

INFORMATICA PER LA COMUNICAZIONE



MOTORI DI RICERCA

Motori di ricerca

Si stima vi siano almeno **diversi miliardi** di pagine web, oltre [un miliardo](#) di siti web



Sistemi per la ricerca e la catalogazione delle pagine web

- **motori di ricerca** (Google, Yahoo!, Bing,...)
- **cataloghi sistematici** (Yahoo! Directory, [Open Directory Project](#))



Motori di ricerca

- **Motore di ricerca:**
strumento di IR
(Information Retrieval)
- Ricerca per parole chiave
- Risultato di una ricerca:
lista ordinata di pagine che
trattano argomenti descritti
dalle parole chiave
- Presenza collegamenti
sponsorizzati

[Università degli studi di Bergamo](#)

www.unibg.it/ 

Iniziative. UniBergamoRete. Marketplace degli stage. Centro Universitario Sportivo. RBG - La radio dell'Università di Bergamo. BergamoUniversità ...

[UniBg - Facoltà di Lingue e ...](#)

Università degli Studi di Bergamo - English ... Presidio di ...

[Marketplace degli stage](#)

Logo dell'Università' degli Studi di ...

[Ingegneria industriale](#)

Il Dipartimento di Ingegneria industriale dell'Università.

[Presentazione](#)

Per tutte le persone interessate ad accrescere e aggiornare ...

[Servizi bibliotecari](#)

Università di Bergamo - Servizi bibliotecari - Homepage.

[RBG](#)

RBG - La Radio dell'Università degli Studi di Bergamo.

[Altri risultati in unibg.it »](#)

[Università degli Studi di Bergamo - Wikipedia](#)

it.wikipedia.org/wiki/Università_degli_Studi_di_Bergamo 

Sede dell'Università, in Piazza Vecchia.

[UNIVERSITA' di BERGAMO università UNIBG.Bacheca studenti ...](#)

universando.com/Bergamo.htm 

L'Università di Bergamo ha una dimensione a misura d'uomo ed è situata in una città che offre numerose strutture e uno stile di vita adatto agli studenti.



Motori di ricerca

- Numero interrogazioni: migliaia al secondo
- Tempi di risposta istantanei



Informazione e Web

Caratteristiche del Web

- Grande collezione di documenti
- Informazione **non strutturata**, priva di **organizzazione**
- Tecniche delle **basi di dati** → **non applicabili** direttamente al Web
- Tecniche alternative di **indicizzazione** e **interrogazione**



Information Retrieval

- *Information Retrieval (IR)*: disciplina che studia come rispondere alle **esigenze informative**
 - ▣ Cataloghi biblioteca
 - ▣ Motori di ricerca
 - ▣ ...
- Processo di selezione dell'informazione **rilevante** all'interno di un **corpus** di documenti



Information Retrieval

Sistema IR

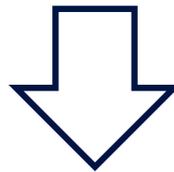
- **Interrogazione** (*query*)
dell'utente: stringa di testo
Es. Parole chiave
- **Risposta** del sistema
 - ▣ **Selezione** all'interno del corpus
della parte **rilevante**
 - ▣ Eventuale **ordinamento**
risultato



Information Retrieval

Obiettivi sistemi IR

- **Efficacia:** accuratezza della risposta
- **Efficienza:** velocità nel fornire risposte



Obiettivi contrastanti



Information Retrieval

Sistemi IR analizzano preventivamente documenti

- Estrarre **informazione significativa**
- Memorizzazione **efficiente**

Obiettivi:

- ▣ Rilevanza risultati
- ▣ Limitare i confronti



Tecniche di indicizzazione

- **Indice: struttura per reperimento efficiente di documenti correlati a interrogazione**
- Riduzione tempi di ricerca
- Informazioni memorizzate nell'indice
 - ▣ Documenti in cui compare T
 - ▣ Frequenza T
 - ▣ Parte in cui compare T



Information Retrieval

Documento 1

Antonio e
Cleopatra

Antonio
Bruto
Cesare
Cleopatra

Documento 2

Giulio
Cesare

Antonio
Bruto
Cesare
Calpurnia

Documento 3

Amleto

Bruto
Cesare

Documento 4

Cesare

Otello

Documento 5

Antonio
Cesare

Macbeth



Tecniche di indicizzazione

□ Struttura di un indice

▣ Termine T

▣ Riferimenti ai documenti collegati a T

| Termine | Riferimenti |
|-----------|---|
| Antonio | Documento 1 (frequenza 125); Documento 2 (frequenza 43), Documento 5 (frequenza 3) |
| Bruto | Documento 1 (frequenza 15); Documento 2 (frequenza 83), Documento 3 (frequenza 2) |
| Cesare | Documento 1 (frequenza 115); Documento 2 (frequenza 298), Documento 3 (frequenza 2), Documento 4 (frequenza 2), Documento 5 (frequenza 3) |
| Calpurnia | Documento 2 (frequenza 21) |
| Cleopatra | Documento 1 (frequenza 124) |

Interrogazione

- Risultato interrogazione:
 - ▣ Lista documenti correlati alla ricerca
 - ▣ Valore di rilevanza → similarità tra parole chiavi e termini documento
- Documenti con scarsa rilevanza → scartati

