

# Motori di Ricerca

presente e futuro prossimo


## Cosa è un Compressore ?

Paolo Ferragina, Università di Pisa

## Perché comprimere ?

**Obiettivo:** Eliminazione della ridondanza nei testi



- Riduzione spazio
  - 33% tecniche standard (gzip, winzip,...)
  - 20% tecniche avanzate (bzip, ppm)
- Miglioramento delle prestazioni



Paolo Ferragina, Università di Pisa

## Gzip ('77-'78, raggiunge il 30%)

- Elimina ridondanza copiando pezzi di testo già visti



Più è lungo il testo, più ripetizioni ci aspettiamo, più risparmio otteniamo

Ogni sottostringa viene sostituita da una tripla  $\langle x,y,c \rangle$  che rappresenta la distanza dalla sua precedente occorrenza (x), la sua lunghezza (y), e il carattere seguente (c).

Paolo Ferragina, Università di Pisa

## Motori di Ricerca

presente e futuro prossimo

Cosa è una  
Lista Invertita ?

Paolo Ferragina, Università di Pisa

## Indicizzatore: il "cuore" del motore

- Come organizzare l'informazione disponibile nell'archivio per rispondere velocemente alle interrogazioni poste dall'utente ?

- **Informazione** = Pagine e hyperlinks, PS, PDF, PPT,...
- **Interrogazione** = insieme di parole chiave

Es. Quali opere di Shakespeare contengono le parole (**Brutus AND Caesar AND NOT Calpurnia**) ?

Paolo Ferragina, Università di Pisa

## Matrice binaria dei termini-documenti

	Antony and Cleopatra	Julius Caesar	The Tempest	Hamlet	Othello	Macbeth
Antony	1	1	0	0	0	1
Brutus	1	1	0	1	0	0
Caesar	1	1	0	1	1	1
Calpurnia	0	1	0	0	0	0
Cleopatra	1	0	0	0	0	0
mercy	1	0	1	1	1	1
worser	1	0	1	1	1	0

- Per rispondere a  $Q=[\text{Brutus AND Caesar AND NOT Calpurnia}]$  la parola, 0 altrimenti
- Prendiamo i vettori di **Brutus, Caesar, Calpurnia**
  - Complementiamo il vettore di **Calpurnia**
  - Eseguiamo l'**AND** logico bit-a-bit

Paolo Ferragina, Università di Pisa

## Spazio occupato ?

- Consideriamo la seguente situazione:
  - Un milione di documenti
  - Ogni documento è di circa 6 Kb, e circa 1000 termini distinti
  - ❖ In totale abbiamo bisogno di 6Gb di dati
- Se il numero totale di termini distinti è 500,000 allora
  - La matrice [Term x Doc] è grande 500K x 1Mil = 500Gb
  - ...ma non più di  $1M * 1,000 = 1Gb$  di uno
- Una migliore rappresentazione ?
  - più efficiente in spazio
  - che assegni una "rilevanza" a ogni risposta (documento)

Paolo Ferragina, Università di Pisa

## Le Liste Invertite

### Doc 2

So let it be with  
Caesar. The noble  
Brutus hath told you  
Caesar was ambitious

### Doc 1

I did enact Julius  
Caesar I was killed  
i' the Capitol;  
Brutus killed me.

I documenti sono analizzati  
per estrarre i termini e questi  
sono memorizzati insieme al  
corrispondente DocID



Term	DocID
I	1
did	1
enact	1
julius	1
caesar	1
i	1
was	1
killed	1
i'	1
the	1
capitol	1
brutus	1
killed	1
me	1
so	2
let	2
it	2
be	2
with	2
caesar	2
the	2
noble	2
brutus	2
hath	2
told	2
you	2
caesar	2
was	2
ambitious	2

Paolo Ferragina, Università di Pisa

Term	DocID
I	1
did	1
enact	1
julius	1
caesar	1
I	1
was	1
killed	1
i'	1
the	1
capitol	1
brutus	1
killed	1
me	1
so	2
let	2
it	2
be	2
with	2
caesar	2
the	2
noble	2
brutus	2
hath	2
told	2
you	2
caesar	2
was	2
ambitious	2

Ordiniamo tutti i termini in modo lessicografico per formare il Dizionario



Term	DocID
ambitious	2
be	2
brutus	1
brutus	2
capitol	1
caesar	1
caesar	2
caesar	2
did	1
enact	1
hath	1
I	1
I	1
i'	1
it	2
julius	1
killed	1
killed	1
let	2
me	1
noble	2
so	2
the	1
the	2
told	2
you	2
was	1
was	2
with	2

