

Sistemi per il recupero delle informazioni

Gabriele Pozzani

A.A. 2014/2015
Corso di Laurea Magistrale in
Editoria e Giornalismo

Interfacce utente per il recupero delle informazioni

L'interfaccia utente

- È la finestra tramite cui si interagisce con un SRI
- Ha l'obiettivo di aiutare nel comprendere i bisogni degli utenti
- Inoltre dovrebbe aiutare gli utenti nel
 - Formulare le loro interrogazioni
 - Selezionare tra le sorgenti di informazioni disponibili
 - Comprendere i risultati delle ricerche
 - Tenere traccia dei progressi nelle ricerche

3

Come gli utenti cercano (I)

- L'interazione tra gli utenti e i SRI dipende da
 - Il tipo di richiesta
 - L'esperienza e la conoscenza dell'utente
 - La quantità di tempo a disposizione
- Vi sono due tipi principali di ricerche
 - Information lookup
 - Exploratory search

4

Information lookup

- La ricerca di un particolare fatto o risposta
- Soddisfatta da frammenti ben definiti di informazione: numeri, date, nomi, siti web
- Funziona bene con i classici motori di ricerca

5

Exploratory search

- Si divide ulteriormente in
 - Learning search
 - Richiede più di un'interrogazione e di un risultato
 - Richiede tempo
 - Per scorrere e leggere diversi risultati
 - Per trasformare quanto letto in nuova conoscenza
 - Investigating: processo di lungo periodo
 - Richiede più sessioni di ricerca su un lungo periodo di tempo
 - Può richiedere il recupero di una grossa parte dei documenti rilevanti disponibili

6

Come gli utenti cercano (II)

- La ricerca di informazioni può essere vista come parte di un processo più generale di *sensemaking*
 - Processo iterativo che porta a formarsi una rappresentazione concettuale di una grande collezione di informazioni

7

Ricerca classica vs dinamica

- Nella definizione classica di ricerca dell'informazione si ha il seguente processo
 - Identificazione del problema
 - Strutturazione del bisogno informativo
 - Formulazione della query
 - Analisi dei risultati
- Recentemente si è enfatizzata la natura dinamica delle ricerche secondo cui
 - Gli utenti imparano mentre cercano
 - Il bisogno informativo evolve durante la ricerca e l'analisi dei risultati intermedi

8


Orienteering

- L'attuale strategia di ricerca degli utenti web è detta orienteering ed è parte dell'approccio dinamico
 - Eseguire una prima ricerca
 - Osservare i risultati ottenuti
 - Raffinare o riformulare la query sulla base dei risultati precedenti
- Il 52% degli utenti modifica la propria interrogazione

9

Il processo di ricerca (I)

- Numerosi studi sono stati effettuati su come le persone affrontano il problema della ricerca di informazioni
- Risultati comuni in queste ricerche sono
 - Gli utenti spesso riformulano le query apportando piccole modifiche
 - Spesso gli utenti cercano qualcosa che hanno già cercato in passato (il 33% delle query sono ripetute [Yahoo!])
- Per questo diversi SRI includono nell'interfaccia
 - la storia delle ricerche passate (e.g., Bing)
 - la possibilità di riformulare velocemente la query (ricerche



Il processo di ricerca (II)

- Inoltre si è osservato che gli utenti
 - Valutano con difficoltà se un documento è rilevante o no rispetto ad un argomento
 - La difficoltà aumenta con la minore conoscenza dell'argomento
 - Tendono ad osservare solo i primi risultati più rilevanti
 - Tendono a pensare che il primo o i primi due risultati siano migliori di quelli successivi
 - Valutano con difficoltà quanta porzione dei documenti rilevanti essi hanno trovato
 - Usano diverse strategie a seconda dell'esperienza
 - Gli utenti esperti sono più pazienti
 - Questo atteggiamento positivo porta ad ottenere migliori risultati nelle ricerche

11


Interfaccia

- La classica interfaccia di un SRI include un campo testuale
 - La dimensione del campo è correlata alla lunghezza delle query
 - Un campo piccolo scoraggia query lunghe
 - Un campo lungo incoraggia query lunghe

