

Summer School LDA

Libraries in the digital age: linked data technologies for a global knowledge sharing

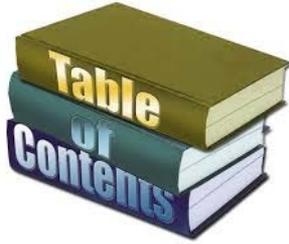
Pula (Cagliari), 29 agosto - 1° settembre

Introduzione al Semantic Web

Oreste Signore
(W3C Italy)

Slide a: <http://www.orestesignore.eu/education/lda/slides/lda1.pdf>

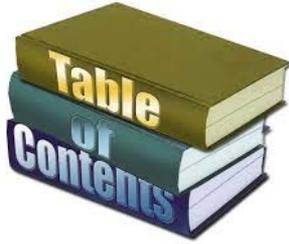




Ringraziamenti

- ❖ Questa presentazione è basata in gran parte sul materiale di presentazioni tenute da [Ivan Herman](#), già W3C Semantic Web Activity Lead
- ❖ Il materiale di questa presentazione può essere riutilizzato nel rispetto delle leggi sul copyright e delle regole del W3C
- ❖ Un particolare ringraziamento agli organizzatori di [Summer School LDA](#) per avermi invitato a tenere questo seminario

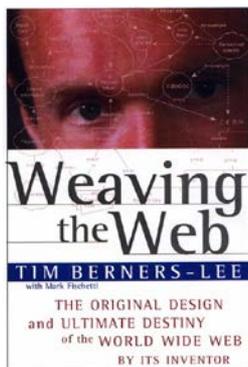




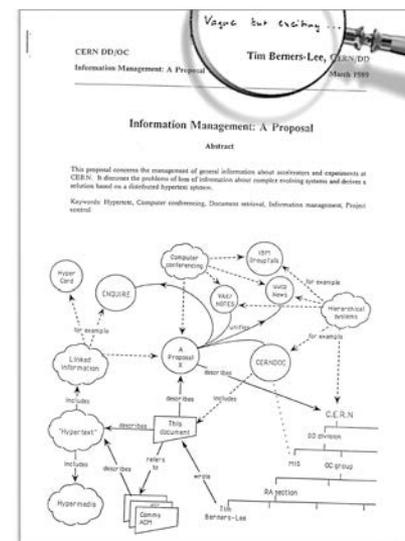
Contenuto

- ❖ **Integrazione dei dati**
 - ✓ Un esempio semplice
 - ✓ Merging e URI
- ❖ **Semantic Web**
 - ✓ Architettura
 - ✓ Metadati
- ❖ **RDF**
- ❖ **Conclusioni**

C'era una volta...



- ❖ 1970(?) Un ragazzo che parlava con il padre:
 - ✓ How to make a computer intuitive, able to complete **connections** as the brain did
- ❖ 1980, al CERN:
 - ✓ Suppose all the information stored on computers everywhere were linked. Suppose I could program my computer to create a space in which **anything could be linked to anything...** There would be a **single, global information space.**
- ❖ 1989 Vague but exciting
- ❖ **...e il Web fu ...**
- ❖ 1994
 - ✓ “The very first *International World Wide Web Conference*, at CERN, Geneva, Switzerland, in September 1994”
<http://www.w3.org/Talks/WWW94Tim/>
- ❖ 1999 Semantic Web Activity nel W3C (ora: Data Activity)
- ❖ 2007 LOD (W3C **L**inking **O**pen **D**ata project)





I limiti del Web attuale

- ❖ **Nel web tradizionale si rappresenta l' informazione utilizzando:**
 - ✓ linguaggio naturale
 - ✓ grafica, elementi multimediali, struttura della pagina
- ❖ **Spesso è necessario *combinare le informazioni* (provenienti da fonti diverse)**
- ❖ ***Per gli esseri umani è facile ...***
 - ✓ dedurre fatti da informazioni incomplete
 - ✓ creare e seguire associazioni mentali
 - ✓ provare varie esperienze sensoriali
 - ✓ aggregare le informazioni indipendentemente dalle tecnologie utilizzate
- ❖ ***... ma le macchine non sono intelligenti!***
 - ✓ non possono utilizzare informazioni parziali
 - ✓ hanno difficoltà ad aggregare informazioni strutturate in forma diversa

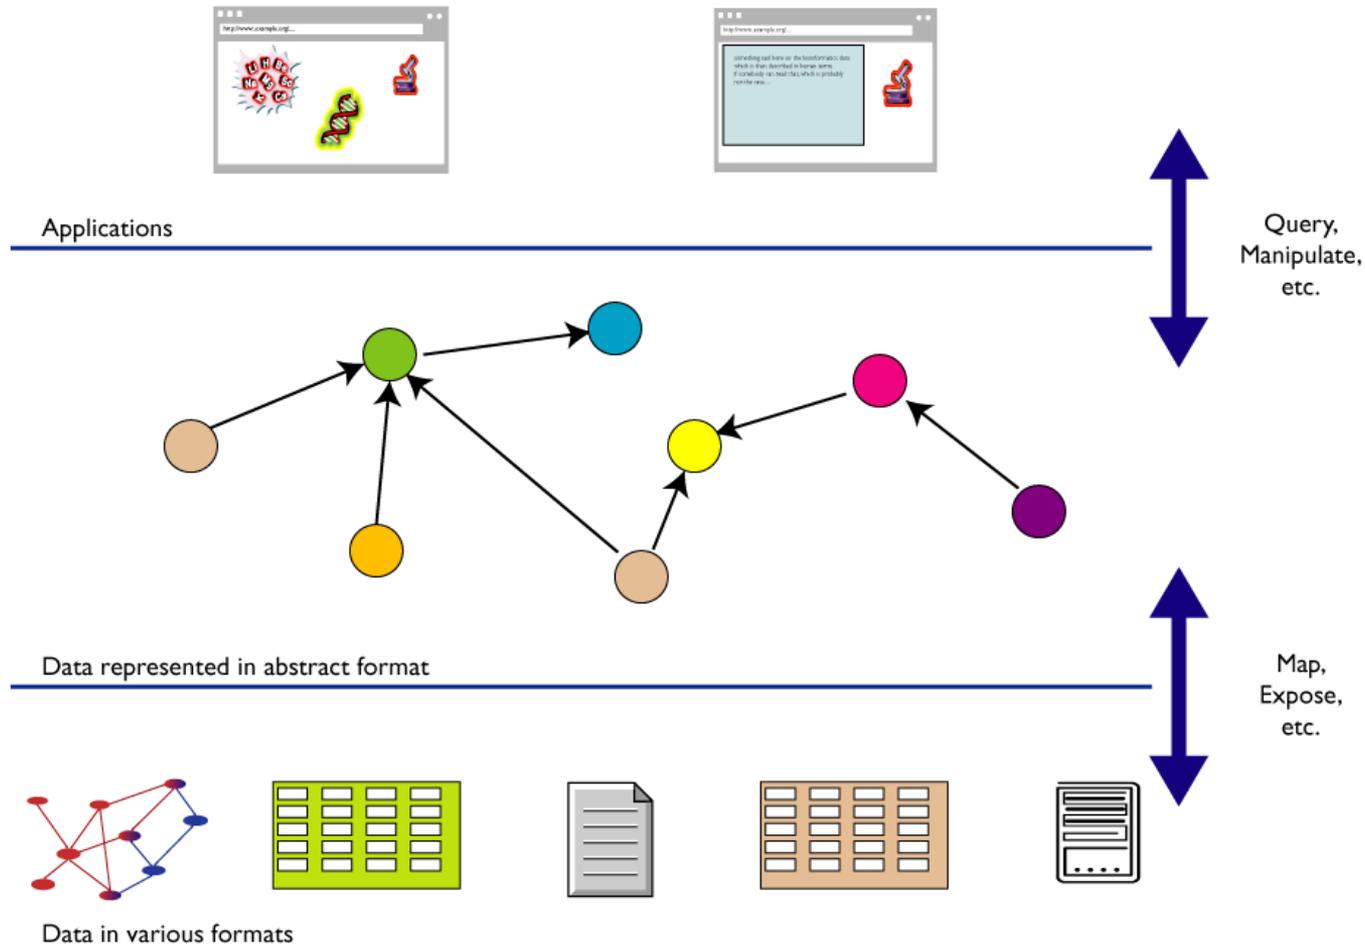




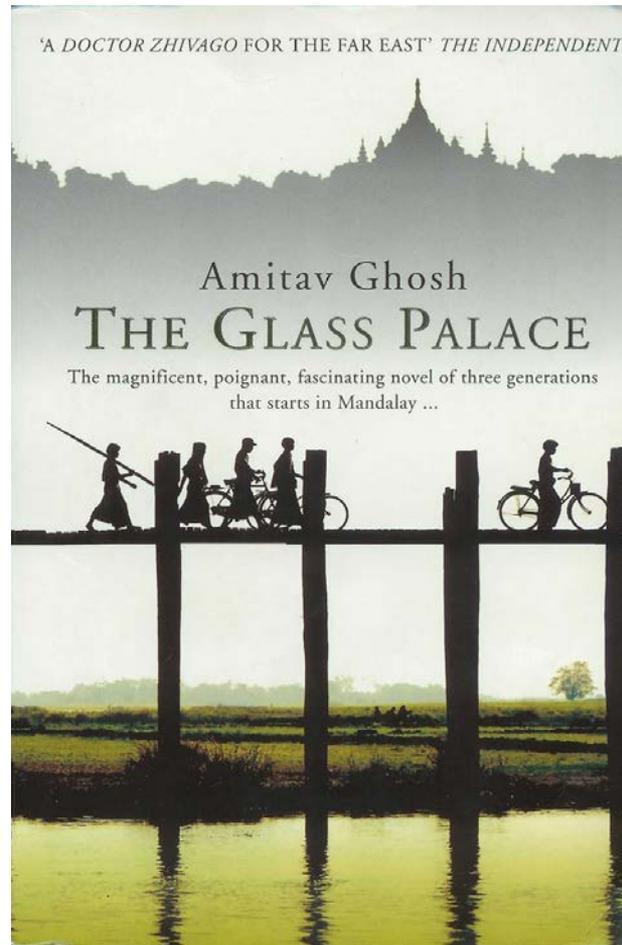
Data integration (visione semplificata)

- ❖ Mappare i vari dati su una rappresentazione astratta dei dati
 - ✓ rendere i dati **indipendenti** dalla loro rappresentazione interna...
- ❖ Merge delle rappresentazioni risultanti
- ❖ Cominciamo a formulare query sul complesso risultante!
 - ✓ query che non sarebbe stato possibile eseguire sui singoli dataset

L'integrazione dei dati



Un libro (nella biblioteca "A")



Una versione semplificata di una biblioteca (Dataset "A")

❖ Tabella Book

ID	Author	Title	Publisher	Year
ISBN 0-00-651409-X	id_xyz	The Glass Palace	Id_qpr	2000

