INTRODUZIONE A INTERNET

per studenti universitari

Dr. Giorgio F. Signorini

Dipartimento di Chimica

Università di Firenze

▷ `signo@chim.unifi.it`

▷ `http://www.chim.unifi.it/~signo`

- 2-1: cos'è e come funziona WWW

15 novembre 2004

Tramite Internet, due host possono comunicare in vari modi:

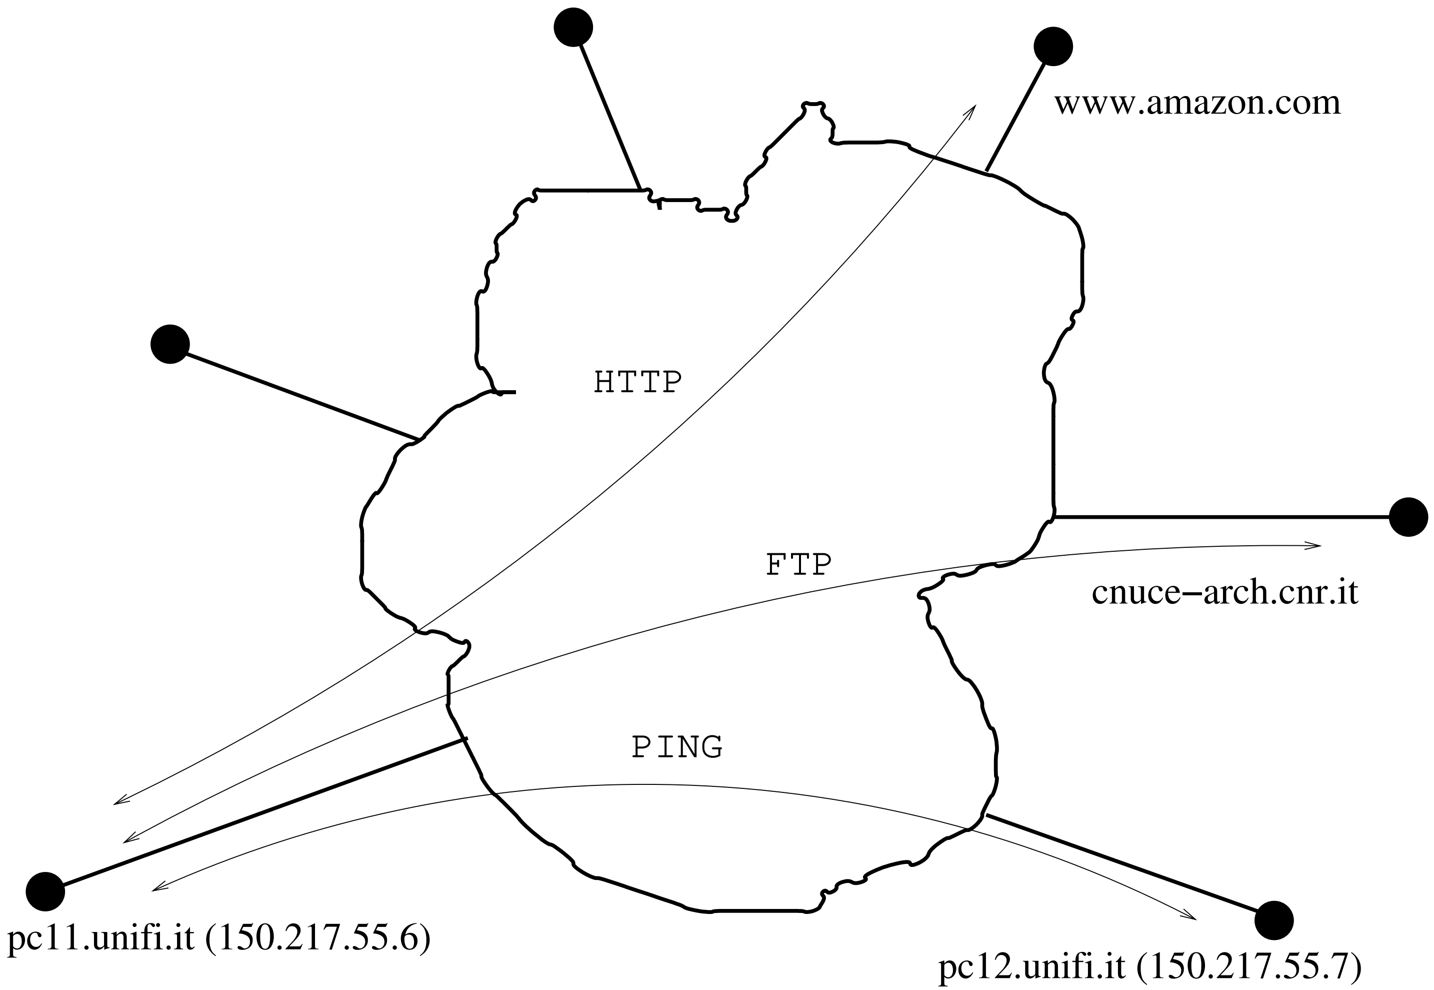

I server di HTTP formano un sottospazio di Internet:

