# NOZIONI DI INFORMATION RETRIEVAL

a cura di Riccardo Ridi (Università Ca' Foscari di Venezia)
aggiornato a Ottobre 2016

- **PERTINENZA = attinenza oggettiva/assoluta**

"assonanza concettuale tra argomento del testo reperito e argomento o materia della lista da costruire" Rino Pensato, *Corso di bibliografia*, Bibliografica, 4a ed. 1998, 1a rist. 2000, p. 80.

- **RILEVANZA = attinenza soggettiva/relativa**
  **(effettiva utilità personale)**

"concetto quantitativo e qualitativo insieme, poggia sul grado di innovazione e originalità e sulla quantità di nuove conoscenze, nuovi dati, nuovi modi di approccio forniti da un testo in rapporto all'argomento oggetto di studio o di repertorio" Rino Pensato, *ivi*.

**Ma altri autori (fra cui A. C. Foskett, *Il soggetto*, Bibliografica, 2001, p. 36-38) utilizzano i due termini con significato inverso.**

- **RICHIAMO = recuperare TUTTI i doc. attinenti**
- **PRECISIONE = recuperare SOLO i doc. attinenti**

## RAPPORTO INVERSO FRA RICHIAMO E PRECISIONE

aumentando il richiamo
diminuisce la precisione
(e l'inverso)

$$\text{richiamo} = \frac{\text{documenti attinenti recuperati nella ricerca}}{\text{documenti attinenti esistenti nella banca dati}}$$

$$\text{precisione} = \frac{\text{documenti attinenti recuperati nella ricerca}}{\text{documenti (attinenti o no) recuperati nella ricerca}}$$

o no = rumore

- **RUMORE = doc. recuperati ma non attinenti**
- **SILENZIO = doc. attinenti ma non recuperati**

- **PUNTO DI FUTILITA' ---> ranking**

## "TRASPARENTE":

- **MECCANISMI INVISIBILI**
  **BLACK BOX, AUTOMAGIC,**
  **GUI (graphical user interface)**
- **MECCANISMI VISIBILI**
  **ACQUARIO, COMPRENSIONE & RIPETIBILITA',**
  **CUI (character user interface)**

## RICERCA DI INFORMAZIONI:

- **NEI METADATI**
  **IN CAMPI NORMALIZZATI**
- **NEI DATI PRIMARI**
  - **TESTUALI (RICERCA FULLTEXT)**
  - **NON TESTUALI (MULTIMEDIA INFORM. RETRIEVAL)**
- **ATTRAVERSO I RIFERIMENTI BIBLIOGRAFICI** (vale solo per le informazioni bibliografiche)
  - **VERSO IL PASSATO (bibliografie di libri e articoli)**
  - **VERSO IL FUTURO (citation indexes)**