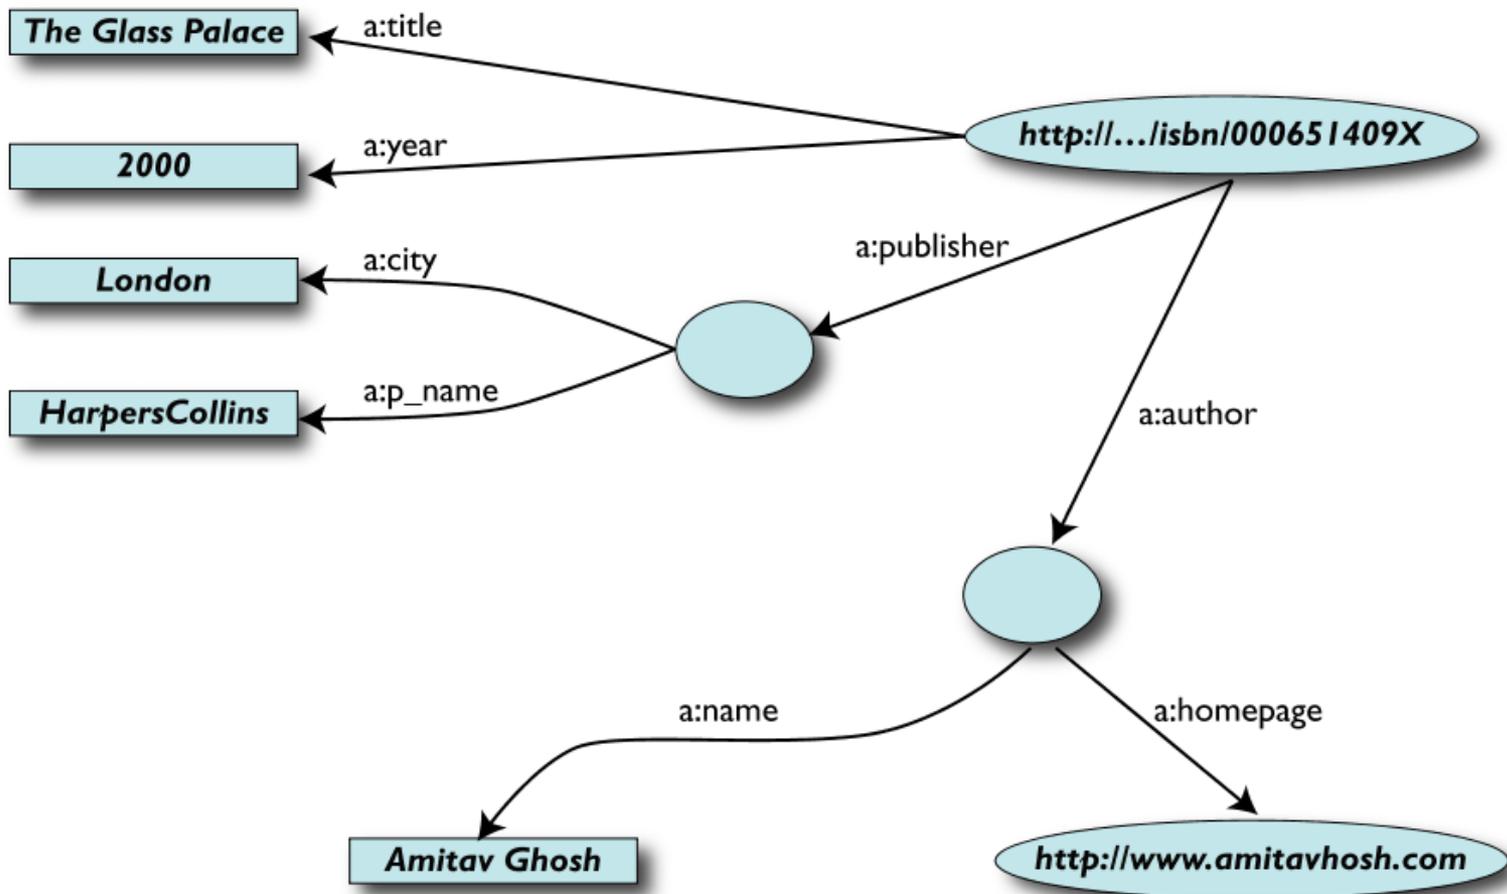
❖ Tabella Author

ID	Name	HomePage
id_xyz	Amitav Ghosh	http://www.amitavghosh.com

❖ Tabella Publisher

ID	PublisherName	City
id_qpr	Harper Collins	London

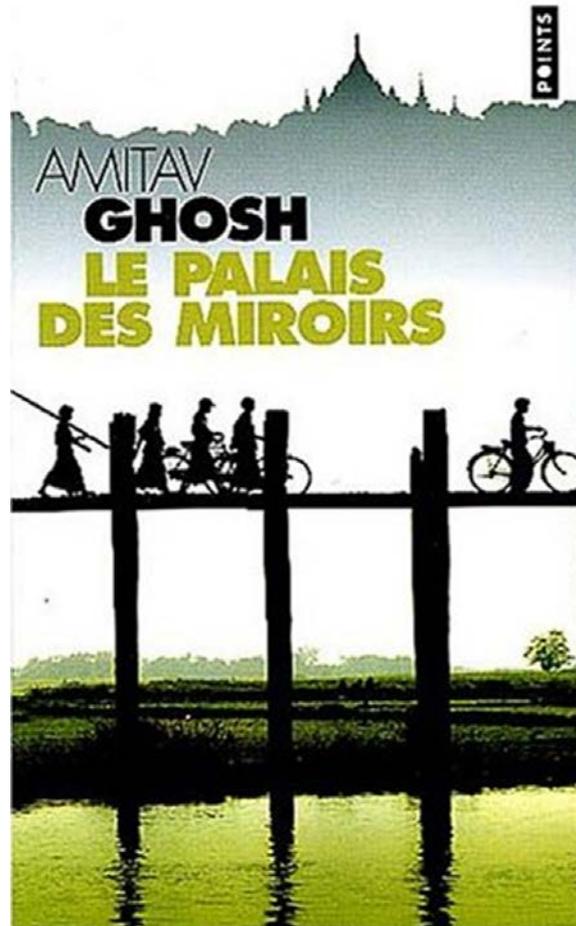
Rappresentata come grafo...



Alcune osservazioni sull'esportazione dei dati

- ❖ **Le relazioni formano un *grafo***
 - ✓ i nodi individuano dati "reali" o contengono caratteri ("literal")
 - ✓ è inessenziale il modo in cui i grafi sono rappresentati nella macchina
- ❖ **L' esportazione dei dati *non* comporta necessariamente una trasformazione fisica**
 - ✓ **le relazioni possono essere generate dinamicamente al momento della richiesta**
 - con SQL "bridges"
 - scraping di pagine HTML
 - estrazione di dati da fogli Excel
 - etc.
- ❖ **L' esportazione dei dati può essere *parziale***

Un libro (nella biblioteca "F")



Un'altra biblioteca (dataset "F")

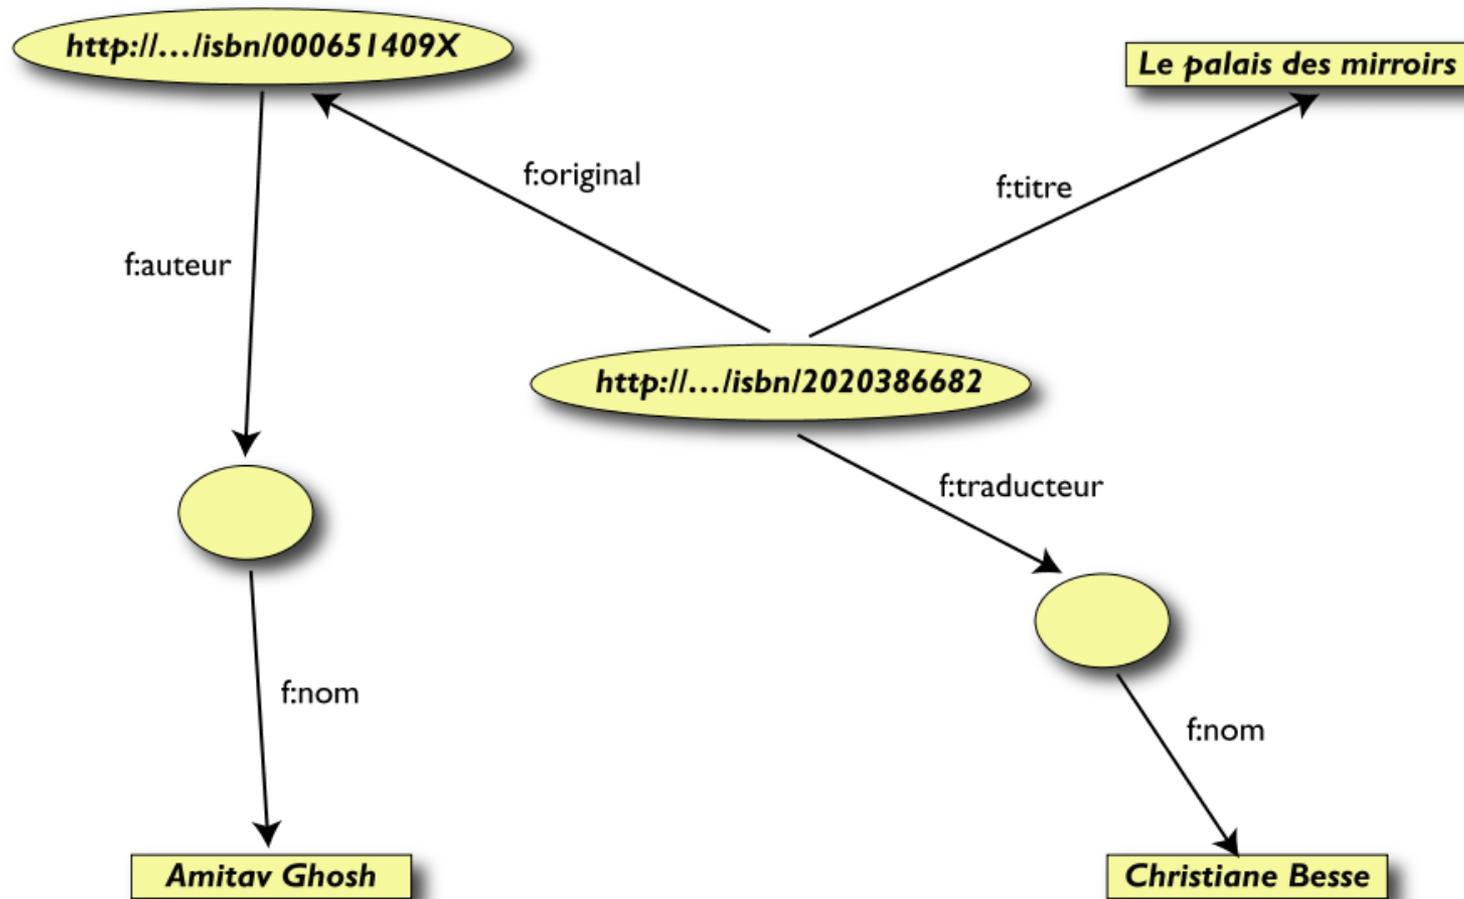
A	B	C	D	
1	ID	Titre	Traducteur	Original
2	ISBN 2020286682	Le Palais des Miroirs	\$A12\$	ISBN 0-00-6511409-X
3				
4				
5				
6	ID	Auteur		
7	ISBN 0-00-6511409-X	\$A11\$		
8				
9				
10	Nom			
11	Ghosh, Amitav			
12	Besse, Christianne			



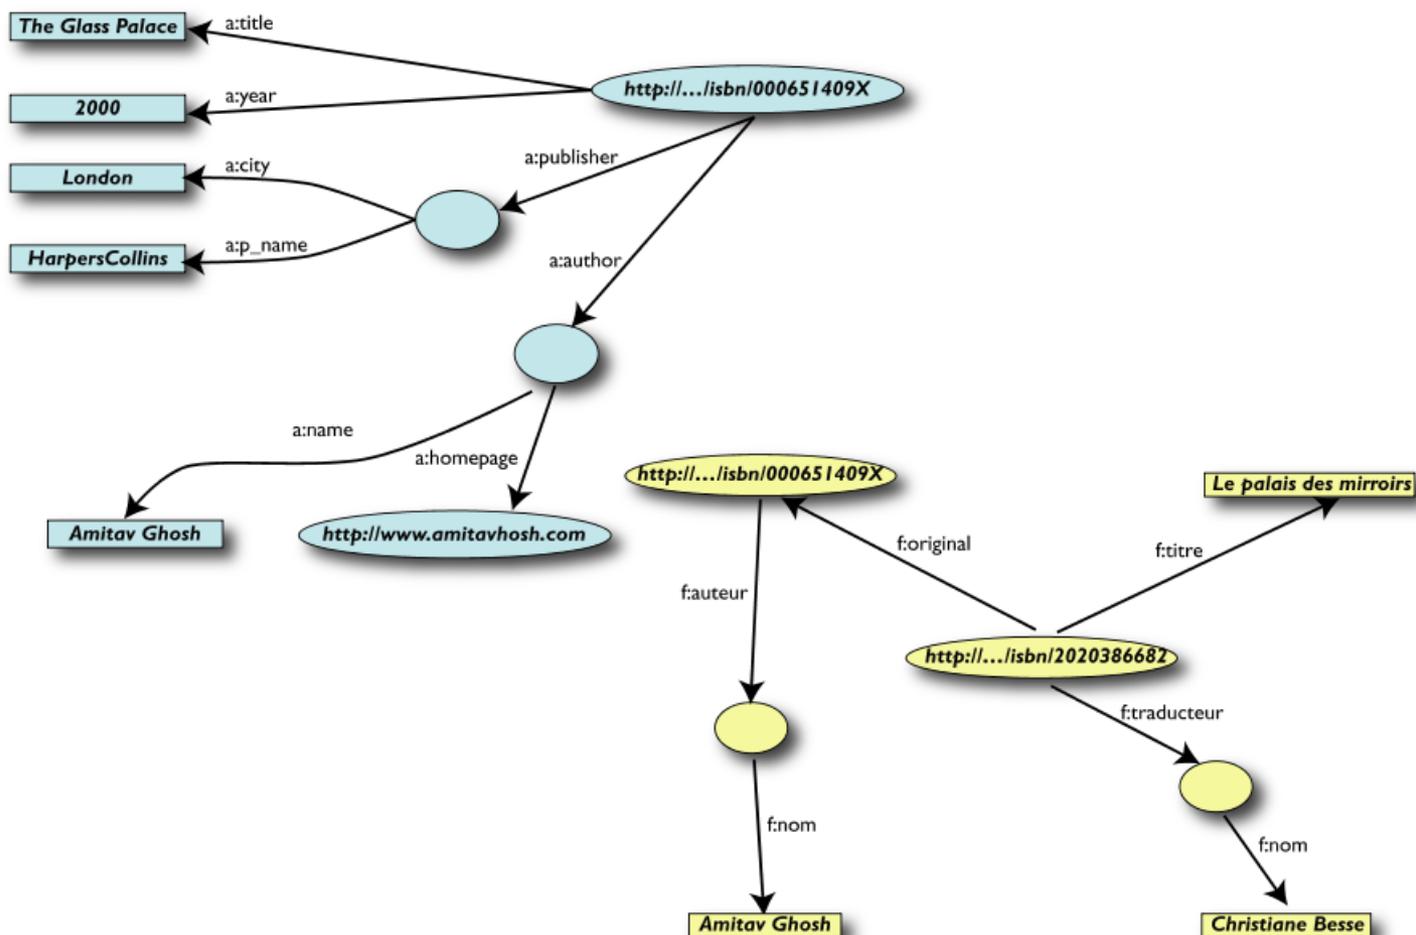
W3C

WORLD WIDE WEB
consortium
Ufficio Italiano

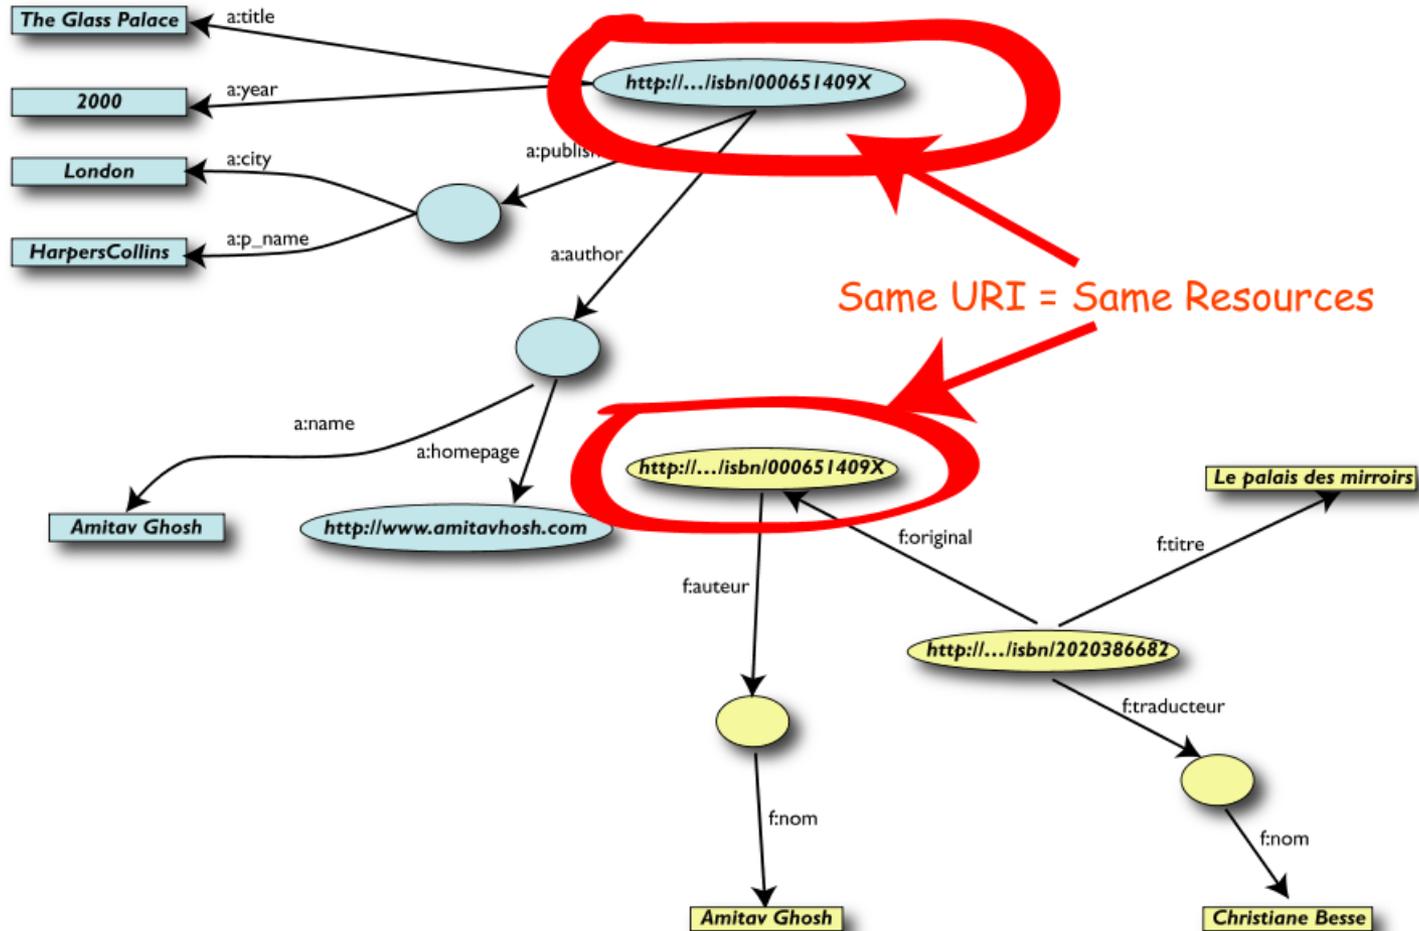
Secondo passo: esportare il secondo insieme di dati