Paolo Ferragina, Università di Pisa

Term	DocID
ambitious	2
be	2
brutus	1
brutus	2
capitol	1
caesar	1
caesar	2
caesar	2
did	1
enact	1
hath	1
I	1
I	1
i'	1
it	2
julius	1
killed	1
killed	1
let	2
me	1
noble	2
so	2
the	1
the	2
told	2
you	2
was	1
was	2
with	2

Le occorrenze dello stesso termine nello stesso documento sono "fuse insieme" incrementando opportunamente il valore della frequenza del termine



Term	DocID	Freq
ambitious	2	1
be	2	1
brutus	1	1
brutus	2	1
capitol	1	1
caesar	1	1
caesar	2	2
did	1	1
enact	1	1
hath	2	1
I	1	2
i'	1	1
it	2	1
julius	1	1
killed	1	2
let	2	1
me	1	1
noble	2	1
so	2	1
the	1	1
the	2	1
told	2	1
you	2	1
was	1	1
was	2	1
with	2	1

Paolo Ferragina, Università di Pisa

- Tutte le info suddivise in due file: *Dizionario* e *Posting list* memorizzate su disco

Term	DocID	Freq
ambitious	2	1
be	2	1
brutus	1	1
brutus	2	1
capitol	1	1
caesar	1	1
caesar	2	2
did	1	1
enact	1	1
hath	2	1
I	1	2
i'	1	1
it	2	1
julius	1	1
killed	1	2
let	2	1
me	1	1
noble	2	1
so	2	1
the	1	1
the	2	1
told	2	1
you	2	1
was	1	1
was	2	1
with	2	1

Paolo Ferragina, Università di Pisa


Term	# tot docs	Tot Freq	DocID	Freq
ambitious	1	1	2	1
be	1	1	2	1
brutus	2	2	1	1
brutus	2	2	2	1
capitol	1	1	1	1
caesar	2	3	1	1
caesar	2	3	2	2
did	1	1	1	1
enact	1	1	1	1
hath	1	1	1	1
I	1	2	1	2
i'	1	1	1	1
it	1	1	2	1
julius	1	1	2	1
killed	1	2	1	1
killed	1	2	2	1
let	1	1	1	2
me	1	1	2	1
noble	1	1	1	1
so	1	1	2	1
the	2	2	2	1
told	1	1	1	1
you	1	1	2	1
was	2	2	2	1
was	2	2	1	1
with	1	1	2	1

## Memorizzazione delle *posting list*

- Un termine come **Calpurnia** occorre forse in un documento su un milione, e quindi possiamo codificarlo con molti bit ( $\log_2 1M \sim 20$ ).
  - Un termine come **the** occorre probabilmente in ogni documento, quindi dovremmo usare pochi bit (20 sono troppi).
  - **Soluzione:** ordiniamo la *posting list* di ogni termine per docID
    - **Brutus:** 33, 47, 97, 107, 115, ...
    - $\Delta$  : 33, 14, 50, 10, 8, ...
- ...e speriamo che gran parte dei valori da rappresentare siano piccoli e richiedano dunque pochi bit.

Paolo Ferragina, Università di Pisa

## Risoluzione di una interrogazione ?



Paolo Ferragina, Università di Pisa

## Ricerca per Frase: 45% delle ricerche [Aprile 2003]

- Interrogazione "**Paolino Paperino**"
- Non è più sufficiente la coppia  $\langle \text{docID}, \text{freq} \rangle$
- Ma occorre avere informazioni più dettagliate
  - $\langle \# \text{ docs contenenti il termine corrispondente};$   
 $\text{doc1: pos1, pos2, pos3, ...};$   
 $\text{doc2: pos1, pos2, pos3, ...};$   
 $\text{...} \rangle$

Possiamo ancora comprimere la *posting lists*,  
agendo su *due livelli: documenti e posizioni*

Paolo Ferragina, Università di Pisa

## Come risolvere una "phrase query"

- Si estraggono le posting list dei termini: *Paolino, Paperino*
- Troviamo i documenti che contengono **tutte** le parole presenti nell'interrogazione
- Esaminiamo le posizioni delle occorrenze e garantiamo che siano **consecutive** nel documento

- **Paolino:**

- 2:1,17,74,222,551; 4:8,27,101,429,433; 7:13,23; ...

- **Paperino:**

- 1:17,19; 4:17,191,291,430,436; 5:14,19,101; ...