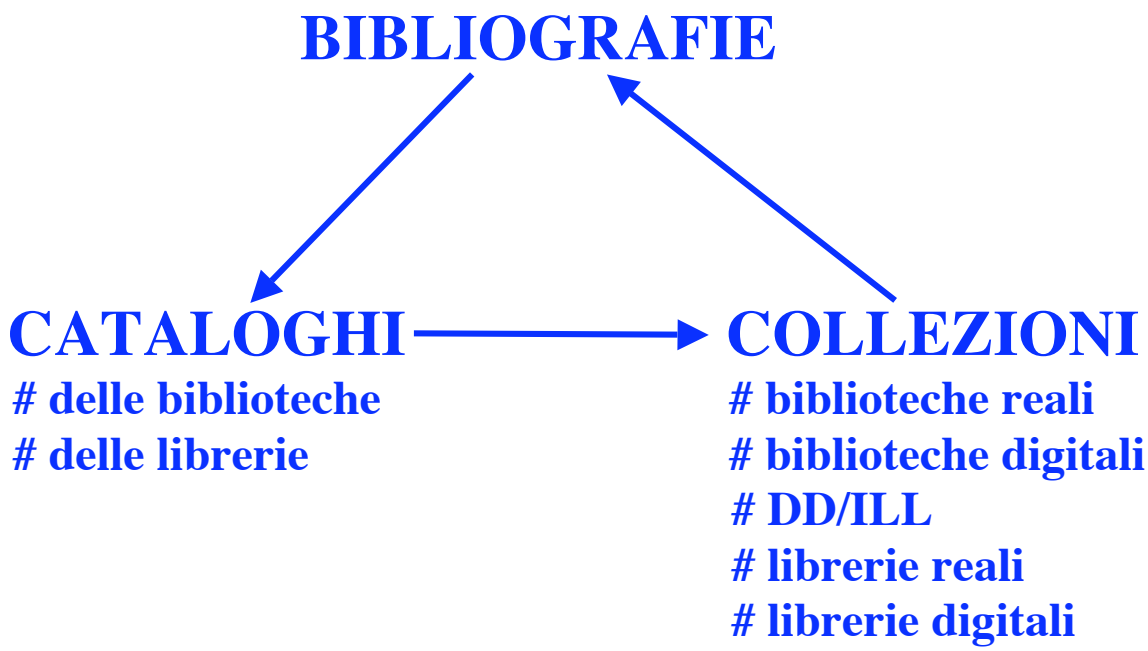

# OPERATORI BOOLEANI

## GEORGE BOOLE (1815-1864)

**AND**

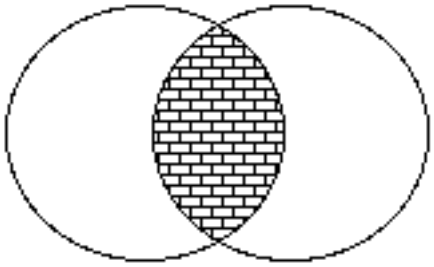

PROMESSI AND SPOSI

**OR**

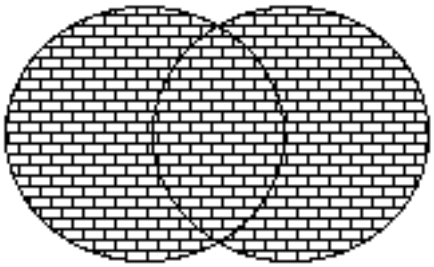

PROMESSI OR SPOSI

**NOT**

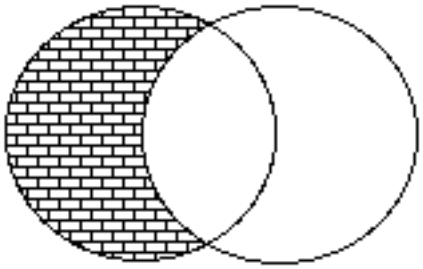

PROMESSI NOT SPOSI

**XOR**

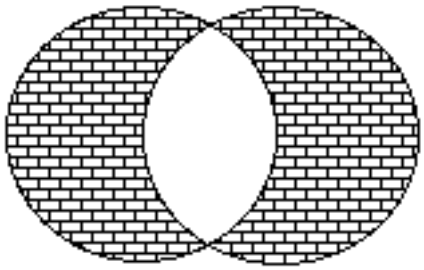

PROMESSI XOR SPOSI

# OPERATORI RELAZIONALI

**>  <  =**

# FILTRI

**(per anno, per lingua,**
**per tipo di documento....)**

# OPERATORI DI PROSSIMITÀ

(AND potenziato)

## SAME
## NEAR
## ADJ /WITH

Gli **operatori di prossimità** costituiscono una sorta di **AND potenziato**, e rintracciano i termini cercati solo se presenti nello stesso campo o sottocampo:

- in qualsiasi ordine e a qualsiasi distanza fra loro (spesso **SAME**);
- solo se posti uno accanto all'altro o a una determinata distanza, specificabile, fra loro, in qualsiasi ordine (spesso **NEAR**);
- solo se posti uno accanto all'altro o a una determinata distanza, specificabile, fra loro, nell'ordine dato (spesso **ADJ** o **WITH**).