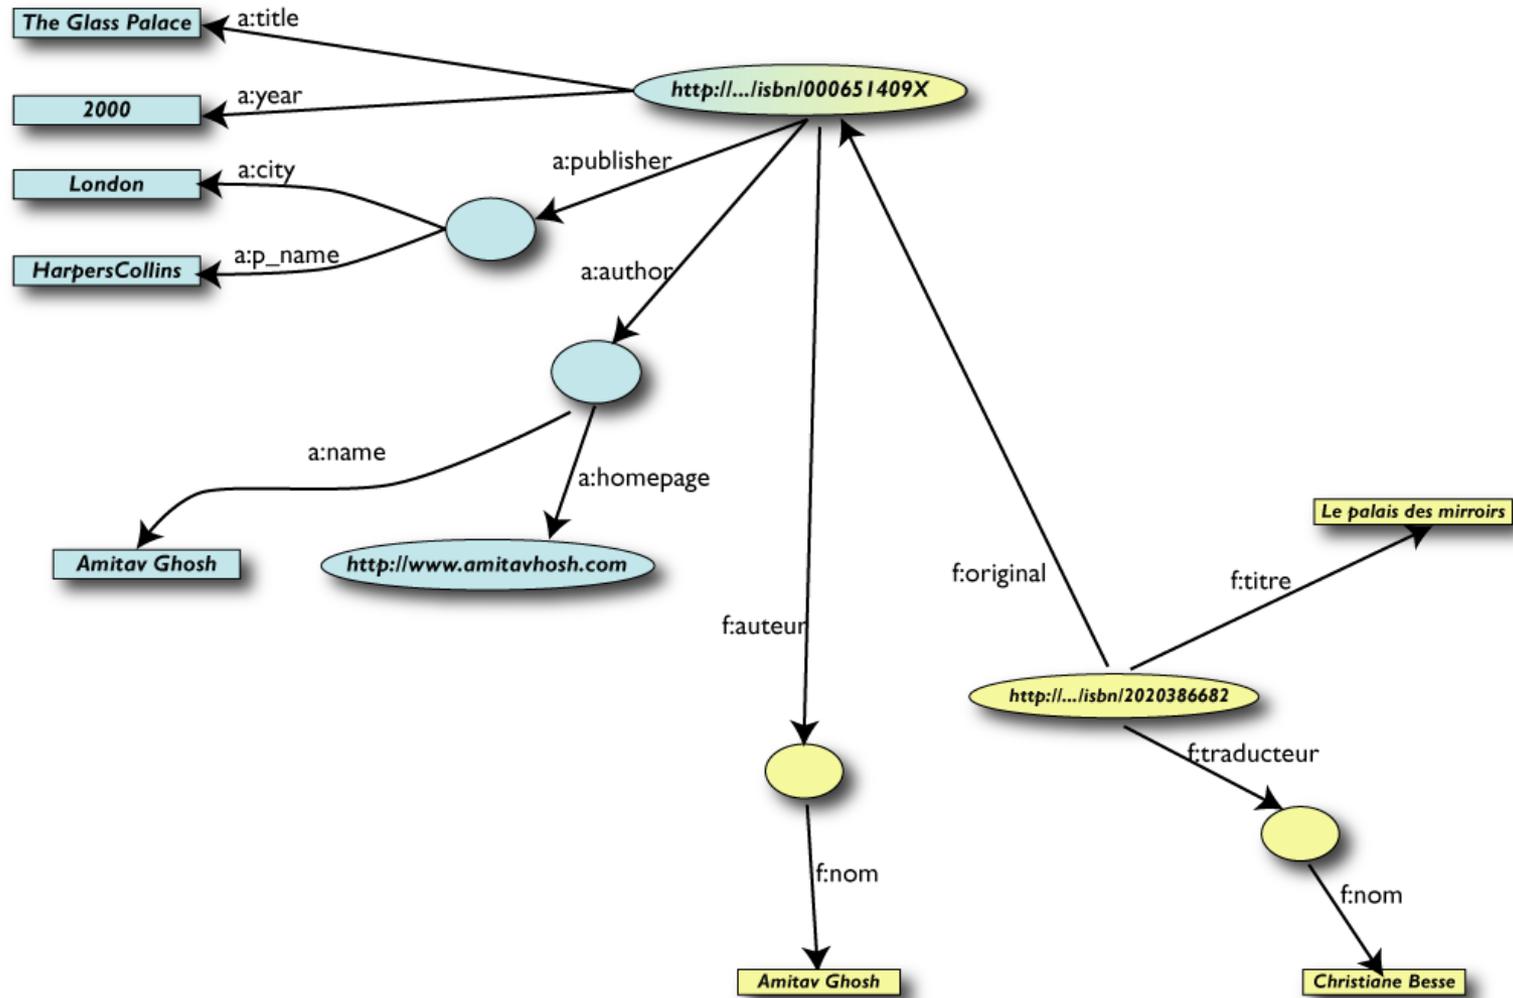
Terzo passo:merging dei dati



Terzo passo:merging dei dati

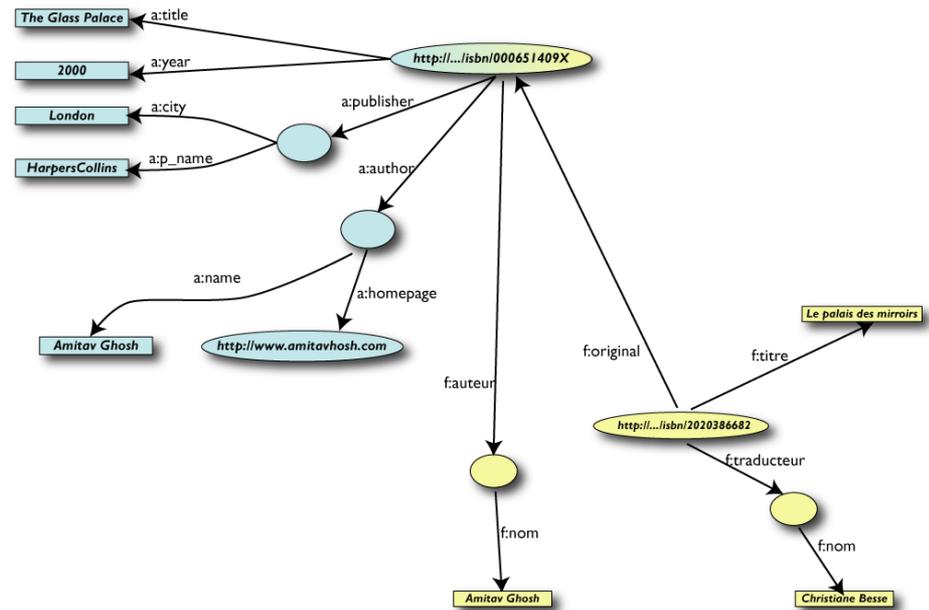


Merging delle risorse identiche



Le Query più semplici...

- ❖ L'utente dei dati "F" può ora formulare query del tipo: *"donnes-moi le titre de l'original"* o *"give me the title of the original"*
- ❖ Questa informazione non è nel dataset "F" ...
- ❖ ...ma può essere ritrovata grazie al merging con il dataset "A"!

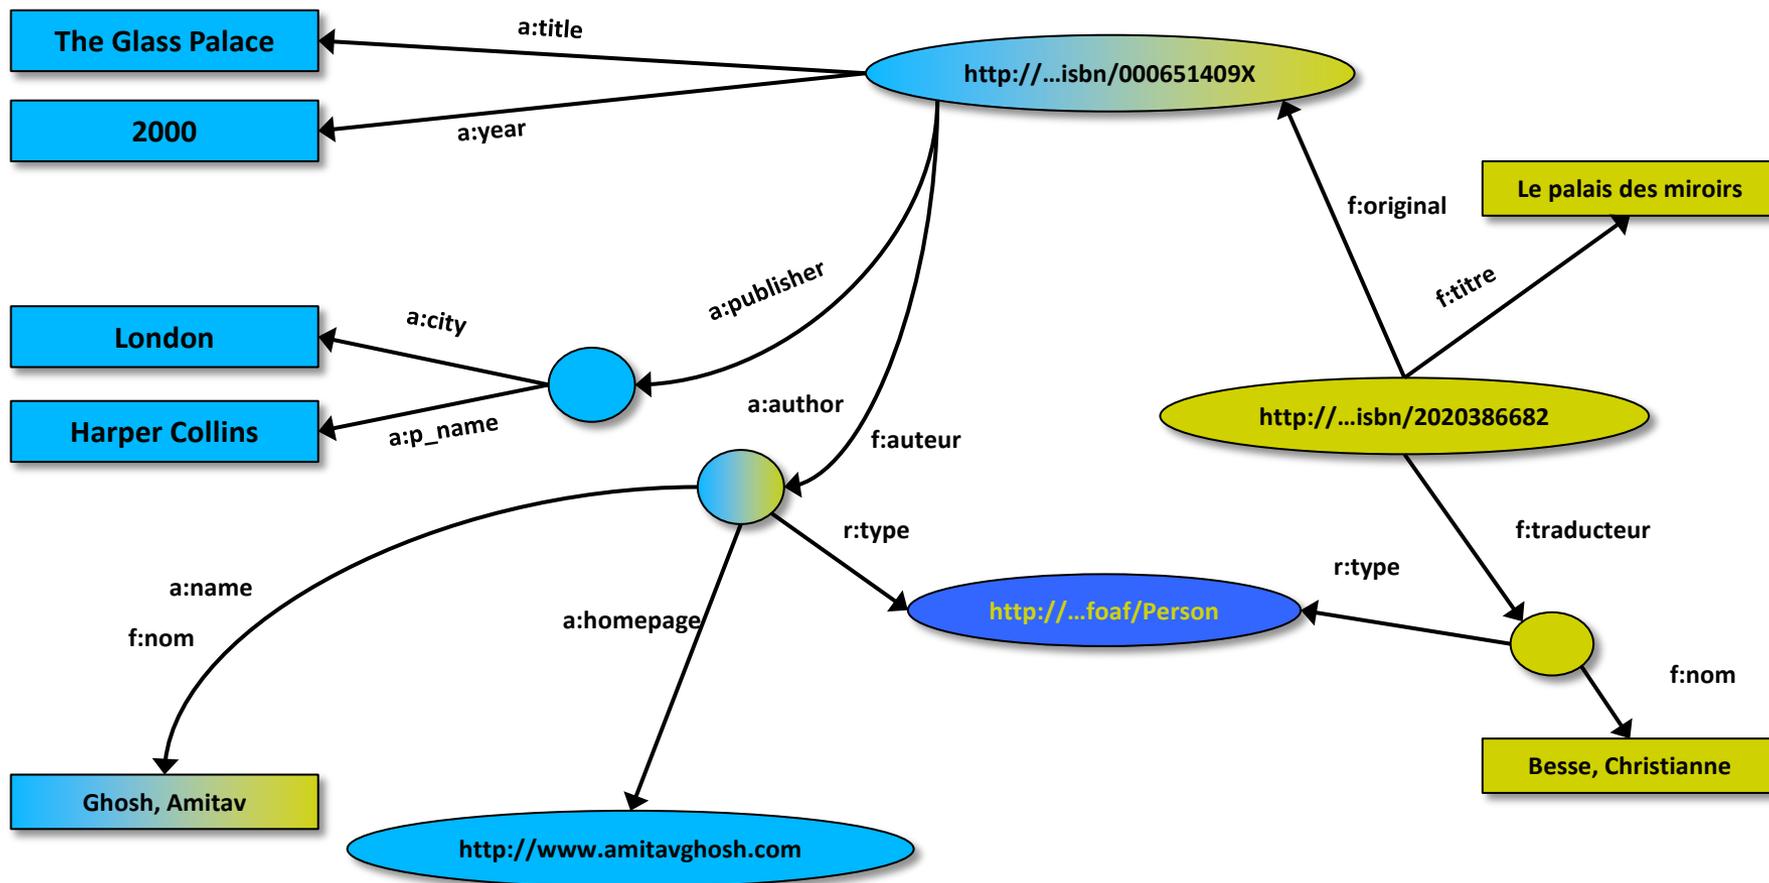


...ma si può avere di più...