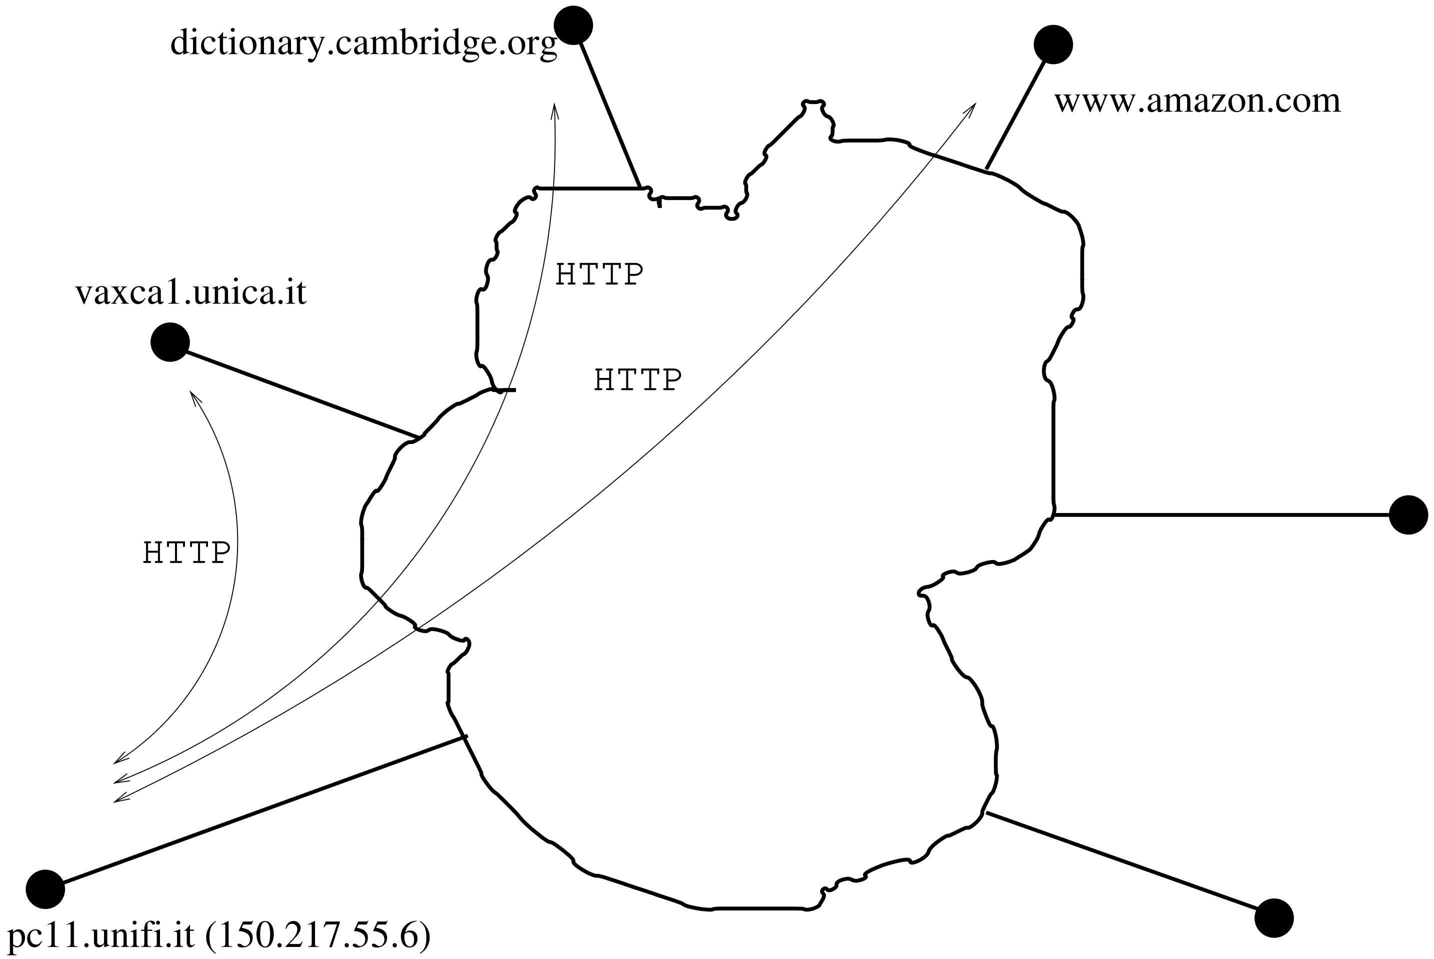

World Wide Web

- WWW è quella parte di Internet che può essere visitata da un client HTTP

- WWW è un (enorme) insieme di documenti interconnessi, distribuiti in tutto il mondo, accessibili via Internet con il protocollo HTTP

L'accesso è basato su un meccanismo richiesta/risposta (client/server)

***Server*:** il computer dove stanno i documenti, con un programma per trasmetterli usando il protocollo HTTP

***Client*:** il vostro computer, con un programma per ricevere i documenti usando il protocollo HTTP, e per visualizzarli (il *navigatore* o "*browser*").

Aspetti principali:

- protocollo di comunicazione (HTTP)
- formato dei documenti (HTML)
- indirizzo dei documenti (URI)

I documenti presenti su WWW sono generalmente *ipertesti*.

- ipertesto

  è un documento in forma elettronica che contiene rimandi attivi (*"link"*) ad altri documenti.

  una serie di documenti di questo tipo costituisce un testo che può essere letto seguendo vari percorsi.

  Esempio: il manuale on-line di un programma (Word)

  Il testo può essere multimediale.

- ipertesto in rete

  su WWW, un ipertesto situato su un certo server può rimandare a documenti presenti su un server diverso

  Formato di ipertesti (multimediali) usato su WWW: HTML

HTML

HyperText Markup Language

È standard stabilito “a posteriori” da un Consorzio di società (W3C, 1994). Ultimo (12/1999): HTML 4.01. Sta venendo sostituito da XHTML (più formale)

- attributi testo: grassetto, corsivo, vari livelli di intestazioni, font, etc.
- testo strutturato: testata, corpo, titoli, etc.
- liste, tabelle
- figure
- link
- moduli (“*form*”)
- aree indipendenti (“*frame*”)
- animazioni, musica, spreadsheets, (applets)...

È un linguaggio di programmazione che viene interpretato dal vostro browser. L’aspetto del documento può variare, a seconda del browser. Un maggiore controllo sull’aspetto del documento si ottiene con le “schede di stile” (*style sheets*) introdotte con HTML 4.

