



Web Crawling & Information Extraction

Gianni Pantaleo

Dipartimento di Ingegneria dell'Informazione, DINFO

Università degli Studi di Firenze
Via S. Marta 3, 50139, Firenze, Italy
Tel: +39-055-2758517

DISIT Lab
<http://www.disit.org>
gianni.pantaleo@unifi.it

MASTER: Big Data Analytics And Technologies For Management – MABIDA
Sabato 18 Novembre 2017



Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni





Outline

- **1. Sistemi di Web Crawling**

- 1.1 Introduzione
- 1.2 Strategie di Crawling
- 1.3 Robot Exclusion Protocol
- 1.4 Concorrenza



- **2. Tecniche di Parsing ed Estrazione di Informazioni**

- 2.1 Introduzione
- 2.2 NLP: Cenni Storici
- 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
- 2.4 NLP Tools

- **3. Applicazioni**

1.1 - Introduzione: Dati e Informazione sul Web

- **The Zettabyte Era ($1 \text{ ZB} = 10^{12} \text{ GB}$)**: Secondo studi e stime di **CISCO**, la quantità di dati prodotti ed archiviati nel cloud data center globale sarà pari nel **2020**, a **1.8 Zettabytes** (1.8 mila miliardi di Gigabytes), equivalente alla quantità di spazio archiviable in circa **45 millioni di DVD all'ora**, con una crescita di 5 volte rispetto al 2015 (*).



- La quantità di traffico dati nel web globale (*global data center traffic*), arriverà a **15.3 Zettabyte nel 2020** (**).

* [Cisco Global Cloud Index: Forecast and Methodology, 2015–2020 White Paper](#) (Cisco Public Knowledge)

** <http://www.cisco.com/c/en/us/solutions/service-provider/visual-networking-index-vni/index.html>
(Source: Global Cloud Index Infographic [GCI 2016](#))

1.1 - Introduzione: Generalità di un Web Crawler

Definizione di **Web Crawler**

- Un **Crawler Web** è un software usato per collezionare ed archiviare il contenuto di pagine web, documenti presenti in una rete o in un database
- Definito anche **Web Spider**, **Web Robot**, o semplicemente **Bot**



1.1 - Introduzione: Aree Applicative

Un **Web Crawler** può essere usato per:

- Creare un indice generale (**general Web search**)
- Creare indici di topics o argomenti specifici (**vertical Web search**)
- Archiviare il contenuto di pagine web e documenti (**Web archival**)
- Analizzare il contenuto di pagine e siti web per produrre statistiche e analisi aggregate (**Web characterization**)
- Tenere copie o repliche di siti web (**Web mirroring**)
- Analisi di siti web (**Web site analysis**)



1.1 - Introduzione: Processo di Crawling



1.1 - Introduzione: Principali *Search Bot*

Bot Name	% of Sites Crawled	Bot Type
Googlebot	96%	Search Bot
Baidu Spider	89%	Search Bot
MSN Bot/BingBot	82%	Search Bot
Yandex Bot	73%	Search Bot
Soso Spider	61%	Search Bot
ExaBot	35%	Search Bot
Sogou Spider	31%	Search Bot
Google Plus Share	24%	Crawler
Facebook External Hit	24%	Crawler
Google Feedfetcher	22%	Feed Fetcher

Fonte: <https://www.incapsula.com/blog/know-your-top-10-bots.html>

1.1 - Introduzione: Principali Crawler Open Source



<https://webarchive.jira.com/wiki/display/Heritrix>



<http://nutch.apache.org/>



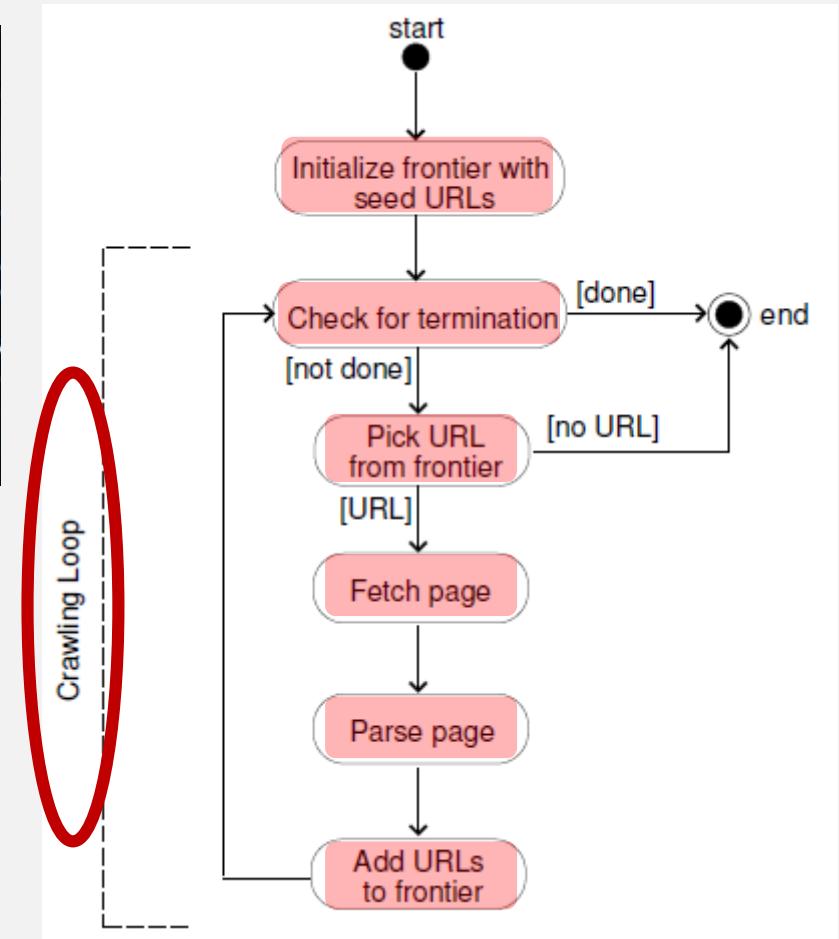
<https://www.cs.cmu.edu/~rcm/websphinx/>

1.1 - Introduzione: Principi di Funzionamento

- Il web è visto come un grafo: i nodi sono le pagine web e gli archi sono i link (**hyperlinks**)



- E' utilizzato per archiviare le pagine web visitate per una loro successiva elaborazione (estrazione di informazioni, indicizzazione, ecc..)
- Analizza le pagine partendo da una lista di indirizzi web (**URL**) iniziali. Gli URL sono contenuti in una struttura dati che si chiama **frontiera**



1.1 - Introduzione: La Frontiera di un Crawler

- E' una struttura dati dinamica che contiene URL non ancora visitati
- Può riempirsi molto velocemente rispetto alle pagine web via via crawlate
- Con una media (stimata) di n links per pagina, la velocità di popolazione della frontiera è lineare, ma cresce di circa n volte rispetto al numero delle pagine già crawlate
- Occorre limitare la sua dimensione con un valore massimo



Occorre stabilire un meccanismo per decidere quale URL ignorare in caso di limite raggiunto



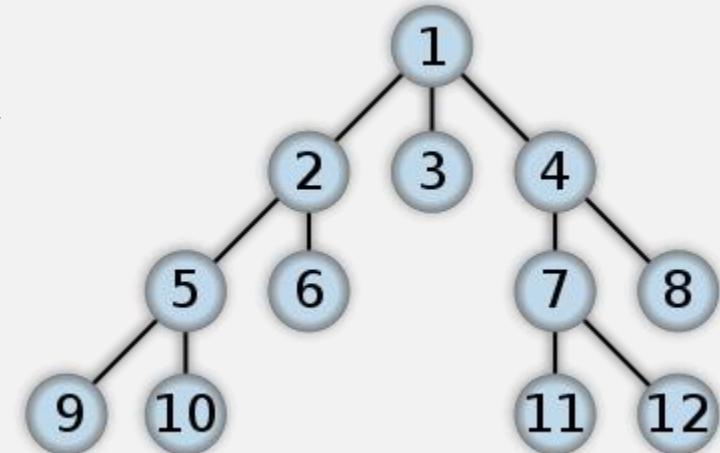
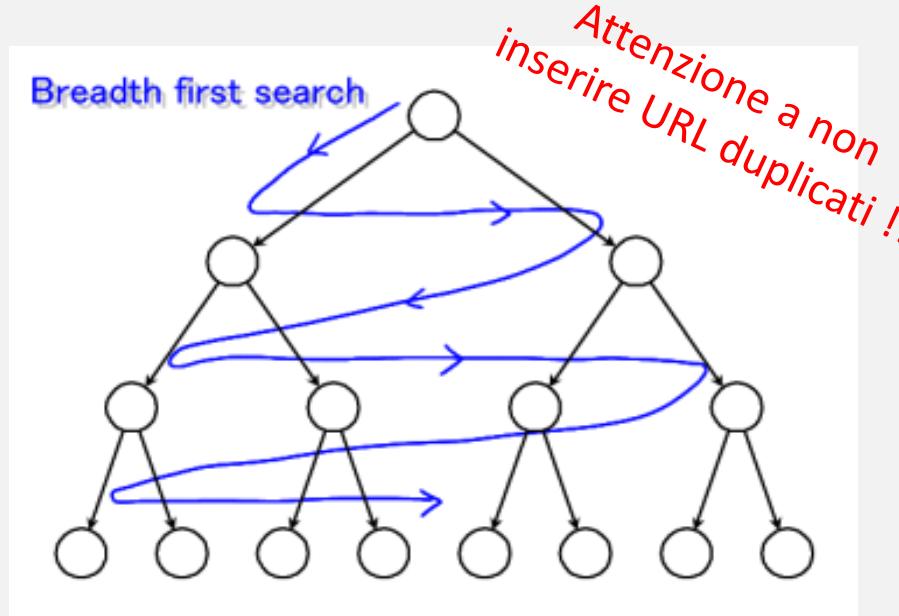
Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling 
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni

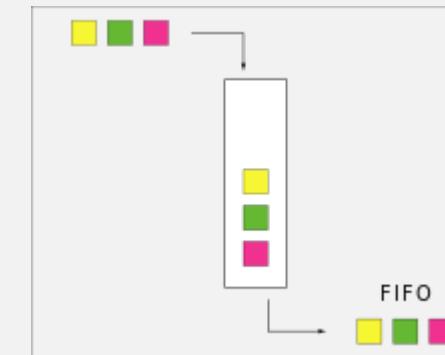


1.2 - Strategie di Crawling: Breadth First Search

➤ Breadth First Search

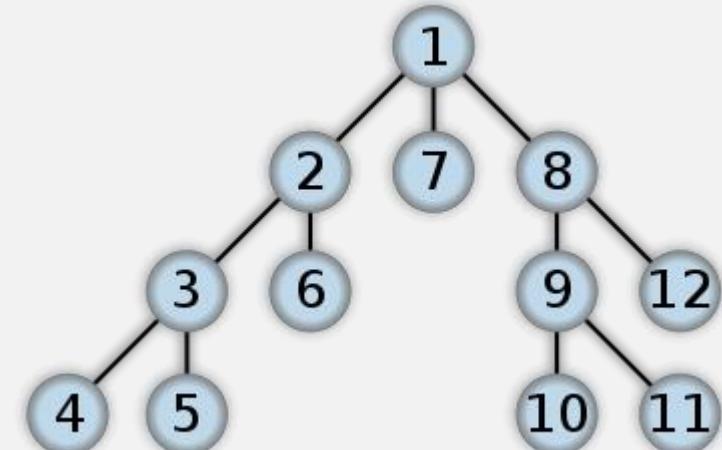
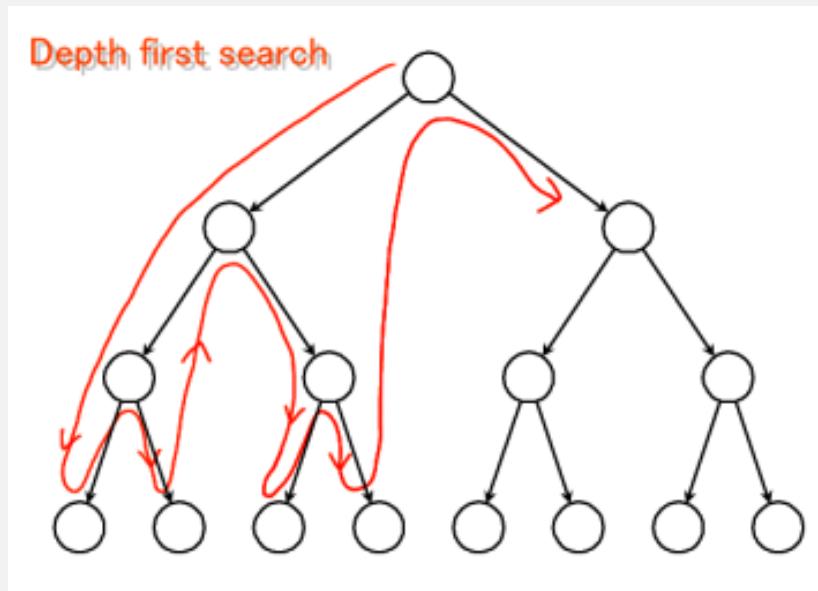


- Struttura dati lineare con politica
FIFO : First In First Out (CODA)

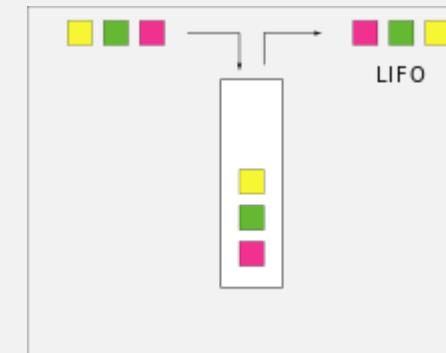


1.2 - Strategie di Crawling: Depth First Search

➤ Depth First Search



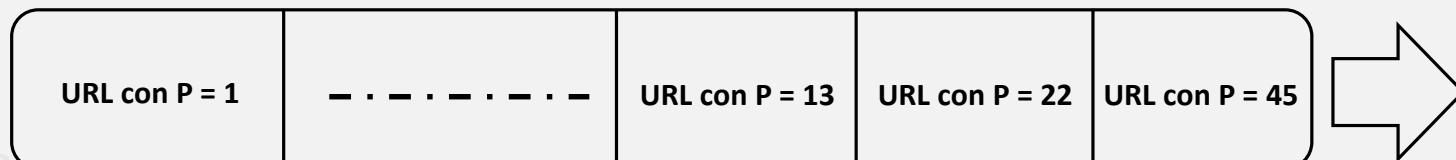
- Struttura dati lineare
con politica
LIFO: Last In First Out (PILA o STACK)



1.2 - Strategie di Crawling

➤ Priority Search

- Struttura dati lineare: l'URL con maggiore priorità viene scelto
- Array dinamico ordinato in base allo score attribuito ad ogni URL
- Gli url sono aggiunti nella frontiera in maniera tale da preservarne l'ordine in base allo score





