Web Server

Corso di ***Applicazioni Telematiche***

A.A. 2008-09 – Lezione n.5

Prof. Roberto Canonico

Università degli Studi di Napoli Federico II

Facoltà di Ingegneria

Web Server

- Per realizzare un sistema “web server” si ricorre tipicamente ad un software apposito che implementa:
  - la logica del protocollo HTTP lato server
  - la traduzione tra URL e file memorizzati in un file system locale
  - funzioni di logging
  - eventuali estensioni che consentono di eseguire codice in seguito alla richiesta di una URL
- Esistono varie implementazioni software di web server: Apache httpd, IIS di Microsoft, Zeus, …
- Esistono anche implementazioni minimali di web server interamente hardware per sistemi embedded (interfacce web per la configurazione di apparecchi di vario tipo)

Web Server: gestione della concorrenza

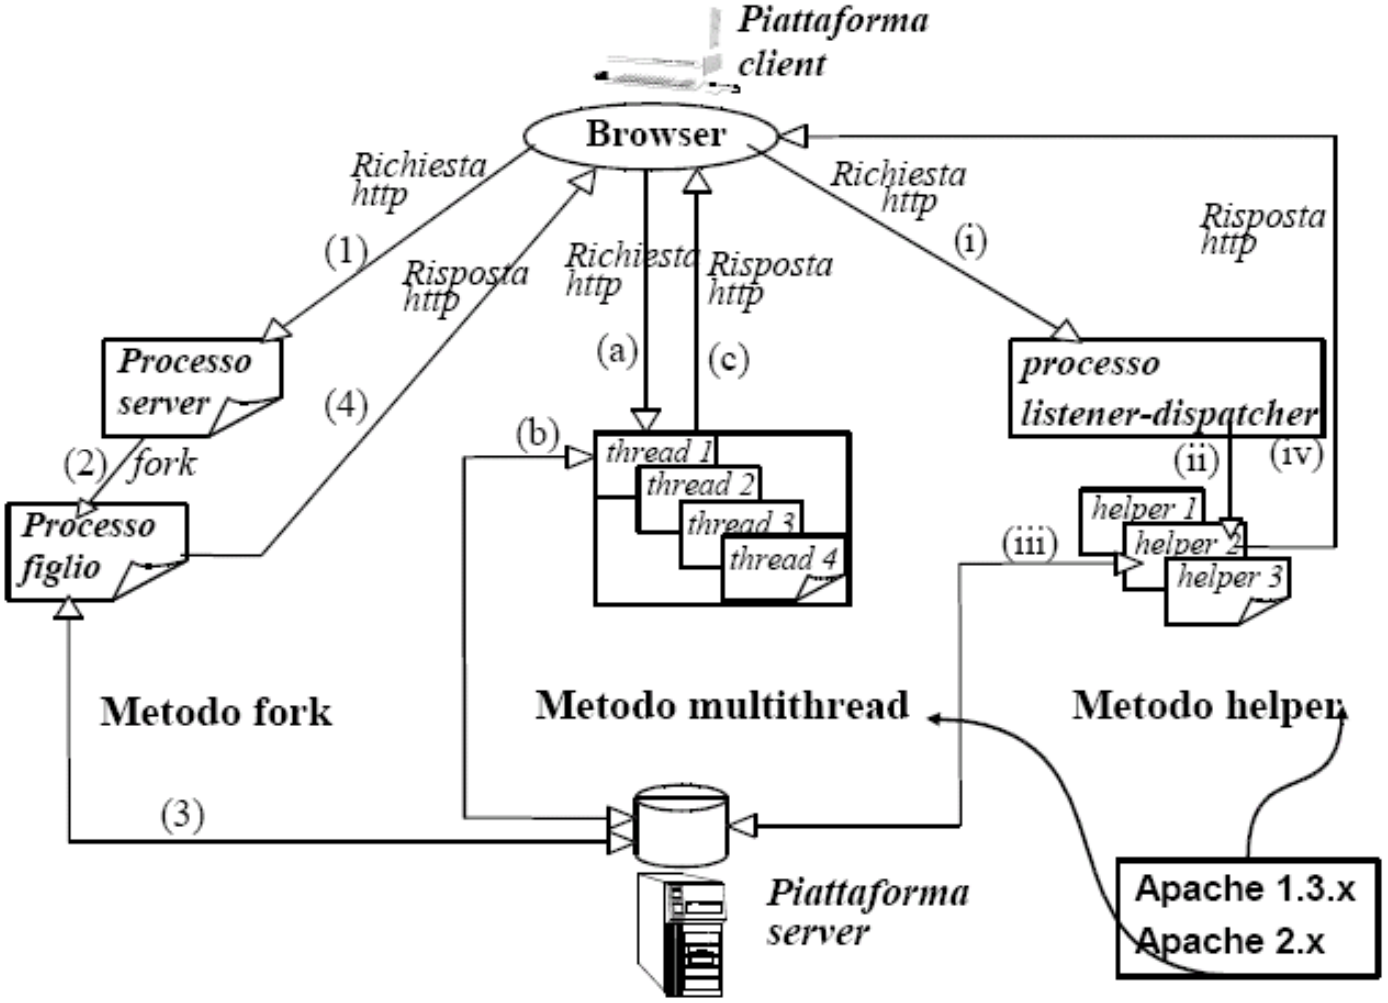

Gestione della concorrenza (2)

- Server monoprocesso
- Servizio parallelo mediante fork
  - Si genera un nuovo processo ad ogni richiesta
- Servizio parallelo mediante processi helper
  - Usato da Apache 1.3
  - Si crea un pool di processi helper a cui vengono smistate le richieste
- Servizio parallelo con thread
  - Usato da Apache 2.0
  - I thread sono più “leggeri” dei processi

Pro e contro del multithreading

- Pro: Creazione di thread ha costo minore rispetto a processi
  - non c'è bisogno di copiare lo spazio di indirizzamento del processo padre nel figlio
- Pro: Context switch ha costo minore rispetto ai processi
  - Spazio di indirizzamento è condiviso tra i thread, non bisogna cambiare lo spazio di indirizzamento
- Contro: un malfunzionamento di un thread si può propagare ad altri thread perché condividono la stessa memoria

Apache HTTP Server

- Apache HTTP Server è il web server HTTP della Apache Software Foundation
- Sviluppato e aggiornato per sistemi operativi come UNIX e Windows
- Open-source
- Apache è dal 1996 il web server più diffuso in Internet
- http://httpd.apache.org
- La versione più recente (2.x) ha una struttura sw che combina l'esistenza di più processi con il multithreading