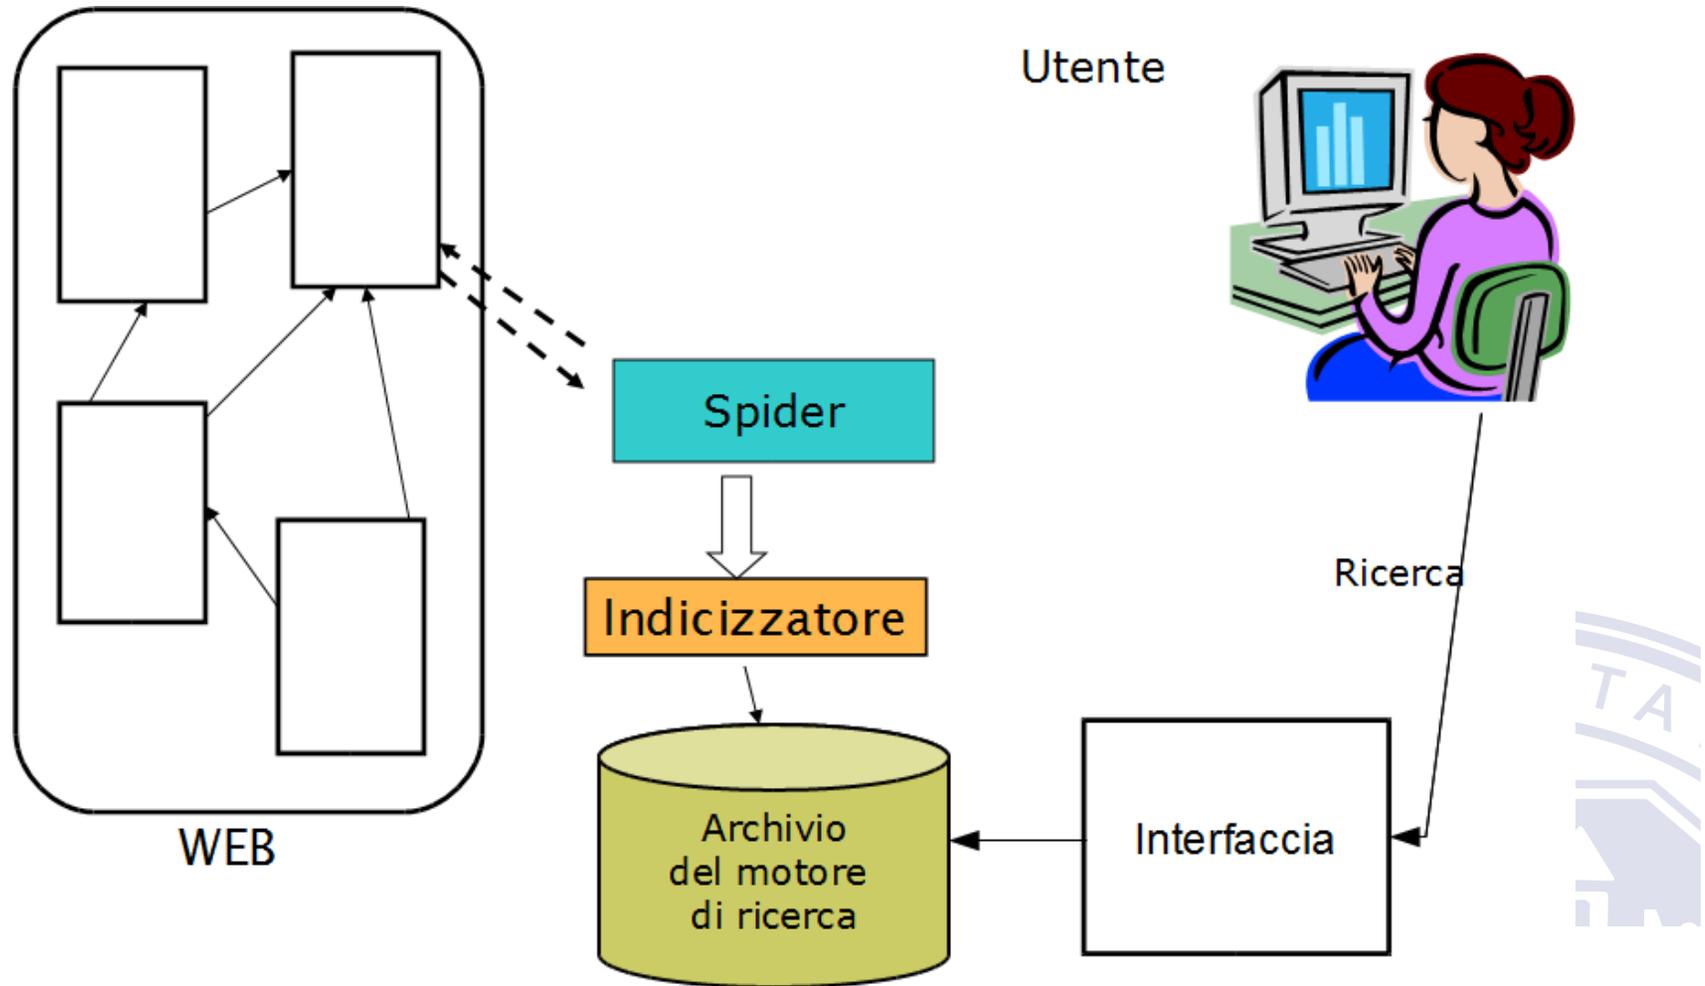


Motori di ricerca

- Come funziona un motore di ricerca?
- **Attività di un motore di ricerca:**
 - ▣ **Raccolta**
 - ▣ **Analisi e indicizzazione**
 - ▣ **Interrogazione**



Motori di ricerca



Motori di ricerca

Raccolta: *esplorazione* del Web

- Utilizzo link
- Generazione indirizzi
- Programmi per la raccolta: *crawler, spider, robot*
- Informazioni raccolte memorizzate in base di dati
→ **archivio Web**



Motori di ricerca

Analisi e indicizzazione

- Elaborazione delle informazioni raccolte dagli spider → **contenuto informativo**
- Utilizzo tecniche IR
 - ▣ Analisi del documento
 - ▣ Costruzione indice

| Parole chiave | Pagine web |
|---------------|---|
| Notizie | www.corriere.it www.repubblica.it ... |
| Università | www.unimi.it www.unibg.it ... |
| ... | ... |

Motori di ricerca

Interrogazione: risposta a richieste utenti

- **Selezione** dei documenti rilevanti
- Accesso solo all'**indice** e all'**archivio** del motore di ricerca
- Risultati della ricerca → **ordine con cui sono mostrati**
- Pagine ordinate in base a rilevanza (*ranking*)



Motori di ricerca

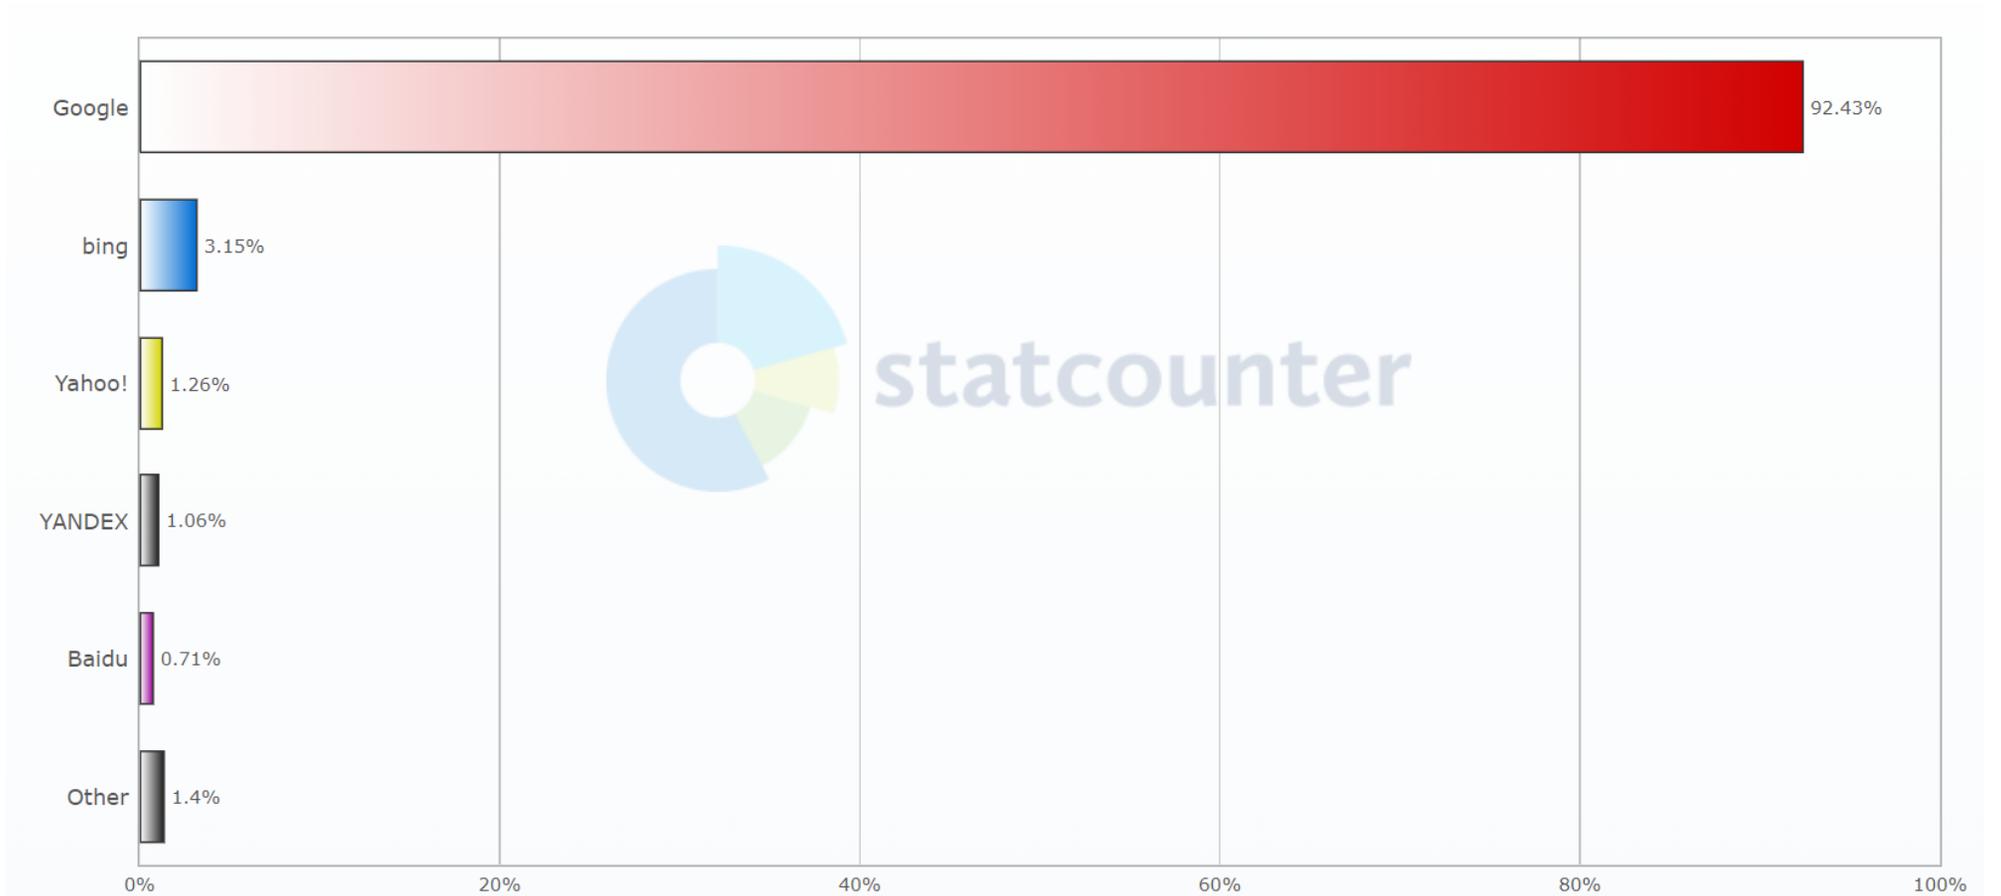
Motori di ricerca **generalisti**

- **Google (1998)**
- **Yahoo! Search (2004)**
- **DuckDuckGo (2008)**
- **Bing (2009)**
- ...