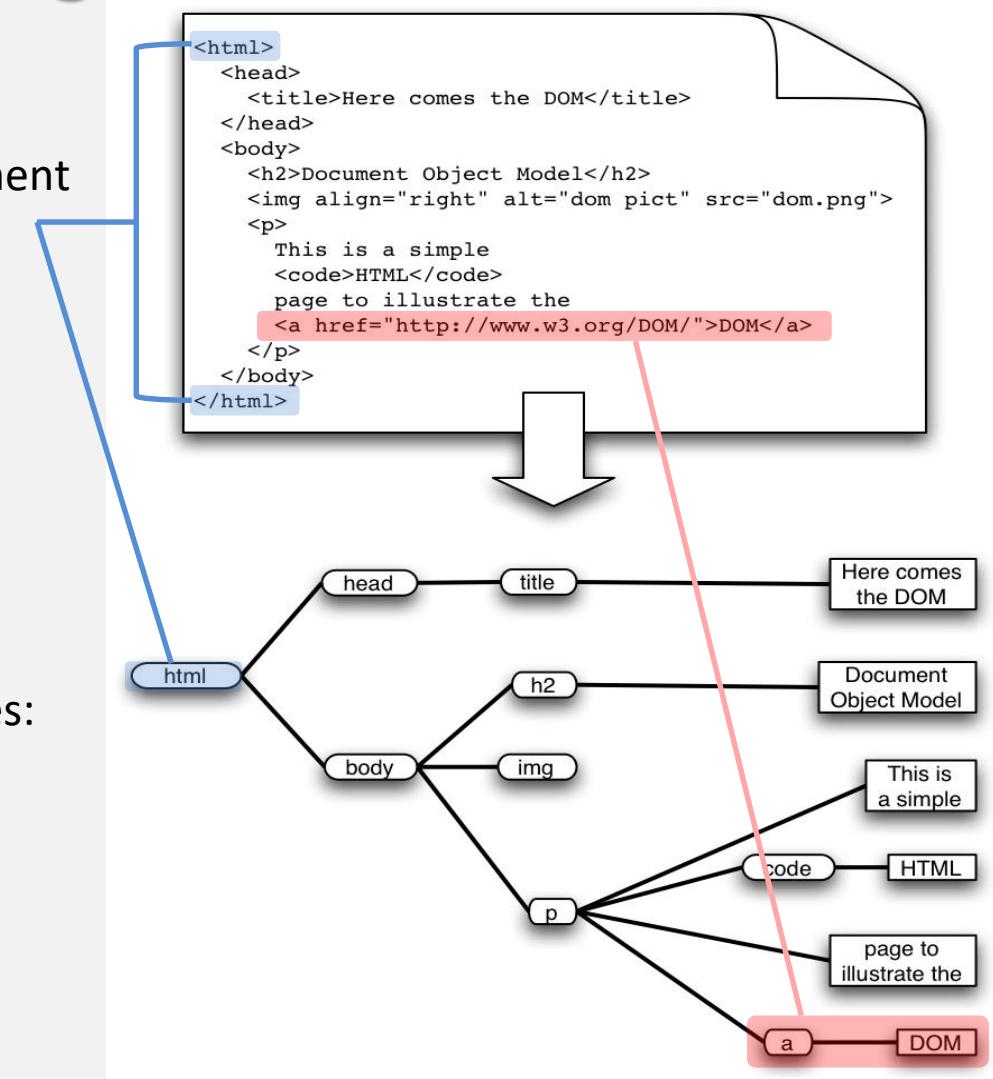
1.2 - Strategie di Crawling

- Evitare il fetch della stessa pagina:
 - Tenere in memoria una lista delle pagine visitate
- La dimensione della frontiera cresce velocemente
 - Può essere necessaria una politica di priorità sugli URLs
- Fetcher deve essere robusto
 - Evitare crash in caso di fallimenti nei downloads
 - Prevedere meccanismi di timeout
- Determinazione dei file non desiderati
 - Esaminare estensioni dei file (filtrando formati come multimedia, immagini, video ecc.)
 - Content-Type (MIME) headers



1.2 - Strategie di Crawling

- I documenti HTML hanno una struttura ad albero - DOM (Document Object Model) definite da
- Spesso i documenti HTML non rispettano gli standard di sintassi
- Occorre trattare le entità e i tag HTML
- Vi sono molti formati diversi di files:
 - ❖ Flash, SVG, RSS, AJAX...





Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol 
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni



1.3 Robot Exclusion Protocol

- Un server può specificare a quale parte dell'albero dei propri documenti può essere accessibile a un crawler (robot) esterno
- Questa informazione è nel file 'robots.txt' posto nell' HTTP root directory
- Un crawler dovrebbe sempre verificare la presenza di questo file prima di inviare richieste al server



1.3 Robot Exclusion Protocol

www.apple.com/robots.txt

```
# robots.txt for http://www.apple.com/
```

User-agent: *

Disallow:

Tutti i crawlers ...

...possono analizzare qualsiasi
pagina!

1.3 Robot Exclusion Protocol

www.microsoft.com/robots.txt

Robots.txt file for <http://www.microsoft.com>

User-agent: *

Disallow: /canada/Library/mnp/2/aspx/
Disallow: /communities/bin.aspx
Disallow: /communities/eventdetails.mspx
Disallow: /communities/blogs/PortalResults.mspx
Disallow: /communities/rss.aspx
Disallow: /downloads/Browse.aspx
Disallow: /downloads/info.aspx
Disallow: /france/formation/centres/planning.asp
Disallow: /france/mnp_utility.mspx
Disallow: /germany/library/images/mnp/
Disallow: /germany/mnp_utility.mspx
Disallow: /info/customerror.htm
#etc...

Tutti i crawlers ...

... non hanno accesso a
questi percorsi del
grafo del sito web



1.3 Robot Exclusion Protocol

www.springer.com/robots.txt

Robots.txt for <http://www.springer.com> (fragment)

User-agent: Googlebot

Disallow: /chl/*

Disallow: /uk/*

Disallow: /italy/*

Disallow: /france/*

User-agent: slurp

Disallow:

Crawl-delay: 2

User-agent: MSNBot

Disallow:

Crawl-delay: 2

User-agent: scooter

Disallow:

all others

User-agent: *

Disallow: /

Google crawler può analizzare tutte le pagine eccetto queste

Yahoo e MSN/Windows Live possono analizzare tutte le pagine ma il processo deve essere "lento" (2 secondi)

AltaVista non ha limiti

A tutti gli altri crawlers non è permesso niente



Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza 
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni



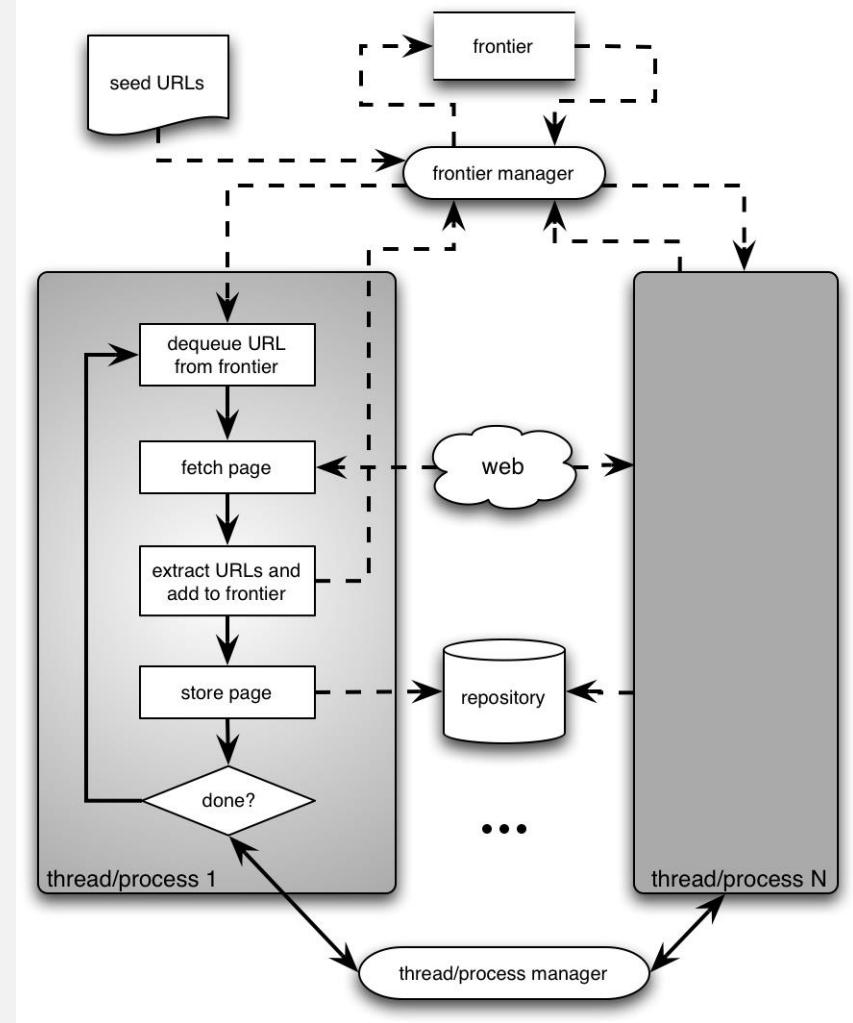
1.4 - Concorrenza

- Le operazioni effettuate dal crawler possono richiedere diverso tempo:
 - Risoluzione indirizzi IP
 - Connessioni al server e invio risposte
 - Ricezione pagina di risposta
- Soluzione: Ridurre i suddetti tempi eseguendo la scansione di più pagine in maniera concorrente



1.4 - Concorrenza

- Ogni thread lavora come un crawler sequenziale e condivide le strutture dati: frontiera e repository (concorrenza in lettura)
- Le strutture dati condivise devono essere sincronizzate (concorrenza in scrittura)





Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni



2.1 - Tecniche di Parsing: Introduzione

- Natural Language Processing
- Scenario / Requisiti
 - ❖ Dotare l'IA delle abilità linguistiche proprie dell'essere umano
 - ❖ Comprensione e generazione di testo non strutturato (**linguaggio naturale**)
 - ❖ Contesto multi-language: differenti regole e strutture a seconda della lingua
- Applicazioni
 - ❖ Generalizzazione delle query nei motori di ricerca
 - *"Chi si occupa di sistemi distribuiti nell'Università di Firenze ?"*
 - ❖ Supporto automatizzato per Help-Desk
 - ❖ Tutoring assistito (e-tutoring, e-teaching...)
 - ❖ Summarization: creare compendi da una collezione
 - ❖ eterogenea di documenti
 - ❖ Machine translation: tradurre testi in lingue diverse



2.1 - Tecniche di Parsing: Introduzione

➤ Scenario / Requisiti

- ❖ I linguaggi sono purtroppo ambigui.
- ❖ Le ambiguità si possono avere a 4 livelli:
 - ✓ Ambiguità lessicale: «attacco» (verbo, sostantivo)
 - ✓ Ambiguità strutturale: «Ieri ho visto l'uomo col telescopio»
«Una vecchia legge la regola»
 - ✓ Ambiguità semantica: «acuto» (persona intelligente, tipo di suono)
 - ✓ Ambiguità pragmatica: «se Buffon non gioca contro la Spagna, l'Italia perderà»

L'intensione comunicativa viene recepita diversamente dagli interlocutori:

- interpretazione emotiva: l'assenza di Buffon è psicologicamente fondamentale per i tifosi
- Interpretazione referenziale: l'Italia senza Buffon è più debole

Ciò rende il processo di elaborazione automatica del linguaggio naturale un task molto complesso !





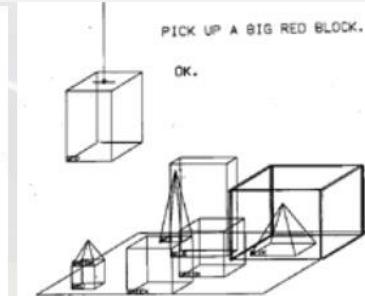
Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici 
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni

2.2 - Tecniche di Parsing – NLP: Cenni Storici

- **SHRDLU** [Winograd - 1971]
 - ❖ Interfaccia per automa preposto al semplice movimento di blocchi 3D
 - ❖ Dominio limitato, query semplici

```
Person: PICK UP A BIG RED BLOCK.  
Computer: OK. (does it)  
Person: GRASP THE PYRAMID.  
Computer: I DON'T UNDERSTAND WHICH PYRAMID YOU MEAN.  
Person: FIND A BLOCK WHICH IS TALLER THAN THE ONE YOU ARE HOLDING AND PUT IT INTO THE BOX.  
Computer: BY "IT", I ASSUME YOU MEAN THE BLOCK WHICH IS TALLER THAN THE ONE I AM HOLDING.  
Computer: OK. (does it)  
Person: WHAT DOES THE BOX CONTAIN?  
Computer: THE BLUE PYRAMID AND THE BLUE BLOCK.
```



- **Apple Siri** [iOS Siri - 2010]
 - ❖ Virtual personal assistant
 - ❖ Knowledge navigator
 - ❖ User recommendation system.



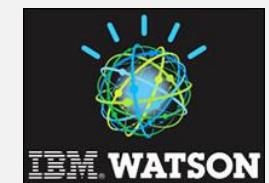
- **Google Assistant**



- **Microsoft Cortana**



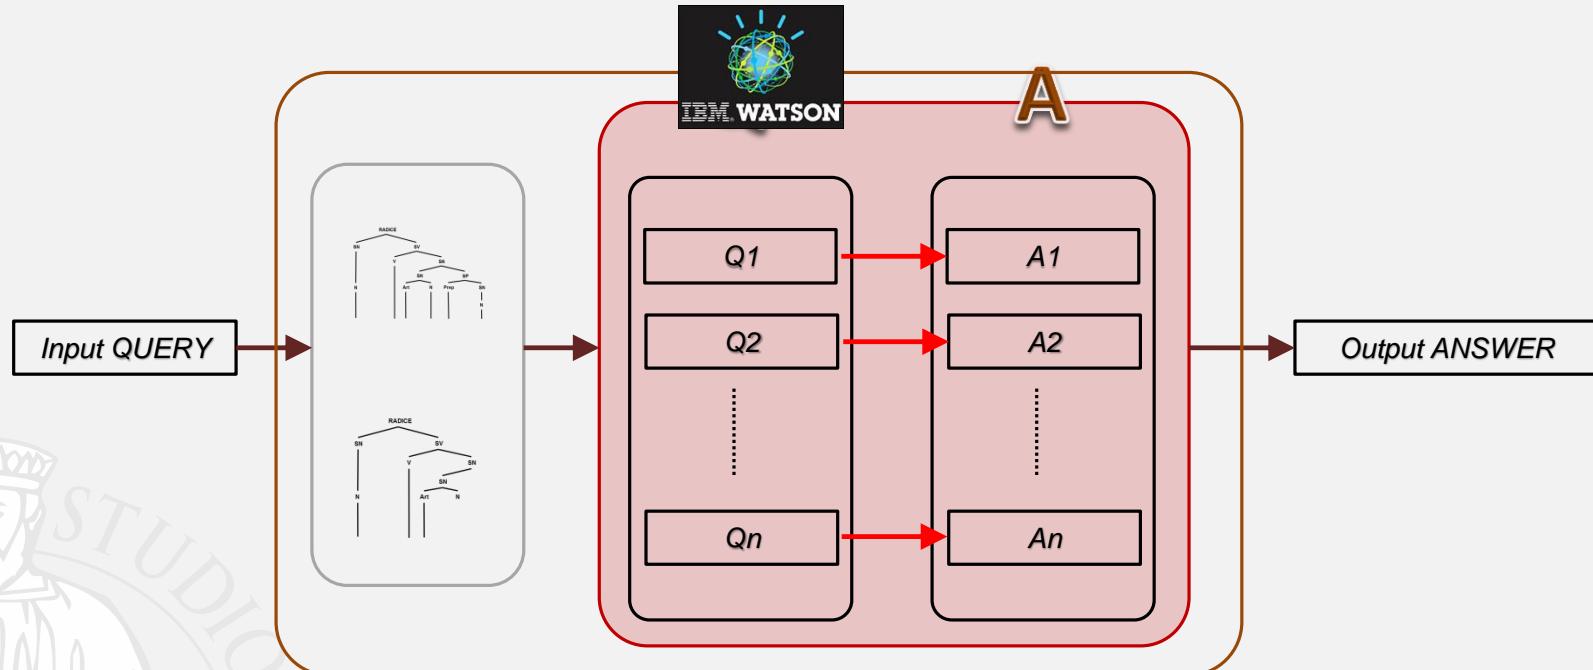
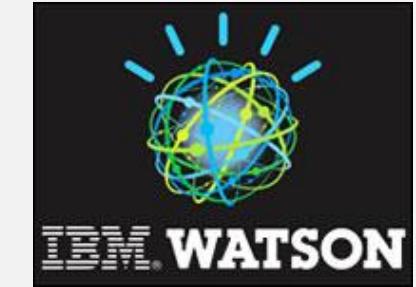
- **IBM Watson** [IBM Watson - 2012]
 - ❖ Nato come sistema Question & Answer per il quiz televisivo americano *Jeopardy!*, successivamente è stato sviluppato come *cognitive system* completo con meccanismi di auto-apprendimento.



2.2 - Tecniche di Parsing – NLP: Cenni Storici

➤ IBM Watson

- ❖ Database built-in in cui sono già presenti le domande relazionate con le rispettive risposte corrette.
- ❖ Il sistema si limita ad analizzare la query in input, attraverso l'elaborazione del grafo sintattico, cercando un match con una delle domande presenti nel set.





Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale 
 - 2.4 NLP Tools

3. Applicazioni

2.3 – Fasi di Elaborazione in Linguaggio Naturale



Morphological Analysis: le parole vengono analizzate (disintegrazione dei morfemi che le compongono) ed i simboli (punteggiature) vengono separati dalle parole .

Syntactic Analysis: Le sequenze di parole sono trasformate in strutture che mostrano come le parole sono in relazione l'una con l'altra.