- ❖ Abbiamo la "*sensazione*" che a:author e f:auteur siano la stessa cosa
- ❖ Ma un *processo automatico* non se ne può accorgere!
- ❖ Aggiungiamo un po' di *informazione addizionale* ai dati combinati:
 - ✓ a:author same as f:auteur
 - ✓ entrambi identificano una "*Person*", che è un termine che una comunità può aver già definito:
 - una "*Person*" è definita univocamente dal suo nome e email, o codice fiscale
 - può essere usato come "*categoria*" per certi tipi di risorse
- ❖ e si può utilizzare la conoscenza extra *unendo altri grafi...*

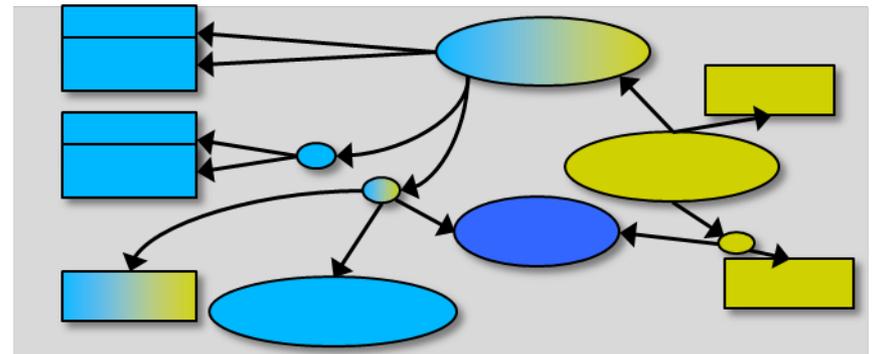


Usiamo la conoscenza "extra"



Query più "ricche"

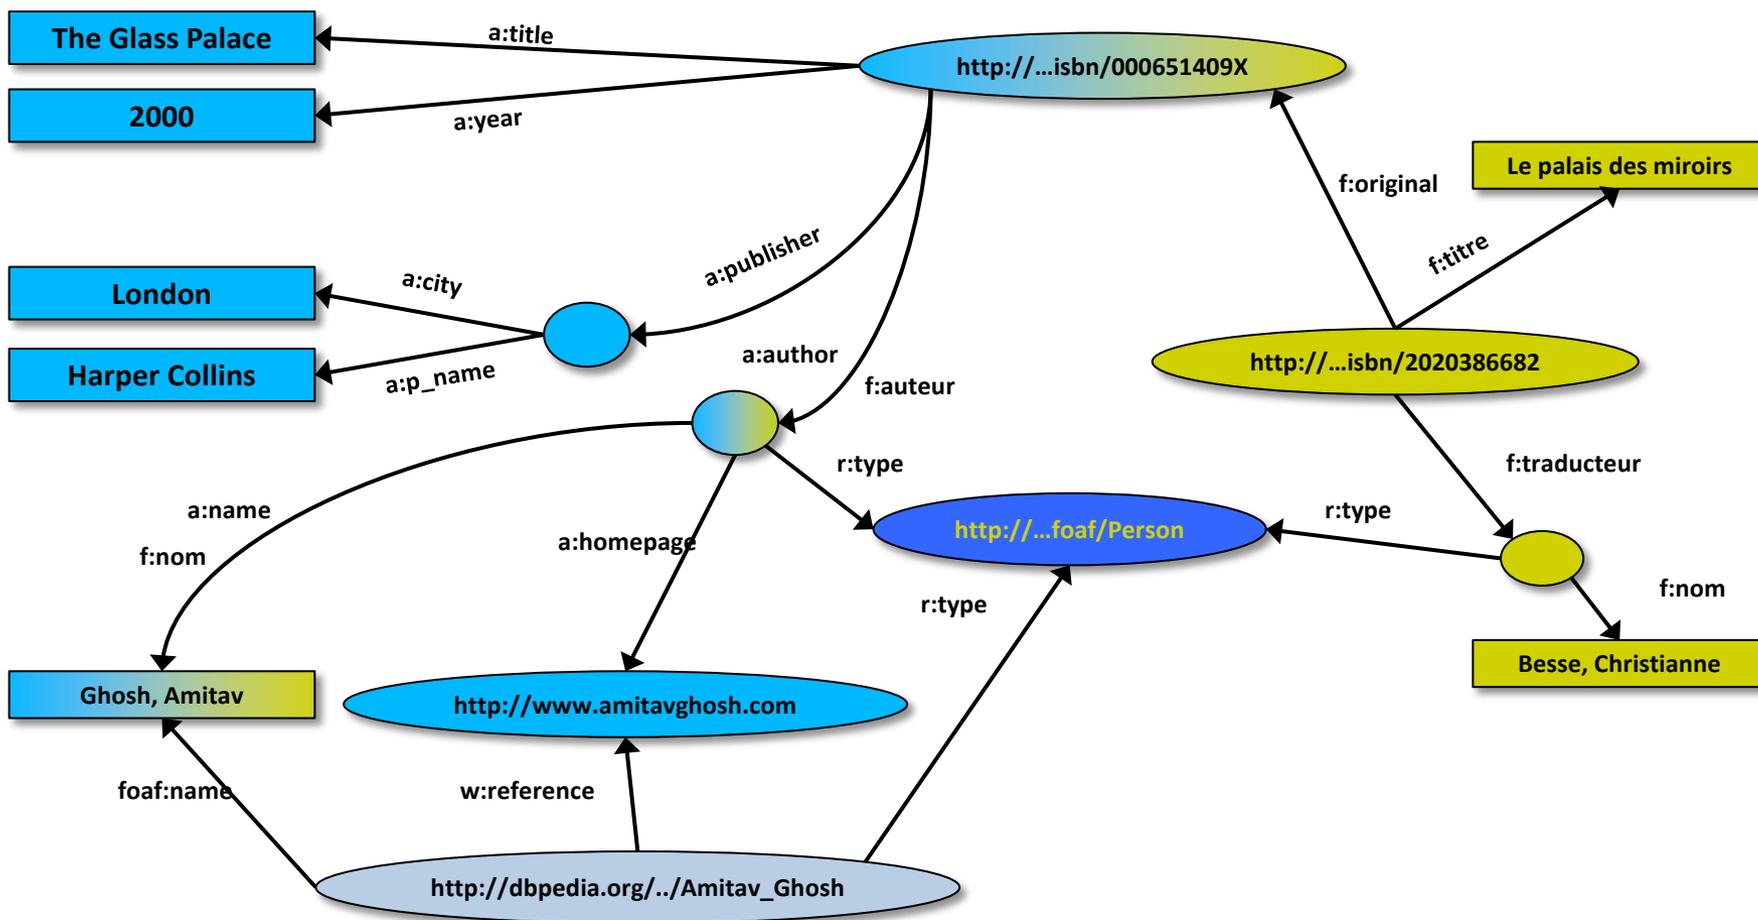
- ❖ L'utente del dataset "F" può ora chiedere:
 - ✓ "donnes-moi la page d'accueil de l'auteur de l'original"
 - cioè... "dammi la homepage dell'autore dell'originale"
- ❖ L'informazione non è né nel dataset "A" né nel dataset "..."
- ❖ ...ma è stata resa accessibile grazie al processo di:
 - ✓ merge dei dataset "A" e "F"
 - ✓ aggiunta di tre semplici statement che fungono da "collante"



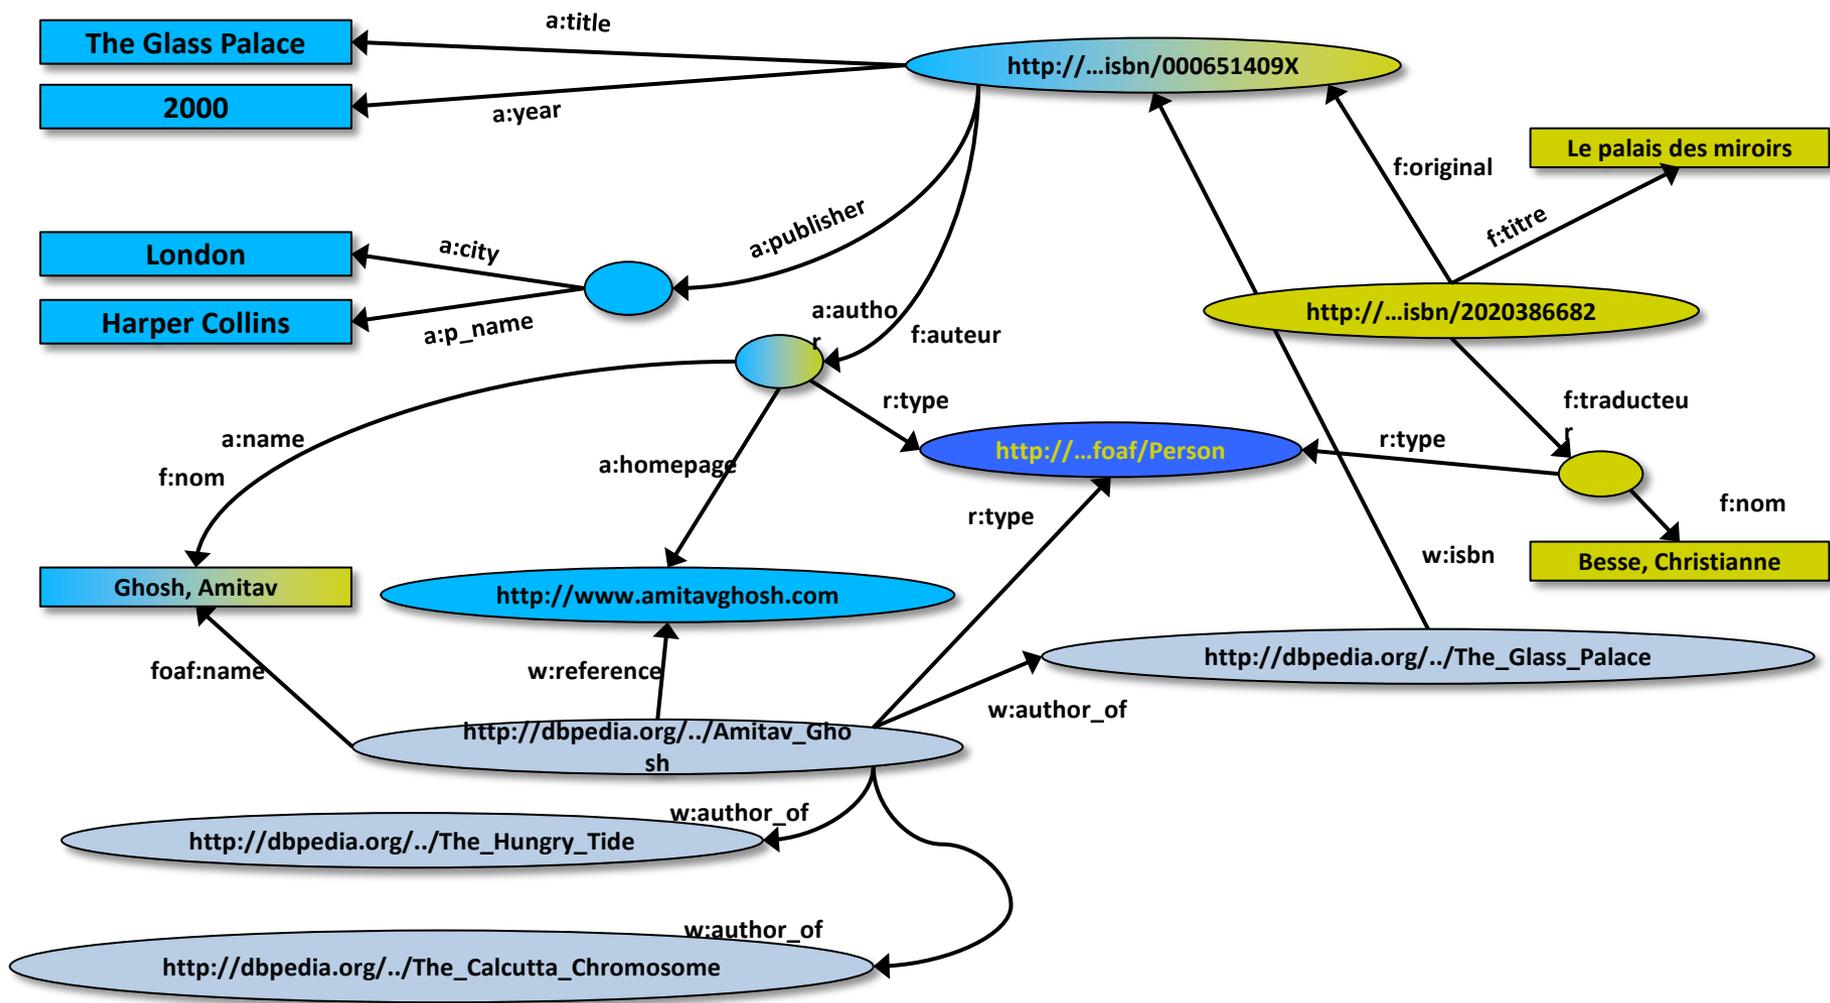
Combiniamo altri dataset

- ❖ Per esempio, usando “Person”, il dataset può essere combinato con altre sorgenti di dati
- ❖ Per esempio, è possibile estrarre i dati contenuti in Wikipedia utilizzando alcuni tool, specifici
 - ✓ il progetto “[dbpedia](#)” può già estrarre l’informazione “infobox” da Wikipedia

Combiniamo con i dati di Wikipedia



Combiniamo con i dati di Wikipedia



Sorpresi?

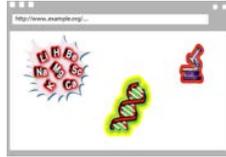
- ❖ Forse, ma in realtà no
- ❖ È esattamente quanto avviene normalmente a tutti gli utenti del Web (ma in questo caso grazie a un processo *automatico*)
- ❖ La **differenza**: è necessario un po' più di rigore (per es. **dare un nome** alle associazioni) perché le macchine possano riuscirci

In realtà...

