Sistemi per il recupero delle informazioni

Gabriele Pozzani

A.A. 2013/2014

Corso di Laurea Magistrale in Editoria e Giornalismo

Sistemi per il recupero dell'informazione sul Web: Search Engine Optimization

SEO (I)

- Oltre a comportamenti scorretti per aggirare gli algoritmi dei motori di ricerca e migliorare il ranking del proprio sito, esistono tecniche lecite per migliorare la propria “reperibilità” e visibilità
- Tali tecniche ricadono sotto il nome di Search Engine Optimization (SEO)
- Esistono aziende apposite per l'ottimizzazione dei siti web con tecniche SEO
  - Ma attenzione, ne esistono anche molte “meno serie” che usano tecniche non lecite

SEO (II)

- Spesso il termine SEO non è ben distinto dalle tecniche di posizionamento illecite
- A tal fine può essere utile parlare anche di
  - Black hat SEO: insieme delle tecniche illecite (=spamdexing)
  - White hat SEO: insieme delle tecniche di ottimizzazione lecite
    - Hanno l'obiettivo di aumentare effettivamente la qualità del sito e quindi di creare “valore”

SEM (I)

- Il SEO è una delle attività del Search Engine Marketing (SEM)
- Obiettivi del SEM sono:
  - Benchmarking online: studio dello scenario competitivo sui motori di ricerca (in termini di saturazione del canale e qualitativi dei messaggi/contenuti proposti)
  - Online branding: incremento della notorietà attraverso il presidio dei risultati dei motori di ricerca
  - Brand monitoring: monitoraggio del sentiment nei risultati dei motori di ricerca
  - Database building: avvio di ulteriori attività di marketing che sfruttino il motore come porta di ingresso verso le iniziative promozionali
  - Vendita diretta (E-commerce) attraverso i motori di ricerca e i comparatori prezzi (motori verticali)
  - Online customer support: assistenza clienti online

SEM (II)

- Le principali attività nel SEM sono:
  - Search results monitoring: monitoraggio dei risultati proposti per specifiche query
  - Posizionamento sui motori di ricerca
    - Posizionamento naturale tramite la SEO
    - Posizionamento a pagamento sui motori di ricerca
      - inserzioni a pagamento (link sponsorizzati) per le quali l'inserzionista acquista le parole per le quali vuole comparire
  - Search engine advertising (SEA): attività di gestione di campagne di link a pagamento su siti e portali che maggiormente consentono di raggiungere il target d'impresa (detta anche Keyword advertising)

SEO (III)

- Negli ultimi anni i motori di ricerca hanno aggiornato i propri algoritmi di indicizzazione
- Alla parte basata sull'analisi dei link (e.g., PageRank) hanno aggiunto l'analisi dei contenuti
- Le tecniche SEO puntano ad ottimizzare i contenuti di un sito al fine di migliorarne l'"aspetto", il valore e la qualità agli occhi del motore di ricerca
- L'ottimizzazione avviene rispetto alle linee guida (best practice) dettate dai motori di ricerca

Linee guida (I)

- Le linee guida puntano a migliorare la qualità di un sito sotto diversi aspetti
  - Struttura
  - Contenuti
  - Comportamento nei confronti dei crawler
- Una parte delle linee guida nasce da studi di usabilità ed interazione uomo-macchina
  - Sono utili in generale per costruire un buon sito, indipendentemente dai motori di ricerca

Linee guida (II)

- Vediamo ad esempio le linee guida suggerite da Google
  - Istruzioni per webmaster
  - Ottimizzazione per motori di ricerca
  - Guida introduttiva di Google all'ottimizzazione per motori di ricerca (SEO)

SEO base, titolo (I)

- Titoli
  - Il titolo comunica gli argomenti della pagina sia agli utenti che ai motori di ricerca
  - Il titolo va indicato nel tag <title> all'interno del tag <head>
  - Il contenuto del tag <title> comparirà, di norma, nella prima riga dei risultati
  - Buone norme
    - Possibilmente, usare un titolo univoco per ogni pagina del sito
    - Titolo che comunichi efficacemente l'argomento del contenuto
    - Titoli brevi ma descrittivi

SEO base, titolo (II)

```
<html>
<head>
<title>Le figurine dei calciatori di Marco - vendita online di figurine, guida ai prezzi, articoli e novità</title>
<meta name="description" content="Le figurine dei calciatori di Marco: vasta selezione di figurine di tanti famosi protagonisti del mondo del calcio">
</head>
<body>
```

SEO base, descrizione (I)

- Le descrizioni (o sommari) possono essere specificati per ogni pagina
  - Il meta tag `description` di una pagina fornisce ai motori di ricerca un sommario dell'argomento della pagina
  - Potrebbero essere usati come snippet (frase di descrizione) per le pagine
  - Buone norme
    - Scrivere una descrizione che possa informare ed interessare gli utenti
    - Usare una descrizione unica per ogni pagina