Difficoltà nel confronto tra i diversi motori di ricerca

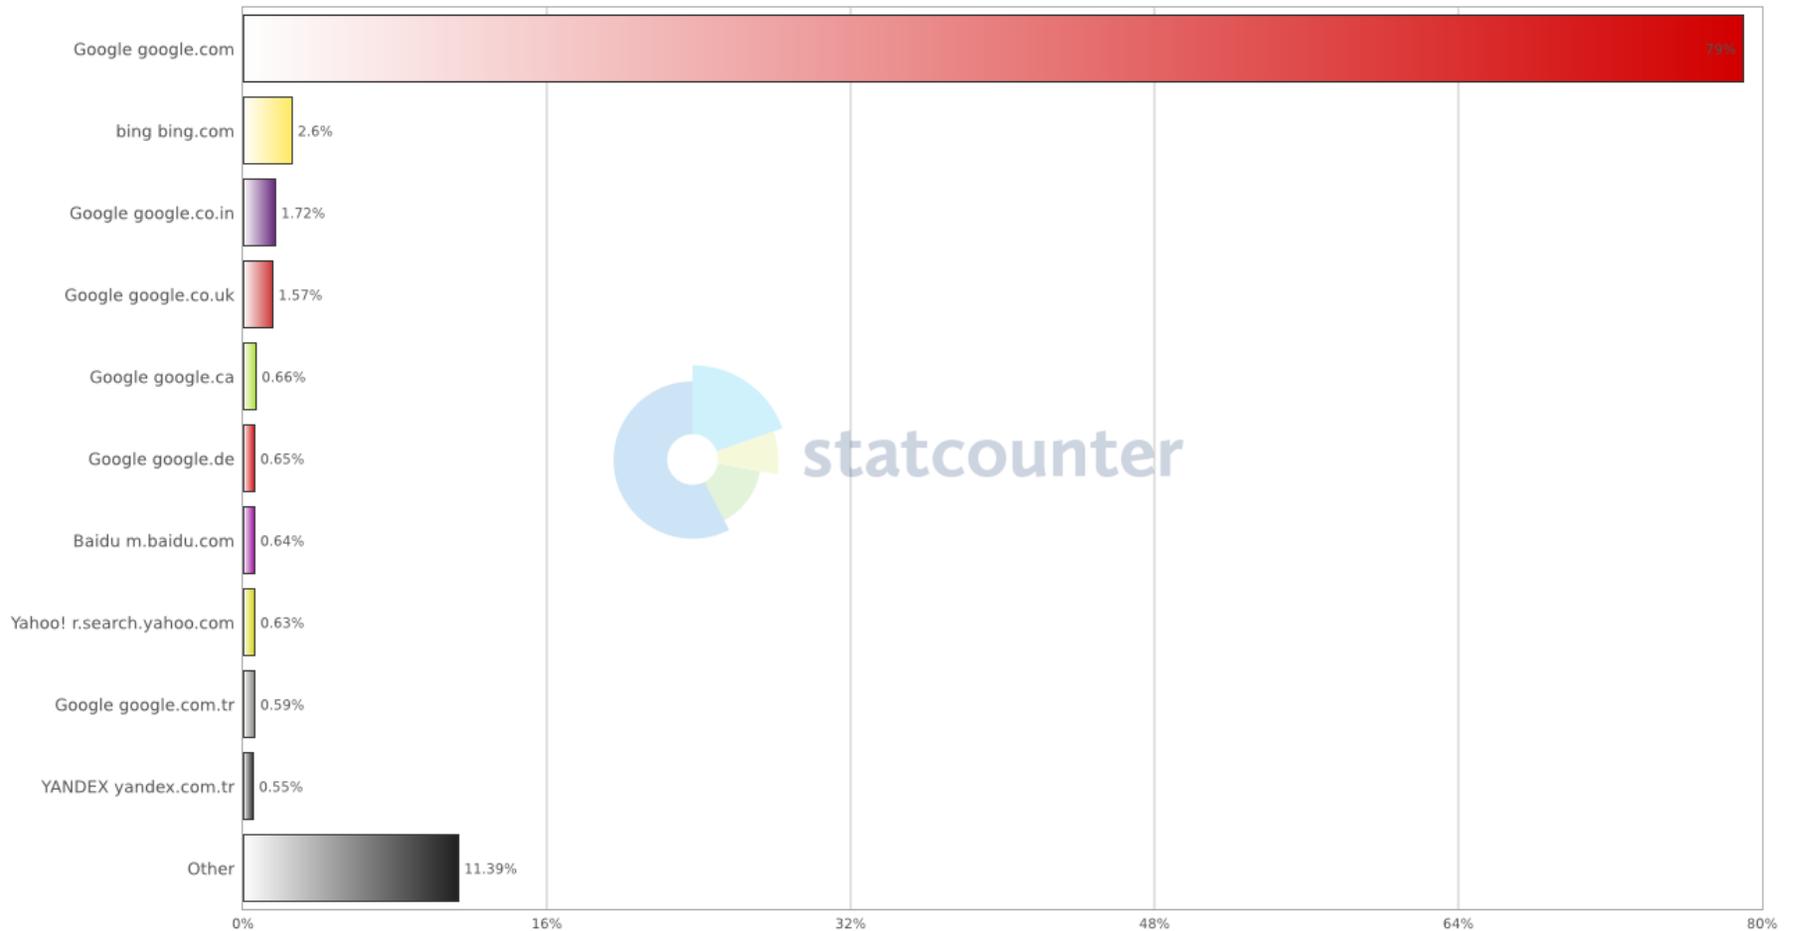


Motori di ricerca



Motori di ricerca

StatCounter Global Stats
Search Engine Host Market Share Worldwide from Nov 2019 - Nov 2020



Altri motori di ricerca

- **Metamotori**: sintesi di una ricerca su più motori
- **Plurimotori**: ricerche in parallelo
- **Motori specialistici**: motori di ricerca in ambiti specifici
 - Pubblicazioni scientifiche: [Google Scholar](#)
 - Notizie: Google News
 - Libri: Google Books
 - Immagini, video



Motori di ricerca

- ❑ **Interrogazione:** risposta a richieste utenti
- ❑ Accesso solo all'indice e all'archivio Web
- ❑ Risultati della ricerca → **ordine con cui sono mostrati**
- ❑ Pagine ordinate in base a rilevanza (*ranking*)
- ❑ Come funzionano **nella realtà?**
- ❑ Come **costruiscono il ranking?**



Ordinamento

Ricerca e ordinamento dei risultati



SERP

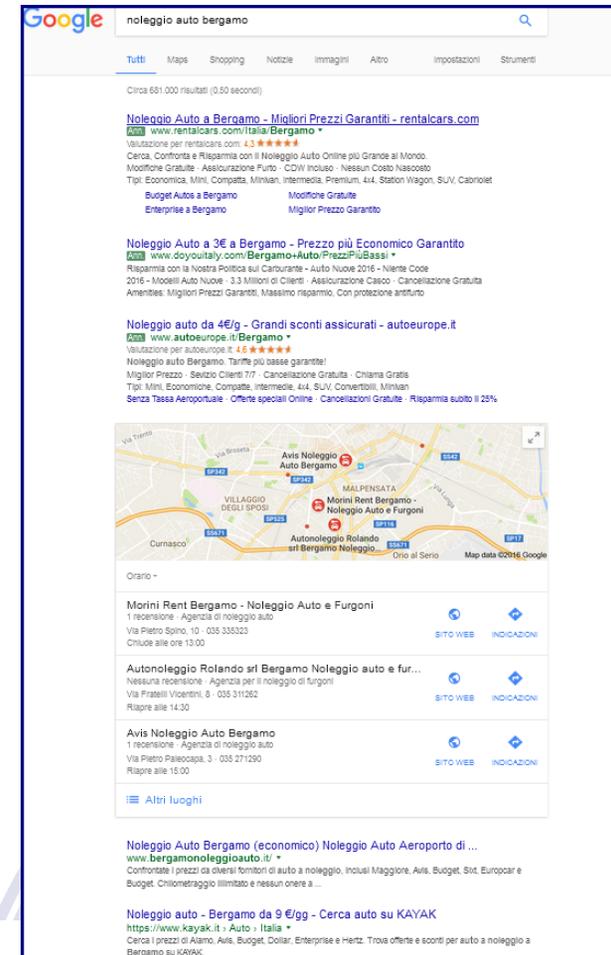
□ SERP (*Search Engine Results Page*): risultati di un motore di ricerca

▣ Risultati organici

▣ Risultati a pagamento

▣ Ricerca sulle mappe

▣ ...