Semantic Analysis: Viene assegnato un significato alle strutture sintattiche trovate.

Discourse integration: il significato di una frase spesso dipende dalla frase che la precede e può influenzare quello della frase che la segue.

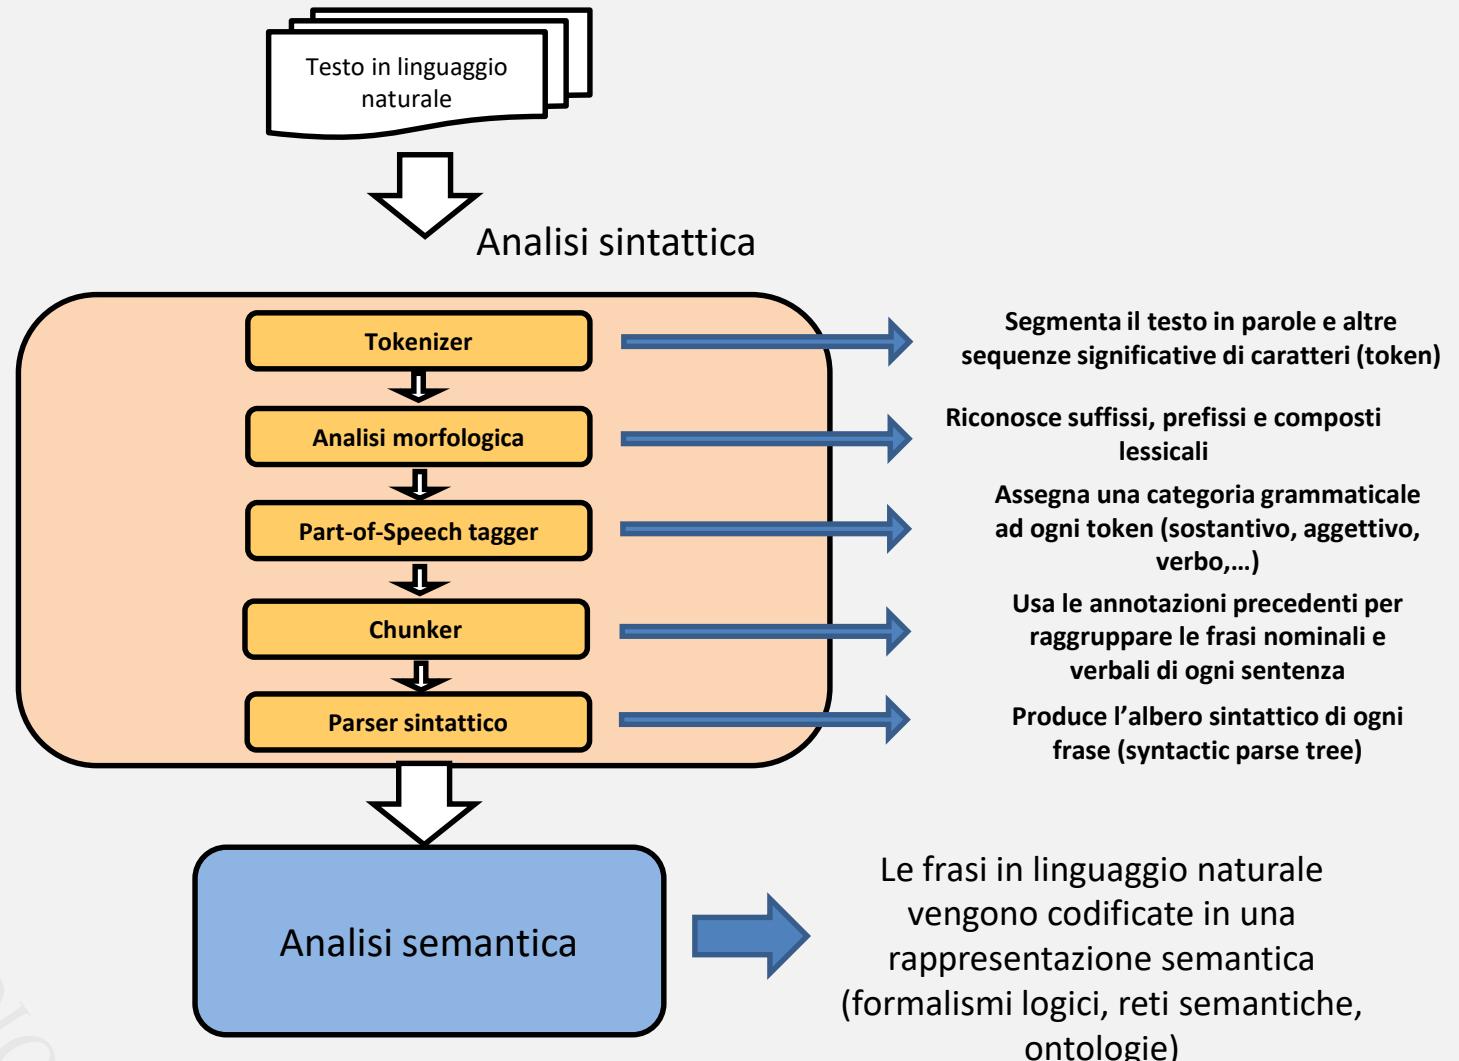
Pragmatic Analysis: la frase è reinterpretata per determinare il significato specifico della frase stessa.

“la porta è aperta” necessita di conoscere quale è stata l'intenzione dell'interlocutore:

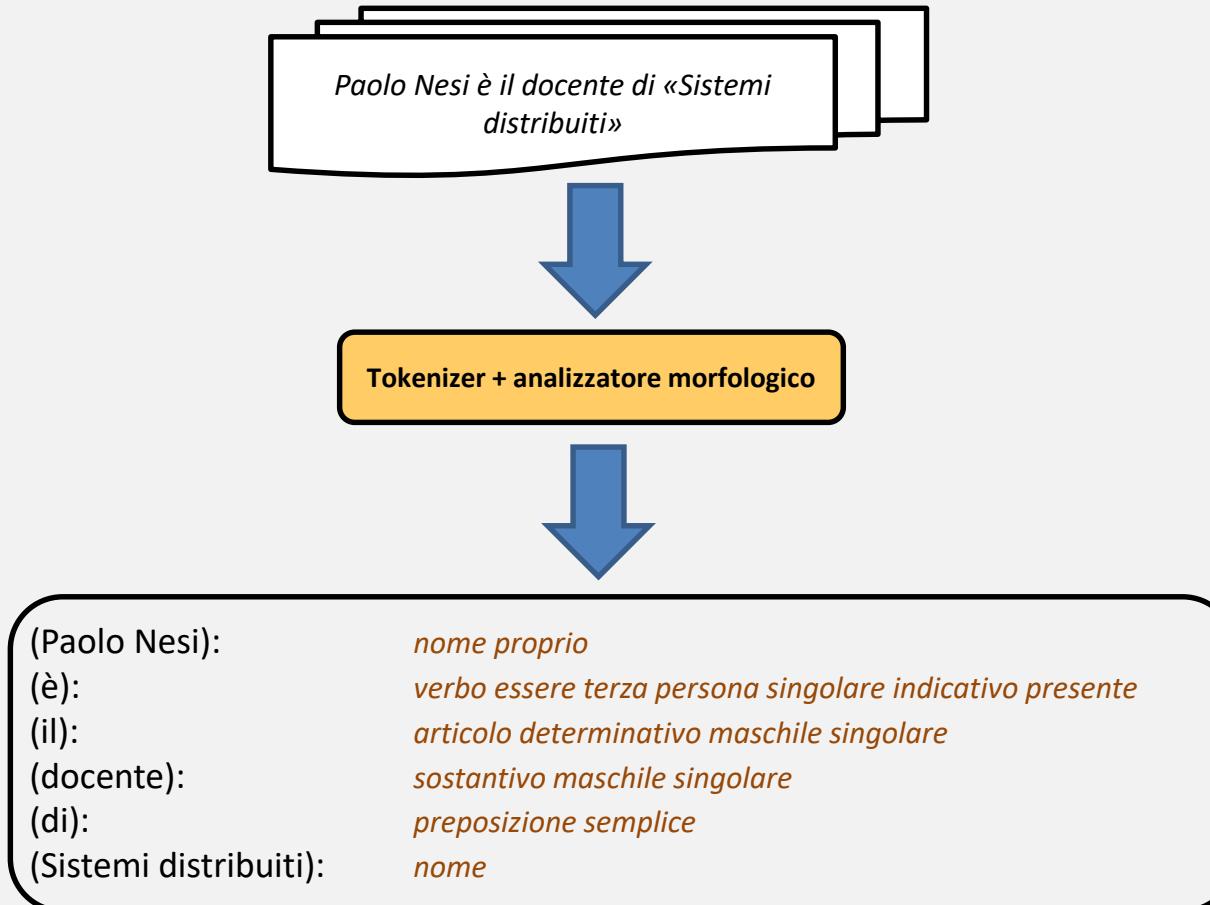
- Si è creata una corrente d'aria...
- Invito ad entrare liberamente...
- Richiesta affinché qualcuno chiuda la porta...



2.3 – Fasi di Elaborazione in Linguaggio Naturale



2.3 – Fasi di Elaborazione in Linguaggio Naturale



(Paolo Nesi):
(è):
(il):
(docente):
(di):
(Sistemi distribuiti):

nome proprio
verbo essere terza persona singolare indicativo presente
articolo determinativo maschile singolare
sostantivo maschile singolare
preposizione semplice
nome

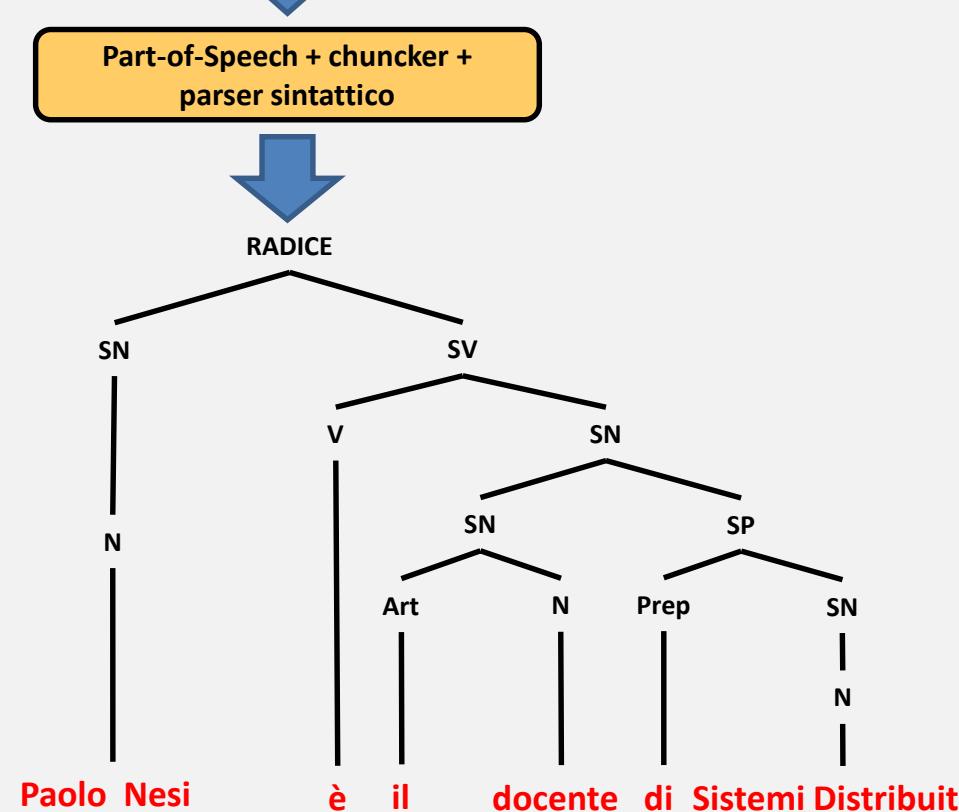


Part-of-Speech + chuncker +
parser sintattico



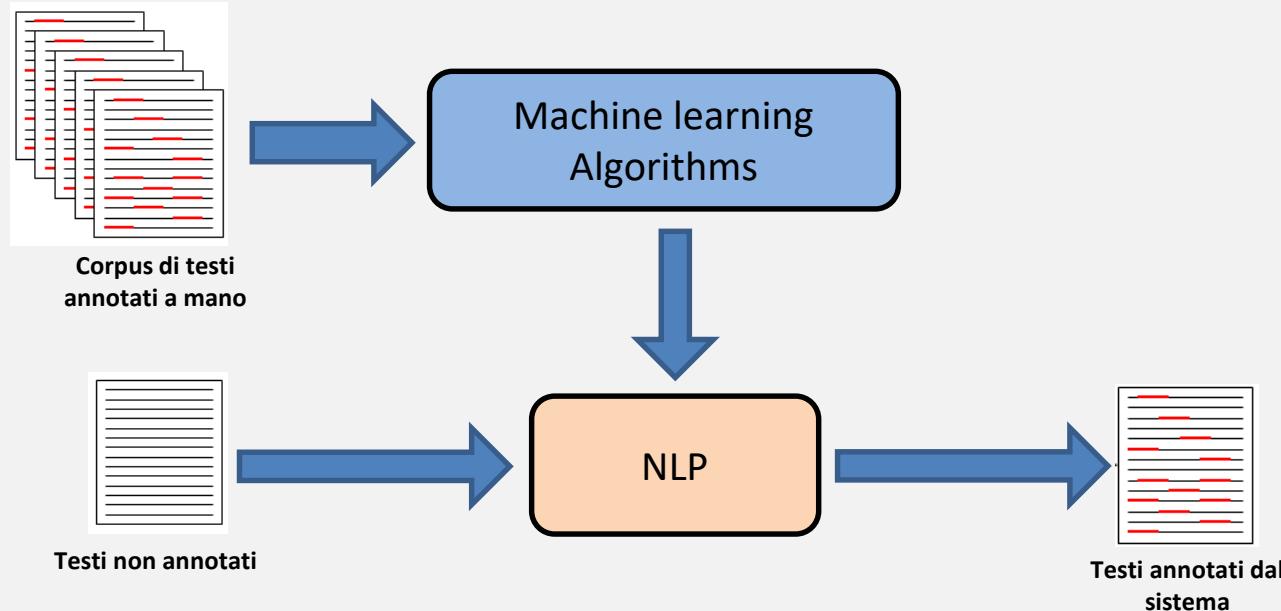
RADICE

SN: sentenza nominale
SV: sentenze verbale
SP: sentenza preposizionale
N: nome
V: verbo
Art: articolo
Prep: preposizione



2.3 – Fasi di Elaborazione in Linguaggio Naturale

I sistemi di NLP usano principalmente algoritmi di machine learning addestrati su grandi corpus di testi annotati a mano





