il seguente:

- Testo del progetto (file *progettoSOLFarm_23-24.pdf*)
- Un programma *generafile.c* per generare i file per i tests
- Uno script Bash (*test.sh*) contenente alcuni semplici test che il programma deve superare (non consegnare il progetto se i test contenuti nello script non vengono superati almeno sulla **VM Xubuntu**, vedere “Consegna del progetto”).

Consegna del progetto

Il progetto deve essere consegnato sul portale Moodle <https://elearning.di.unipi.it/course/view.php?id=126> facendo l’upload di un file zip o tgz (non consegnare RAR o altri formati) avente il seguente nome:

NomeCognome-Matricola.zip (o *NomeCognome-Matricola.tgz*).

Il file zip (o tgz) contiene una cartella con tutti i file necessari per compilare e testare il progetto.

Il docente verificherà la funzionalità del progetto eseguendo lo script Bash *test.sh* su una macchina multi-core Linux Ubuntu 22.04 LTS. Si osservi, che in caso di problemi di esecuzione del progetto, il docente verificherà il progetto sulla macchina virtuale Virtualbox Xubuntu (VM Xubumbtu) del vecchio corso SOL reperibile al seguente link: <http://didawiki.cli.di.unipi.it/doku.php/informatica/sol/laboratorio21>

La VM Xubuntu NON deve essere aggiornata, e deve essere configurata **con almeno 2 cores** per eseguire il progetto. Se il progetto non compila ed esegue correttamente sulla VM Xubuntu, non verrà accettato come valido (NOTA: per compilare con gcc sulla VM Xubuntu utilizzare il flag `-std=c99`).

Lo studente dovrà implementare tutto il codice del programma separando in file diversi il codice contenente la funzione *main*, il codice che implementa il Master thread, il codice che implementa il pool dei Worker thread, il codice che implementa la funzione eseguita dai Worker threads, ed il codice che implementa il Collector. Dovrà essere fornito il *Makefile* per la compilazione del progetto. Il *Makefile* dovrà avere almeno un target *test* per poter lanciare l’esecuzione dello script *test.sh*, ed un target *clean* per fare pulizia di tutti i file `.o` `.a`, dell’eseguibile, socket file, etc. Infine dovrà essere fornita una breve relazione (massimo 5 pagine) **in formato PDF** che descrive le principali scelte implementative ed eventuali test aggiuntivi fatti dallo studente per testare le varie funzionalità. Il progetto deve essere svolto da un singolo studente.

Esempi di possibili esecuzioni

```
> ./farm -n 4 -q 4 file1.dat file2.dat file3.dat file4.dat file5.dat -d testdir
```

```
103453975 file2.dat
112546319 testdir/testdir/file7.dat
153259244 file1.dat
293718900 file3.dat
380867448 file5.dat
584164283 file4.dat
672594110 testdir/file6.dat
```

```
> valgrind --leak-check=full ./farm -n 8 -q 4 -t 200 file*      (dopo circa 1 secondo viene inviato SIGINT
                                                                al processo MasterWorker)
```

```
==37245== Memcheck, a memory error detector
==37245== Copyright (C) 2002-2017, and GNU GPL'd, by Julian Seward et al.
==37245== Using Valgrind-3.15.0 and LibVEX; rerun with -h for copyright info
==37245== Command: ./farm -n 8 -q 4 -t 200 file1.dat file2.dat file3.dat file4.dat file5.dat file6.dat file7.dat
==37245==
```

```
64834211 file100.dat
1146505381 file10.dat
1884778221 file111.dat
258119464 file116.dat
```

```
^C ← 380867448 file5.dat
```

```
==37246==
==37246== HEAP SUMMARY:
==37246==   in use at exit: 0 bytes in 0 blocks
==37246== total heap usage: 1 allocs, 1 frees, 1,024 bytes allocated
==37246==
==37246== All heap blocks were freed -- no leaks are possible
==37246==
==37246== For lists of detected and suppressed errors, rerun with: -s
==37246== ERROR SUMMARY: 0 errors from 0 contexts (suppressed: 0 from 0)
==37245==
==37245== HEAP SUMMARY:
==37245==   in use at exit: 0 bytes in 0 blocks
==37245== total heap usage: 18 allocs, 18 frees, 2,888 bytes allocated
==37245==
==37245== All heap blocks were freed -- no leaks are possible
==37245==
==37245== For lists of detected and suppressed errors, rerun with: -s
==37245== ERROR SUMMARY: 0 errors from 0 contexts (suppressed: 0 from 0)
```