- ❖ Abbiamo combinato dataset diversi
 - ✓ ognuno di essi può provenire da un *qualunque sito web*
 - ✓ possono avere originariamente *formati differenti* (MySQL, fogli excel, XHTML, etc)
 - ✓ possono avere *nomi diversi per le relazioni* (multilinguismo)
- ❖ Li abbiamo potuti combinare perché avevano *lo stesso URI* (l' ISBN nell' esempio)
- ❖ Possiamo aggiungere *conoscenza addizionale*, utilizzando terminologie comuni definite dalle varie comunità
- ❖ Di conseguenza, è stato possibile identificare e utilizzare *nuove relazioni*

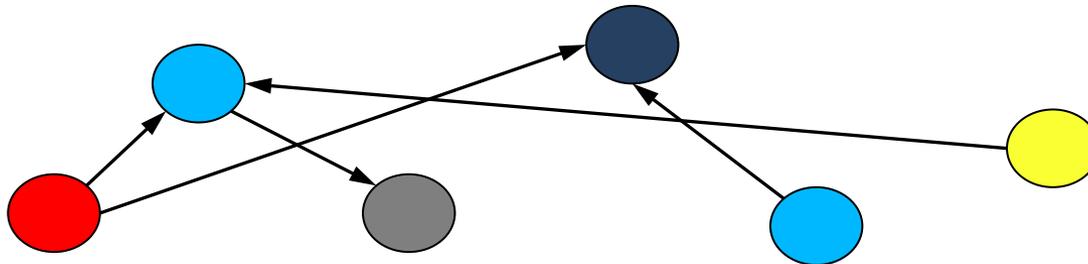


Cosa abbiamo fatto?



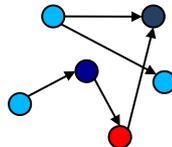

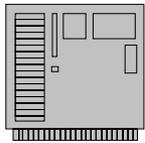
Applications

↑ Manipulate
Query
...



Data represented in abstract format

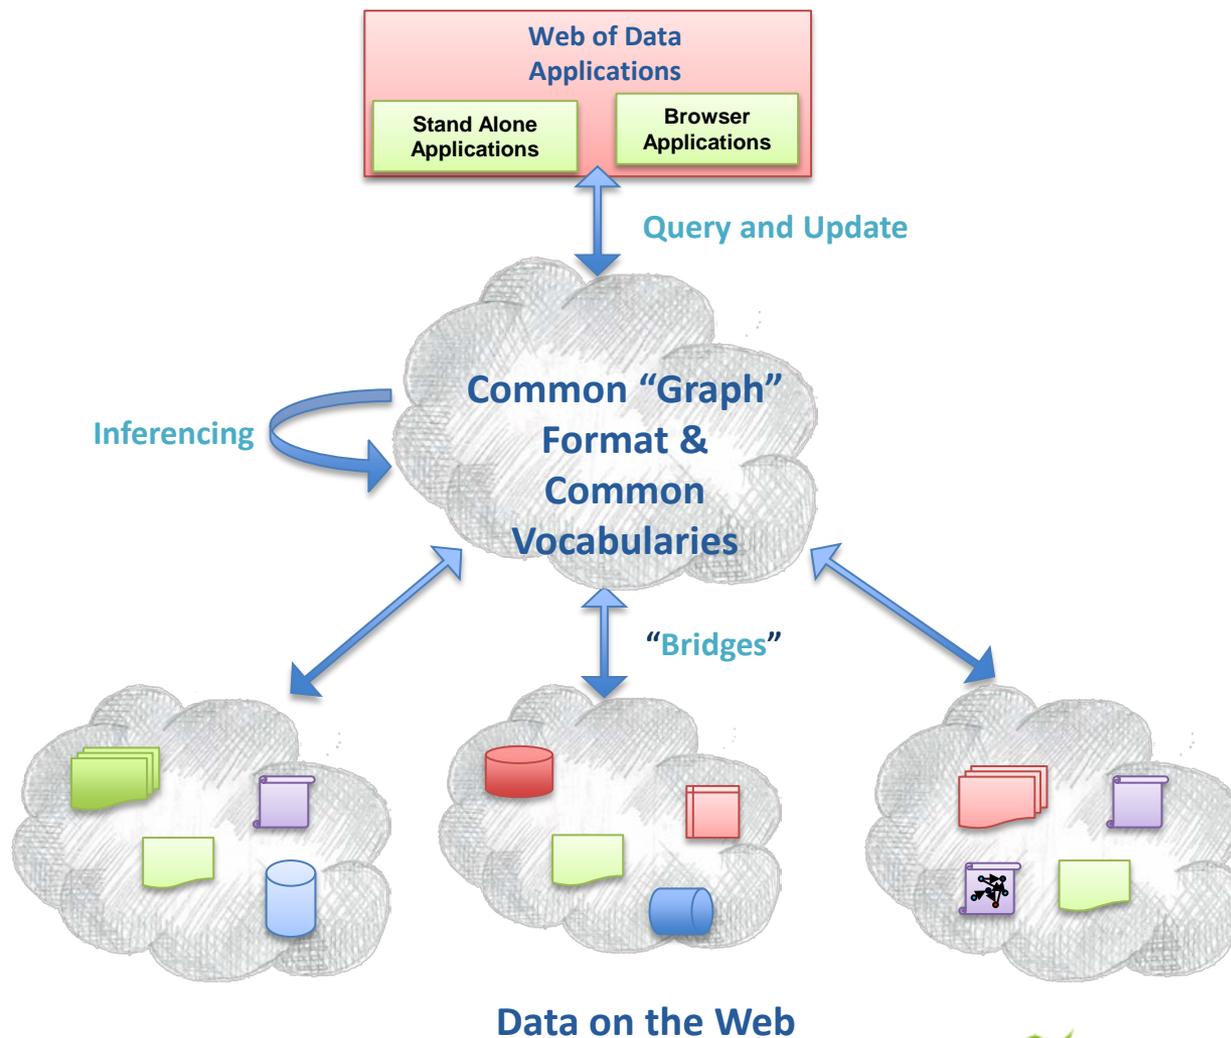
↑ Map,
Expose,
...



Data in various formats



Cosa abbiamo fatto? (un'altra visione)



I vantaggi del processo di astrazione...

- ❖ ... la rappresentazione come grafo è indipendente dalle strutture reali sottostanti
- ❖ ... modifiche a database schema, strutture XHTML, etc. non hanno impatto sul complesso:
 - ✓ “schema independence”
- ❖ ... possono essere aggiunti, senza soluzione di continuità, nuovi dati o nuove connessioni
 - ✓ flessibilità, espandibilità



"Effetto network"

- ❖ Esteso ai dati sul Web
- ❖ Mediante gli URI possiamo collegare **qualunque** dato a **qualunque** altro



E il processo può essere anche più ricco

- ❖ La conoscenza addizionale può essere anche molto complessa
- ❖ È qui che entrano in gioco le **ontologie**, le **regole**, etc.
- ❖ Il processo di **astrazione** è vantaggioso perché la rappresentazione come **grafo** è indipendente dalle strutture dati sottostanti

E il Semantic Web?

- ❖ **Il Semantic Web fornisce le tecnologie che rendono possibile questa integrazione!**
 - ✓ **lo scopo di questo tutorial è appunto quello di fornire unquadro complessivo...**



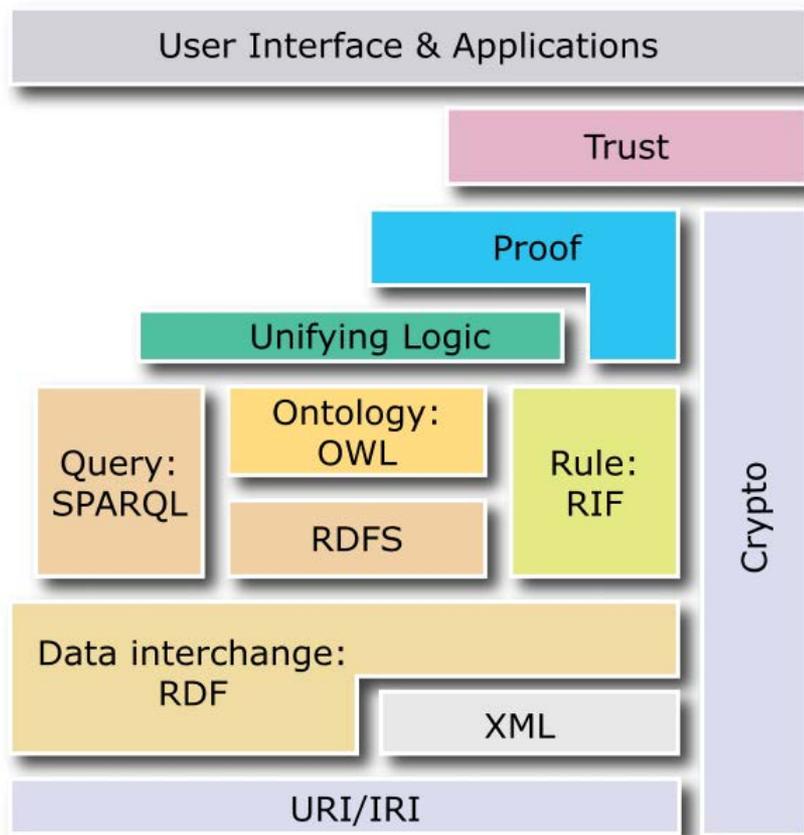
L'architettura del Semantic Web

❖ Il Semantic Web ...

- ✓ è un' infrastruttura basata su metadati per poter svolgere *ragionamenti* sul Web
- ✓ *estende*, non sostituisce il web attuale

❖ I metadati sono:

- ✓ Informazioni, elaborabili automaticamente (*machine understandable*), relative a una risorsa web o a qualche altra cosa
- ✓ ... *data about data*
- ✓ ... informazioni che possono essere utilizzate da *intelligent software agents* per fare un uso appropriato delle risorse
- ✓ ... *dati* ...
- ✓ ... che possono essere *descritti da altri metadati* ...





Perché i metadati?

- ❖ Nel Web di oggi tutte le informazioni sono "***machine readable***"
- ❖ Nel Semantic Web le informazioni devono essere "***machine understandable***".
Quindi occorrono:
 - ✓ ***nomi non ambigui*** per le risorse (URI)
 - ✓ un ***data model condiviso*** per esprimere i metadati (RDF)
 - ✓ un modo per ***accedere ai metadati*** sul Web
 - ✓ ***vocabolari condivisi (ontologie)***



❖ Decentralizzazione

❖ Gli elementi fondamentali

✓ URI

- L'innovazione più fondamentale del Web
- Possono identificare qualunque cosa (risorse, concetti)

✓ HTTP

- Format negotiation
- Protocollo per recuperare le risorse (fetch resources)

✓ HTML

- Strutturazione dei documenti

❖ RDF (**R**esource **D**escription **F**ramework)

- ✓ è per il **Semantic Web** ciò che **HTML** è stato per il **Web**



Cosa è RDF?

- ❖ L' uso efficace dei metadati richiede la definizione di convenzioni per:
 - ✓ **semantica** (definita dalle singole comunità disciplinari)
 - ✓ **sintassi** (organizzazione dei data element per l' elaborazione automatica)
 - ✓ **struttura** (vincolo formale sulla sintassi)
- ❖ **RDF:**
 - ✓ *Resource Description Framework*
 - ✓ strumento base per **codifica, scambio e riutilizzo** di metadati strutturati
 - ✓ consente l' **interoperabilità** tra applicazioni che si scambiano sul Web informazioni **machine-understandable**

RDF è per il Semantic Web ciò che HTML è stato per il web





Triple RDF

❖ Formalizzando quanto abbiamo fatto:

- ✓ Abbiamo “collegato” i dati...
- ✓ Ma il semplice collegamento non è sufficiente:
 - occorre **assegnare un nome** ai dati
- ✓ Ecco come nascono le triple RDF:
 - Una connessione etichettata tra due risorse





Triple RDF (cont.)

- ❖ **Le risorse possono usare un qualunque URI**
 - ✓ `http://www.example.org/file.html#home`
 - ✓ `http://www.example.org/f.xml#xpath(//q[@a=b])`
 - ✓ `http://www.example.org/form?a=b&c=d`
- ❖ **Le triple RDF costituiscono un grafo diretto (o grafo orientato) etichettato (directed, labeled graph)**
 - ✓ (è questo il modo migliore di considerarle!)





Triple Rdf (cont.)

- ❖ Una tripla RDF (s,p,o) è definita in modo che:
 - ✓ "s", "p" sono URI, cioè risorse sul Web; "o" è un URI o un "literal"
 - ✓ dal punto di vista concettuale: "p" *collega*, o *mette in relazione* "s" e "o"
 - ✓ si noti che vengono utilizzati URI per denotare i nomi: per esempio, possiamo utilizzare <http://www.example.org/original>
 - ✓ ecco la codifica completa della tripla:
`<http://...isbn 6682>, <http://.../original>, <http://...isbn 409X>`
- ❖ **RDF** è un modello generale per queste triple (con un formato machine readable come RDF/XML, Turtle, n3, RXR)
 - ✓ *ed è tutto qui! (semplice, dopo tutto)*