SEO base, descrizione (II)

```
<html>
<head>
<title>Le figurine dei calciatori di Marco - vendita online di figurine, guida ai prezzi, articoli e novità</title>
<meta name="description" content="Le figurine dei calciatori di Marco: vasta selezione di figurine di tanti famosi protagonisti del mondo del calcio">
</head>
<body>
```

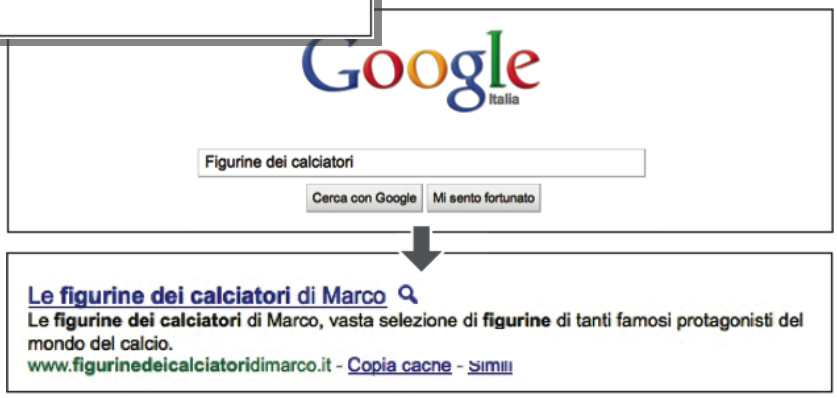

Struttura, URL (I)

- URL semplici da capire comunicano meglio i contenuti
  - Se l'URL contiene parole rilevanti, fornisce agli utenti e ai motori di ricerca più informazioni sulla pagina
  - l'URL di un documento viene mostrato come parte di un risultato di ricerca, sotto il titolo e la snippet
  - Buone norme:
    - Utilizzare delle parole nell'URL, anziché codici o sigle
    - Semplificare la struttura delle tue directory
    - Fornire una versione unica dell'URL per raggiungere un dato documento

Struttura, URL (II)

Struttura, semplicità di navigazione (I)

- Pianificare la navigazione basandosi sulla pagina principale
  - Pensare al modo in cui un visitatore passerà dalla pagina principale ad una con contenuti più specifici
- Utilizzare le liste “breadcrumb”
  - lista di link in linea in cima o in fondo alla pagina che permette ad un visitatore di tornare indietro verso la sezione precedente o verso la home page

Struttura, semplicità di navigazione (II)

- Preparare due sitemap: una per gli utenti
  - pagina che mostra l'architettura del sito e che, generalmente, consiste in una lista gerarchica delle pagine.
  - Un visitatore potrebbe usarla per orientarsi meglio sul sito e trovare quello che sta cercando

  una per i motori di ricerca
  - rende la scansione del sito più semplice per i crawler
  - Dice ai crawler ogni quanto rileggere il sito perché potrebbe essere cambiato

Contenuti

- Offrire contenuti e servizi di qualità
- Pensare alle parole che un utente potrebbe utilizzare per trovare una parte del contenuto
  - Utenti diversi possono usare ricerche diverse per cercare un sito
  - Anticipare tali differenze di approccio alla ricerca e tenerne conto durante la stesura del contenuto (usando una buona combinazione di frasi chiave)
- Creare testi facili da leggere
- Organizzare il contenuto a seconda dell'argomento

Contenuti, anchor text

- L'anchor text è il testo cliccabile dei link
  - Dice qualcosa di utile sulla pagina linkata sia per gli utenti che per i motori di ricerca
  - Scegliere testi descrittivi
  - Usare un testo conciso
  - Formattare i link in modo che siano riconoscibili dal resto del testo

Contenuti, immagini

- Usare nomi di file e testo alternativo brevi ma descrittivi
  - Il testo alternativo è
    - Visualizzato quando per qualche ragione l'immagine non può essere visualizzata
    - Usato dai motori di ricerca come “descrizione dell'immagine” al fine di indicizzarla
- Raggruppare tutte le immagini in un'unica cartella
- Usare formati di immagini comunemente supportati
  - JPEG, GIF, PNG, BMP

Contenuto, suddivisione del testo

- Organizzare il testo in paragrafi
- Evidenziare in modo appropriato titoli e sotto titoli
  - Con gli appositi attributi HTML

Comunicare con i crawler

- Ogni crawler prima di accedere ad un sito vi cerca un particolare file, robots.txt
  - Questo file comunica ai motori di ricerca se debbano o meno accedere e indicizzare le varie sezioni del sito