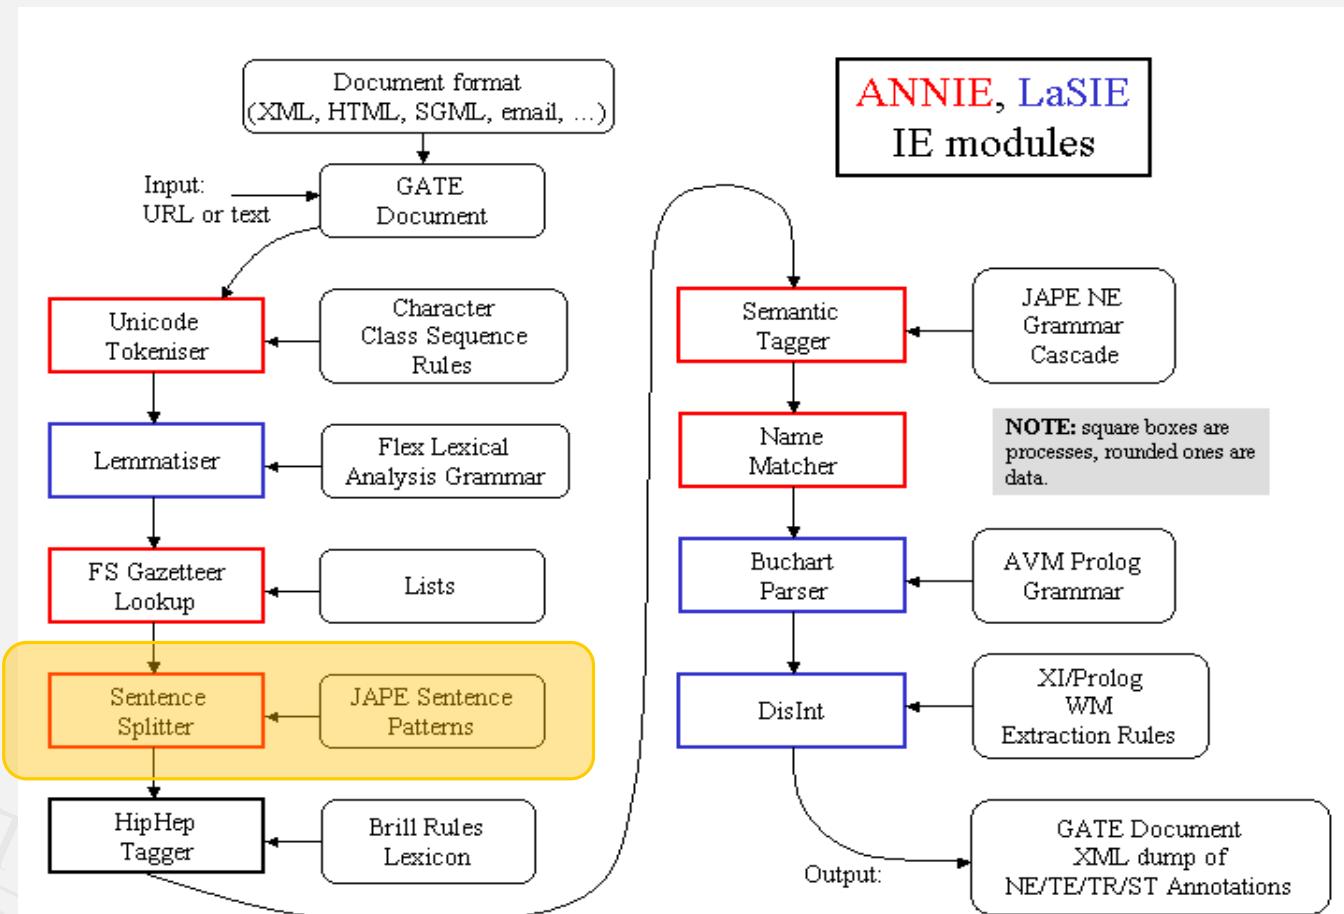
Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni



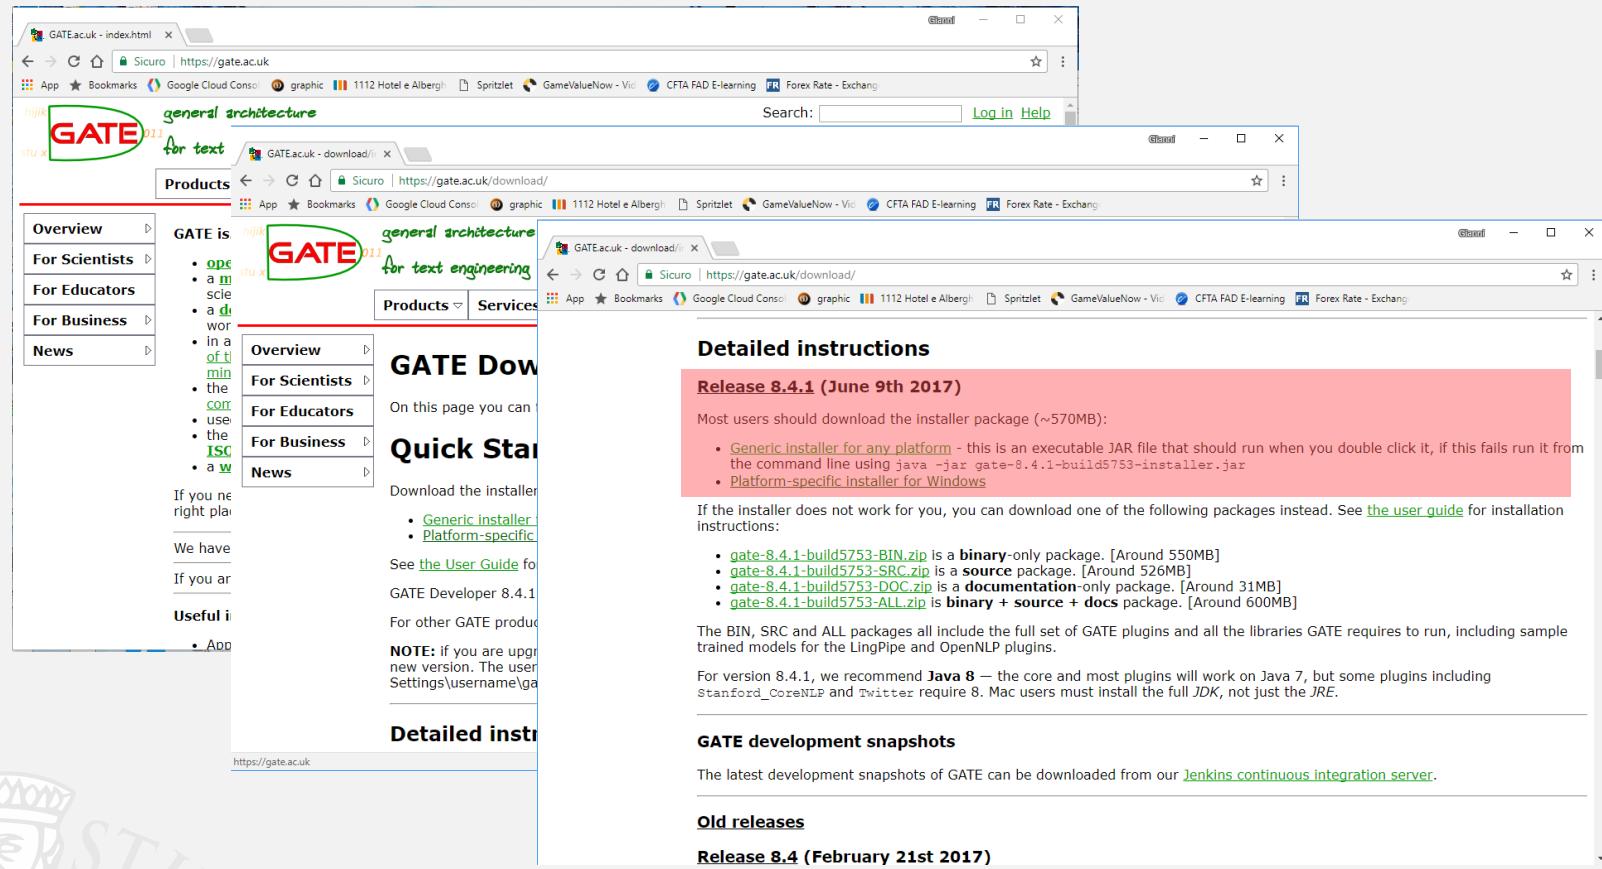
2.4 - NLP Tools: GATE

- **GATE – General Architecture for Text Engineering (<https://gate.ac.uk/>)**
 - ❖ Supporta documenti plain text, HTML, XML ...



2.4 - NLP Tools: GATE

- **GATE – General Architecture for Text Engineering (<https://gate.ac.uk/>)**



The screenshot shows three browser windows and one search result page for the GATE website.

- Top Left Window:** Displays the GATE homepage (<https://gate.ac.uk/>). The main content area features the GATE logo and the text "general architecture for text engineering". A sidebar on the left contains links for "Overview", "For Scientists", "For Educators", "For Business", and "News".
- Top Middle Window:** Displays the "Products" page (<https://gate.ac.uk/download/>). It includes a "Products" dropdown menu and a "Services" link. The main content area is titled "GATE Down" and provides instructions for downloading the software.
- Bottom Right Window:** Displays the "Detailed instructions" page for "Release 8.4.1 (June 9th 2017)". It lists download options:
 - Generic installer for any platform (JAR file, ~570MB)
 - Platform-specific installer for Windows
- Search Result Window:** Shows a search result for "gate ac uk download" from Google Cloud Console. The result points to the "Products" page on the GATE website.

2.4 - NLP Tools: GATE

➤ ANNIE (A Nearly New IE System)

- ❖ Utilizza regole per il **Part of Speech (POS) Tagging**. Tali regole sono predefinite (tag hmtl) o customizzate dall'utente
- ❖ Una regola ha un left hand side (LHS) e un right hand side (RHS)
 - **LHS**: espressione regolare da riscontrare nel testo in input
 - **RHS**: descrive le annotazioni che devono essere aggiunte all'*AnnotationSet*
 - Utilizzano regole predefinite (tag hmtl) o customizzate dall'utente
- ❖ Sintassi:
 - ❖ {LHS} > {Annotation type}; {attribute1}={value1}; ...; {attribute n}={value n}
- ❖ Es.:
 - ❖ "UPPERCASE _ LETTER" "LOWERCASE _ LETTER" * > Token; orth=upperInitial; kind=word.
- ❖ Tipi di Token previsti: Word, Number, Symbol, Punctuation, Space Token



2.4 - NLP Tools: GATE

➤ JAPE (Java Annotations Pattern Engine)

- ❖ Permette di ricercare espressioni regolari nel testo in input
- ❖ Regole composte da **LHS** e **RHS**
- ❖ Es. di sintassi di una regola JAPE:

```

Phase: Address_Retrieval
Input: Token Lookup
Options: control = appelt

Rule: FindStreetAddress
Priority: 20

(
    ({Token.string == "Via"} | Token.string == "Piazza" | {Token.string == "Largo"})
    ( (Lookup.majorType == NomeProprio) | (Lookup.majorType == Cognome) |
        (Lookup.majorType == Cognome) )
)
:address
-->
: address.indirizzo = {rule = "FindStreetAddress"}

```

Headers della regola: Phase, Input, Options

Nome della regola e priorità: Rule, Priority

Label: :address

RHS: : address.indirizzo = {rule = "FindStreetAddress"}

LHS: The pattern part of the rule, enclosed in parentheses.

2.4 - NLP Tools: GATE

www.unifi.it/index.php?module=oform&mode=2&cmd=1&AA=2012&fac=200006&ord=N&doc=3f2a3d2e36302b

Università degli Studi di Firenze

Università degli Studi di Firenze

home | Conosce | Conoscere l'università | home | home studenti | ateneo | relazioni internazionali | ricerca | biblioteche | servizi informatici

Pubblicazioni

Didattica, Insegnamenti, Corsi

FACOLTÀ DI INGEGNERIA

PERSONALE DOCENTE DELLA FACOLTÀ

NESI PAOLO

Legenda

- Contributo su rivista
- Articolo su libro
- Libro
- Contributo in atti di convegno (proceeding)
- Brevetto
- Curatela
- Altro
- Tesi di Dottorato

Publications

Information general

Curriculum

Interests

Publications

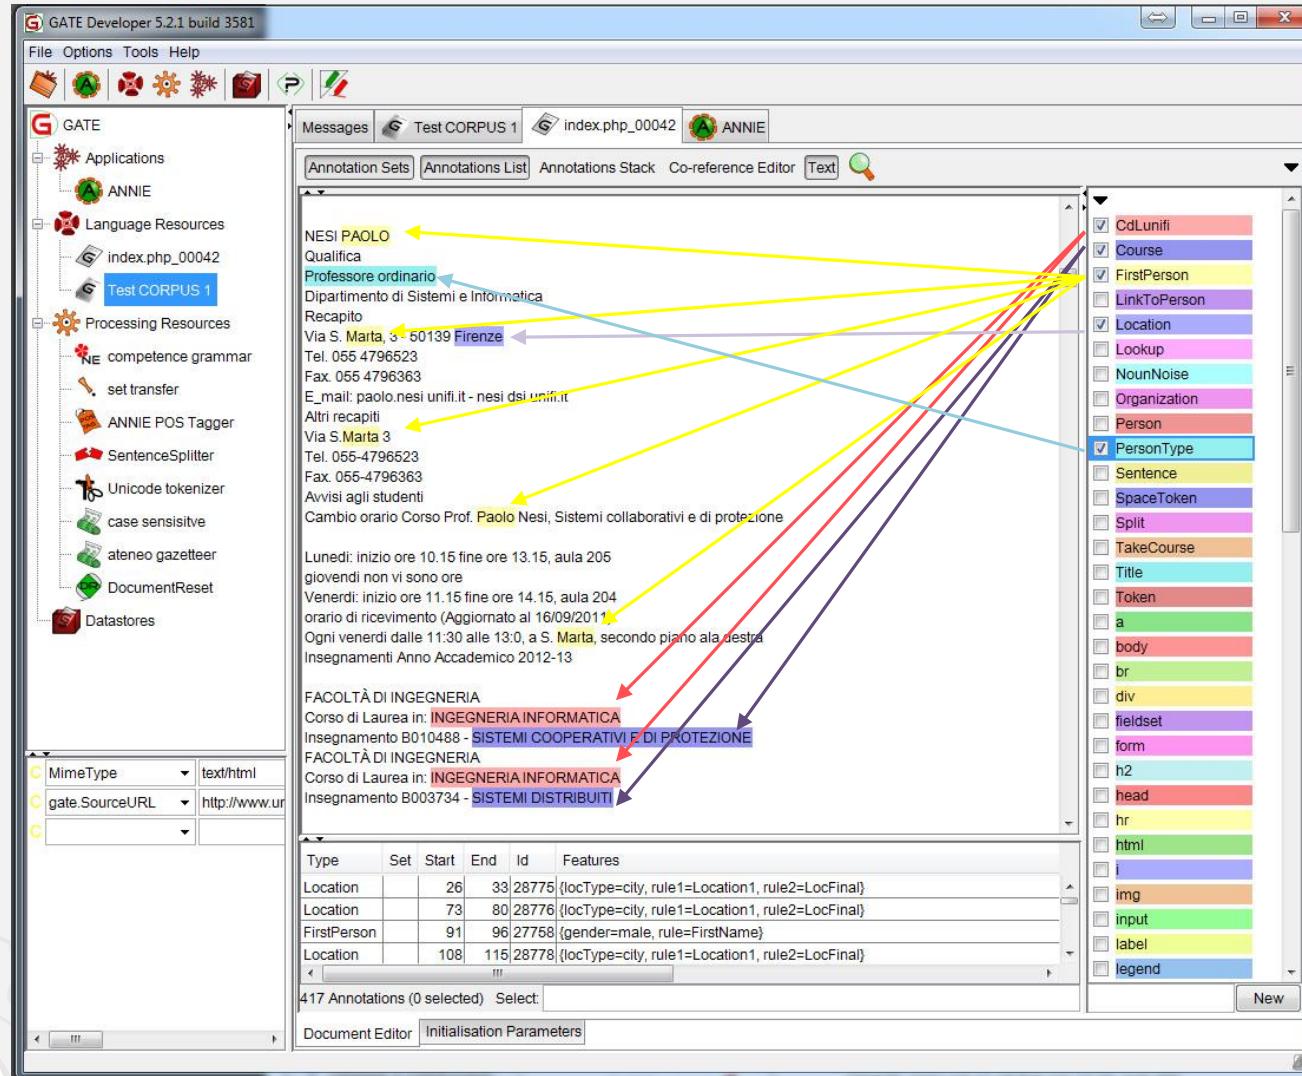
Legend

- Pierfrancesco Bellini,Ivan Bruno,Paolo Nesi,Daniele Cenni (2012). Micro Grids for Scalable Media Computing and Intelligence in Distributed Scenarios. IEEE MULTIMEDIA, vol. 19, pp. 69-79, ISSN:1070-988X
- Paolo Nesi, Raffaella Santucci (cura di) (2012). ECLAP 2012 Conference on Information Technologies for Performing Arts, Media Access and Entertainment. FIRENZE UNIVERSITY PRESS.
- D. Cenni, P. Nesi, M. Paolucci, (2012). Functionalities and Flow Analyses of Knowledge Oriented Web Portals. In: Proceeding of the 18th International Conference on Distributed Multimedia Systems, DMS 2012, Eden Roc Renaissance Miami Beach, USA, SEKE software engineering and knowledge engineering institute, 9-11 August, 2012., pp. 1-6.
- Pierfrancesco Bellini, D. Cenni, P. Nesi, (2012). Indexing and Searching Cross Media Content in a Social Network. In: Proceeding of the ECLAP 2012 International Conference on Information Technologies for Performing Arts, Media Access and Entertainment", Florence University Press, May 2012., pp. 52-57, ISBN:9788866551256
- Pierfrancesco Bellini, Sergio Boncinelli, Francesco Grossi, Marco Mangini, Luca Malandrino, Paolo Nesi, (2012). Mobile Emergency: shortening communications in hospital. In: Media Tablets & Apps for Medicine, Health, and Home-Care, R&D Workshops & Demos, 1st-2nd March 2012, Politecnico di Milano, Milano, , pp. 1-6.
- Pierfrancesco Bellini, Ivan Bruno, Daniele Cenni, Alice Fuzier, Nicola Mitolo, Paolo Nesi, Michela Paolucci (2012). Mobile Medicine: Smart Applications and Content for Medical Training and Support. In: Media Tablets & Apps for Medicine, Health, and Home-Care, R&D Workshops & Demos, 1st-2nd March 2012, Politecnico di Milano, Milano, , pp. 1-6.
- P. Bellini, D. Cenni, P. Nesi, (2012). On the Effectiveness and Optimization of Information Retrieval for Cross Media Content. In: Proceeding of the KDIR 2012 is part of IC3K 2012, International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management, 4-7 October 2012, Barcelona, Spain, , pp. 1-8.
- F. Argenti, P. Nesi, G. Pantaleo (2011). Automatic Transcription of Polyphonic Music Based on the Constant-Q Bispectral Analysis. IEEE TRANSACTIONS ON AUDIO, SPEECH, AND LANGUAGE PROCESSING, vol. 19 (#6), pp. 1610-1630, ISSN:1558-7916 URL: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5640655
- F. Argenti, P. Nesi, G. Pantaleo (2011). Automatic music transcription: from monophonic to polyphonic. In: J. Solis, K. Ng. Musical Robots and Interactive Multimodal Systems, pp. 27-46, Heidelberg: Springer. DOI: 10.1007/978-3-642-22291-7
- Pierfrancesco Bellini, Ivan Bruno, Daniele Cenni, Alice Fuzier, Paolo Nesi, Michela Paolucci (2011). Mobile Medicine: semantic computing managementfor health care applications on desktop and mobile devices. MULTIMEDIA TOOLS AND APPLICATIONS, vol. 53, pp. 1-39, ISSN:1380-7501 URL: <http://www.springerlink.com/content/q8512555u0j00584/fulltext.pdf>