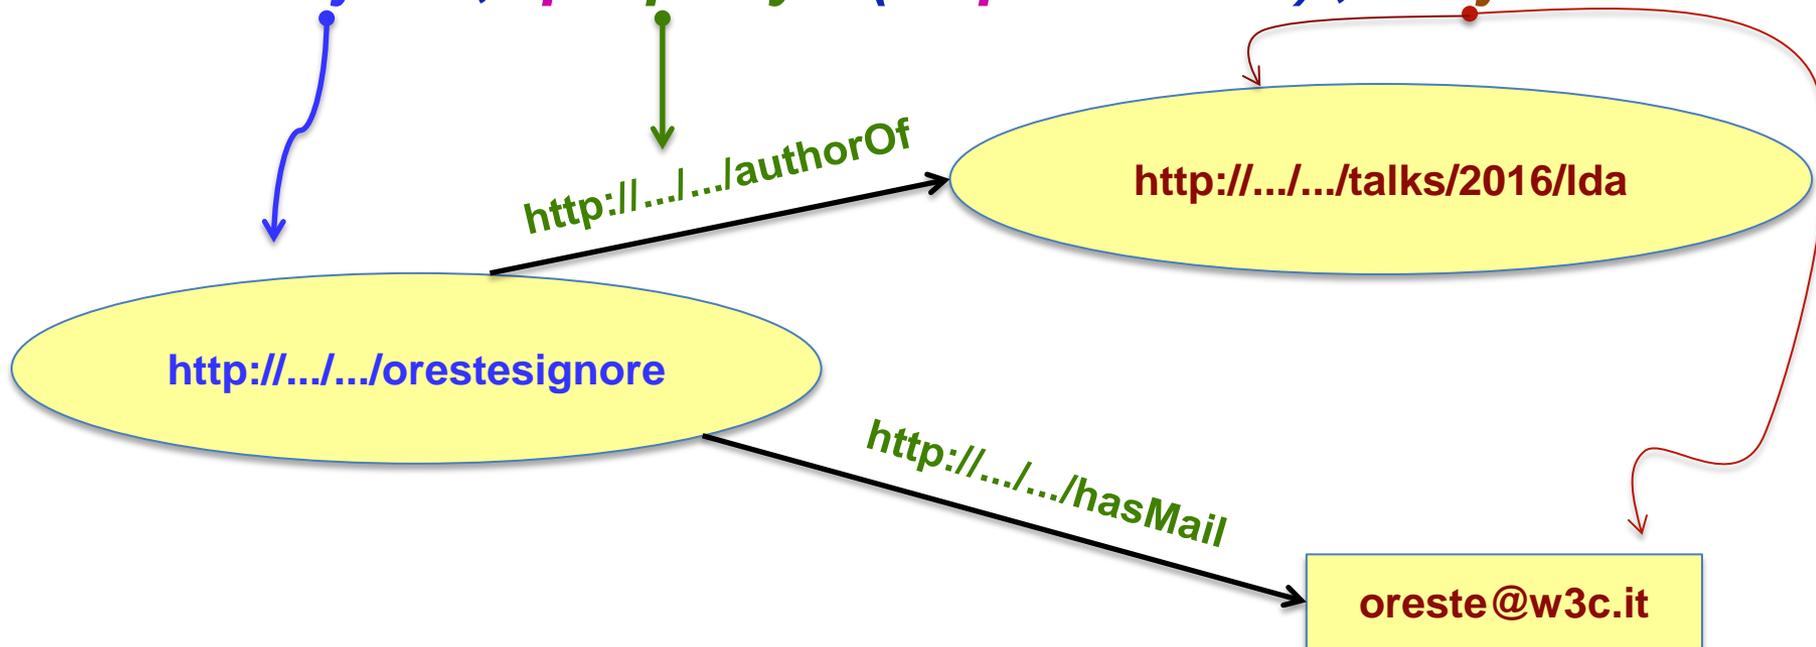




RDF in due parole

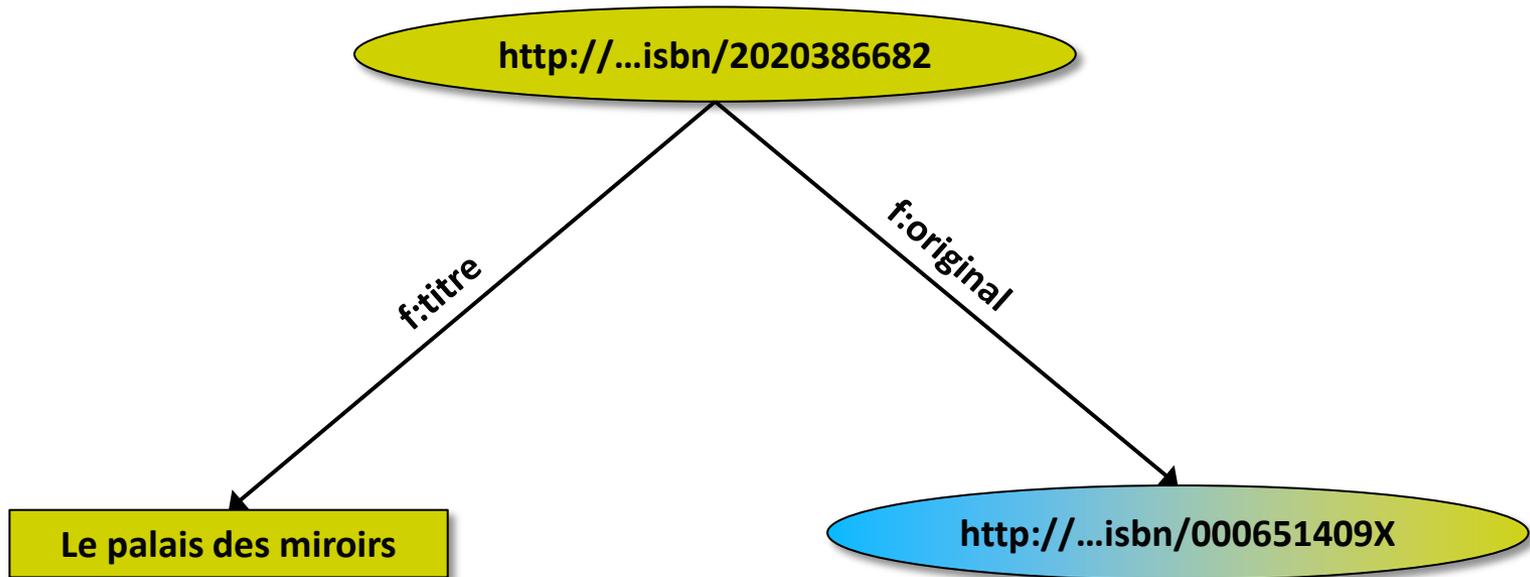
❖ Una tripla RDF (s,p,o)

✓ "subject", "property" (o "predicate"), "object"





Un esempio semplice (in RDF/XML)



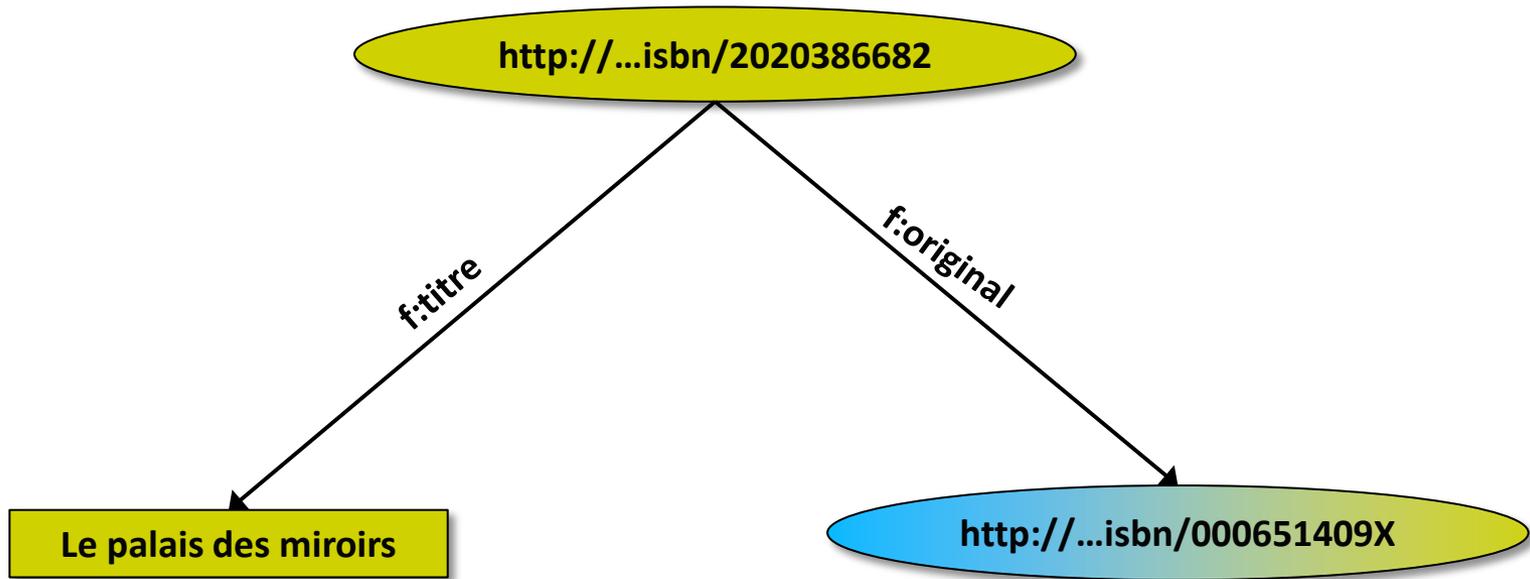
```
<rdf:Description rdf:about="http://.../isbn/2020386682">  
  <f:titre xml:lang="fr">Le palais des miroirs</f:titre>  
  <f:original rdf:resource="http://.../isbn/000651409X"/>  
</rdf:Description>
```

(Nota: per semplificare gli URI sono stati usati I namespace)





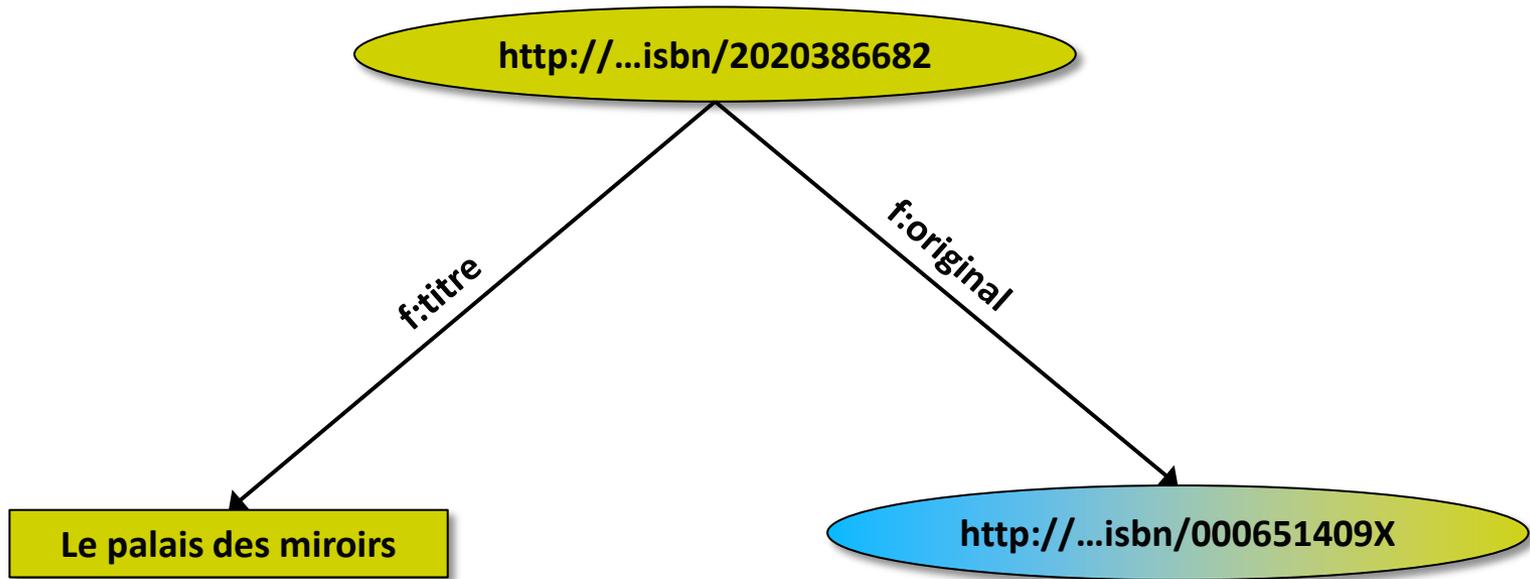
Un esempio semplice(in Turtle)



```
<http://.../isbn/2020386682>  
  f:titre "Le palais des miroirs"@fr ;  
  f:original <http://.../isbn/000651409X> .
```



Un esempio semplice (in RDFa)



```
<p about="http://.../isbn/2020386682">The book entitled  
"<span property="f:title" lang="fr">Le palais des miroirs</span>"  
is the French translation of the  
"<span rel="f:original" resource="http://.../isbn/000651409X">Glass  
Palace</span>"</p> .
```



Quale sintassi?

- ❖ La sintassi (RDF/XML, Turtle) è semplicemente ***sintassi***
- ❖ La cosa importante sono il ***modello*** sottostante e i ***concetti***
- ❖ Non tratteremo in dettaglio gli aspetti sintattici (abbiamo comunque già visto alcuni esempi in Turtle e in RDF/XML)
 - ✓ si tratta di trasformazioni meccaniche, ben documentate e supportate da molti tool



Il ruolo fondamentale degli URI

- Gli URI hanno reso possibile il *merge*
- ***Chiunque*** può creare (meta)dati su *qualsunque* risorsa sul Web, per esempio:
 - lo stesso file XHTML può essere annotato con altri termini
 - è possibile *aggiungere semantica* alle risorse Web esistenti utilizzando URI
 - gli URI rendono possibile *collegare (con proprietà)* i dati tra di loro
- ***Gli URI sono la base del ruolo di RDF nel Web***
 - si può reperire l'informazione utilizzando tool già esistenti
 - per questo motivo il "Semantic Web", è il ... "Semantic Web"



URI, URL, URN ...

❖ URI

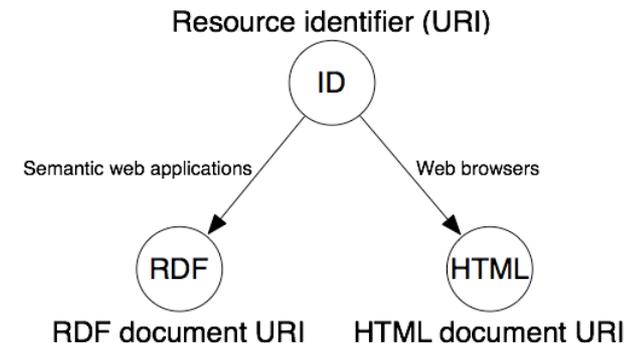
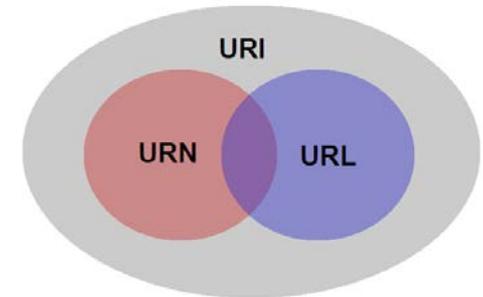
- ✓ Uniform Resource Identifier
- ✓ stringa che identifica univocamente una risorsa generica
 - può essere un indirizzo Web, un documento, un'immagine, un file, un servizio, un indirizzo di posta elettronica, etc.