Posizionamento

- Un aspetto fondamentale per la **visibilità** di un sito
→ **posizionamento** nella SERP
- Gli utenti usano spesso i motori di ricerca
 - ▣ Nel 2017 circa 3,5 miliardi di ricerche al giorno



Importanza del posizionamento

- Da una ricerca di AOL 2006:
 - ▣ I primi 10 risultati: **89.71% delle selezioni**
 - ▣ Risultati da 11 a 20: 4.37%
 - ▣ Risultati da 21 a 30: 2.42%
- In base alla posizione
 - ▣ **42%** delle selezioni: **prima posizione**
 - ▣ **12%** delle selezioni: **seconda posizione**
 - ▣ **9%** delle selezioni: **terza posizione**
 - ▣ **4%** delle selezioni: **quarta posizione**



Visibilità dei risultati

| Rank | Visibilità |
|------|------------|
| 1 | 100% |
| 2 | 100% |
| 3 | 100% |
| 4 | 85% |
| 5 | 60% |
| 6 | 50% |
| 7 | 50% |
| 8 | 30% |
| 9 | 30% |
| 10 | 20% |



Motori di ricerca

I motori di ricerca costruiscono i risultati da presentare in **due fasi**:

- **Individuazione** delle pagine rilevanti (IR)
- **Ordinamento** (*Ranking*) delle pagine rilevanti



Motori di ricerca

- Motori di ricerca cercano le pagine che contengono le parole chiave inserite
- Come funzionano **nella realtà?**
- Esempio:
 - ▣ Esempio1.html
 - ▣ Esempio2.html
 - ▣ Esempio3.html
 - ▣ Esempio4.html
- Ordinamento rispetto alla ricerca: Università Bergamo?



Motori di ricerca

- Alla fine degli anni '90 analisi della **struttura del Web** per individuare le pagine **più rilevanti**
- Da cosa è costituita questa struttura?
 - ▣ Pagine web
 - ▣ **Link ipertestuali**
- Link ipertestuali → **legame** tra le pagine web



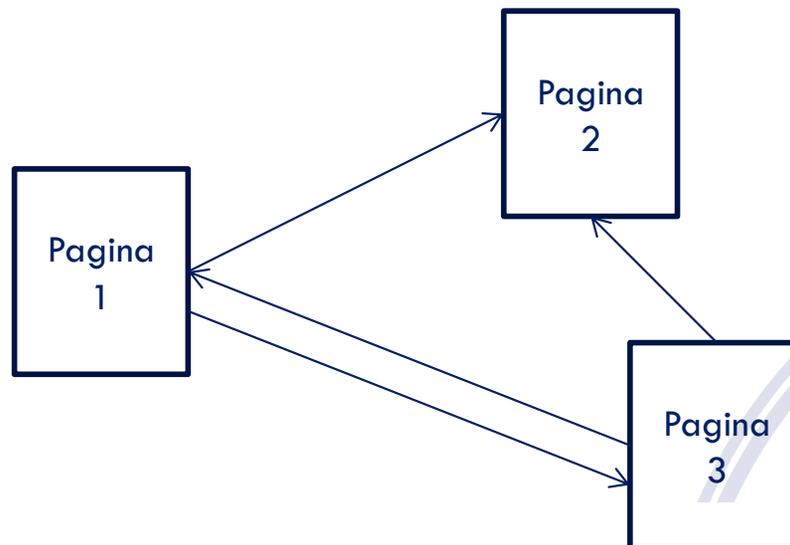
Grafo del Web



Motori di ricerca

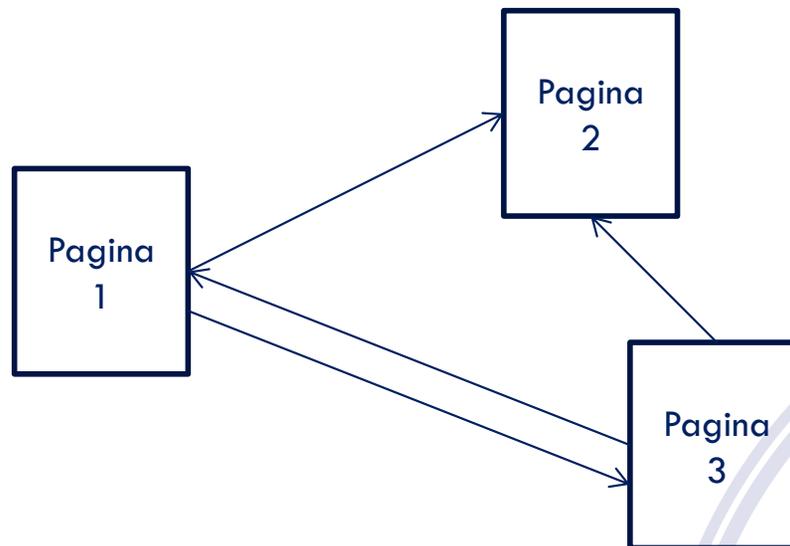
- Alla fine degli anni '90 analisi della **struttura del Web** per individuare le pagine **più rilevanti**