Area Riservata

English Version

2.4 - NLP Tools: GATE



Outline

- 1. Sistemi di Web Crawling
 - 1.1 Introduzione
 - 1.2 Strategie di Crawling
 - 1.3 Robot Exclusion Protocol
 - 1.4 Concorrenza
- 2. Tecniche di Parsing ed Estrazione di Informazioni
 - 2.1 Introduzione
 - 2.2 NLP: Cenni Storici
 - 2.3 Fasi dell'Elaborazione in Linguaggio Naturale
 - 2.4 NLP Tools
- 3. Applicazioni



3 - Applicazioni: OSIM (Open Space Innovative Mind)

- Open Space Innovative Mind (<http://openmind.disit.org>) [Bellandi et al., 2012] è un progetto per la realizzazione di un portale nel quale industrie, istituti di ricerca, ricercatori, studenti possono effettuare ricerche per individuare, all'interno dell'Ateneo Fiorentino:
 - le competenze possedute dai gruppi di ricerca, dai laboratori e dal personale universitario
 - le competenze offerte da corsi specifici nell'ambito dei vari corsi di laurea.
 - Le relazioni esistenti tra competenze diverse
 - Le pubblicazioni scientifiche
 - Le relazioni di conoscenza tra docenti
 - ...

Nell'architettura di OSIM sono implementate tutte le tecnologie presentate:

- ❖ *Data Mining*
- ❖ *Web Crawling*
- ❖ *NLP*
- ❖ *Semantic Web*
- ❖ *Interrogazione della conoscenza e Reasoning (OSIM Query Wizard)*

The screenshot shows the OSIM Query Wizard interface. At the top, there's a navigation bar with links for Home, Documentation, Search, Managing Knowledge, Browsing People & Publications, and Contact DISIT. A red 'BETA' badge is visible on the right. Below the navigation, there's a 'Question Answer' section with a 'Query Wizard' link. The main area is titled 'Wizard' and contains several search fields with dropdown menus and 'try' buttons. The fields include:

- Quale Persona o Struttura ha questa competenza
- Quale Persona (all) ha questa competenza
- Elenco le competenze relazionate con
- Elenco le competenze della Persona (dropdown set to Aaron Thomas Fargion)
- Elenco le Persone del Dipartimento (dropdown set to Agronomia e produzioni erbacee)
- Elenco le pubblicazioni della Persona (dropdown set to Aaron Thomas Fargion)
- dal 1955 al 2012
- Elenco le Persone con area CUN Scienze matematiche e informatiche e settore scientifico disciplinare (SSD) INFORMATICA
- dal 1955 al 2012

3 - Applicazioni: OSIM (Open Space Innovative Mind)

I motori di ricerca attuali, ad esempio Google, sono keyword-based

Vengono restituiti i documenti che contengono esattamente le parole specificate dall'utente nella ricerca, senza tener conto della semantica di quanto espresso dall'utente stesso



Se per esempio un utente chiede una specifica competenza non è desiderabile avere come risposta tutte le pagine che contengono quella competenza, ma ci si aspetta di conoscere quali Professori o ricercatori hanno quella competenza, in quali corsi universitari può essere acquisita e quali gruppi di ricerca hanno maggior esperienze in quel settore.

La risposte trovate dovrebbero essere ordinate secondo una certa rilevanza



In riferimento, ad esempio, alla ricerca di chi possiede una specifica competenza, un docente/ricercatore può avere più rilevanza se possiede una competenza più specifica rispetto a quella cercata, di un docente/ricercatore che possiede una competenza più generale rispetto a quella cercata

3 - Applicazioni: OSIM (Open Space Innovative Mind)



ha cercato nell'area di INGEGNERIA

Cerca

Ricerca base

Forse cercavi: sistemi distribuiti

Dottorato in Informatica, Sistemi
... Il corso punterà a completare la formazione progettazione ed analisi. ... Sicurezza ...
www.unifi.it/dist/cmpro-v-p-6.html - 23

Dottorato in Informatica, Sistemi
... Sono di interesse i sistemi di gestione software, i sistemi distribuiti, il software ...
www.unifi.it/dist/cmpro-v-p-16.html - 2

Dipartimento di Energetica - Laboratorio IBIS -
... F., Morin F., Miglioramento delle prestazioni tramite sistemi di monitoraggio e controllo della manutenzione ... della catena logistica tramite simulazione ...
www.ibis.unifi.it/cmpro-l-s-4.html - 32k - 2009-05-19

Informatica e Applicazioni
Referente: Rosario Pugliese

Obiettivi:
Scopo del Dottorato è la formazione verso gli aspetti applicativi. Questo (che debbono fare i conti con frequenze soprattutto ad allargare la base curriculare di studi di informatica e di discipline lavorative non collegate alla ricerca). Il corso punterà a completare la formazione progettazione ed analisi. ... Sicurezza ...
www.unifi.it/dist/cmpro-v-p-6.html - 23

DIPARTIMENTO DI ENERGETICA - LABORATORIO IBIS
home ateneo | home polo | home dipartimento | home laboratorio

Lingua - Language 

Menù

- ▶ Home
- ▶ Aree di ricerca
- ▶ Collaborazioni
- ▶ Progetti
- ▶ Prodotti
- ▶ Strumenti
- ▶ Persone
- ▶ Contatti
- ▶ Dove siamo

Utilità

- ▶ Mappa
- ▶ Statistiche
- ▶ Redazione

Area di ricerca



Condition Monitoring & Condition Based Maintenance
Progettazione di sistemi per l'acquisizione dei dati di campo e per il monitoraggio remoto delle condizioni dei sistemi (impianti industriali, macchinari, flotte, ecc.), sviluppo sistemi e modelli per la manutenzione predittiva.

Reliability analysis & Expert Systems
Modellazione e analisi di affidabilità e di disponibilità di sistemi complessi, sviluppo di modelli diagnosticati, previsione vita utile residua del bene).

Service Management and Engineering
Analisi del valore, sviluppo service concept, ingegnerizzazione servizi, due diligence tecnologica, progettazione logistica di supporto.

Di seguito si illustrano le competenze acquisite in riferimento alle tematiche di cui al presente documento, da parte dei membri del comitato scientifico del laboratorio.

Primo risultato

Secondo risultato

sensibilità
alle industrie
oni si punta
posizioni

condii loro

49



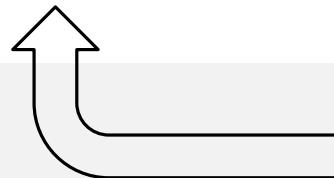
3 - Applicazioni: OSIM (Open Space Innovative Mind)

The screenshot shows the OSIM search interface. At the top, there is a navigation bar with links: Home, Documentation, Search, Managing Knowledge, Browsing People & Publications, and Contact DISIT. A "BETA" badge is visible above the "Testing" text. Below the navigation bar, the main title "Question Answer" is displayed, followed by a link to "Query Wizard". A search input field contains the query "sistemi distribuiti", and a magnifying glass icon is to its right.

Results Displayed / Found: 1 - 3 / 3 in 21235 millisec

sistemi distribuiti (course)	Freqs: 1 score: 5.14	Paolo Nesi (full professor)	Freqs: 0 score: 4.91
sistemi distribuiti (skill)	Freqs: 0 score: 4.32		

Previous 1 Next

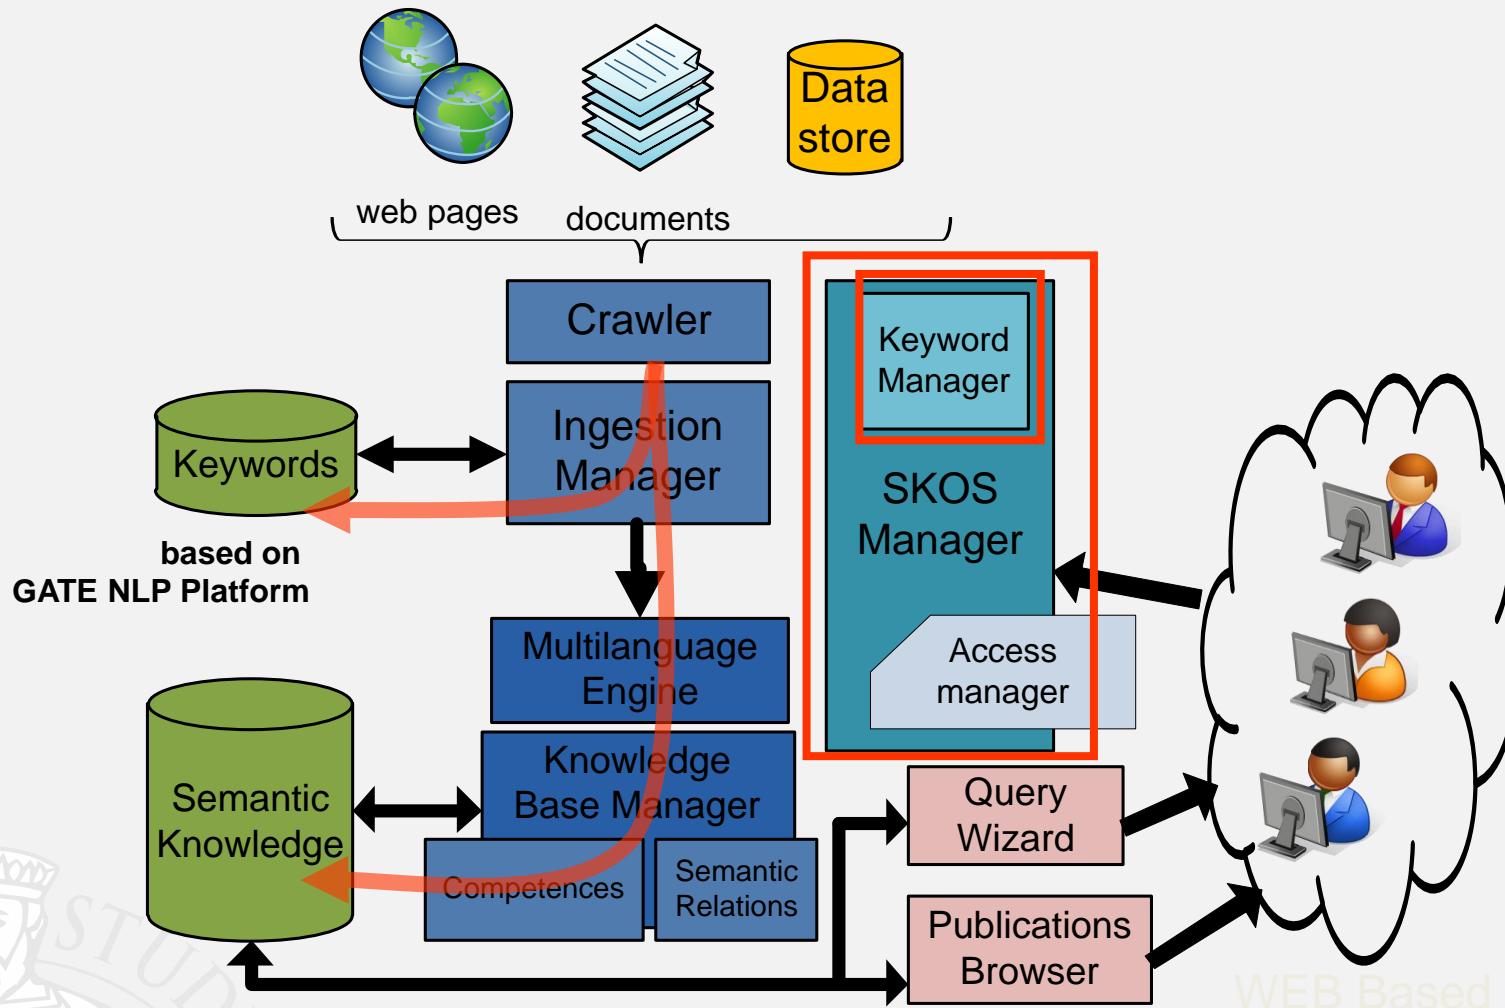


I risultati non sono i documenti che contengono la parola “sistemi distribuiti”

I risultati sono “il corso di Sistemi distribuiti” e la competenza “Sistemi distribuiti”

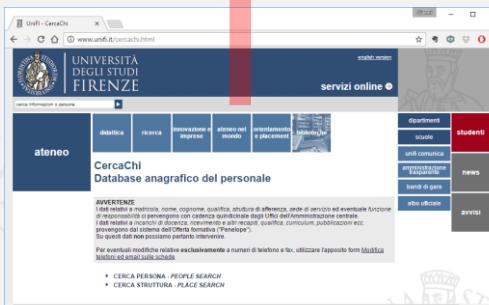
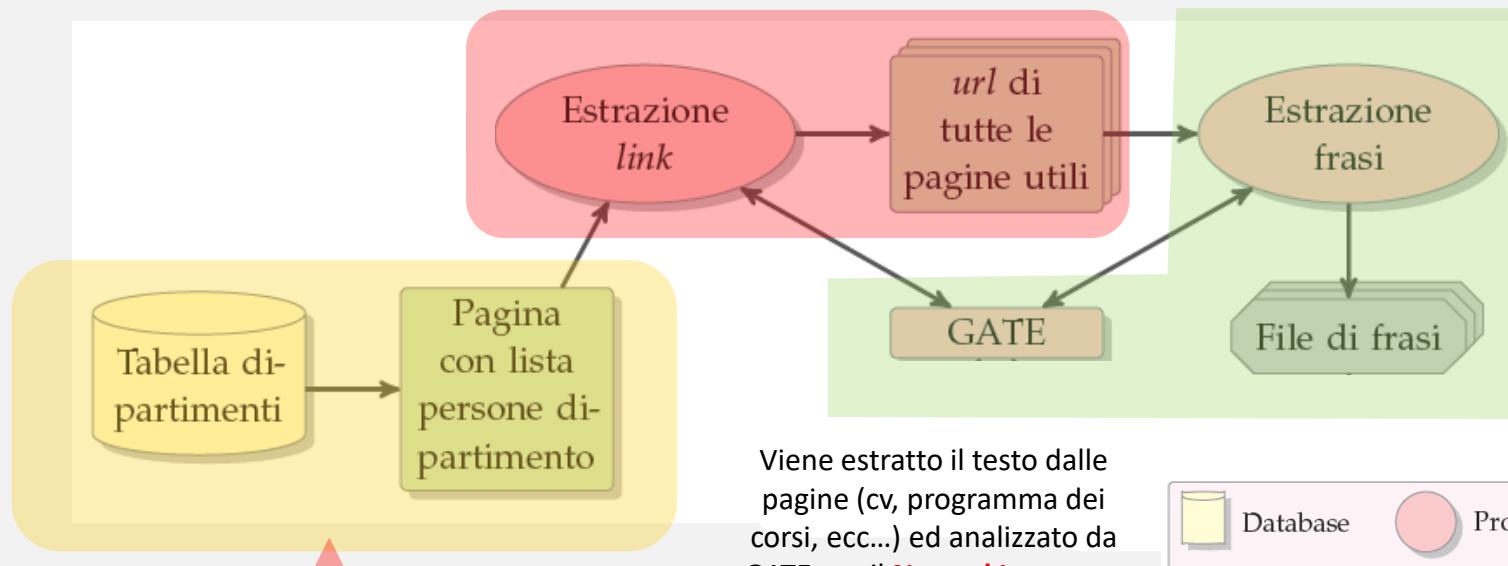