Market Share for Top Servers

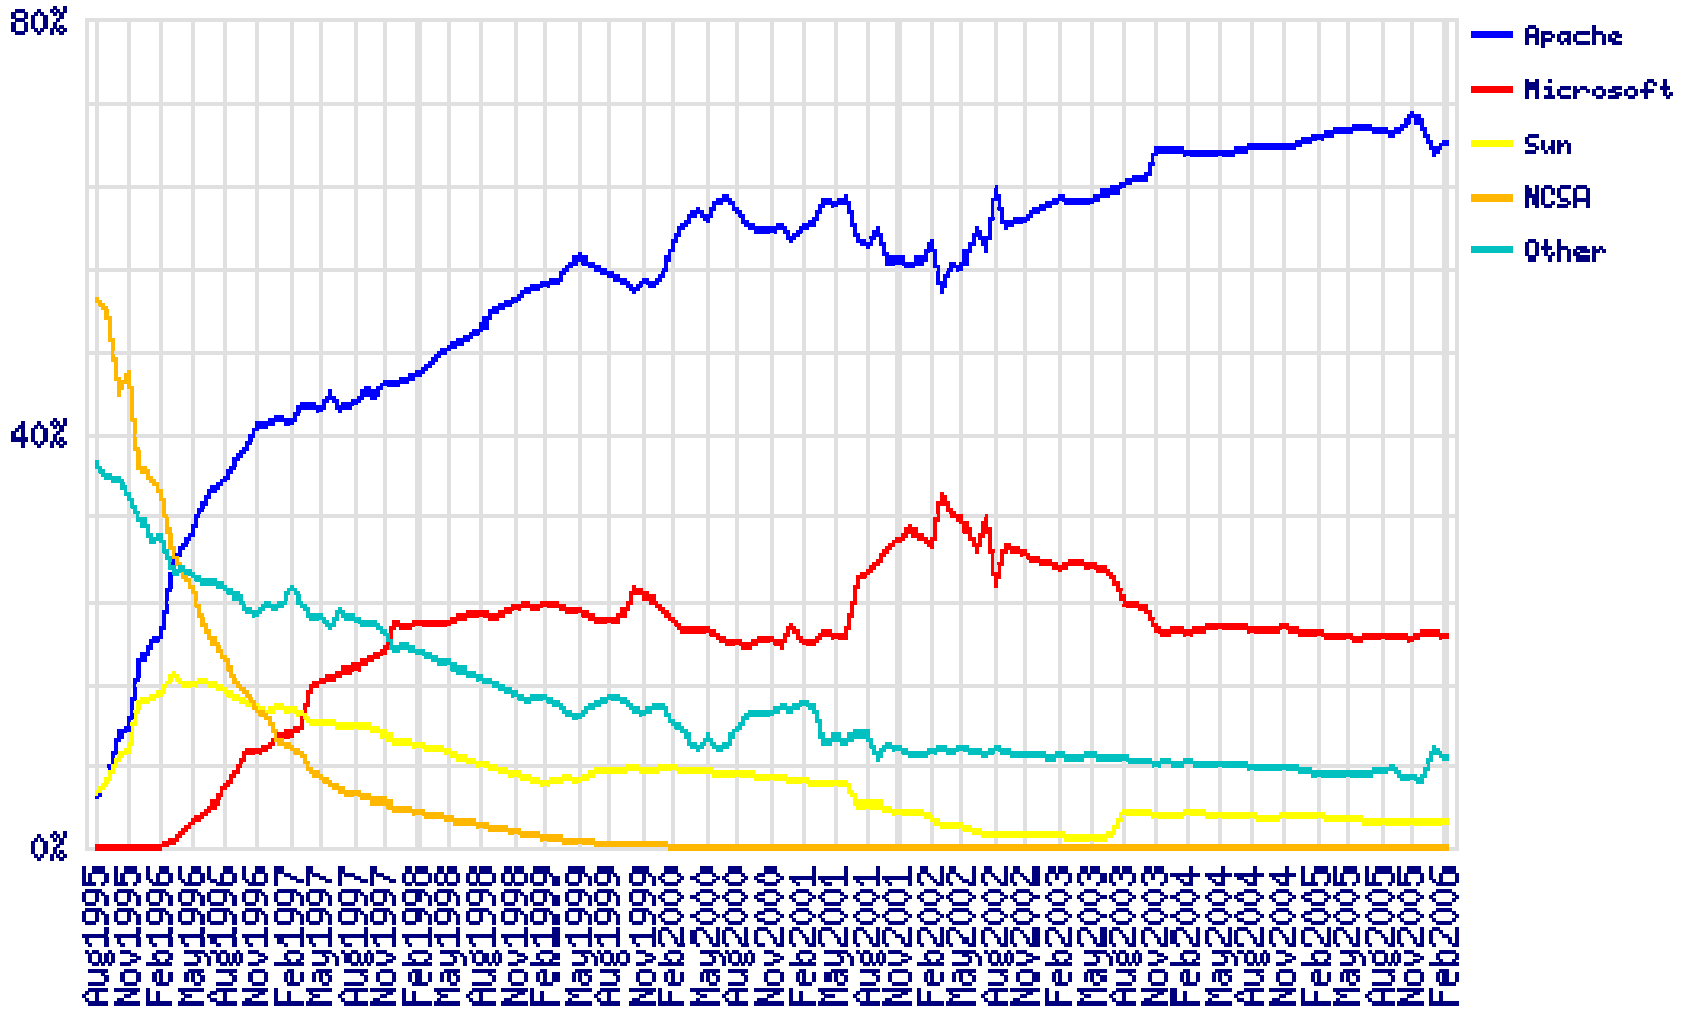

news.netcraft.com - February 2006

Modularità di Apache

- Apache è un server modulare: le sue funzionalità sono rese disponibili tramite dei moduli che possono essere aggiunti o disattivati nel server sfruttando il modulo *mod_so*
- Le funzionalità di base sono incluse nel core
- Nel file di configurazione (httpd.conf) si possono scegliere i moduli da aggiungere al server
- I moduli possono essere :
  - Compilati staticamente nel web server
  - Aggiunti dinamicamente nel file httpd.conf tramite il supporto DSO (Dynamic Shared Object)