12

Funzionalità

- Il campo di ricerca può includere diverse funzionalità
 - Aggiunta di un ulteriore campo per filtrare subito la ricerca
 - La capacità di interpretare richieste temporali come “domani”, “mercoledì” (zvents)
 - Auto-completamento, suggerimenti
 - Sulla base di quanto scritto finora
 - Sulla base di ricerche precedenti




Visualizzazione dei risultati (I)

- I documenti recuperati possono essere mostrati
 - Completamente
 - Un qualche surrogato
- Il surrogato mostrato all'utente “riassume” il documento
 - È una scelta fondamentale nel successo di un SRI
 - La sua scelta e qualità influenza la rilevanza percepita dall'utente

Visualizzazione dei risultati (II)

- Tipici surrogati sono
 - Il titolo del documento
 - Metadati (data di pubblicazione, autore, URL)
 - Un testo estratto dal documento stesso (snippet)
 - Dove appaiono i termini ricercati (keywords in context)
- Diversi tipi di risultati possono essere mostrati contemporaneamente
 - Documenti testuali
 - Video
 - Immagini



Visualizzazione dei risultati (III)

- Quando il surrogato contiene l'informazione cercata si parla di “answer engine”
- Determinare quale testo mostrare nel sommario di un risultato è un problema centrale
 - Mostrare brevi estratti che contengono i termini cercati
 - Mostrare frasi complete e contigue
 - Aiuta a comprendere il contesto e valutare meglio la rilevanza del risultato
 - Frasi troppo lunghe però sono poco desiderabili
 - Trade-off

Riformulazione delle query (I)

- Come detto, l'interazione con il SRI avviene solitamente tramite una riformulazione della query sulla base dei risultati ottenuti nella query precedente
 - Alcuni SRI forniscono apposite funzionalità a tale fine
 - Correzione degli errori di battitura
 - Suggerimenti
 - Ricerche correlate

17

Riformulazione delle query (II)

- Suggerimenti e ricerche correlate sono ampiamente adottate dai SRI e usate
 - Circa il 6% degli utenti clicca sulle ricerche suggerite
 - Circa l'8% delle query è generata dai suggerimenti
- Suggerimenti e ricerche correlate possono essere basate:
 - Sulle ricerche passate dello stesso utente
 - Sul comportamento di altri utenti
 - Query simili effettuate da altri utenti
 - Usare termini estratti dai documenti cliccati da altri utenti che hanno effettuato la stessa ricerca

18

Riformulazione delle query (III)

- Un'altra tecnica è quella di richiedere all'utente un feedback
 - Permettere all'utente di indicare quali documenti recuperati sono rilevanti
 - Il SRI calcola una nuova query sulla base del feedback
- Poco o per nulla usata
 - Gli utenti non sono bravi nel valutare la rilevanza dei documenti recuperati

19

Organizzare i risultati

- Per gli utenti può essere utile ottenere i risultati organizzati in gruppi
 - Categorie
 - Cluster
- Categorie
 - “etichette” che rappresentano concetti rilevanti
 - Meglio se “complete” (coprono il maggior numero di casi)


20

Categorie (I)

- Vi sono tre tipi di suddivisione in categorie:

1) Flat: semplice lista di argomenti/soggetti

- Possono essere usate sia per raggruppare che per filtrare i risultati



21

Categorie (II)

- Vi sono tre tipi di suddivisione in categorie:
- 2) Gerarchica: risultati suddivisi in categorie e queste in sottocategorie
 - Utilizzata da alcuni dei primi motori di ricerca
 - Non più utilizzata nei motori di ricerca web
 - Utilizzata in alcuni SRI per libri
 - La gerarchia è data dalla suddivisione in capitoli, sezioni, ... dei libri

22

Categorie (III)

- Vi sono tre tipi di suddivisione in categorie:

3) Faceted (dimensionale):

- Al contrario delle categorie flat, le faceted permettono ad uno stesso risultato di appartenere a più categorie
- Ogni categoria corrisponde ad una dimensione/caratteristica dei risultati

Faceted search, esempio



Search for:

in:

Submit

☐ Disable automatic phrases
 ☐ Synthetic query expansion:

Whole phrase

Found 1 matching venue

Found 1474 publication records. Showing 1474 according to the selection in the facets