3 - Applicazioni: OSIM (Open Space Innovative Mind)

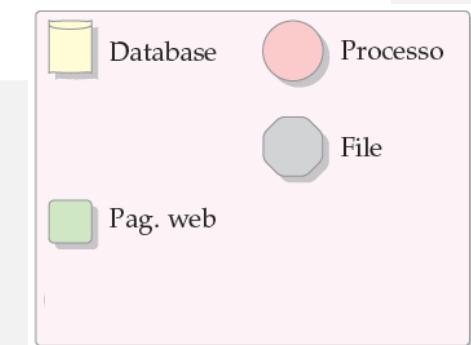


3 - Applicazioni: OSIM (Open Space Innovative Mind)

Vettore di URLs. Gli URLs sono scelti dalle apposite sezioni delle pagine, basandosi sui tags HTML delle pagine stesse



Viene estratto il testo dalle pagine (cv, programma dei corsi, ecc...) ed analizzato da GATE per il **Natural Language Processing**



Welcome root [Logout](#) [OSIM Managing Knowledge HOME](#)

dipartimento di matematica per le decisioni - crawler is running

english

ONTOLOGY MANAGER

KEYS SELECTION

RELATIONS MANAGER





all

20/113 (#2258)

id	value	translated values	occurrences	gazetteer	black list	no action	lang	Proposed
9390	algebra	algebra	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
1201	complementary	complementare	9	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="button" value="en"/>	0
9139	changes	variazioni	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
9143	horizon	orizzonte	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
7611	decomposition	decomposizione	9	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="button" value="en"/>	0
9148	infinite	infiniti	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
7365	laboratory	laboratorio	9	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="button" value="en"/>	0
8646	angles	angoli	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
8397	embrechts	embrechts	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
9427	bond	obbligazione	9	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="button" value="en"/>	0
9431	fields	campi	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
9689	edition	edizione	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0
8673	min	min	9	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="button" value="en"/>	0
482	decomposition	scomposizione	9	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="button" value="en"/>	0
8426	year.old	anni	9	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="button" value="en"/>	0

Trova: Maiuscole/minuscole

ONTOLOGY MANAGER | KEYS SELECTION | RELATIONS MANAGER



INSTANCES

filtered by black list

5



Concepts Repository

- 2
- A
 - able (18)
 - academic (25)
 - access (20)
 - access methods (5)
 - acm (21)
 - acm multimedia (9)
 - acquired (54)
 - acquired skills (48)
 - acquisition (6)
 - actions (8)
 - addresses (5)
 - addressing (5)
 - agreement (7)
 - allocation (26)
 - analyze (27)
 - and phase margin pulse crossing (5)
 - applications (105)
 - applied (6)

SKOS TREE

with frequencies



- Concept Schema
 - architectural (2)
 - area of software engineering (1)
 - artificial intelligence (2)
 - automated control (0)
 - computer science (0)
 - algorithm (95)
 - application (10)
 - code (8)
 - binary (4)
 - information (220)
 - notation (11)
 - xml (0)
 - database (0)
 - distributed systems (4)
 - life cycle (0)
 - programming (0)
 - condition (0)
 - e-commerce (0)
 - e-learning (2)
 - event (0)

LOG

1. skos tree node is re-loaded
2. skos tree node is re-loaded
3. [INFO]: LOOKUP FOR acquisition (6)
4. Related Subject:
5. http://www.unifi.it/off_form/insegnamenticc.php?cmd=2&cds=B070&cur=GEN&esa=B010480-FIRENZE&fac=200006<s=INGEGNERIA&AA=2009&codice=4480&bol=&cognome=&nome=&f=s
6. http://www.unifi.it/off_form/insegnamenticc.php?cmd=2&cds=B070&cur=GEN&esa=B010480-FIRENZE&fac=200006<s=INGEGNERIA&AA=2010&codice=4480&bol=&cognome=&nome=&f=s
7. Related Person:
8. Carlo Colombo (6)

CoSKOSAM

ONTOLOGY MANAGER | KEYS SELECTION | RELATIONS MANAGER



INSTANZE

filtra per lista nera ▾

10



Concepts Repository

- ↳ A
- ↳ B
- ↳ C
- ↳ D
- ↳ E
- ↳ F
 - ↳ famiglia (12)
 - ↳ finito (13)
 - ↳ fisica (12)
 - ↳ flusso massimo (17)
 - ↳ fondamenti (35)
 - ↳ fondamenti di programmazione (11)
 - ↳ fondazioni (35)
 - ↳ forma (33)
 - ↳ forme (22)
 - ↳ fornire (58)
 - ↳ fornire strumenti (11)
 - ↳ frequenza obbligatoria (150)
 - ↳ funzionamento (14)
 - ↳ funzioni (55)
- ↳ G

ALBERO SKOS

con traduzione ▾



Concept Schema

- ↳ L'architettura multi-tier (EN: multi-tier architecture)
- ↳ algoritmi di ricerca (EN: search algorithms)
- ↳ architetturali (EN: architectural)
- ↳ area dell'ingegneria del software (EN: area of software)
- ↳ condizione (EN: condition)
- ↳ controllo automatizzato (EN: automated control)
- ↳ e-commerce (EN: e-commerce)
- ↳ e-learning (EN: e-learning)
- ↳ evento (EN: event)
- ↳ evento (EN: time concept)
- ↳ gestione (EN: management)
- ↳ grafico (EN: graphic)
- ↳ informatica (EN: computer science)
- ↳ intelligenza artificiale (EN: artificial intelligence)
- ↳ interazione (EN: interaction)
- ↳ matematica (EN: math)
- ↳ media (EN: media)
- ↳ metriche (EN: metrics)
- ↳ middleware (EN: middleware)
- ↳ modello (EN: model)

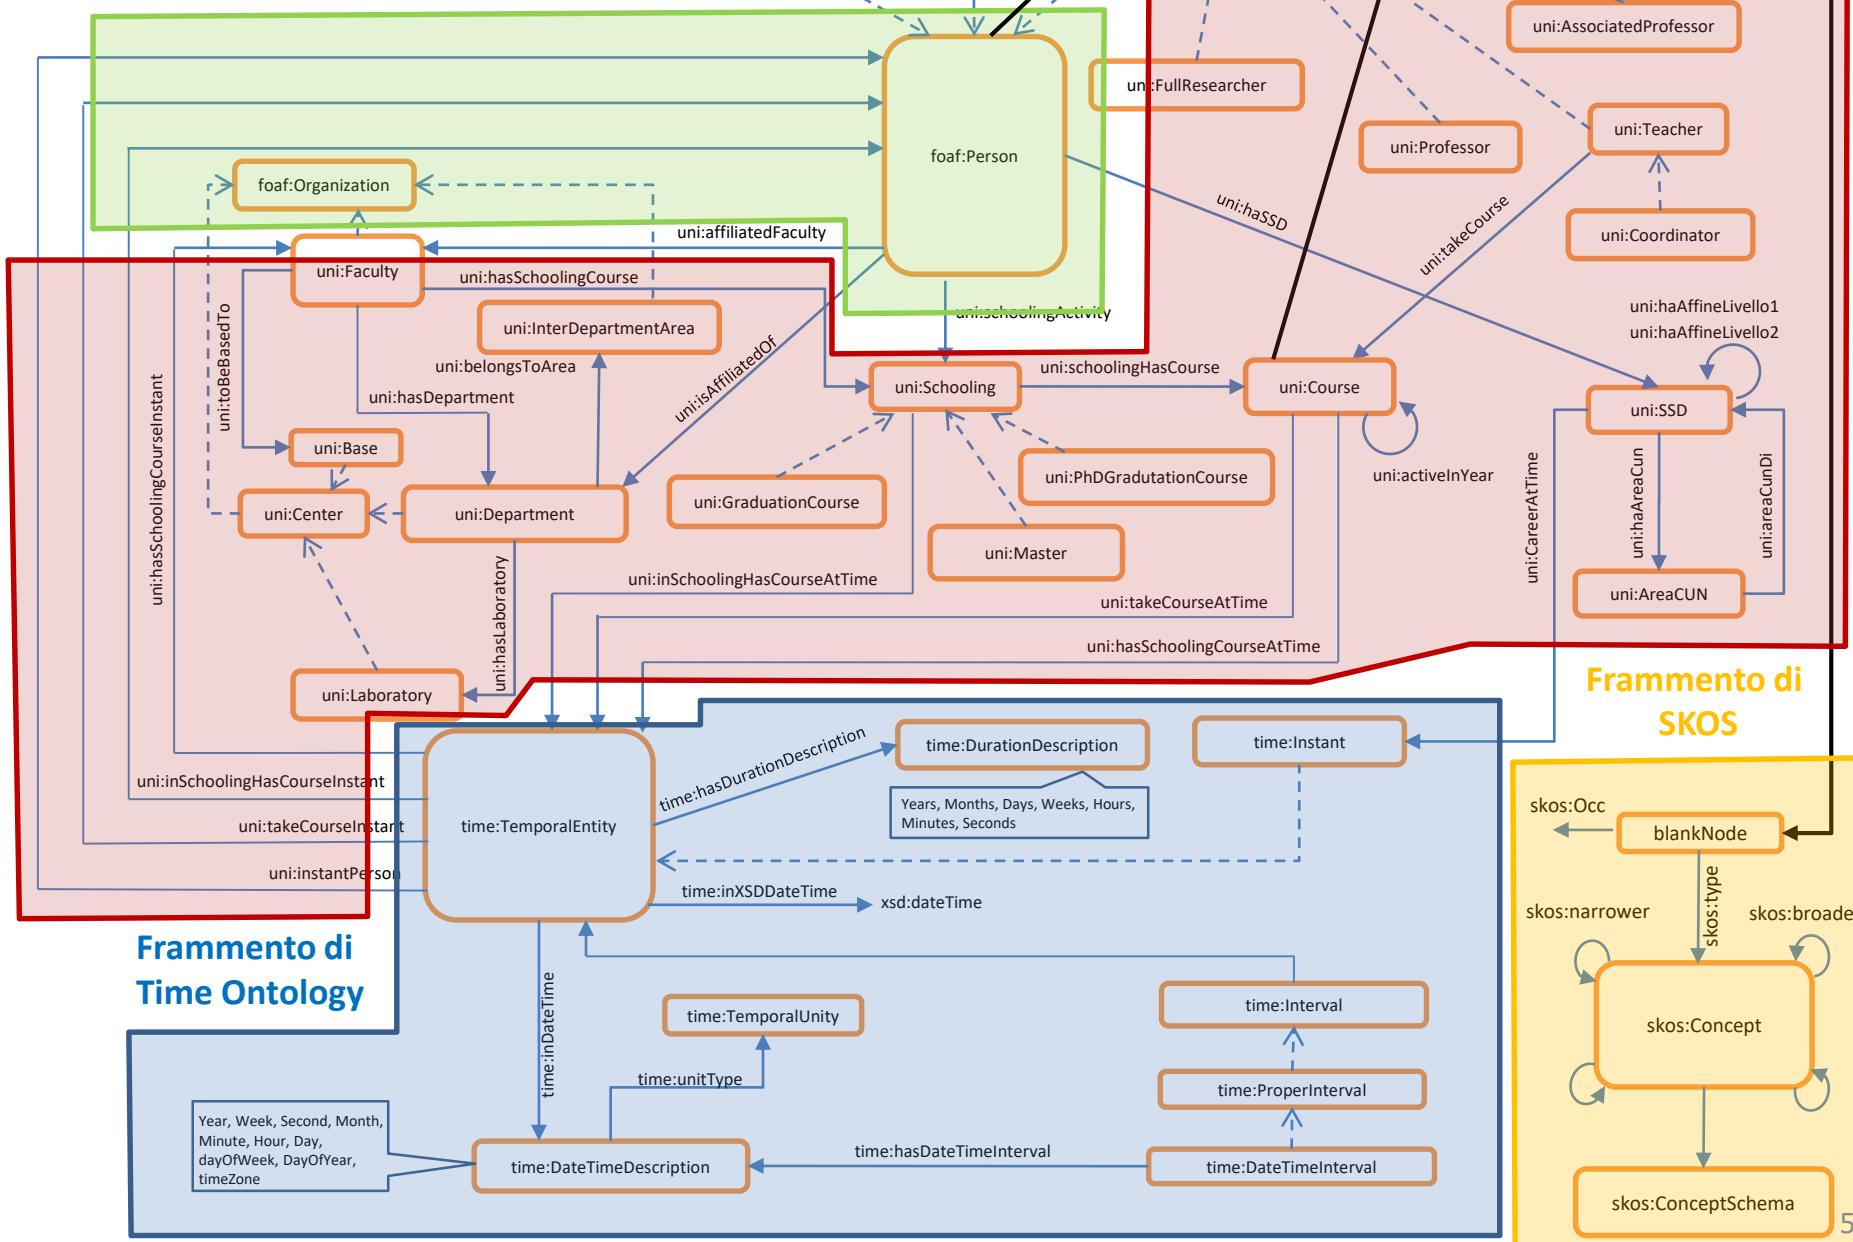
LOG

3. [INFO]: LOOKUP FOR fornire strumenti (11)
4. Related Subject:
5. http://www.unifi.it/off_form/insegnamenticc.php?cmd=2&cds=B086&cur=B38&esa=B001635-amp;fac=200049&s=PSICOLOGIA&AA=2009&codice=4563&bol=&cognome=&nome=&f=s
6. http://www.unifi.it/off_form/insegnamenticc.php?cmd=2&cds=B064&cur=D02&esa=B010314-amp;fac=200006&s=INGEGNERIA&AA=2009&codice=138&bol=&cognome=&nome=&f=s
7. http://www.unifi.it/off_form/insegnamenticc.php?cmd=2&cds=B086&cur=C39&esa=B001635-amp;fac=200049&s=PSICOLOGIA&AA=2009&codice=139&bol=&cognome=&nome=&f=s
8. http://www.unifi.it/off_form/insegnamenticc.php?cmd=2&cds=B064&cur=D02&esa=B010314-amp;fac=200006&s=INGEGNERIA&AA=2009&codice=3460&bol=&cognome=&nome=&f=s

CoSKOSAM

Frammento di unifi ontology

- Relazioni gerarchiche
- Relazioni semantiche



3 - Applicazioni: OSIM (Open Space Innovative Mind)

*Ricerca Full Text
con Logica Fuzzy*



OSIM Open Space Innovative Mind BETA Università degli Studi di Firenze STUDIO

Home Documentation Search Managing Knowledge Browsing People & Publications Contact DISIT

italiano

Question Answer [Query Wizard](#)

Wizard

Quale Persona o Struttura ha questa competenza ? [try](#)

Quale Persona ha questa competenza ? [try](#)

Elenca le competenze relazionate con [try](#)

Elenca le competenze della Persona Aaron Thomas Fargion [try](#)

Elenca le Persone del Dipartimento di Agronomia e produzioni erbacee [try](#)

Elenca le Pubblicazioni della Persona Aaron Thomas Fargion [try](#)

Dal 1955 Al 2012 [try](#)

Elenca le Persone con Area CUN Scienze matematiche e informatiche [try](#)

e settore scientifico disciplinare (SSD) INFORMATICA [try](#)

dal al 2012 [try](#)

Quale persona o corso presenta aspetti legati a acquisisce tecniche [try](#) ?

Quali competenze legate all'attività di acquisisce riguardano Donatella Merlini [try](#) ?