File di configurazione

- Apache viene configurato tramite delle direttive riportate nel file di testo httpd.conf
- La configurazione è aggiornata solo al riavvio del server
- La gestione dei tipi MIME è gestita nel file mime.types
- Le direttive si applicano all'intero server, a meno di specificare lo scope, se consentito, in cui sono valide (es. usando <Directory> per definire la directory in cui applicarla)
- Il file di configurazione principale è *httpd.conf*, ma se ne possono creare di nuovi, per ogni sito o ogni directory. Si usano i file *.htaccess*, le cui direttive vengono applicate solo al sotto albero in cui il file *.htaccess* è presente.

Uso delle direttive nei file di configurazione

- Le direttive nei file di configurazione possono essere applicate all'intero server, a directory, a file, host o URL
- Possono essere valutate solo avvio del server (es. <If Module> oppure ad ogni richiesta ricevuta
- Possono riguardare la struttura del filesystem (es. <Directory>) oppure la struttura del sito (Es. location)

```
<Directory /home/pippo/public_cgi/>
  Options ExecCGI
</Directory>
```

Autenticazione

- Richiede innanzitutto la creazione di un file delle password utente (`htpasswd -c C:\www\passwd`)
- Utilizzando il modulo mod_auth_dbm le utenze possono anche essere gestite tramite un database
- Esempio di configurazione degli accessi:

```
AuthType Basic
AuthName “Restricted Area”
AuthUserFile C:/www/passwd
require valid-user
```

- L’abilitazione all’accesso può essere anche assegnato in base all’host-name o all’host-address della macchina che richiede il documento

```
allow from 143.218.1.3
deny from 143.218.1.165
```

Autenticazione (2)

- AuthType Basic
  - Seleziona il metodo di autenticazione utilizzato
  - Basic è implementato dal modulo mod_auth
  - Digest è implementato dal modulo mod_auth_digest
- AuthName “Restricted Area”
  - identifica un nome per l’area a cui accedere per consentire il riutilizzo delle password al client
- AuthUserFile C:/www/passwd
  - il file contenente le password
- Require valid-user
  - specifica il nome dell’utente abilitato all’accesso. Si possono anche creare dei gruppi per consentire l’accesso a più utenti

Autenticazione (3)

```
C:\www\htdocs\private>c:\wamp\Apache\Apache2\bin\htpasswd
                                -c C:\www\passwd paperino
Automatically using MD5 format.
New password: *********
Re-type new password: *********
Adding password for user paperino
```

File .htaccess

```
AuthType Basic
AuthName "Restricted Files"
# (Following line optional)
AuthBasicProvider file
AuthUserFile C:\www\passwd
Require user paperino
```

Siti virtuali con Apache: httpd.conf

```
<VirtualHost *:80>
    DocumentRoot C:/www/htdocs/pippo
    ServerName pippo
    ErrorLog logs/pippo-error_log
    CustomLog logs/pippo-access_log common
</VirtualHost>
<VirtualHost *:80>
    DocumentRoot C:/www/htdocs/pluto
    ServerName pluto
    ErrorLog logs/pluto-error_log
    CustomLog logs/pluto-access_log common
</VirtualHost>
```