URI o URL

Per identificare un documento (o più in generale, una "risorsa") si usa un indirizzo: Uniform Resource Identifier (oppure: Locator)

`http://`	`www.unifi.it`	`/universita/biblioteche`
1	2	3

1. schema di accesso della risorsa (protocollo)
2. host su cui sta la risorsa
3. percorso per accedere alla risorsa su quell'host

NOTA

`http://`	`www.unifi.it`	`/universita/biblioteche`
1	2	3

1 e 2: non c'è distinzione tra maiuscole e minuscole
3: contiene nomi di directory (cartelle) e file, che in generale fanno distinzione tra maiuscole e minuscole

quindi l'URI precedente si può anche scrivere

- `HTTP://www.unifi.it/universita/biblioteche`
- `http://WWW.UNIFI.IT/universita/biblioteche`

ma NON

- `http://www.unifi.it/universita/BIBLIOTECHE`

- risorsa=anche immagini, caselle di posta, programmi, ...

- schemi= `http`,`ftp`,`telnet`,`mailto`,`file`,...

  - c'è una corrispondenza (non stretta) tra *schemi* e *protocolli applicativi*

  Es: `ftp://garbo.uwasa.fi/software`

Generalizzazione:

WWW è un enorme insieme di *risorse* interconnesse, distribuite in tutto il mondo, accessibili via Internet *tramite un URI*

GLOSSARIO DI TERMINI COMUNI

“Pagina”: un singolo documento, individuato da un URI

- Poiché le pagine sono interconnesse, ad una stessa pagina si può arrivare da vie differenti.
- Una pagina può essere sia punto di arrivo che punto di partenza.
- Alcune pagine sono più “periferiche” (es. capitoli di un libro), altre sono più “di passaggio” (es. elenco di biblioteche)

“sito”: un server, o la sua pagina principale, o l’insieme dei documenti presenti su un server, o una parte di questo insieme che costituisce una struttura omogenea

***“Home page*”:** pagina che costituisce un punto di partenza specifico (di una persona, un’organizzazione, un argomento).

“Portale”: punto di partenza generico. Un ISP ha sempre un portale che contiene come minimo un catalogo per soggetto e un motore di ricerca

IL BROWSER

Il navigatore ("*browser*") è il programma cliente che permette di accedere al WWW, interagendo con i server attraverso HTTP ed altri protocolli come FTP (cfr. gli schemi di un URI)

p.es.: Netscape/Mozilla, Internet Explorer, Opera, Lynx, konqueror, ...

Browser diversi sono equivalenti tra loro, ma non uguali:

- conformi a livelli HTML diversi
- riconoscono, o no, elementi HTML non-standard
- poiché HTML non stabilisce strettamente come deve essere riprodotto un certo elemento (es. un titolo), ma solo la sua funzione nel testo, l'aspetto del documento può variare da un navigatore all'altro

Spesso contengono altre funzioni (ad es. un programma utente per la posta elettronica)

Uso di un *browser* WWW

Funzioni utili:

- `cambiare la pagina iniziale di navigazione (7.1.1.4)`*
- `salvare una pagina web come file (7.1.1.5)`
- `caricare i testi ma non le immagini (7.1.2.4)`
- `visualizzare le immagini (7.1.2.3)`
- `creare un segnalibro (7.4.1)`

*riferimento alle abilità richieste per la patente europea di guida del computer (ECDL), [cfr. `http://www.aicanet.it/ecdl/ecdl.htm`]

- In generale WWW si usa per trasferire dati da un server a un client
  - i dati sono già presenti sul server, che deve solo inviarli
  - il client visualizza i dati ricevuti senza eseguire operazioni ulteriori
- In certi casi il trasferimento innesca l'esecuzione di programmi
  - sul server: per preparare i dati *ad hoc* prima di trasferirli
    * in questo modo si evita di mantenere sul server troppi dati già confezionati
  - sul client: per elaborare i dati dopo il trasferimento
    * si evita di trasferire dati troppo grossi: li si ricostruisce all'utilizzo

ESEGUIRE PROGRAMMI IN WWW: (A) SUL CLIENTE

1. La pagina HTML può contenere istruzioni in un linguaggio interpretato dal browser (JavaScript o VBScript)

   questi linguaggi consistono essenzialmente in funzioni assenti da HTML, che permettono ad es. di scrivere la data di oggi, aprire una nuova finestra, etc.