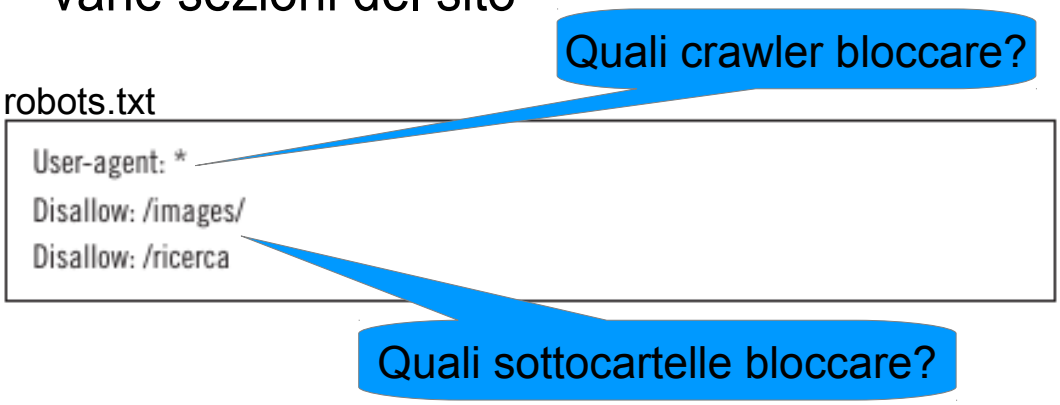

Combattere il web spam in blog e forum (I)

- Un modo di spamdexing consiste nell'inserire nei commenti di blog/forum il link ad una pagina che si vuole “pubblicizzare”

- È possibile dire ai crawler di non seguire alcuni link
  - Attributo `rel="nofollow"` dei link
- Applicando in automatico questo attributo ad eventuali link inseriti nei commenti si evita che questi vengano considerati e creino spam
  - Si evita che il proprio blog/forum venga considerato spam e quindi venga penalizzato dai motori di ricerca

Combattere il web spam in blog e forum (II)

- Inserire un CAPTCHA in modo da bloccare commenti automatici

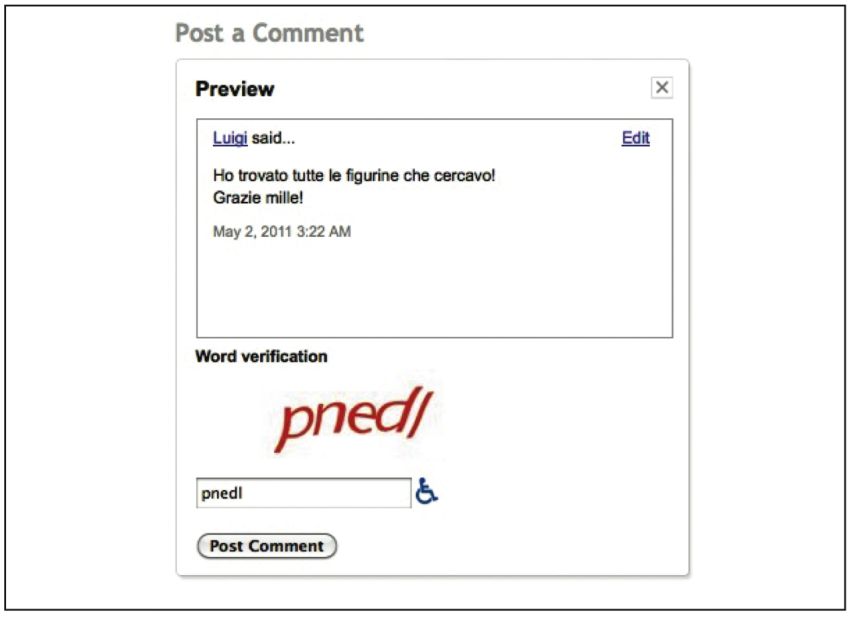

Strumenti online

- Google e Microsoft mettono a disposizione strumenti online gratuiti
  - aiutano ad avere maggiore controllo su come i motori di ricerca interagiscono con i siti web e forniscono informazioni utili a riguardo
- Permettono
  - vedere quali parti di un sito il crawler non riesce a raggiungere
  - invio di una Sitemap XML
  - analizzare e generare file `robots.txt`
  - rimuovere URL indicizzati
  - identificare problematiche relative a titoli e descrizioni delle pagine web
  - conoscere le principali query di ricerca che portano a un sito
  - dare un'occhiata a come il crawler vede le pagine
  - rimuovere elenchi di link indesiderati che potrebbero essere utilizzati nei risultati
  - ricevere notifiche in caso di violazioni delle linee guida della qualità e inoltrare una richiesta di riconsiderazione