I due siti a confronto

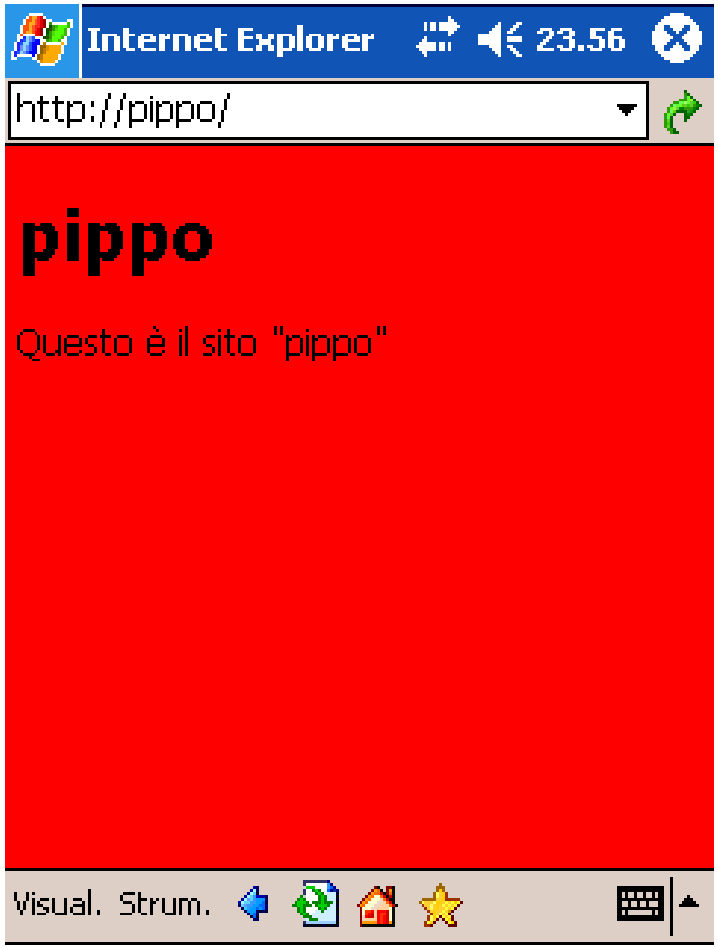

I file di log di Apache

- */logs/access.log*
  - registra gli accessi avvenuti con successo
- */logs/error.log*
  - registra (e descrive brevemente) gli errori
- Nel file di configurazione è possibile settare i nomi dei file di log:

```
ErrorLog logs/error.log
CustomLog logs/access.log
```

- Appositi tool sono in grado di produrre statistiche e grafici dall'analisi dei log (es. AWStats)
  - Analisi di Data Mining sui log (Web Mining)

Server access log file

Formato CLF

IP Address	Userid	Time	Method/URL/ Protocol	Status	Size

IP Address → indirizzo Internet della macchina da cui proviene la richiesta, può corrispondere all'indirizzo di un server proxy.

UserId → presente quando la richiesta richiede l'autenticazione per accedere a determinati file. Se non disponibile compare il segno "-".

Time → tempo al quale il Web server ha ricevuto la richiesta

Method/URL/Protocol → modalità di accesso al Web server

Status → codice ritornato dal server in risposta all'azione richiesta

Size → numero di bytes trasmessi

Server access log file

Formato ECLF

IP Address	Userid	Time	Method/URL/ Protocol	Status	Size	Referrer	Agent

IP Address → indirizzo Internet della macchina da cui proviene la richiesta, può corrispondere all'indirizzo di un server proxy

UserId → presente quando la richiesta richiede l'autenticazione per accedere a determinati file.

Time → momento in cui il Web server ha ricevuto la richiesta

Method/URL/Protocol → modalità di accesso al Web server

Status → codice ritornato dal server in risposta all'azione richiesta

Size → numero di bytes trasmessi

Referrer → URL del documento da cui è stata emessa la richiesta della pagina

Agent → sistema operativo e browser utilizzati dal client

Finalità del Web Mining

- Capire il comportamento degli utenti
  - Analizzare il comportamente di navigazione degli utenti per capirne le preferenze e quindi massimizzare l'attività commerciale
  - Capire chi compra e che cosa compra
  - Scoprire la % di clienti acquisiti/persi
- Determinare l'efficacia di un sito Web
  - Capire i pattern di navigazione per
    - migliorare la struttura del sito
    - personalizzare la navigazione
- Misurare il succeso dell'attività di marketing
  - Capire l'impatto sull'attività commerciale delle campagne di marketing
  - Classificare gli utenti per personalizzare l'offerta
  - Misurare l'efficacia di specifici banner pubblicitari.