❖ URL

- ✓ Uniform Resource Locator
- ✓ URI che, oltre a identificare una risorsa, fornisce mezzi per agire su di essa o per ottenere una rappresentazione della risorsa descrivendo il suo meccanismo di accesso primario o la sua "ubicazione" ("location") in una rete

❖ URN

- ✓ Uniform Resource Name
- ✓ URI che identifica una risorsa mediante un "nome" in un particolare dominio di nomi ("namespace").
 - può essere usato per parlare di una risorsa senza lasciar intendere la sua ubicazione o come ottenerne una rappresentazione.
 - per esempio l'URN `urn:isbn:0-395-36341-1` è un URI che consente di individuare univocamente un libro mediante il suo nome `0-395-36341-1` nel namespace dei codici ISBN, ma non suggerisce dove e come possiamo ottenere una copia di tale libro



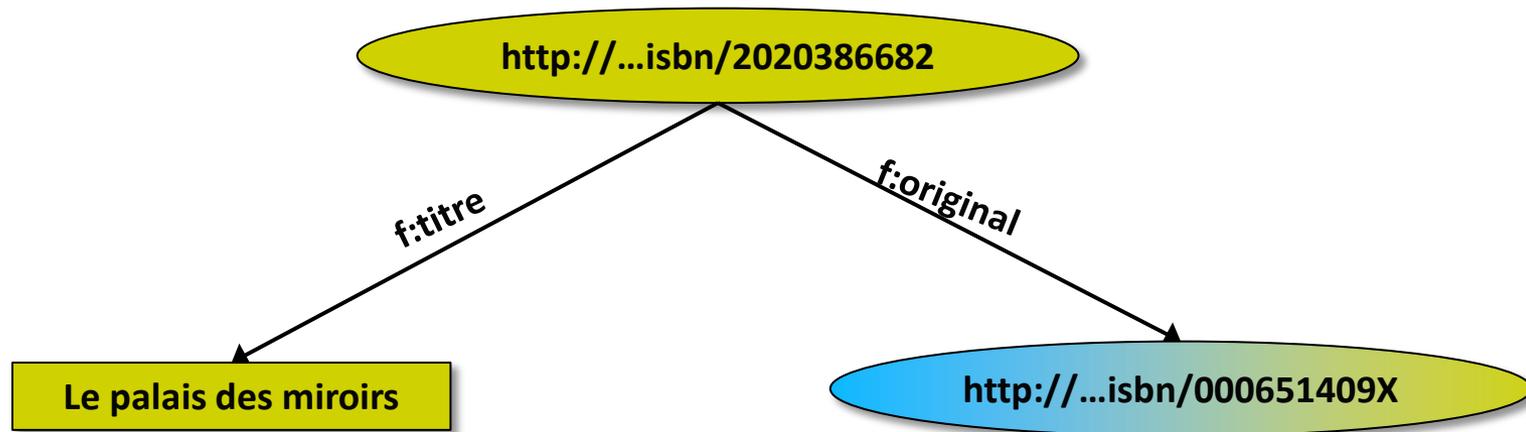
Cool URI don't change!

<https://www.w3.org/TR/cooluris/>





RDF/XML: principi



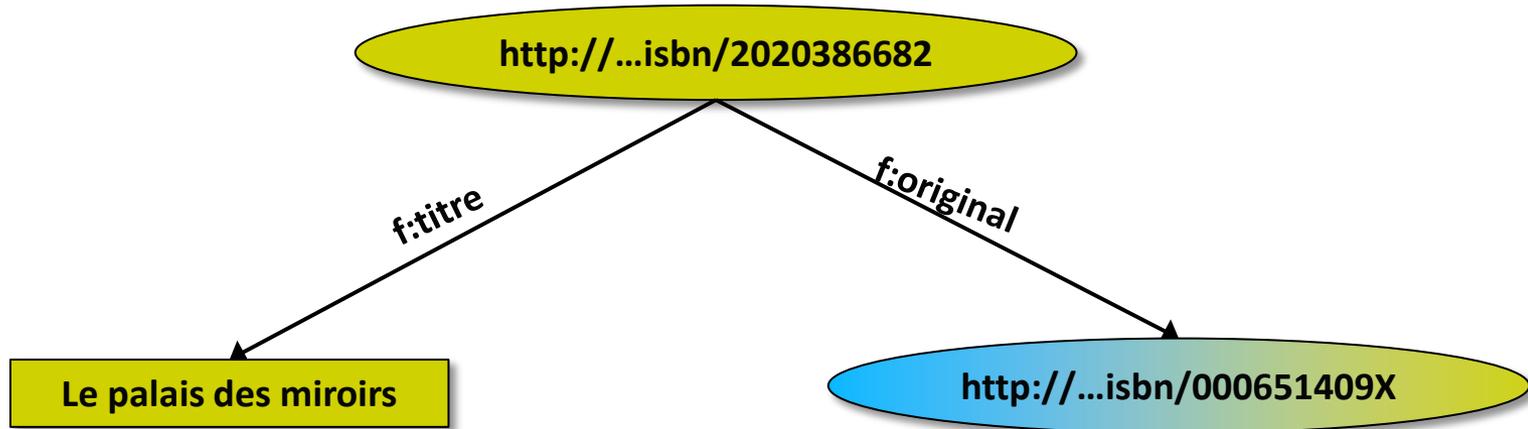
❖ Codificare nodi e archi come elementi o “literal”

```
<<Element for http://.../isbn/2020386682>>
  <<Element for original>>
    <<Element for http://.../isbn/000651409X>>
  </Element for original>
</Element for http://.../isbn/2020386682>
<<Element for http://.../isbn/2020386682>>
  <<Element for titre>>
    Le palais des miroirs
  </Element for titre>
</Element for http://.../isbn/2020386682>
```





RDF/XML: principi (cont.)



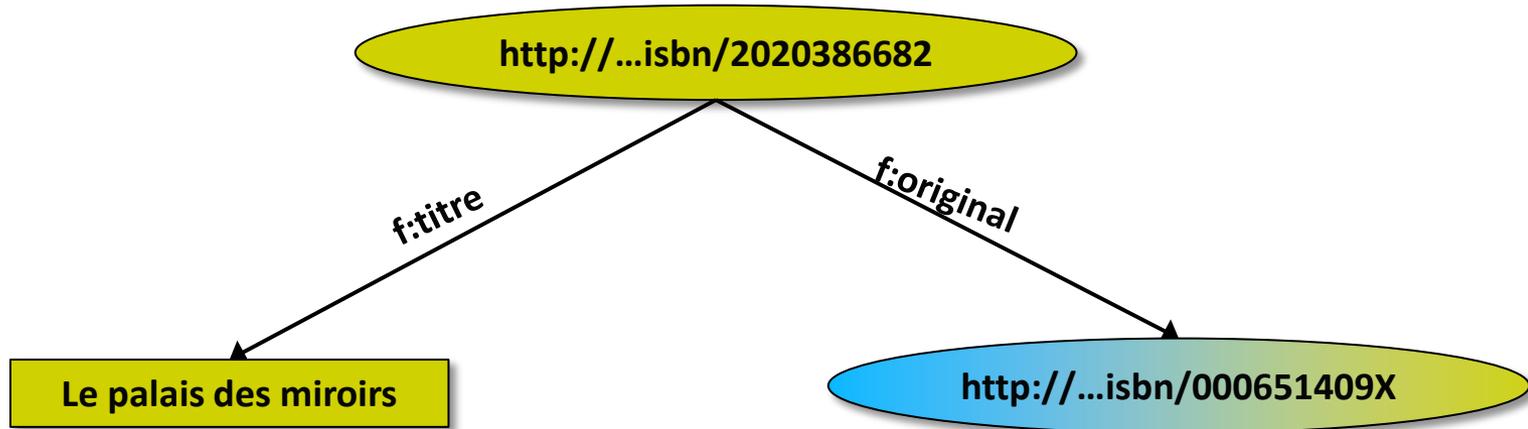
❖ Codificare le risorse (cioè i nodi)

```
<rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#">
  <rdf:Description rdf:about="http://.../isbn/2020386682">
    «Element for original»
    <rdf:Description rdf:about="http://.../isbn/000651409X"/>
    «/Element for f:original»
  </rdf:Description>
</rdf:RDF>
```





RDF/XML: principi (cont.)



❖ Codificare le proprietà (cioè gli archi) nei rispettivi namespace

```
<rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
  xmlns:f="http://www.editeur.fr">
  <rdf:Description rdf:about="http://.../isbn/2020386682">
    <f:original>
      <rdf:Description rdf:about="http://.../isbn/000651409X"/>
    </f:original>
  </rdf:Description>
</rdf:RDF>
```





Nodi "interni"

❖ Consideriamo lo statement:

✓ "l'editore è una **"cosa"** cha ha un nome e un indirizzo"

❖ Abbiamo identificato i nodi mediante URI.

Però:

✓ ...qual è l'URI di **"cosa"**?





Una soluzione: creare un URI «extra»

- ❖ La risorsa sarà visibile sul web
 - ✓ attenzione a definire URI univoci!

```
<rdf:Description rdf:about="http://.../isbn/000651409X">  
  <a:publisher rdf:resource="urn:uuid:f60ffb40-307d-..."/>  
</rdf:Description>  
<rdf:Description rdf:about="urn:uuid:f60ffb40-307d-...">  
  <a:p_name>HarpersCollins</a:p_name>  
  <a:city>HarpersCollins</a:city>  
</rdf:Description>
```



Identificatori **interni** (blank node)

❖ Risorsa non visibile all'esterno

```
<rdf:Description rdf:about="http://.../isbn/000651409X">  
  <a:publisher rdf:nodeID="A234" />  
</rdf:Description>  
<rdf:Description rdf:nodeID="A234">  
  <a:p_name>HarpersCollins</a:p_name>  
  <a:city>HarpersCollins</a:city>  
</rdf:Description>
```

```
<http://.../isbn/2020386682> a:publisher _:A234.  
_:A234 a:p_name "HarpersCollins".
```





E se lasciassimo fare tutto al sistema?

❖ Il sistema provvederà a creare internamente un “nodeID”

✓ non dovremo preoccuparci del nome...

```
< <rdf:Description rdf:about="http://.../isbn/000651409X">
  <a:publisher>
    <rdf:Description>
      <a:p_name>HarpersCollins</a:p_name>
      ...
    </rdf:Description>
  </a:publisher>
</rdf:Description>
```





...in Turtle

```
<http://.../isbn/000651409X> a:publisher [  
  a:p_name "HarpersCollins";  
  ...  
].
```





Riflessioni sui blank node

- ❖ **Nel processo di merging occorre prestare attenzione ai blank node**
 - ✓ i blank node con lo stesso ID in grafi diversi sono differenti
 - ✓ le implementazioni devono considerare attentamente questo fatto ...
- ❖ **Molte applicazioni preferiscono non utilizzare i blank node, e definire nuovi URI “on-the-fly”**
- ❖ **Dal punto di vista della logica, i blank node rappresentano uno statement (proposizione) “esistenziale”**
 - ✓ “esiste una risorsa tale che...”





Reification

❖ Per poter certificare la credibilità di un certo **statement**, è necessario poter formulare **statements about statements**

❖ Questo processo viene detto **reification** nella comunità che si interessa di Knowledge Representation

```
exproducts:item10245  exterms:weight  "2.4"^^xsd:decimal .
```

```
exproducts:triple12345  rdf:type      rdf:Statement .  
exproducts:triple12345  rdf:subject   exproducts:item10245 .  
exproducts:triple12345  rdf:predicate  exterms:weight .  
exproducts:triple12345  rdf:object    "2.4"^^xsd:decimal .
```





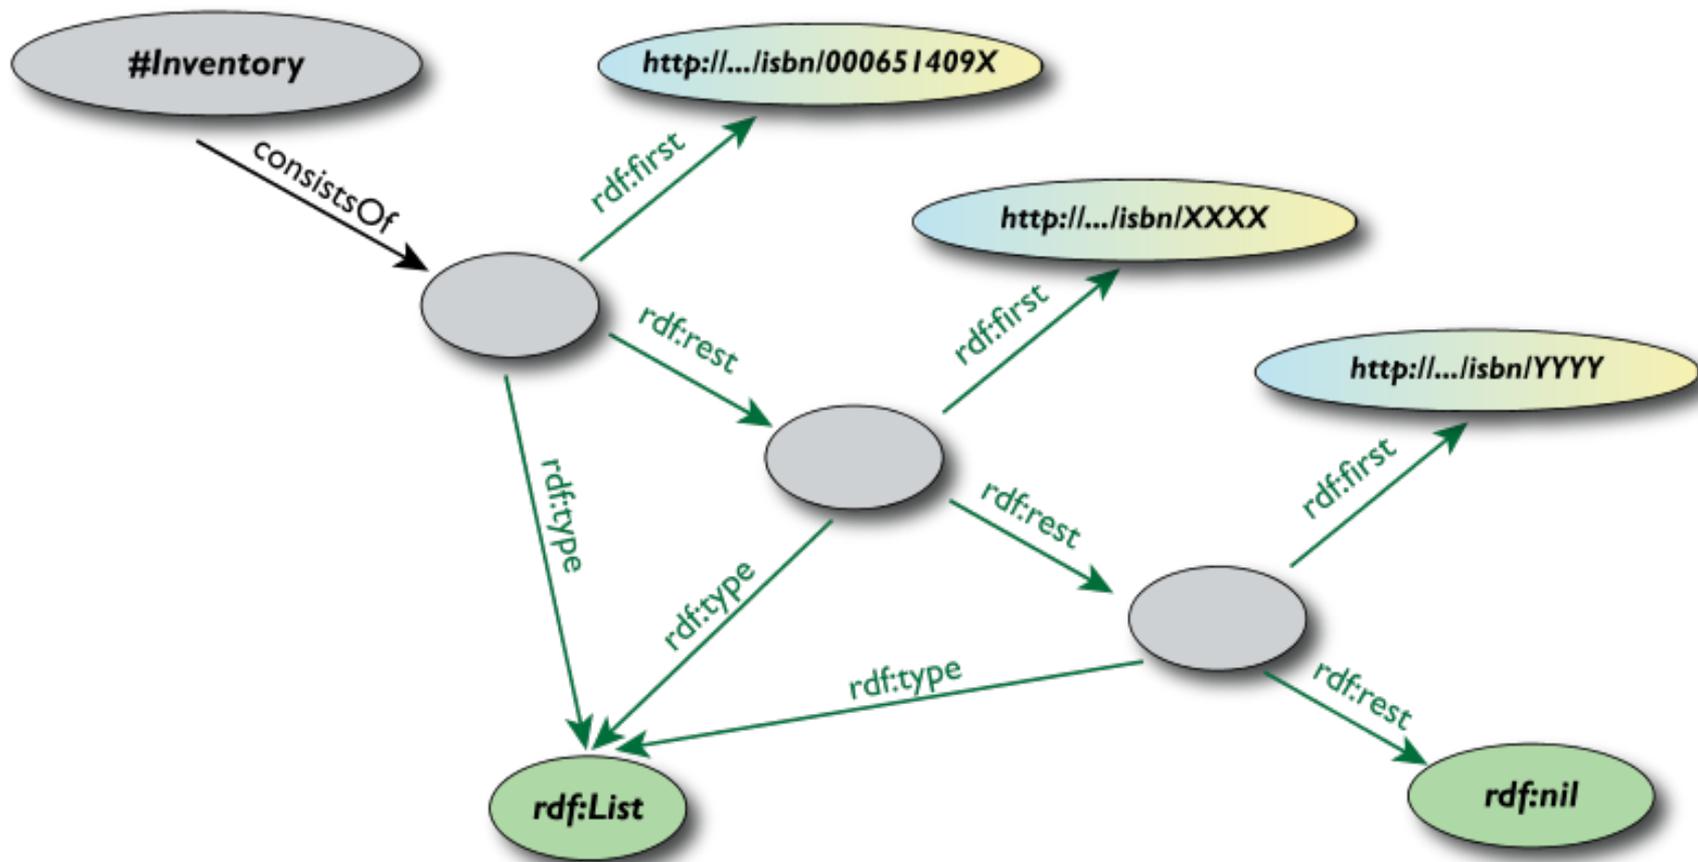
Collezioni (liste)

- ❖ **Potremmo avere degli statement del tipo:**
 - ✓ “Il catalogo dei libri è una “cosa” che consiste di:
<<http://.../isbn/000651409X>>,
<<http://.../isbn/000XXXX>>, ...”
- ❖ **Ma vogliamo elencare gli elementi esattamente in quell’ordine**
- ❖ **I “blank node” non sono adeguati**





Collezioni (liste) (cont.)