Grafo del Web



Grafo del Web

- Grafo del Web
 - Nodi → pagine web
 - Archi (orientati) → link ipertestuali

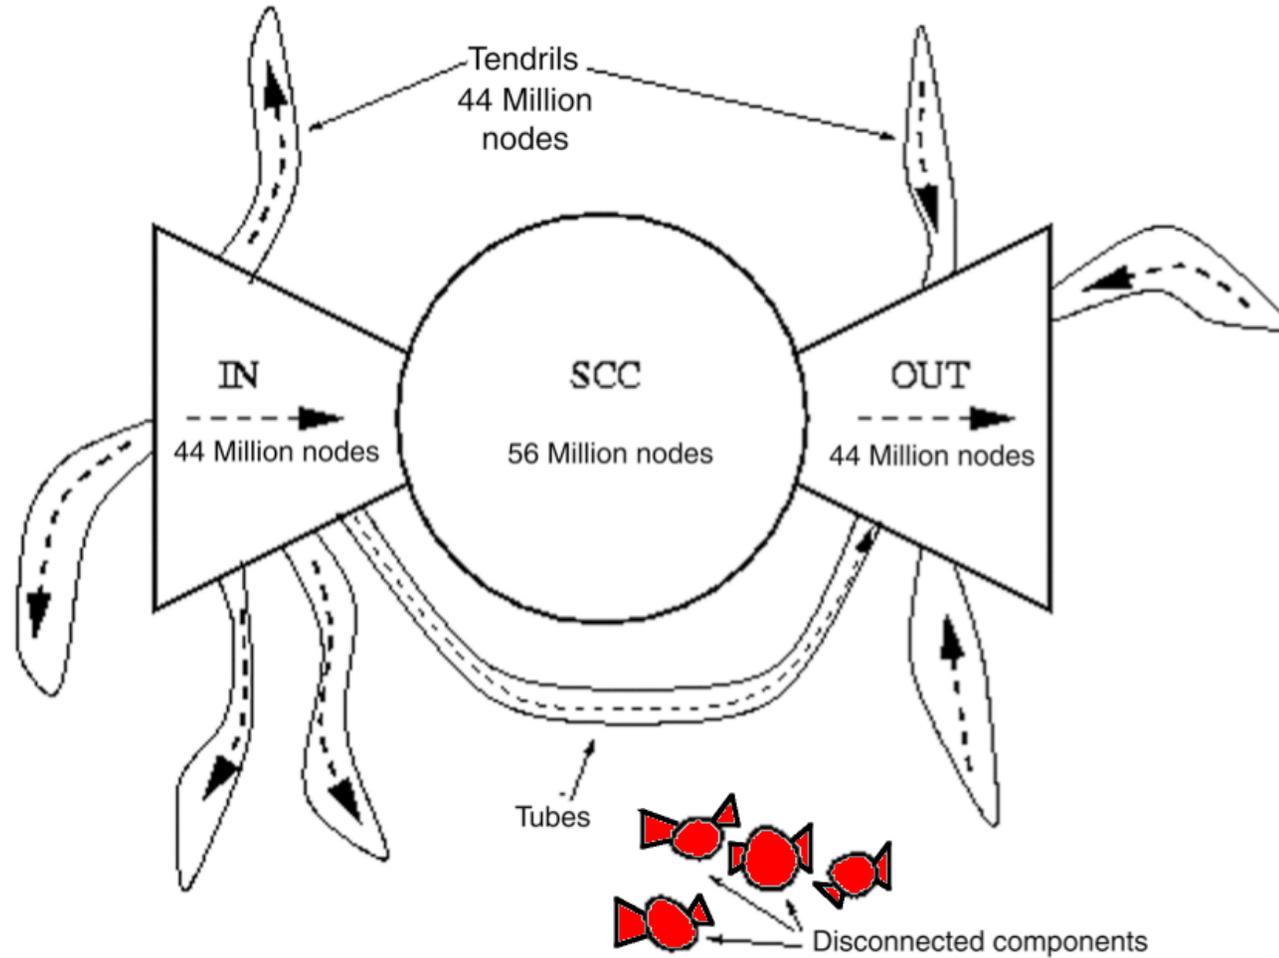


Grafo del Web

- Caratteristiche del grafo del Web
 - ▣ Rete orientata
 - Differenza tra grado uscente e grado entrante
 - ▣ **Grado di separazione: 19 link (*Barabasi*)**
 - ▣ Presenza di
 - Hub
 - Componenti isolate



Grafo del Web



Grafo del Web

Grafo del Web è utilizzato per

- ▣ Esplorazione del Web e **raccolta** di dati
- ▣ **Ordinamento** dei risultati dei motori di ricerca
(*PageRank*)
- ▣ Determinare pagine che si occupano di **argomenti simili**



Indicizzazione

- La struttura del Web condiziona l'**esplorazione** e la conseguente **indicizzazione**
- Nel 1997
 - ▣ Hotbot copriva circa il 33% delle pagine
 - ▣ Altavista il 28%
 - ▣ Lycos 2%



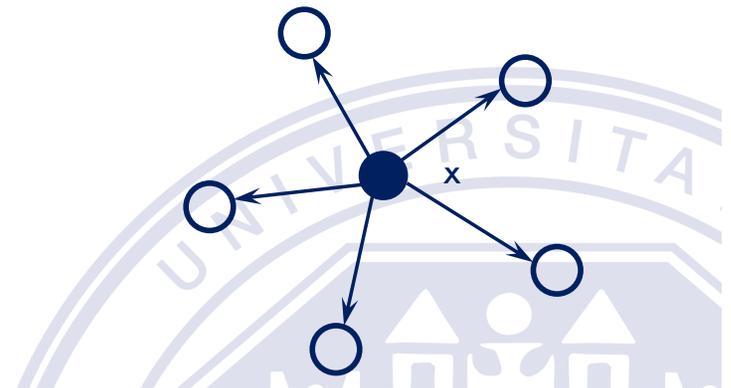
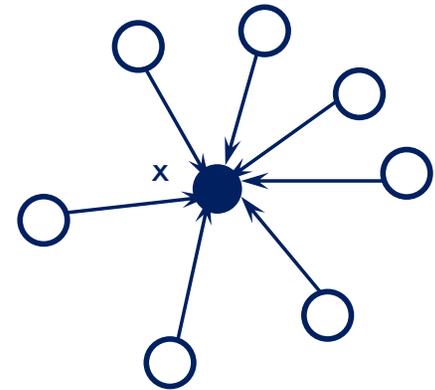
Indicizzazione

- La probabilità che una pagina sia indicizzata dipende dal **numero di archi entranti**
 - ▣ Un link: 10% di probabilità
 - ▣ Tra 21 e 100 link: 90% di probabilità



Ranking

- Due caratteristiche di una nodo/pagina web x :
- link entranti: **stella entrante**
- link uscenti: **stella uscente**

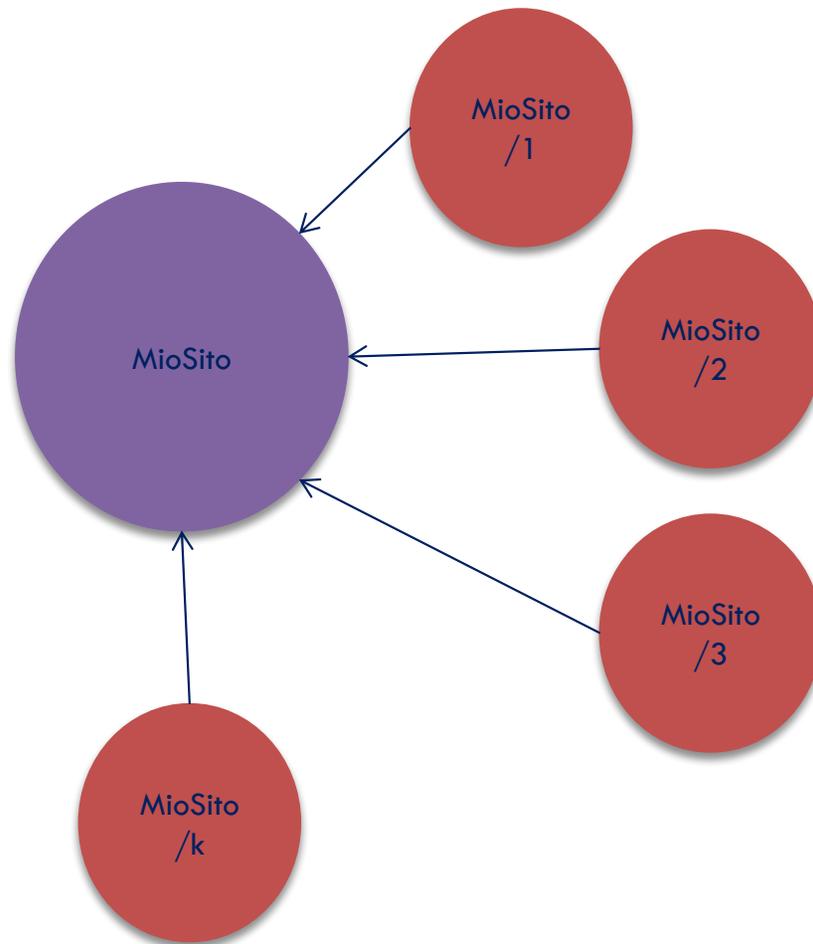


Ranking

- Parametro con cui valutare le caratteristiche di una pagina:
 - ▣ Numero di link nella stella entrante
 - ▣ Numero di link nella stella uscente
- **Siti autorità:** siti autorevoli su un certo argomento
→ molti link entranti



Ranking



Motori di ricerca

- Ulteriori analisi del grafo del Web per definire migliori criteri di **ordinamento**
- Metodi:
 - ▣ *HITS*
 - ▣ *PageRank*



HITS

Hyperlink-Induced Topic Search (HITS):

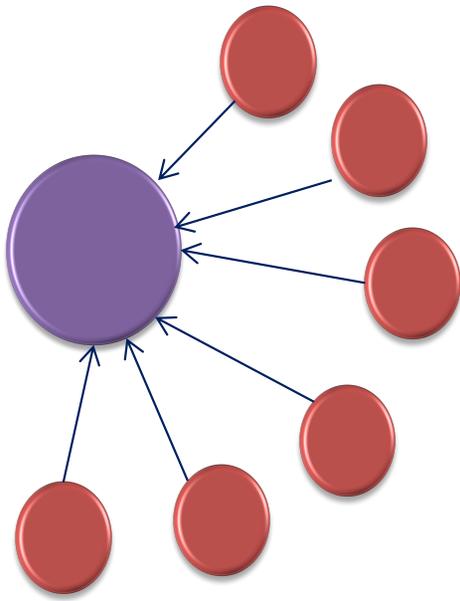
- Analisi di Kleinberg (1999)
- Nodi del grafo del Web possono essere classificati come
 - ▣ Autorità
 - ▣ Aggregatori



HITS

Hyperlink-Induced Topic Search (HITS):

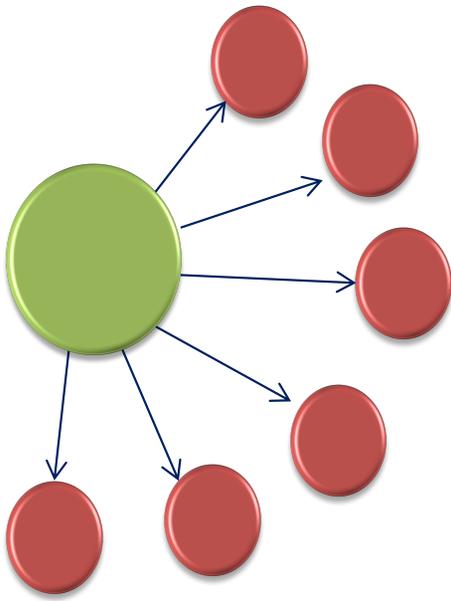
- **Autorità:** nodo con stella entrante molto ampia
 - Autorevolezza su un dato argomento



HITS

Hyperlink-Induced Topic Search (HITS):

- **Aggregatore:** nodo con stella uscente molto ampia



HITS

Pagine autorevoli e aggregatori si influenzano vicendevolmente

- Aggregatori **rilevanti** → pagine **autorevoli**
- Pagine **autorevoli** → Aggregatori **rilevanti**



PageRank

Successo di **Google** → metodo/algoritmo di ranking
(PageRank)

“The heart of our software is PageRank™, a system for ranking web pages developed by our founders Larry Page and Sergey Brin at Stanford University. And while we have dozens of engineers working to improve every aspect of Google on a daily basis, PageRank continues to play a central role in many of our web search tools.”