2. Oppure può contenere un riquadro in cui eseguire un programma scaricabile ("*applet*"), scritto in linguaggio Java.

   Caratteristiche di Java:

   - indipendente dalla piattaforma (hw e sw) cliente
   - contiene funzioni che sfruttano la rete
   - è progettato per essere innocuo verso il computer

   L'*applet* Java viene eseguito sul **cliente**: lo scambio con il server è solo il trasferimento del testo del programma.

ESEGUIRE PROGRAMMI IN WWW: (B) SUL SERVER

Funzionamento: certe risorse sul server, invece di essere inviate direttamente al cliente, prima eseguono un programma, il cui risultato è un documento HTML che viene trasmesso al cliente.

Ad esempio: la ricerca su un database.

http://opac.unifi.it/opac/short?author=alighieri `http://opac.unifi.it/opac/short?author=alighieri`

Tipicamente, l'URI contiene un "?" dopo il quale vengono i parametri da passare al programma del server.

I linguaggi di programmazione più diffusi sono:

- CGI
- (più recente) PHP
- (Microsoft) ASP

In HTTP (a differenza di altri protocolli applicativi, come FTP), le connessioni vengono generalmente chiuse una volta che una richiesta è stata soddisfatta.

Il server si “dimentica” della precedente transazione.

Questo è ideale per il WWW, in cui le pagine molto spesso contengono dei link a pagine ospitate da altri server: è meglio “liberare” un server appena ci ha fornito una pagina.

A volte però è utile conservare memoria delle transazioni precedenti.

Lo si fa dal lato del cliente. Ci sono tipi due meccanismi

- cache/proxy: copia di pagine già visitate

- cookie: dati riassuntivi su una particolare transazione

CACHE DEL BROWSER: la cache è una memoria del vostro computer su cui sono registrate le ultime pagine che avete aperto con quel browser

serve per non doverle ricaricare tutte le volte, magari da un sito poco raggiungibile

- cache di memoria: cancellata quando si chiude il browser

- cache su disco: riutilizzata anche nelle successive sessioni del browser

attenzione! dopo un po' è bene che le pagine "scadano", perché l'informazione potrebbe non essere più aggiornata (es. la homepage di un quotidiano)

PROXY: un proxy HTTP è un server esterno che tiene sul suo disco la cache vostra e di altri utenti.

Serve quando la stessa pagina è visitata spesso da un gruppo di utenti diversi

Si può configurare questo servizio in modo tale che alcune pagine (che cambiano spesso) NON siano accedute tramite proxy, ma direttamente

COOKIE: dati sintetici inviati da un server HTTP ad un browser che lo sta consultando, per essere salvati sul disco del cliente e letti dal server in una successiva connessione

Un cookie è per esempio un modo per:

- salvare preferenze, password, etc
- mettere nel "carrello della spesa" gli oggetti che si sono comprati prima di pagarli tutti insieme

Preoccupati della riservatezza? Ricordate che un cookie non contiene più informazione su di voi di quella che comunque avete già dato al server!

BIBLIOGRAFIA: WWW

- D. E. Comer, Internet e reti di calcolatori, Pearson Education Italia, Collana Accademica, 2003

- Ed Krol, The Whole Internet user's guide and catalog. O'Reilly and Associates, 1996

- Ed Krol, Internet, Milano, Jackson libri, 1994.

- Wikipedia (Enciclopedia online), per definizioni dei termini: `http://www.wikipedia.com/wiki/Main+Page`

- R. Fielding et al.: Hypertext Transfer Protocol – HTTP/1.1.. RFC 2616 http://www.ietf.org/rfc/rfc2616.txt `http://www.ietf.org/rfc/rfc2616.txt`

- W3C (World Wide Web Consortium): HTML 4.01 Specification http://www.w3.org/TR/REC-html40/ `http://www.w3.org/TR/REC-html40/`

- T. Berners-Lee: Uniform Resource Identifiers (URI): Generic Syntax. RFC 2396 http://www.ietf.org/rfc/rfc2396.txt `http://www.ietf.org/rfc/rfc2396.txt`