Prestazioni di un web server

- Parametri prestazionali:
  - Throughput in richieste soddisfatte / secondo
  - Tempo medio di risposta (ms)
  - Percentuale di errori nelle risposte
    - Risposte di errore HTTP date dal server
      - **502 Service Temporarily Overloaded**
      - **503 Service Unavailable**
    - Connessioni TCP non riuscite perché la coda delle connessioni pending è piena

Tempo di risposta di un web server

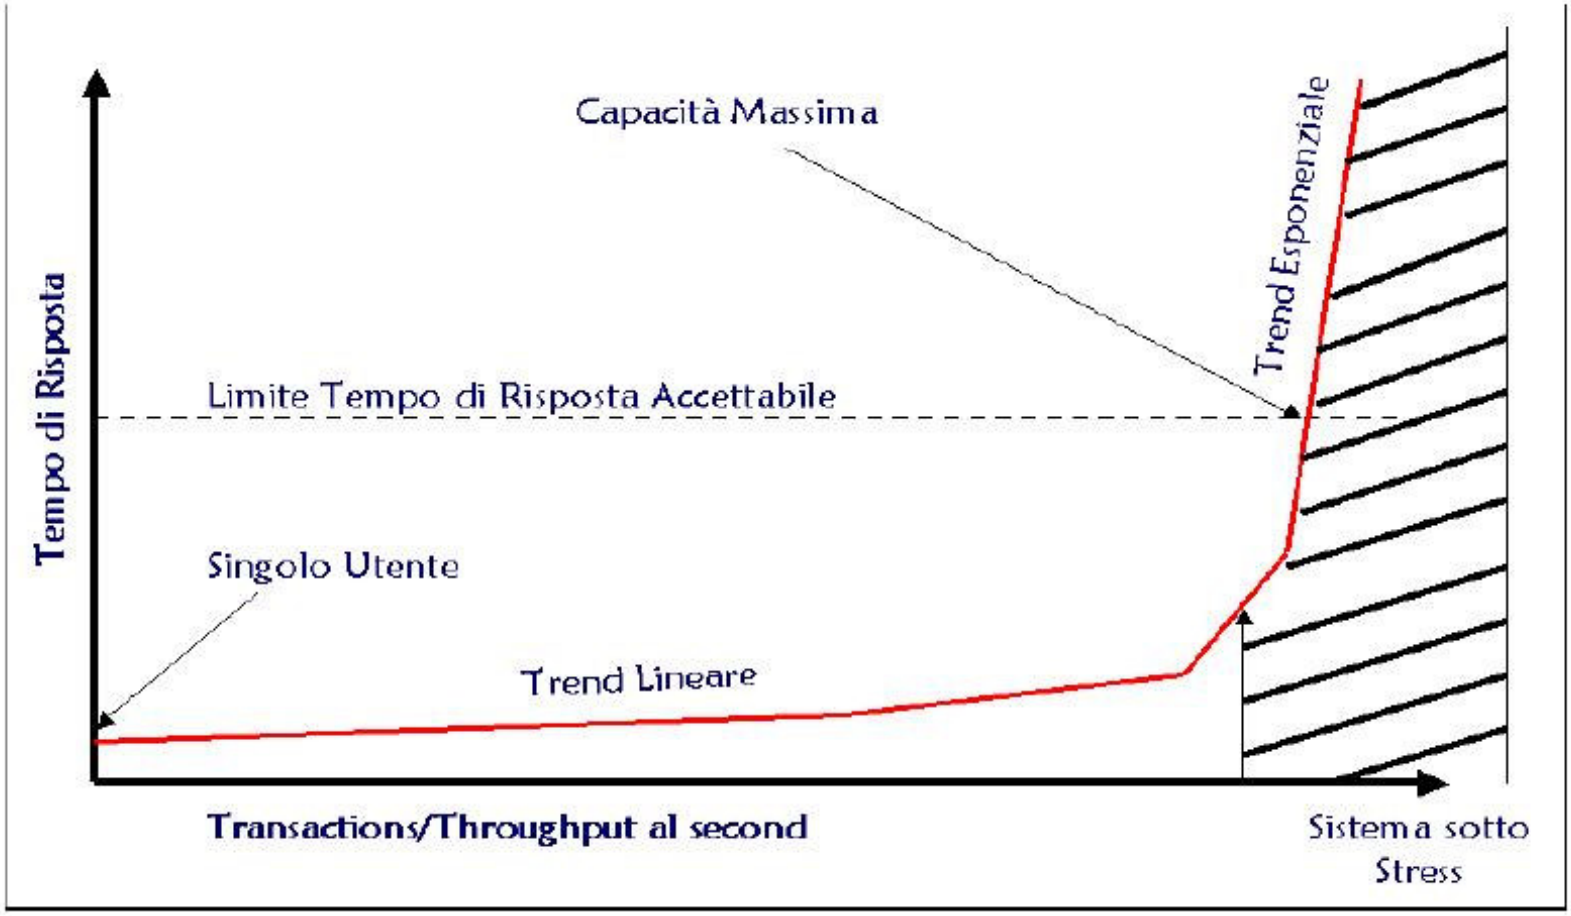

Throughput di un server web

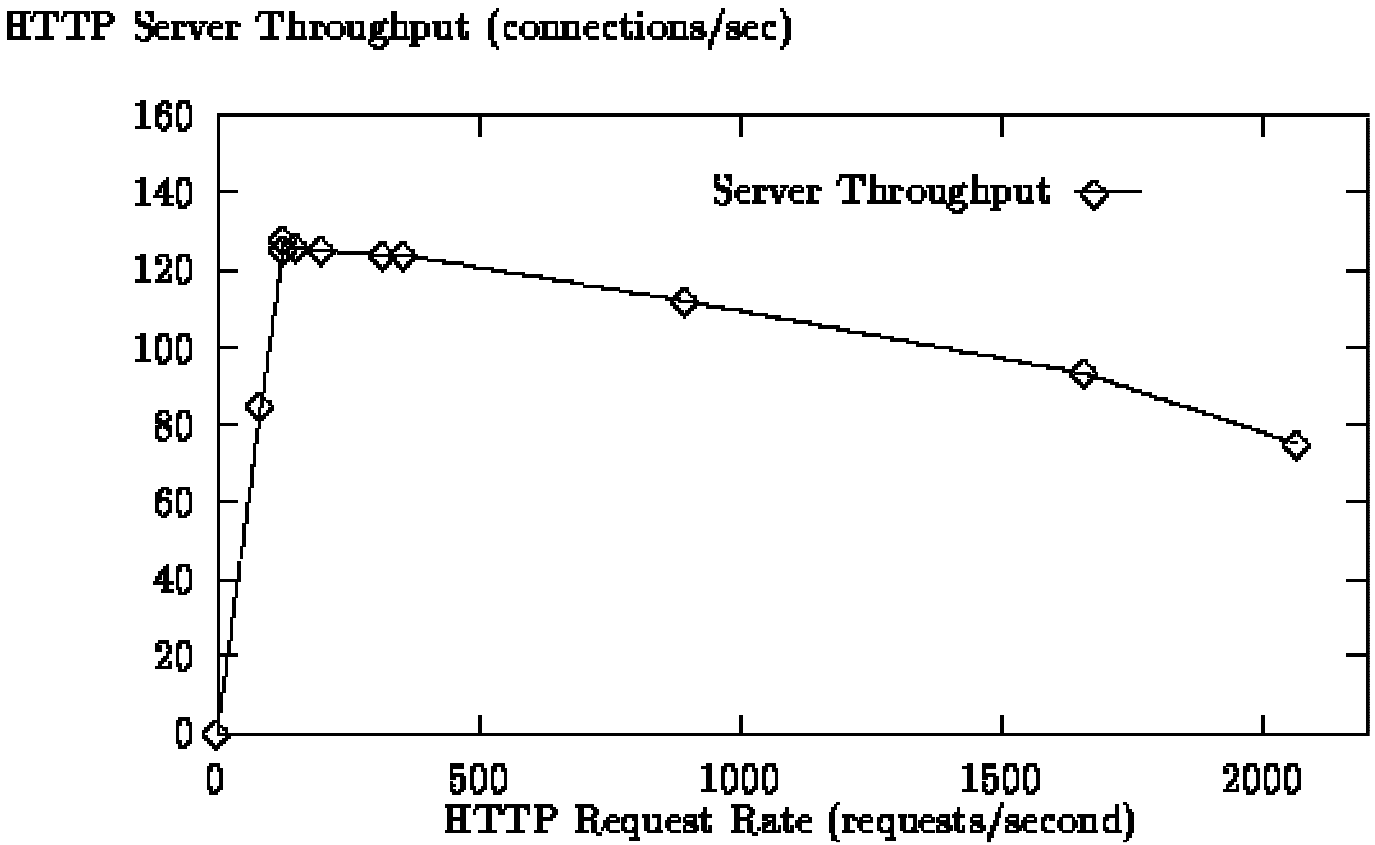

Domande?