(Google technology)

PageRank

- Ranking di Google basato su *PageRank*
- **Rilevanza di una pagina web: funzione della rilevanza delle pagine web collegate (rilevanza pagine delle stelle entranti)**



PageRank

- Calcolo *PageRank*: procedura *ricorsiva* per il calcolo della rilevanze delle pagina
 - ▣ Rilevanza di una pagina web **dipende dalla rilevanza delle pagine web della stella entrante**
 - ▣ Rilevanza della delle pagine web nella **stella uscente influenzata dalla rilevanza mia pagina web**



PageRank

Intuitivamente:

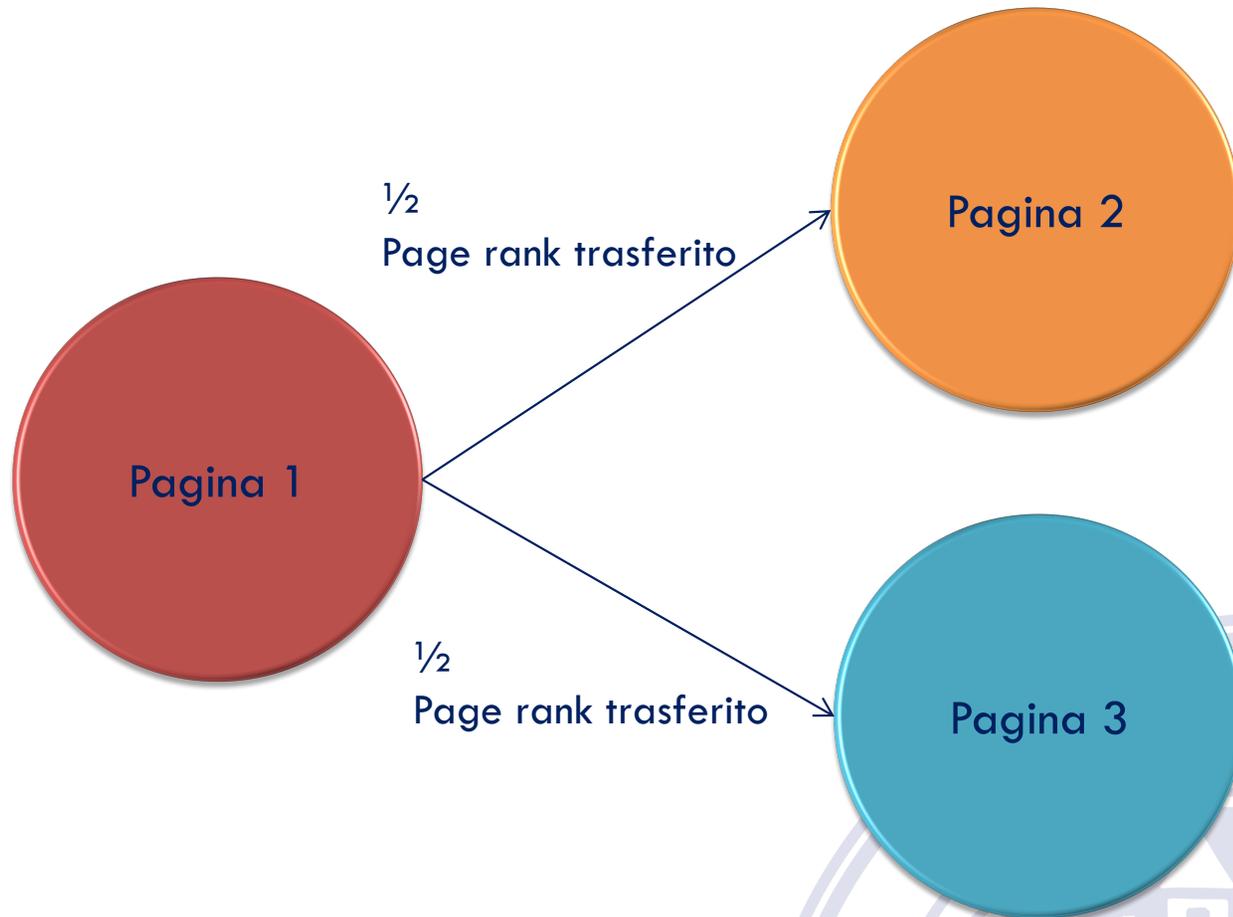
- Se una pagina ha rilevanza X e n link uscenti, **trasmette** una rilevanza X/n ai nodi della stella uscente
- **Rilevanza di una pagina: somma delle rilevanze ricevute** dai nodi della stella entrante