Hits ☐ ☐ Authors	Title	Venue	Year	Link
7	Rudi Cilibrasi, Paul M. B. Vitányi	The Google Similarity Distance	2007	DBLP DOI BibTeX RDF
3	Gabriele D'Angelo, Fabio Vitali, Stefano Zanchi	Content degrading, preserving privacy, with Google Docs and other web applications	2010	DBLP DOI BibTeX RDF

Publication years (Num. hits)

☐ 0-2002 (31)
 ☐ 2003 (49)
 ☐ 2004 (63)
 ☐ 2005 (87)
 ☐ 2006 (141)
 ☐ 2007 (223)
 ☐ 2008 (232)
 ☐ 2009 (258)
 ☐ 2010 (182)
 ☐ 2011 (93)
 ☐ 2012 (95)

Publication types (Num. hits)

☐ article (351)
 ☐ book (19)
 ☐ in collection (10)
 ☐ inproceedings (1092)
 ☐ proceedings (1)
 ☐ www (1)

Venues (Conferences, Journals, ...)

☐ WWW (4)
 ☐ CoRR (36)
 ☐ JCOLI (23)
 ☐ Web Intelligence (23)
 ☐ Hot Interconnects (22)
 ☐ SIGIR (22)
 ☐ Online Information Review (20)
 ☐ JASIST (19)
 ☐ ACM Multimedia (16)
 ☐ CIKM (16)
 ☐ Commun. ACM (16)
 ☐ HCI (15)
 ☐ Scientometrics (15)
 ☐ SIGMOD Conference (15)
 ☐ First Monday (12)
 ☐ CHI Extended Abstracts (11)
 ☐ More (+10 of total 624)

Authors

☐ Michael L. Nelson (10)
 ☐ Alon Y. Halevy (8)

Searching for [google](#) and [googling](#) (from syntactic query expansion for the whole phrase) in all metadata.

Found 1 matching venue

Found 1474 publication records. Showing 1474 according to the selection in the facets


Hits ☐ ☐ Authors	Title	Venue	Year	Link
7	Rudi Cilibrasi, Paul M. B. Vitányi	The Google Similarity Distance	2007	DBLP DOI BibTeX RDF
3	Gabriele D'Angelo, Fabio Vitali, Stefano Zanchi	Content degrading, preserving privacy, with Google Docs and other web applications	2010	DBLP DOI BibTeX RDF

Clustering

- Raggruppamento dei risultati in gruppi rispetto ad un qualche tipo di “similarità”
 - I gruppi (cluster) sono decisi dinamicamente in base alla ricerca e ai risultati
 - I gruppi sono decisi in modo completamente automatico

25

Clustering, esempio



26

La progettazione

- La progettazione dell'interfaccia utente rientra nel campo dell'Interazione Uomo-Macchina (HCI)
 - Basato sullo studio di cosa le persone pensano della tecnologia, come la utilizzano e come vi rispondono
 - È uno studio incentrato sugli utenti
- È un processo iterativo
 - L'interfaccia è solitamente continuamente modificata per venire in contro a nuove esigenze, capacità, funzionalità

27

Valutazione (I)

- Anche la valutazione di un'interfaccia ruota attorno agli utenti
 - Non esistono misure numeriche precise per valutarla in modo oggettivo
 - La qualità di un'interfaccia dipende da come gli utenti la percepiscono e vi rispondono
- Le ragioni in base alle quali gli utenti valutano un'interfaccia sono varie
 - Velocità, FAMILIARITÀ, estetica, funzionalità preferite, accuratezza percepita dei risultati

28

Valutazione (II)

- La valutazione avviene solitamente tramite esperimenti
 - Studio longitudinale
 - I partecipanti all'esperimento utilizzano una nuova interfaccia per un “lungo” periodo di tempo
 - Il loro comportamento/utilizzo viene monitorato e registrato
 - La nuova interfaccia viene valutata basandosi sui dati registrati, su questionari e interviste agli utenti

29

Valutazione (III)

- A/B testing: utilizzato per sistemi già ampiamente in uso
 - Ad un gruppo di utenti casuali viene fatta utilizzare una nuova interfaccia
 - Il loro comportamento viene monitorato e registrato
 - I dati registrati sulla nuova interfaccia vengono confrontati con dati provenienti ad un altro gruppo di utenti casuali che ha continuato ad usare l'interfaccia vecchia

30