# TRONCAMENTI

***biblio?***

***?teca***

# MASCHERAMENTI

***to*o***

***to**o***

# FRASE ESATTA

*"annali della scuola normale superiore"*

# PARENTESI

***promessi* AND *sposi* OR *manzoni***

**(*promessi* AND *sposi*) OR *manzoni***

***promessi* AND (*sposi* OR *manzoni*)**

$$7 \times 2 + 5$$

$$(7 \times 2) + 5 = 19$$

$$7 \times (2 + 5) = 49$$

**— , X & : , + & —**

**NOT, AND, OR, XOR**

# METODI DI RICERCA NEI SISTEMI INFORMATIVI DIGITALI

## 1: SCAN ----------> look simile in **TELNET** e in **WWW**

**= scorrimento di liste (ciascuna relativa ad un solo campo)**
**= ricerca per liste ----> elenchi**

## 2: QUERY --------> look diverso in **TELNET** e in **WWW**

**= estrazione, interrogazione, search, find**
**= ricerca incrociata in più campi ----> testo libero**
**----> mascherine**

**in** TELNET **----> TESTO LIBERO**
**in** WWW **-------> MASCHERINE O TESTO LIBERO**

## 3: BROWSE -----> links ipertestuali da un record verso....

**= navigazione ipertestuale**

..... **SCAN** (meno diffuso)
..... **QUERY** (più diffuso)
..... **BROWSE** (singoli links "creativi" fatti "a mano")

- **RICHIAMO => copertura effettiva**
  - **intranet**
  - **internet invisibile**
  - **web invisibile (database, cms)**
  - **pagine html troppo lunghe**
  - **pagine html troppo recenti**
  - **immagini, filmati, suoni**
  - **teoria del papillon**

BUSINESS WIRE COMMERCIAL PHOTO

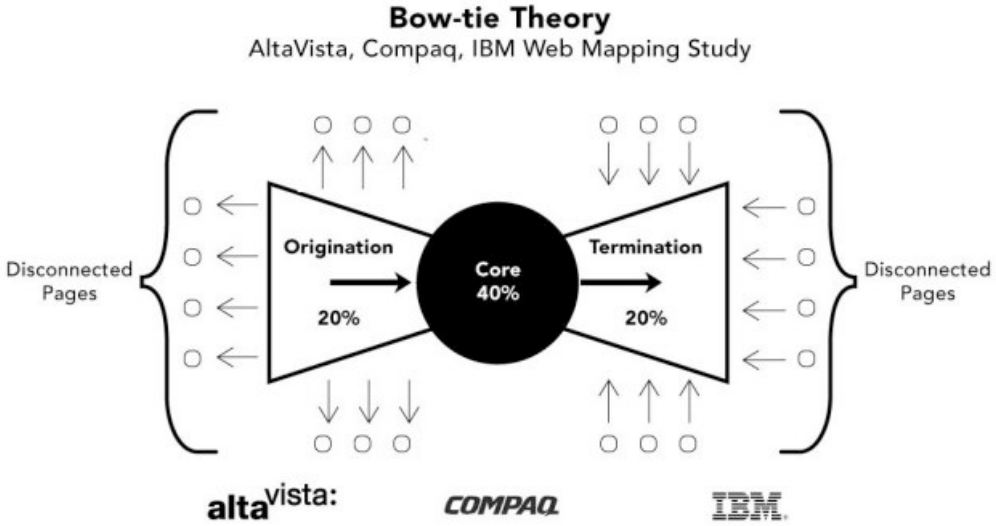


- **PRECISIONE => strumenti di raffinamento**
  - **operatori booleani e virgolette**
  - **ricerca per campi, filtri**

- **PUNTO DI FUTILITA' => relevance ranking**

# NUOVE FRONTIERE DELL'INFORMATION RETRIEVAL

**Multimedia information retrieval** (MMIR), ovvero la ricerca di documenti non testuali con tecniche basate prevalentemente sul loro contenuto multimediale, scavalcando l'intermediazione dei metadati testuali.

**Logica fuzzy** (sfocata), che permette di assegnare sia ai termini usati nella ricerca che agli operatori che li connettono valori percentuali diversi dai due casi estremi (100% e 0%) previsti dalla logica classica, producendo risultati meno netti ma, pare, più vicini alla realtà, che - come si suol dire - non è mai nè completamente bianca nè completamente nera.

**Interfacce tridimensionali**, sia del tipo "realtà artificiale" (non intrusive, sullo schermo del computer) che del tipo "realtà virtuale" (intrusive, con l'ausilio di caschi, occhiali, guanti e tute speciali per raggiungere il massimo del realismo).

**Mappe semantiche**, che visualizzano graficamente la "distanza concettuale" fra i documenti recuperati.

**Natural user interfacce** (NUI), ovvero l'interazione "naturale" col computer, senzà nè linguaggi nè metafore da imparare.