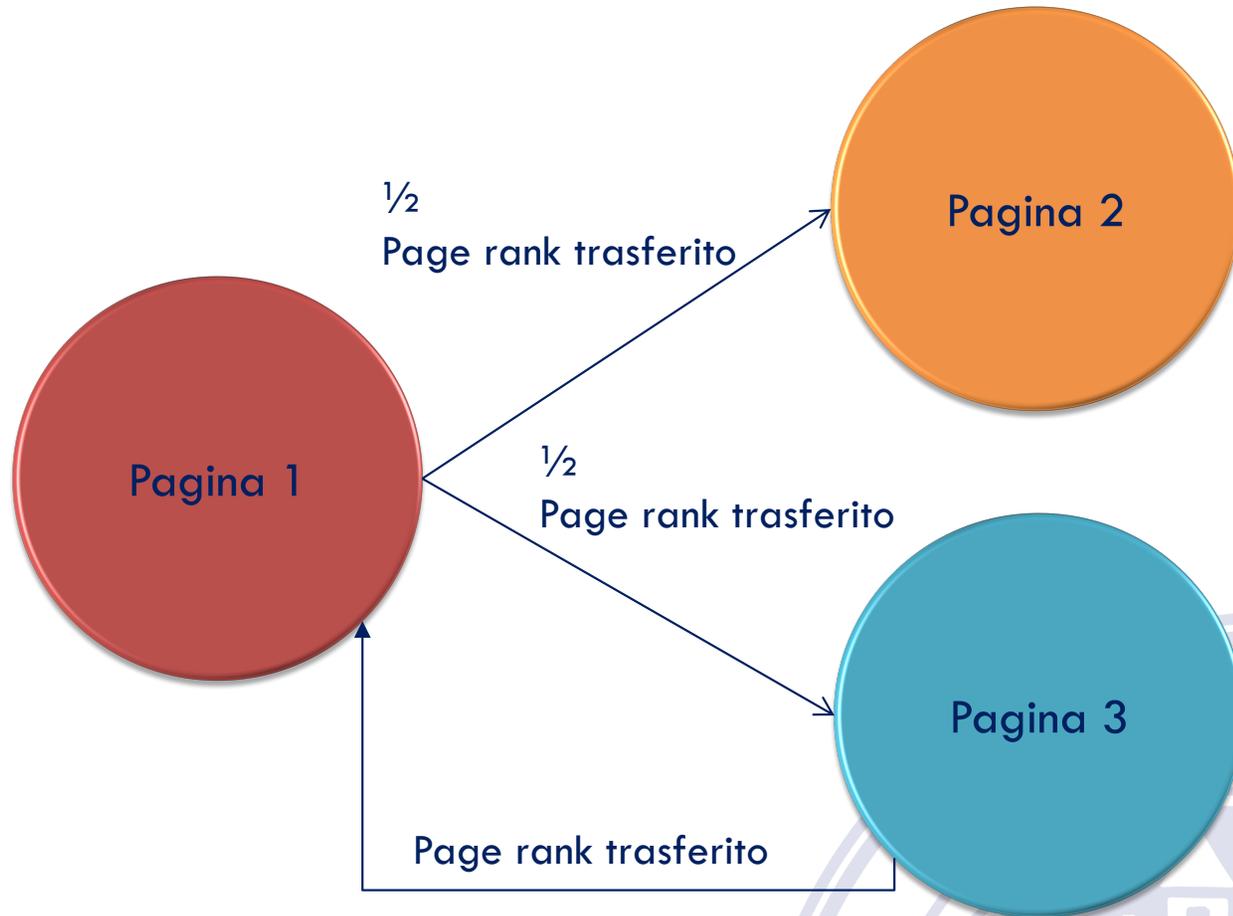
PageRank



PageRank



PageRank

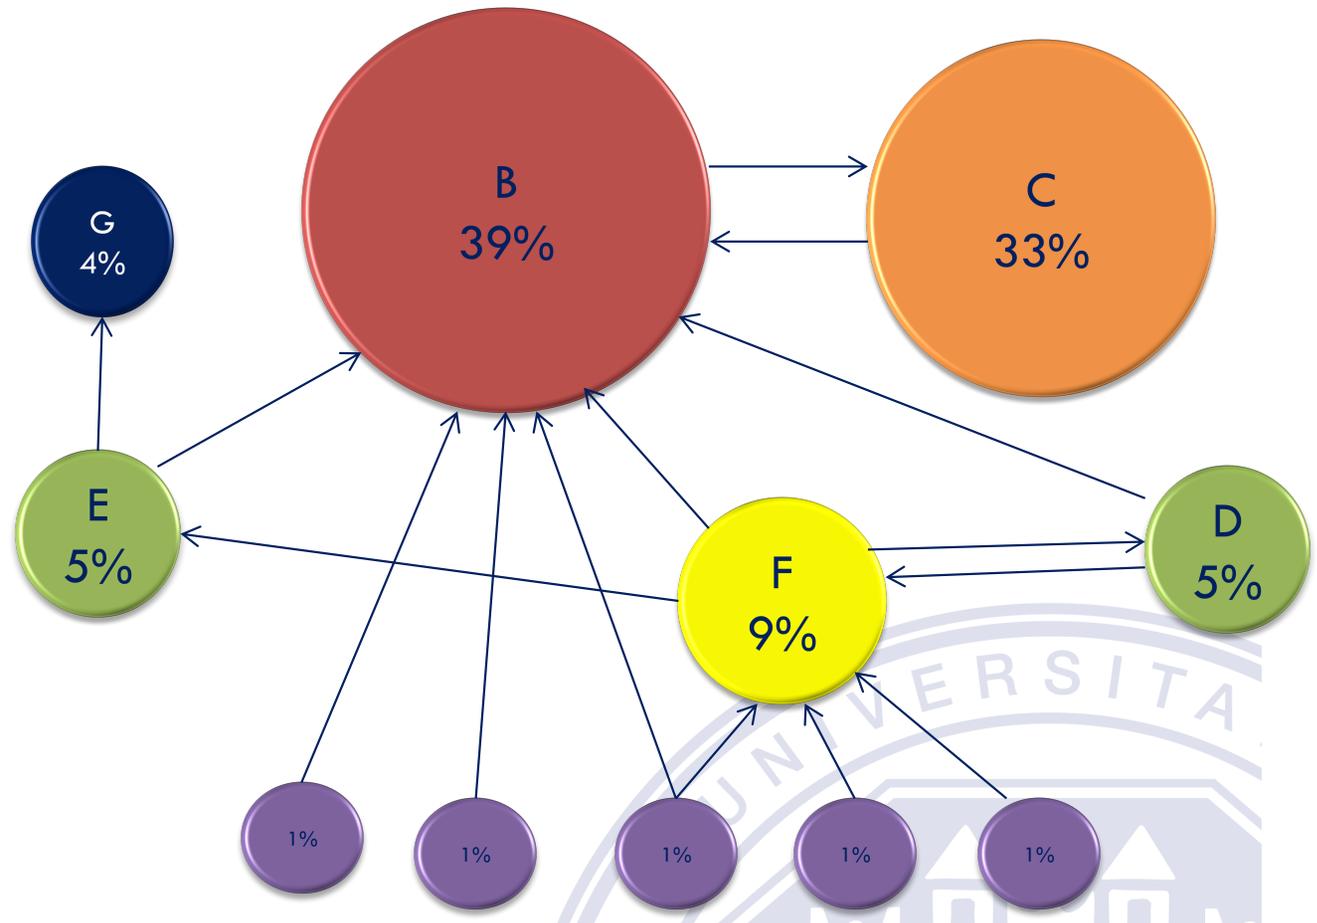


Motori di ricerca

Rilevanza di B
trasferita solo a C

Rilevanza di C
trasferita solo a B

Rilevanza di B:
rilevanza trasferita
da C, D, F, ...



PageRank

- Calcolo *PageRank*: procedura ricorsiva **complessa**
- **Interpretazione: probabilità** che navigando in modo casuale nel Web **si visiti una determinata pagina**
- **Rilevanza di una pagina indipendente dalle parole chiave** utilizzate nelle ricerche
- Valore calcolabile **a priori**
 - ▣ Dipende solo dalla struttura del Web



Ricerca e Web

- Strategie per **condizionare** i motori di ricerca:
 - ▣ Creazione link verso una pagina per aumentarne l'autorevolezza
 - ▣ Vendita link
 - ▣ *Cloaking*: utilizzo versioni differenti del sito



SEO

- ***Search Engine Optimization (SEO)***: tecniche per migliorare il posizionamento nei motori di ricerca
- **Obiettivo**
 - ▣ **Migliorare la visibilità**, sia per motori di ricerca che per utenti
 - Usabilità del sito
 - Link da altre pagine



Tipi di ricerca

- Gli utenti effettuano ricerche per diversi scopi
- I principali:
 - Navigazione
 - Informativa
 - Transazionali



SEO

On page

- Struttura
- Contenuto
- Aspetti tecnici

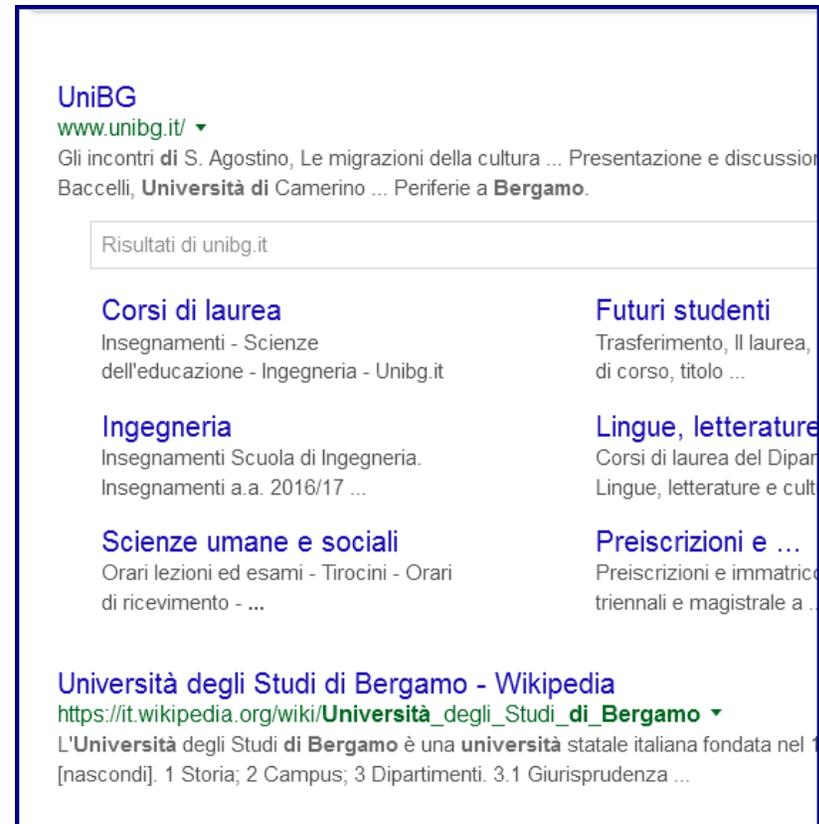
Off page

- Link
- Social media
- ...



Costruzione della pagina

- Aspetti della singola pagina
 - ▣ Titoli univoci e accurati (parole chiave nel *tag title*)
 - ▣ I titoli sono mostrati come descrizione nella SERP



UniBG
www.unibg.it/ ▼
Gli incontri di S. Agostino, Le migrazioni della cultura ... Presentazione e discussione
Baccelli, **Università di Camerino** ... Periferie a **Bergamo**.