*Ricerca
Assistita*



3 - Applicazioni: Motori di Ricerca Semantici



<https://www.google.it/intl/it/insidesearch/features/search/knowledge.html>

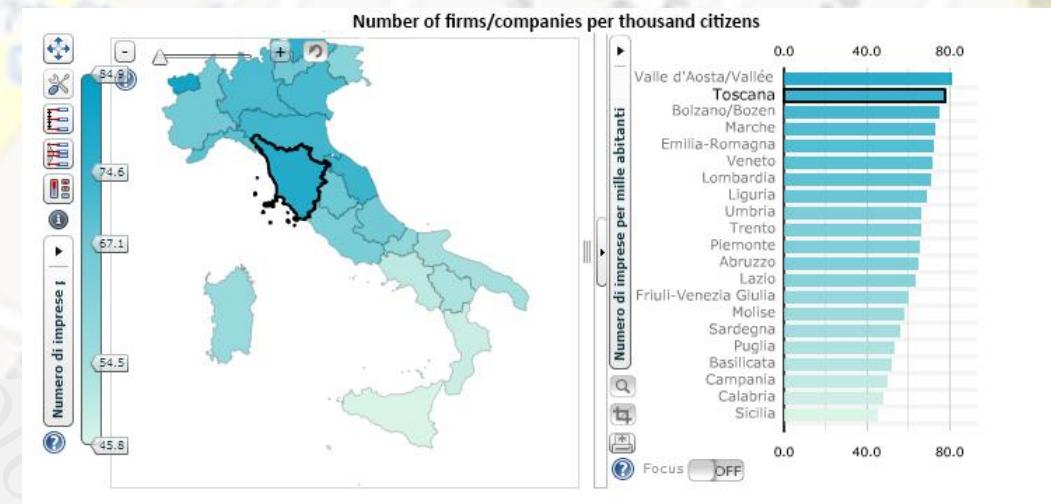


<https://searchengineland.com/library/bing/bing-satori>

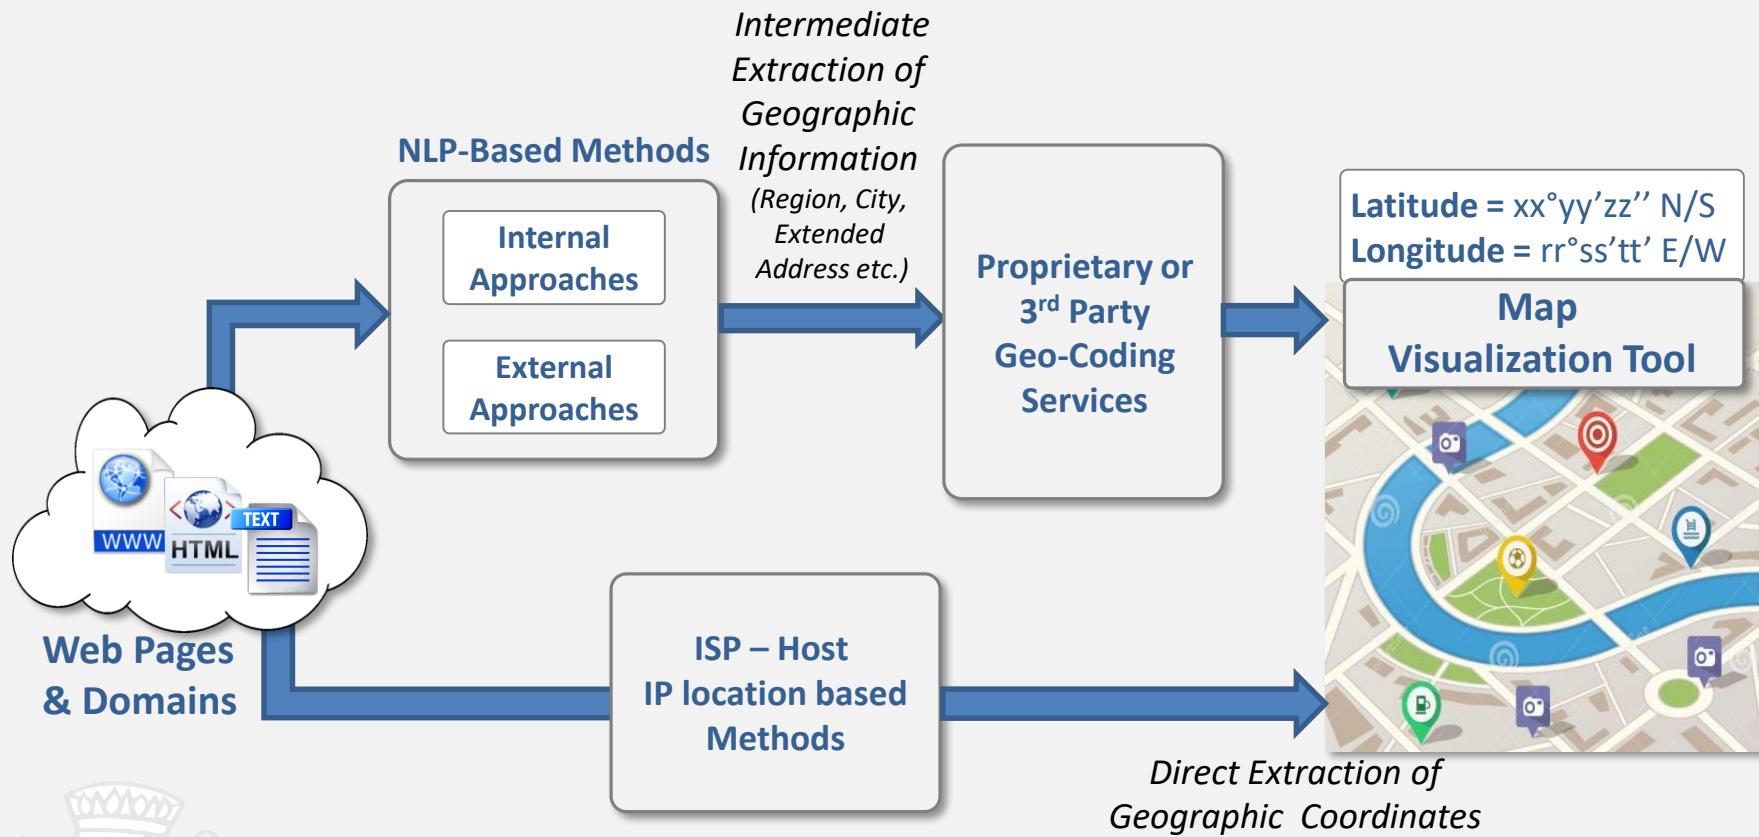
3 - Applicazioni: GeoLocator

- La Geolocalizzazione puntuale di un numero di servizi sempre crescenti (di cui è possibile reperire risorse attraverso il web o gli Open Data delle Pubbliche Amministrazioni) sta diventando un requisito sempre più importante.
- Molti servizi, specialmente in ambito Smart City, sono basati su dati non strutturati e Open Data, spesso in formati diversi e non standardizzati tra loro, e soprattutto non geolocalizzati.

In 2015, Only 30000 commercial operators appears to be active in the Tuscany region, according Public Administration Open Data and among GoodRelations Ontology users.



3 - Applicazioni: GeoLocator



3 - Applicazioni: GeoLocator

GeoLocator [Nesi et al., 2016]

Address Extractor

I tag HTML (in particolare, *footer* e *header*) sono usati generalmente per contenere e visualizzare informazioni amministrative e fisiche dell'azienda / organizzazione / servizio proprietario del dominio web.

Estrazione degli indirizzi tramite tecniche di NLP, in particolare Pattern Matching:

- *General (high level detail) address pattern:*

[REGION] + [PROVINCE] + [POSTAL_CODE] + [CITY].

- *Specific (low level detail) address pattern:*

[STREET_IDENTIFIER] + [STREET_NAME] + [STREET_NUMBER].

- *Pattern per estrarre attributi speciali* (e.g.: “Scala A, Interno 4”):

[INNER_BLOCK_ID1] + [ID1_VALUE] + [INNER_BLOCK_ID2] + [ID2_VALUE].

- *Pattern per estrarre coordinate geografiche* (se presenti):

[LATITUDE_IDENTIFIER] + [LATITUDE_VALUE] + [LONGITUDE_IDENTIFIER] + [LONGITUDE_VALUE].



3 - Applicazioni: Paval - A Location Aware Virtual Personal Assistant -

The screenshot shows a web browser window titled "Query Form Page" at the URL <https://paval.disit.org/Paval/query.jsp>. A location access dialog box is displayed in the center, asking "Will you allow paval.disit.org to access your location?" with "Allow Location Access" and "Don't Allow" buttons. Above the dialog, there is a message: "A quale servizio sei interessato...? Cosa vuoi fare? Dove? vorrei mangiare una quattro stagioni". Below this, there is a section for "Specificare Coordinate Utente (opzionale)" with "Latitudine:" and "Longitudine:" input fields. To the right, a "Select Language: ITA" dropdown is set to "ITA". The background features the "m4City Semantic Service Search" logo and the logos of the University of Florence, DINFO, and DISIT.

Il servizio permette la ricerca tramite query in linguaggio naturale di servizi di interesse per l'utente nella provincia di Firenze, restituendo le aziende legate al tipo di servizio cercato attraverso interrogazione del repository semantico di [Km4City](#), piattaforma Smart City ideata, progettata e realizzata da [DISIT Lab](#) dell'Università di Firenze. Se l'utente accetta di inviare le coordinate relative alla sua posizione attuale, il sistema restituisce i risultati dei servizi considerati attinenti alla ricerca effettuata ordinati in base alla vicinanza con la posizione dell'utente stesso. In alternativa, è possibile per l'utente specificare una coppia di coordinate negli appositi box; in questo caso, le coordinate inserite verranno prese come riferimento di posizione al posto delle coordinate di posizione rilevate. Se inoltre l'utente inserisce nella query di ricerca il riferimento geografico ad un luogo di interesse (via, comune, quartiere), i risultati restituiti saranno ordinati per vicinanza con tale destinazione e non più in base al riferimento posizionale dell'utente.

Esempi di domande:

Esempio 1: "Vorrei vedere un museo in centro"

Esempio 2: "Sono in Via di Novoli e voglio fare la manicure"

Esempio 3: "Mi fanno male i denti"

Esempio 4: "Voglio tagliarmi i capelli a Firenze"

3 - Applicazioni: Paval - A Location Aware Virtual Personal Assistant -

Query Results:

<https://paval.disit.org/Paval/queryProcess.jsp>

DISIT - Km4City Semantic Service Search

Query: vorrei mangiare una quattro stagioni

Lingua impostata: ITA

Query Results:

1. Nome: L'antica Badia
Indirizzo: VIA FAENTINA
n°: 342/A
CAP: 50133
Comune : FIRENZE
Prov: FIRENZE
Latitudine : 43.7992
Longitudine : 11.2756
Descrizione : Pizza sul Panaro
Settore : Pizzeria
ServiceMap URL

User Rating: ★★★★☆

2. Nome: Oliva Filippo
Indirizzo: PLAZZA MINO DA FIESOLE
n°: 2
CAP: 50014
Comune : FIESOLE
Prov: FIRENZE
Latitudine : 43.8067
Longitudine : 11.2936
Descrizione :
Settore : Pizzeria
ServiceMap URL

User Rating: ★★★★☆

3. Nome: I Sette Peccati
Indirizzo: VIA TADDEO ALDEROTTI
n°: 87
CAP: 50139
Comune : FIRENZE
Prov: FIRENZE
Latitudine : 43.7992
Longitudine : 11.246
Descrizione :
Settore : Pizzeria

User Rating: ★★★★☆

Coordinate Utente (impostate manualmente dall'utente) - LAT: 43.8087582, LONG: 11.2693842

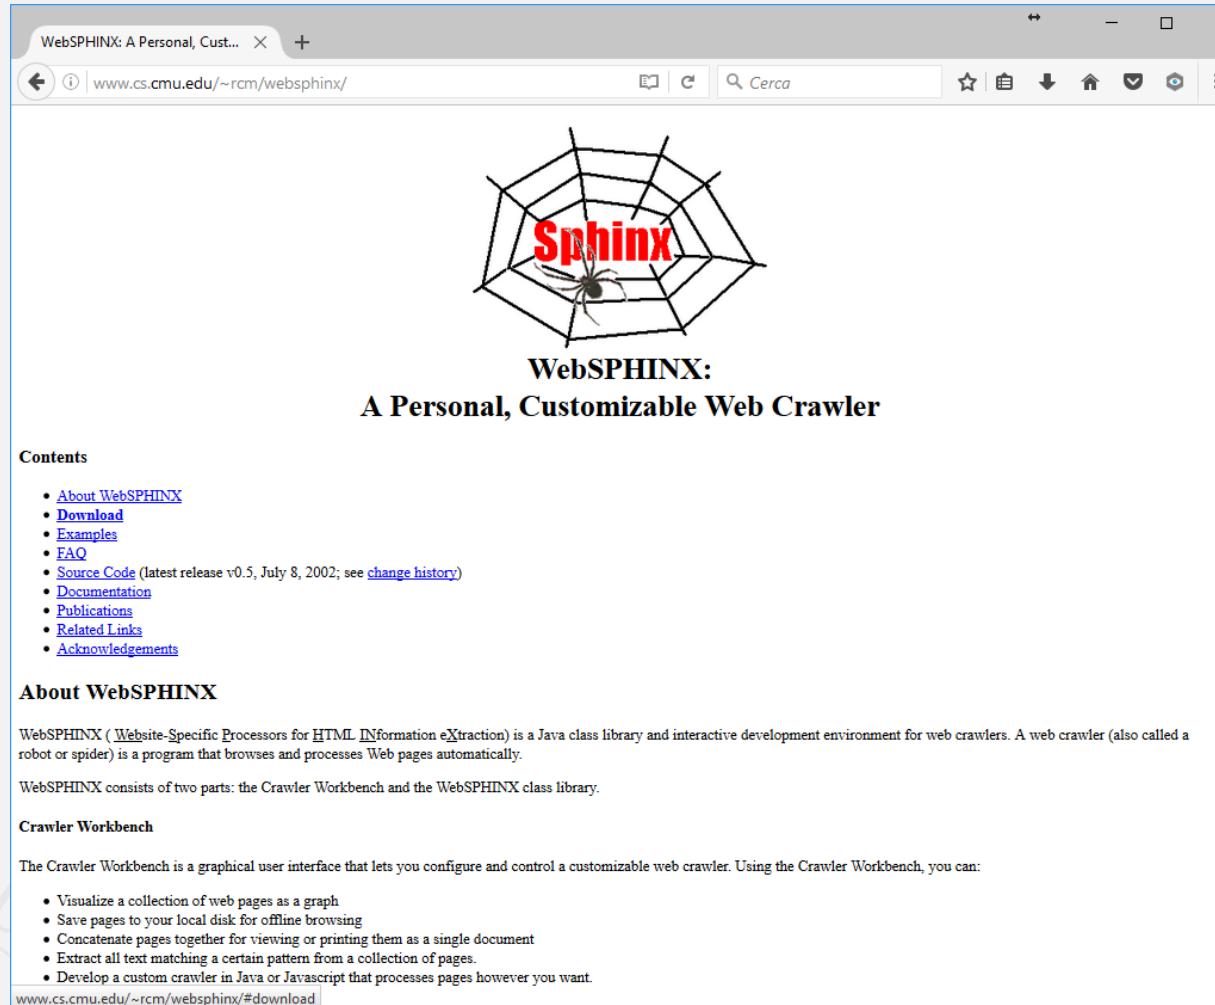
Dall'analisi della query risulta che sei interessato a trovare aziende e servizi relativi a: PIZZERIA nei dintorni della suddetta posizione.

Vengono restituiti 10 risultati per ogni tipologia di servizio considerata attinente alla ricerca effettuata dall'utente. Se l'utente ha accettato di trasmettere la sua posizione geografica (oppure ha inserito manualmente le coordinate), i risultati vengono ordinati per distanza decrescente rispetto a tale posizione; se l'utente non ha accettato di trasmettere la sua posizione geografica ma ha specificato un luogo geografico nella query di ricerca allora i risultati sono ordinati in base alla distanza (sempre decrescente) con il luogo geografico richiesto (se riconosciuto dal sistema); altrimenti, vengono restituiti i primi 10 risultati delle aziende appartenenti al servizio identificato nella provincia di Firenze nell'ordine con cui sono indicizzati nel repository Km4City.