**Riconoscimento vocale** dei comandi (input) e emissione vocale dei risultati (output).

**Agenti intelligenti**, sistemi esperti, collaborative filtering, folksonomies, knowbots (knowledge robots) e altri metodi basati sostanzialmente sulla capacità del sistema di ricerca di imparare dalla ricerca stessa e dagli input più o meno volontari provenienti da fonti diverse per perfezionare progressivamente la propria efficacia. Alcune delle ricerche in questo settore sono collegate a quelle sull'intelligenza artificiale e a sistemi per offrire agli utenti un *reference service* automatizzato.

**Multilinguismo**. Approfondimenti delle tecniche di ricerca in ambienti multilinguistici, collegati anche alle ricerche sulla traduzione automatica. A cavallo fra questo ambito di studi e quelli sull'intelligenza artificiale si collocano le ricerche più spinte sull'uso del linguaggio naturale in ambito di information retrieval.

**Ipertestualità**. Approfondimenti delle tecniche di ricerca ipertestuale, che hanno trovato nel web un fondamentale risultato ma non un punto di arrivo definitivo.

**Open data** (ovvero interoperabilità) e **linked data** (ovvero ipertestualità) come premesse del web **semantico**.

**Integrazione coi motori di ricerca**. Esposizione dei contenuti degli opac e delle biblioteche digitali agli strumenti di ricerca sul web di tipo generale, come *Google*, o specializzati in ambito accademico-scientifico come *Scirus*, sottraendoli ai recessi del web "invisibile". Inversamente, viene approfondita anche l'applicazione dei metodi di ricerca fulltext dei "web search engines" esclusivamente su raccolte di documenti primari omogenei come quelli presenti nelle biblioteche digitali, producendo così risultati più contestualizzati e focalizzati.

**Relevance ranking**. Accanto ai tradizionali metodi di ordinamento utilizzati nei cataloghi e in altre forme di offerta di servizi (bollettini delle nuove acquisizioni, disseminazione selettiva dell'informazione, ecc.), la biblioteca digitale offre la possibilità (che dovrebbe comunque sempre restare solo opzionale) di ordinamenti (ranking) alternativi basati su criteri complessi, mutuati anch'essi dai "web search engines", che cercano di produrre risultati più vicini possibile all'ipotizzata massima rilevanza per l'utente.

**Multiricerca**. La possibilità, offerta dai siti di molte biblioteche universitarie e di ricerca ai propri utenti registrati, di interrogare contemporaneamente sia l'opac locale che tutte le altre fonti informative digitali ivi disponibili, indipendentemente dalla rispettiva tipologia, attraverso strumenti dalle denominazioni varie e mutevoli (opac allargati, portali bibliotecari, **discovery tool***, metaricerche, ricerche federate, ecc.) che consentono talvolta anche varie forme di personalizzazione e di memorizzazione delle ricerche, come ad esempio la possibilità di ripetere automaticamente una certa interrogazione a cadenza regolare, ricevendone i risultati nella propria casella di posta elettronica.

**Reference linking**. L'adozione sempre più diffusa, da parte delle stesse biblioteche, di software per il "reference linking" (detti anche "link resolver") che collegano automaticamente fra loro i documenti digitali e le relative descrizioni bibliografiche e catalografiche, facilitando gli utenti registrati nel passaggio da queste ultime ai relativi testi integrali (se disponibili) fino al punto di rischiare che essi non si rendano nemmeno più conto della distinzione - nonostante tutto ancora significativa - fra bibliografie, cataloghi e collezioni.

**Filtraggi automatici**, applicati ai documenti recuperati in base alle loro caratteristiche, ricavandone sottoinsiemi (**clusters, faccette**) più omogenei.

**Suggerimenti** (sia in fase di immissione della query che in fase di valutazione dei risultati) forniti dal sistema informativo, basandosi sulle precedenti scelte degli utenti.

**Metadati** aggiunti dagli utenti stessi (**social tagging**, **folksonomie**).

**Apps** per smartphones e tablets.

*Il termine "discovery tool" (strumento per la scoperta) andrebbe più appropriatamente utilizzato per indicare solo quei software che, anzichè effettuare una ricerca bibliografica su una pluralità di fonti informative separate e indipendenti, interrogano una sola "base di conoscenza", precedentemente predisposta cumulando i contenuti delle varie fonti disponibili