Risultati di unibg.it

Corsi di laurea
Insegnamenti - Scienze dell'educazione - Ingegneria - Unibg.it

Futuri studenti
Trasferimento, Il laurea, di corso, titolo ...

Ingegneria
Insegnamenti Scuola di Ingegneria. Insegnamenti a.a. 2016/17 ...

Lingue, letterature
Corsi di laurea del Dipar Lingue, letterature e cult

Scienze umane e sociali
Orari lezioni ed esami - Tirocini - Orari di ricevimento - ...

Preiscrizioni e ...
Preiscrizioni e immatricol triennali e magistrale a ...

Università degli Studi di Bergamo - Wikipedia
https://it.wikipedia.org/wiki/Università_degli_Studi_di_Bergamo ▼
L'**Università degli Studi di Bergamo** è una **università** statale italiana fondata nel 1963 [nascondi]. 1 Storia; 2 Campus; 3 Dipartimenti. 3.1 Giurisprudenza ...

```
<link href= sites/all/themes/u  
<title>UniBG</title>  
<link type="text/css" rel="s
```

Costruzione della pagina

- Il *meta tag description* potrebbe essere utilizzato l'informazione come *snippet*
- In alternativa DMOZ Open Directory Project

La Repubblica.it - News in tempo reale - Le notizie e i video di politica ...

www.repubblica.it/ ▼

Repubblica è il quotidiano online aggiornato 24 ore su 24 su politica, cronaca, economia, sport, esteri, spettacoli, musica, cultura, scienza, tecnologia.

```
<meta name="description" content="Repubblica &grave; il quotidiano online aggiornato 24 ore su 24 su politica,
```

Navigazione

- La struttura di un sito è legata alla facilità di **navigazione**
- I motori di ricerca possono utilizzare la struttura per comprendere il **ruolo delle pagine**
- **Mappa del sito**
 - ▣ Mappa per gli utenti
 - ▣ Mappa per motori di ricerca (SiteMap XML)



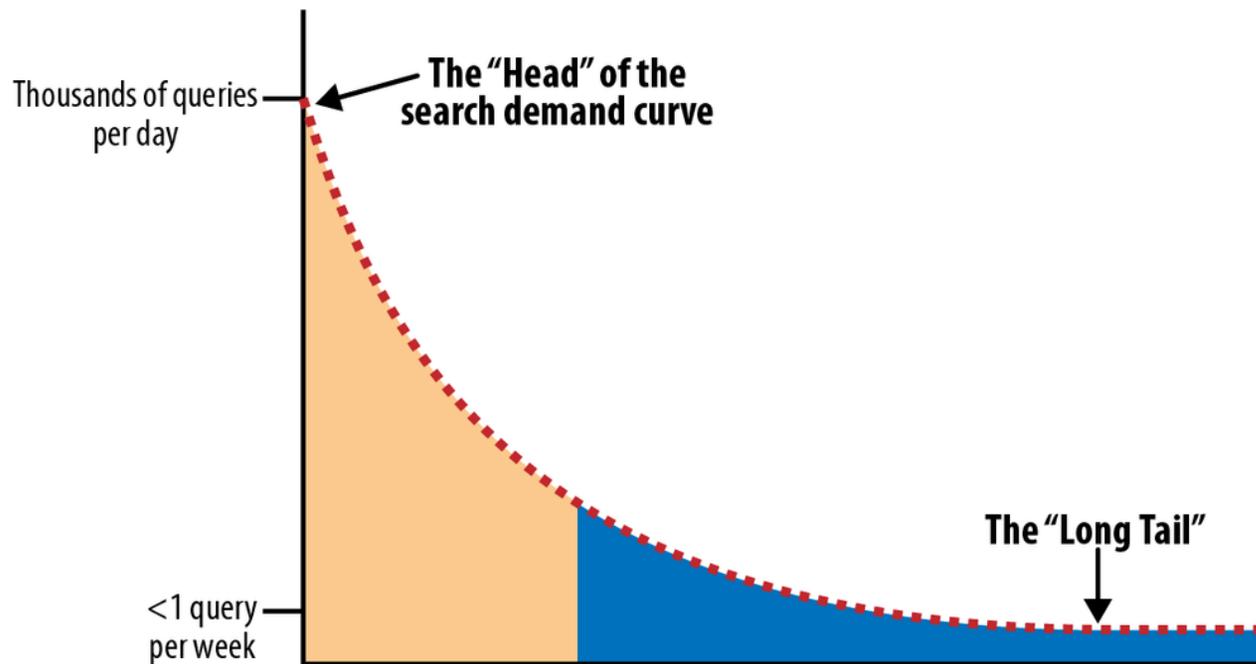
SEO e contenuto

- Analisi delle parole chiave
 - ▣ Parole chiave maggiormente usate
 - ▣ Variazioni delle parole chiave
 - ▣ Relazione con la pubblicità (vedi GoogleAdWords)



Coda lunga delle ricerche

Search engine keyword demand



Popular queries

Stock quotes
NFL
Laptop reviews

“Long Tail” queries

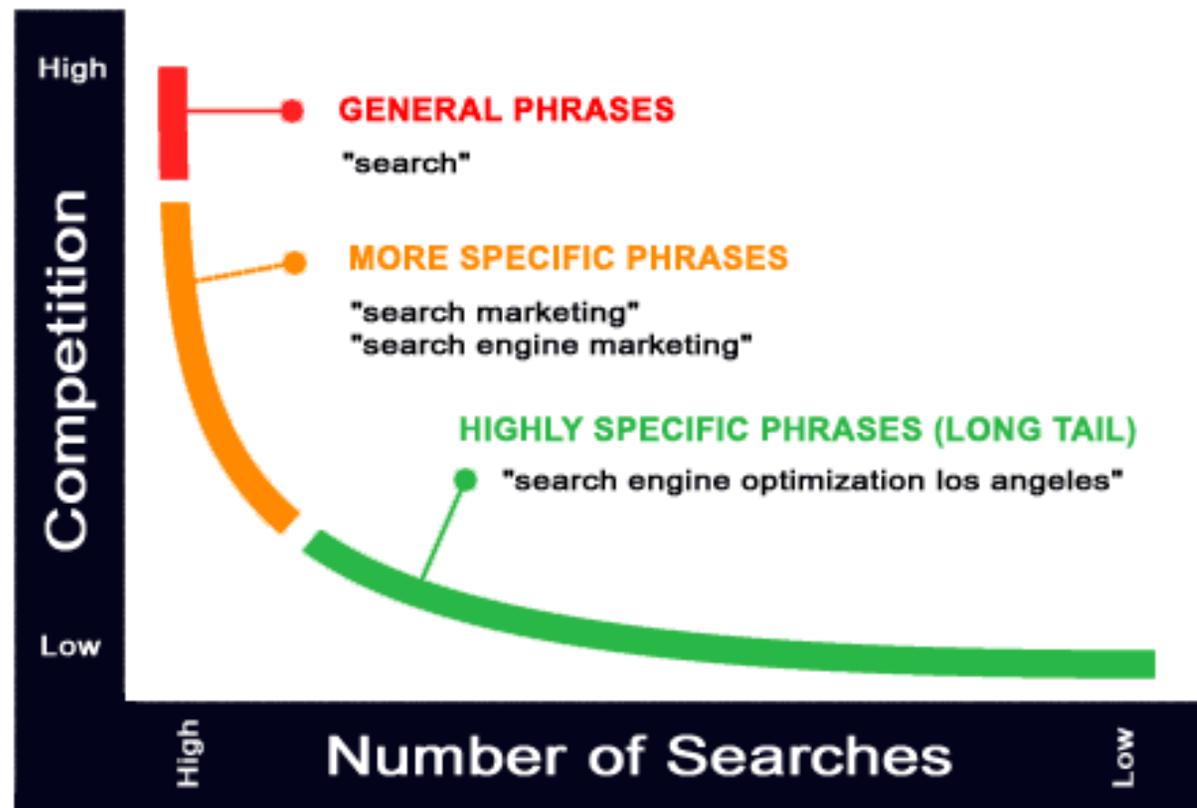
Chart of Argentinian Market in 1994
Draft picks for Seattle Seahawks
Dell m1210 battery life estimates



Da «The art of SEO»

Coda lunga delle ricerche

LONG TAIL SEARCH



Copyright Contract Web Development, Inc. 2010. GuruofSearch.com



Da «The art of SEO»