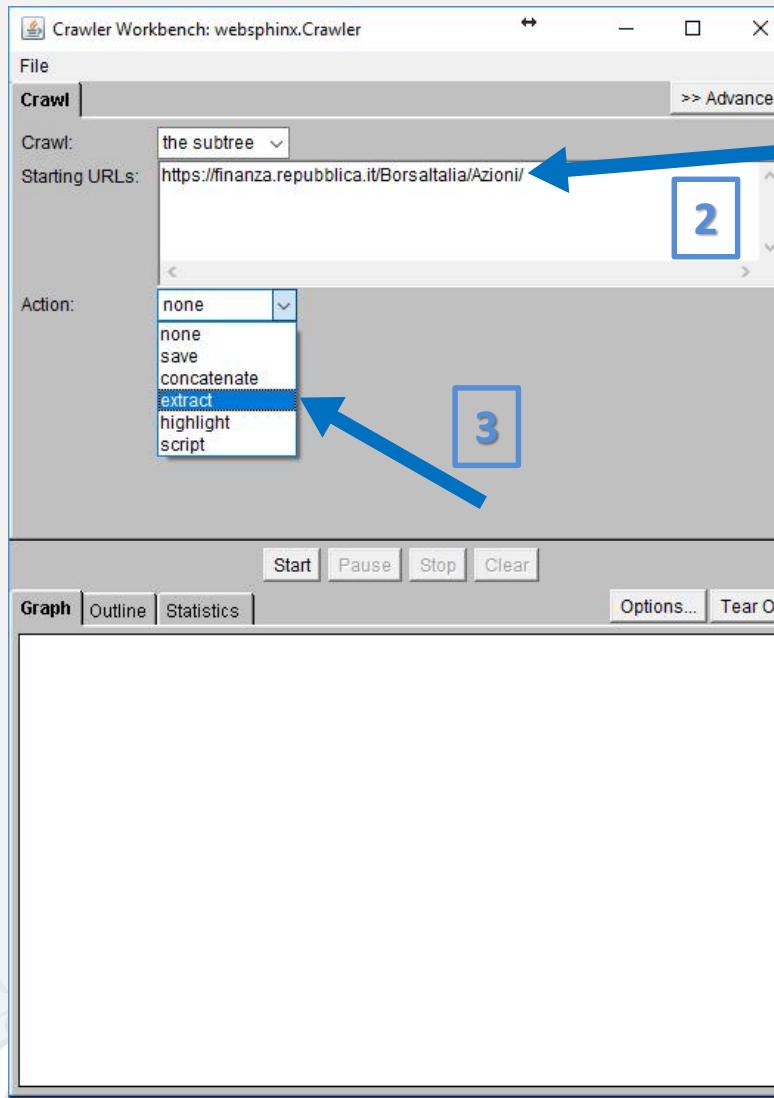
- Il marker rosso identifica la posizione utente (se trasmessa) o, in alternativa, le coordinate inserite manualmente. Se presente, i risultati sono ordinati per distanza da questo.
- Il marker giallo rappresenta un riferimento geografico eventualmente presente nella richiesta dell'utente. Se presente, i risultati sono ordinati per distanza

3 - Applicazioni: WebSPHINX

<http://www.cs.cmu.edu/~rcm/websphinx/>



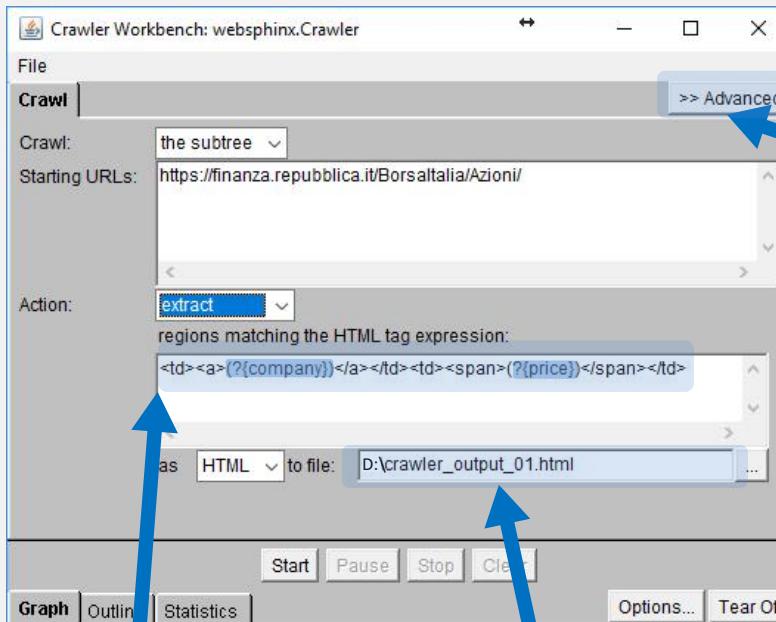
3 - Applicazioni: WebSPHINX



The screenshot shows a web browser window displaying the 'Economia & Finanza' section of the website finanza.repubblica.it. The URL 'https://finanza.repubblica.it/BorsaItalia/Azioni/' is highlighted with a red box labeled '1' above a large red arrow pointing down to the browser's address bar. The page content includes a header with 'la Repubblica.it' and 'Economia & Finanza' (with a Bloomberg logo). Below the header is a navigation menu with links like 'HOME', 'MACROECONOMIA', 'FINANZA', 'LAVORO DIRITTI E CONSUMI', 'AFFARI&FINANZA', 'OSSERVA ITALIA', 'CALCOLATORI', 'GLOSSARIO', 'LISTINO', and 'PORTAFOGLIO'. The main content area features a table titled 'LA BORSA ITALIANA DALLA A ALLA Z' listing various stocks with their latest price, percentage change, and other financial details. To the right of the table, there are several news articles and a 'MARKET OVERVIEW' section.

<https://finanza.repubblica.it/BorsaItalia/Azioni/>

3 - Applicazioni: WebSPHINX



7a Inserire il pattern HTML scelto

8 Specificare il nome del file in cui salvare il risultato dell'elaborazione

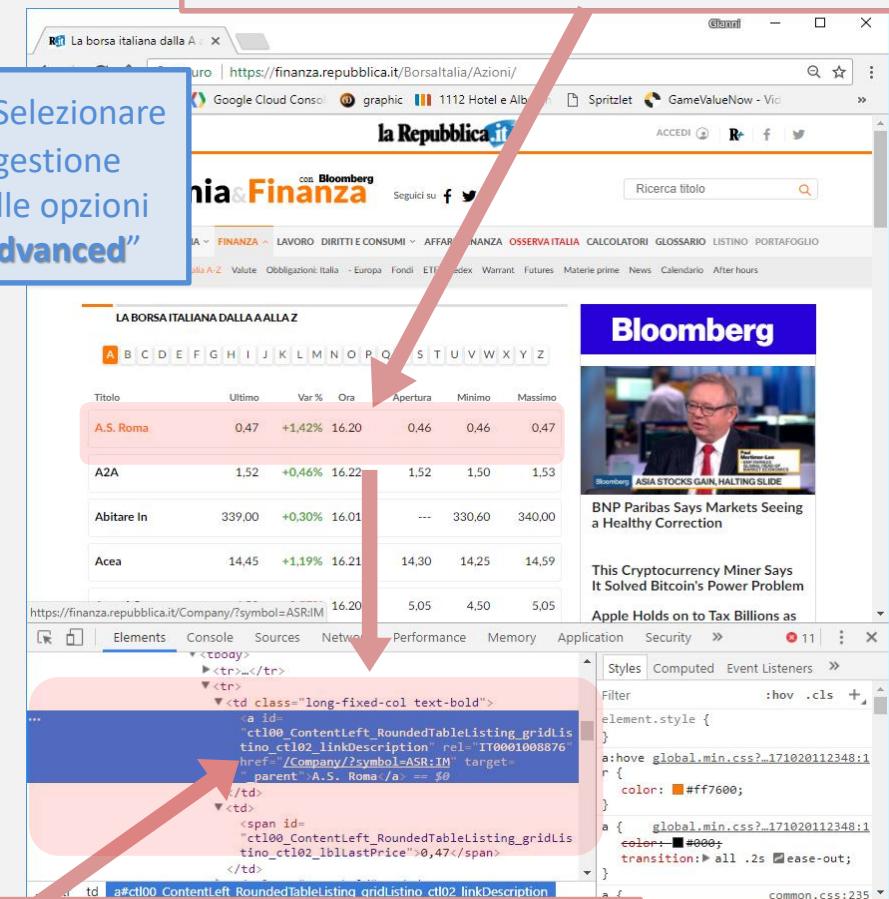
7b Per stampare nel file di uscita delle etichette per le descrivere risorse informative estratte:

```
<td><a>({{company}})</a></td>
<td><span>({{price}})</span></td>
```

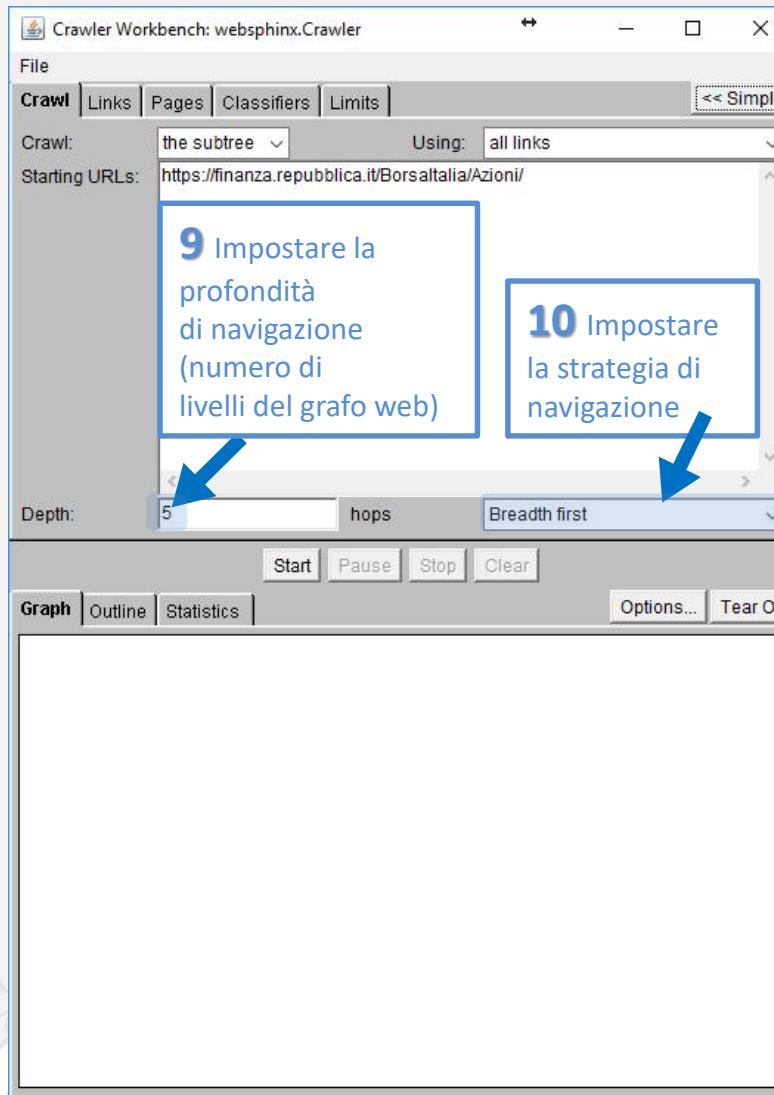
6 Selezionare la gestione delle opzioni "Advanced"

4 Visualizzare il codice HTML della pagina:
F12 (Explorer, Firefox, Google Chrome)
Ctrl + U (Safari, Opera)

5 Identificare la/le risorsa/e informativa da Estrarre nel codice HTML e individuare un pattern HTML significativo con cui addestrare il crawler



3 - Applicazioni: WebSPHINX



The browser window displays a news article from **la Repubblica.it** under the **Economia Finanza** section. The article is about the Italian stock market. The developer tools (Elements tab) are open, showing the HTML structure of the page, specifically focusing on a table listing companies like A.S. Roma, A2A, Abitare In, and Acea.

```

<table>
  <thead>
    <tr>
      <th>Titolo</th>
      <th>Ultimo</th>
      <th>Var %</th>
      <th>Ora</th>
      <th>Apertura</th>
      <th>Minimo</th>
      <th>Massimo</th>
    </tr>
  <tbody>
    <tr>
      <td>A.S. Roma</td>
      <td>0,47</td>
      <td>+1,42%</td>
      <td>16,20</td>
      <td>0,46</td>
      <td>0,46</td>
      <td>0,47</td>
    </tr>
    <tr>
      <td>A2A</td>
      <td>1,52</td>
      <td>+0,46%</td>
      <td>16,22</td>
      <td>1,52</td>
      <td>1,50</td>
      <td>1,53</td>
    </tr>
    <tr>
      <td>Abitare In</td>
      <td>339,00</td>
      <td>+0,30%</td>
      <td>16,01</td>
      <td>---</td>
      <td>330,60</td>
      <td>340,00</td>
    </tr>
    <tr>
      <td>Acea</td>
      <td>14,45</td>
      <td>+1,19%</td>
      <td>16,21</td>
      <td>14,30</td>
      <td>14,25</td>
      <td>14,59</td>
    </tr>
  </tbody>
</table>

```

3 - Applicazioni: WebSPHINX

Crawler Workbench: websphinx.Crawler

Crawl

Crawl: the subtree

Starting URLs: <https://finanza.repubblica.it/BorsaItalia/Azioni/>

Action: extract

regions matching the HTML tag expression:

```
<td><a>({company})</a></td><td><span>({price})</span></td>
```

as HTML to file: D:\crawler_output_01.html

Start | Pause | Stop | Clear

Graph | Outline | Statistics | Options... | Tear Off



Extracted Records

file:///D:/crawler_output_01.html

	company	price
1.	A.S. Roma	0,46
2.	A2A	1,52
3.	Abitare In	339,00
4.	Acea	14,39
5.	Acotel Group	4,57
6.	Acsm-Agam	2,32
7.	Adidas	185,20
8.	Advanced Micro Devices	9,96
9.	Aedes	0,48
10.	Aeffe	2,20
11.	Aegon	5,09
12.	Aeroporto Guglielmo Marconi di Bologna	15,36
13.	Agatos	0,28
14.	Ageas	40,43
15.	Ahold Del	16,98
16.	Air Liquide	107,20
17.	Airbus	85,50
18.	Alerion	2,93
19.	Alfio Bardolla	7,40
20.	Allianz	196,80
21.	Alphabet Classe A	884,50
22.	Altaba	59,25
23.	Ambientthesis	0,39
24.	Ambromobiliare	3,65
25.	Amgen	150,00
26.	Amplifon	12,42
27.	Anheuser-Busch	97,55
28.	Anima Holding	5,59

- Riferimenti

[Winograd, 1971]

Winograd, Terry (1971), *Procedures as a Representation for Data in a Computer Program for Understanding Natural Language*, MAC-TR-84, MIT Project MAC, 1971.

[IBM Watson, 2012]

<https://www-03.ibm.com/innovation/us/watson/>

[IOS Siri, 2010]

<http://www.apple.com/ios/siri/>

[Bellandi et al., 2012]

A. Bellandi, P. Bellini, A. Cappuccio, P. Nesi, G. Pantaleo, N. Rauch, *Assisted Knowledge Base Generation, Management and Competence Retrieval*, Int. Journal of Software Engineering and Knowledge Engineering, World Scientific Publishing Company, press, Vol. 32(8), pp.1007-1038, 2012.

[Nesi et al., 2016]

P. Nesi, G. Pantaleo and M. Tenti, *Geographical localization of web domains and organization addresses recognition by employing natural language processing, Pattern Matching and clustering*, Engineering Applications of Artificial Intelligence, Vol. 51, pp. 202-211, 2016.





- Link Utili

➤ **NLP**

GATE: <http://gate.ac.uk/>

The Stanford University NLP Group: <https://nlp.stanford.edu/>

Italian NLP Lab: <http://www.italianlp.it/>

➤ **Web Crawlers**

Websphinx: <https://www.cs.cmu.edu/~rcm/websphinx/>

Heritrix: <http://crawler.archive.org/index.html>

Apache Nutch: <http://nutch.apache.org/>

➤ **Semantic Technologies**

The Semantic Web: https://en.wikipedia.org/wiki/Semantic_Web

FOAF (Friend-Of-a-Friend) Ontology: <http://xmlns.com/foaf/spec/>

Time Ontology: <https://www.w3.org/TR/owl-time/>

SKOS (Simple Knowledge Organization System) Ontology: <https://www.w3.org/TR/2008/WD-skos-reference-20080829/skos.html>