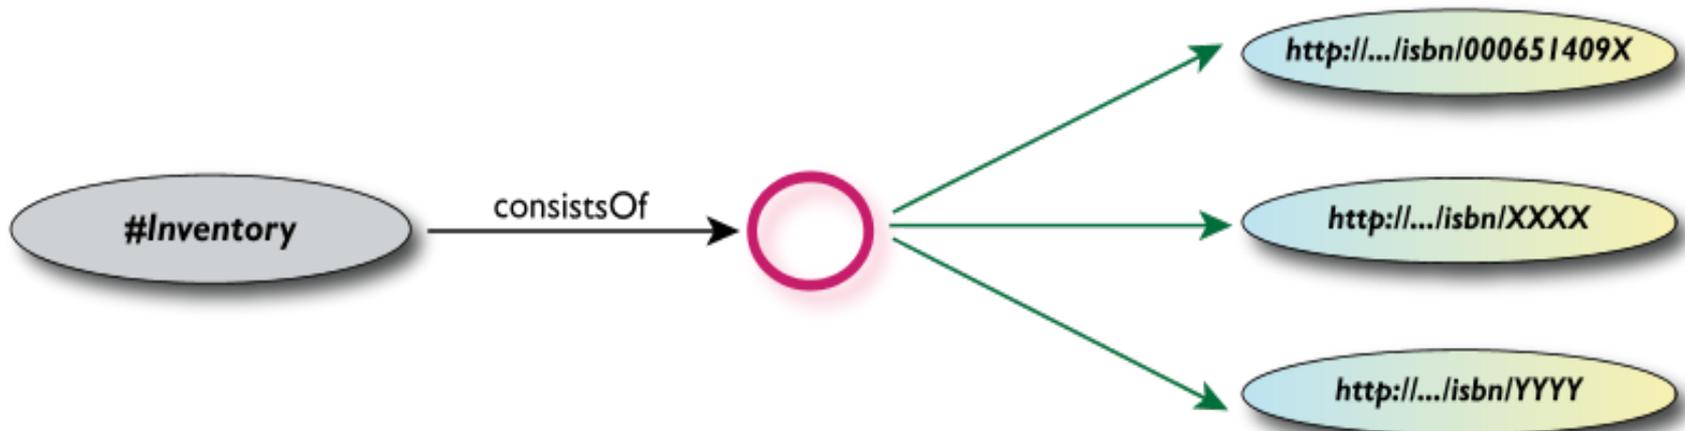




...in RDF/XML e Turtle

```
<rdf:Description rdf:about="#Inventory">  
  <a:consistsOf rdf:parseType="Collection">  
    <rdf:Description rdf:about="http://.../isbn/000651409X"/>  
    <rdf:Description rdf:about="http://.../isbn/XXXX"/>  
    <rdf:Description rdf:about="http://.../isbn/YYYY"/>  
  </a:consistsOf>  
</rdf:Description>
```

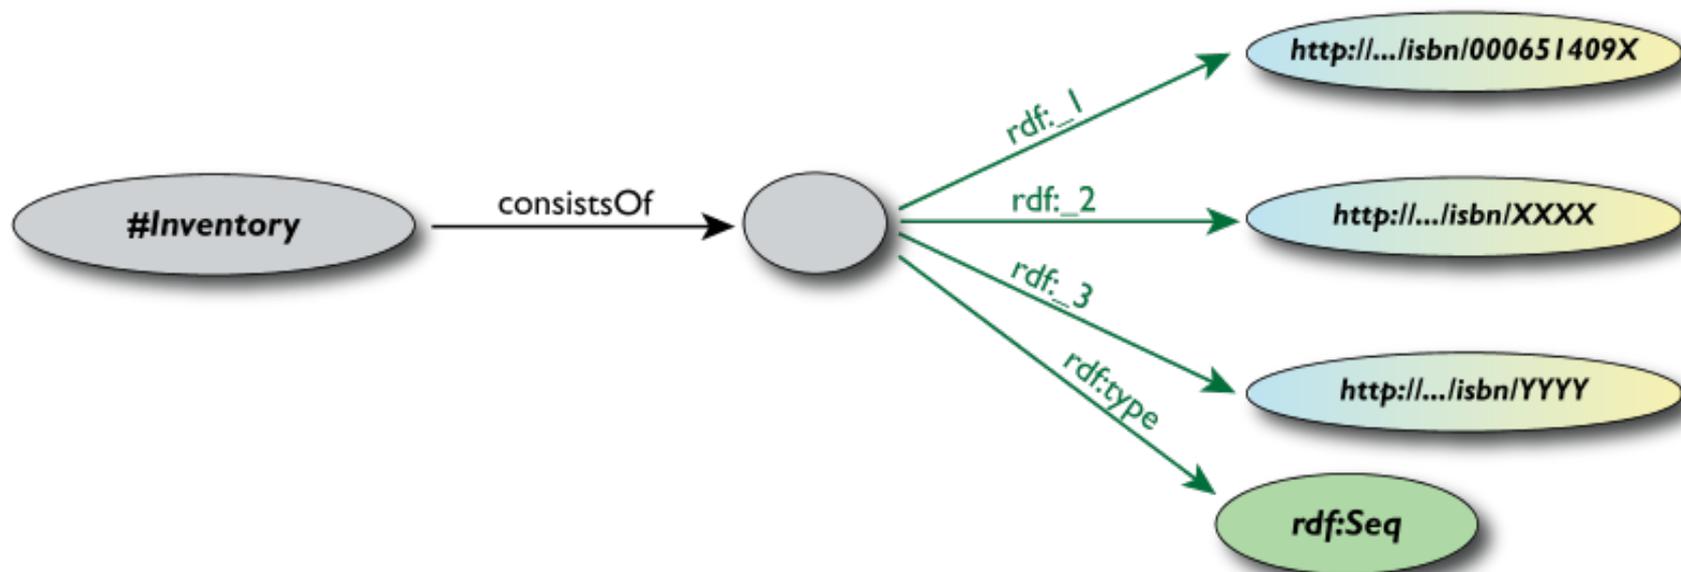
```
:Inventory a:consistsOf  
(<http://.../isbn/000651409X> <http://.../isbn/XXXX> ...)
```





Sequence

- ❖ Usare i costrutti predefiniti:
 - ✓ RDF Schema class Seq
 - ✓ RDF properties `rdf:_1`, `rdf:_2`, ...
- ❖ L'accordo sulla semantica è di contenuto sequenziale





Serializzazione delle Sequence

❖ In RDF/XML:

```
<rdf:Description rdf:about="#Inventory">
  <a:consistsOf>
    <rdf:Description>
      <rdf:type rdf:resource="http:...rdf-syntax-ns#Seq">
      <rdf:_1 rdf:resource="http://.../isbn/000651409X">
      ...
    </rdf:Description>
  </a:consistsOf>
</rdf:Description/>
```

❖ In Turtle

```
:Inventory
  a:consistsOf [
    rdf:type <http:...rdf-syntax-ns#Seq>;
    rdf:_1   <http://.../isbn/000651409X>;
    ...
  ].
```





Sequences (RDF/XML semplificato)

```
<rdf:Description rdf:about="#Inventory">
  <a:consistsOf>
    <rdf:Seq>
      <rdf:li rdf:resource="http://.../isbn/000651409X">
        ...
      </rdf:Seq>
    </a:consistsOf>
  </rdf:Description/>
```





Altri contenitori

❖ Definiti anche in RDFS

✓ **rdf:Bag**

- contenitore generico, senza una particolare semantica

✓ **rdf:Alt**

- accordo sulla semantica: solo uno dei costituenti è “valido”

❖ Nota: la definizione semantica di questi contenitori è incompleta:

✓ **meglio non utilizzarli...**

✓ **per i bag, utilizzare predicati ripetuti**

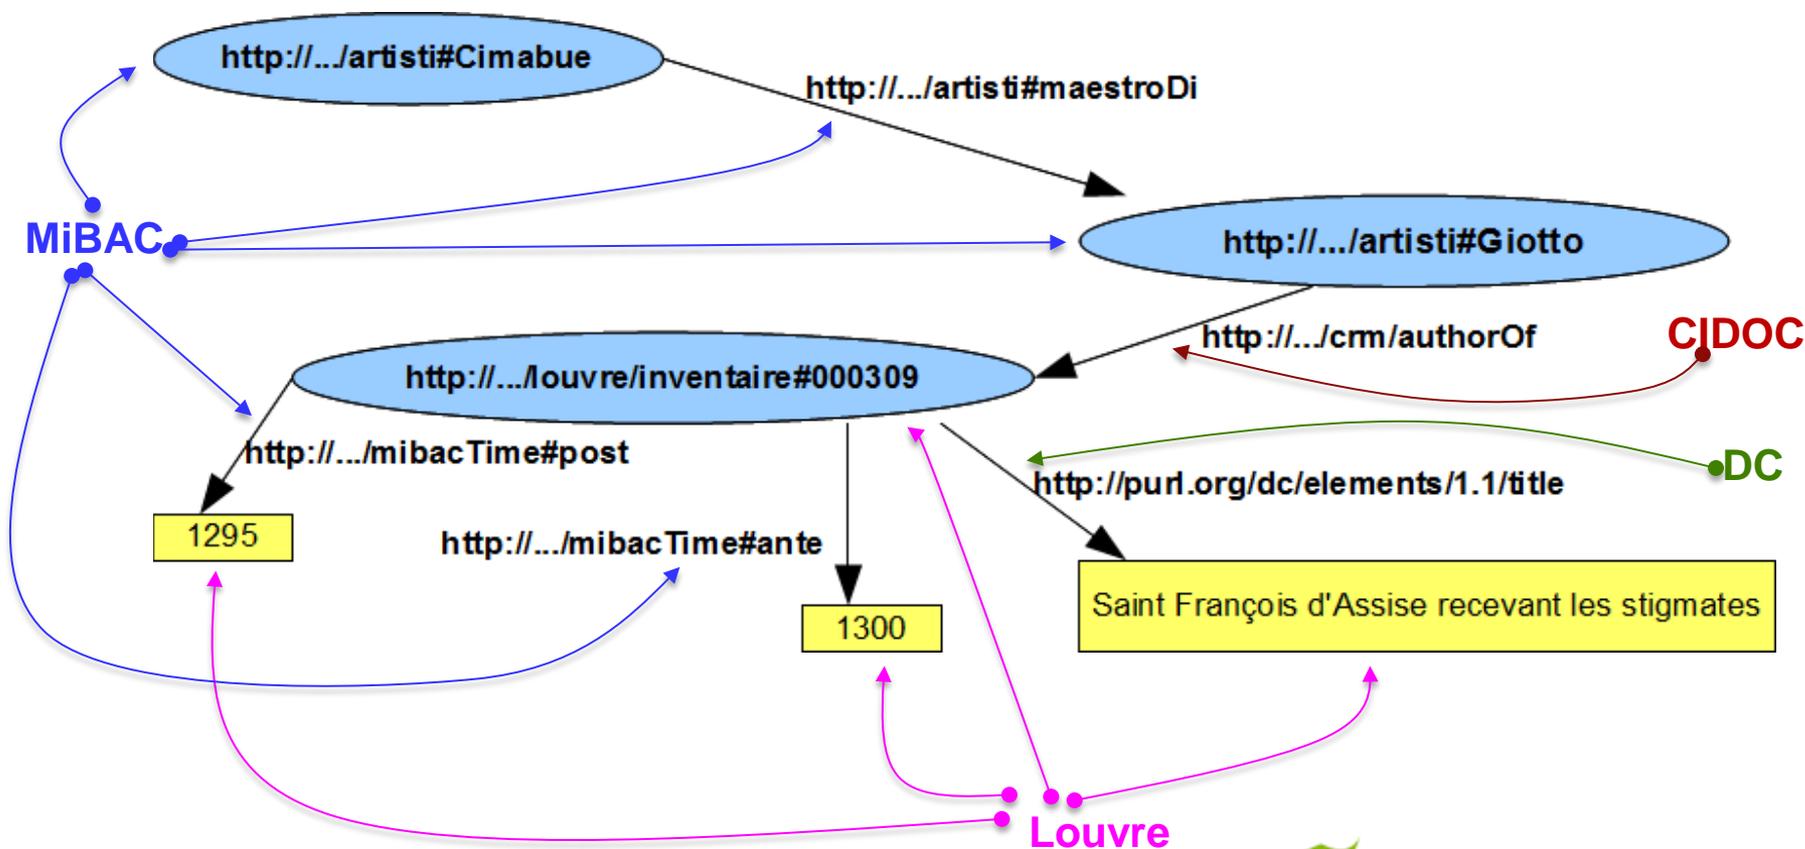
✓ **per le sequenze, usare le liste**





Un grafo RDF (WorldWide!)

...un insieme di triple s-p-o (subject-predicate-object)





Conclusioni

- ❖ Il Web è nato per **condividere conoscenza**
- ❖ **RDF** è la base
- ❖ Le tecnologie del **Semantic Web** costituiscono il quadro di riferimento

Grazie per
l'attenzione!

(Nobody's perfect!)



?

Domande

Slide a: www.orestesignore.eu/education/lda/slides/lda1.pdf

