XPath Optimization

Basi di dati 2

Luca Rossi
rossi@dia.uniroma3.it

Disheng Qiu
disheng.qiu@gmail.com

What kind of optimization?

- Physical optimization
  - Smart usage of physical structures
  - Storage strategies tailored to enable effective query evaluation.
- Logical optimization
  - *Equivalence* and *containment* between XPath queries.
  - Query rewriting in order to gain efficiency

Physical optimization

- What if a single document is *too big* to fit on a single disk page?
  - We have to fragment it into multiple pieces.
  - The way we do it affects query performances.

Fragmentation choices

- How could we fragment an XML document?
- Many choices:
  - Traversal-based (ex.: pre-order)
  - Store the document in **relations**. How?
    - Only one relation containing edges
    - A relation for each element
    - A relation for each path
- What are the **pros** and **cons**?
  - What factors should drive these decisions?

Questions that matter

- What are my **data access patterns**?
  - Do I need "wildcard" queries using * or // ?
  - Do I need updates?
  - Which are the most frequent queries?
    - I need to evaluate them efficiently

- What is the **structure** of my data?
  - What is the depth of the document tree?
  - How much structured is my data?

Traversal-based fragmentation

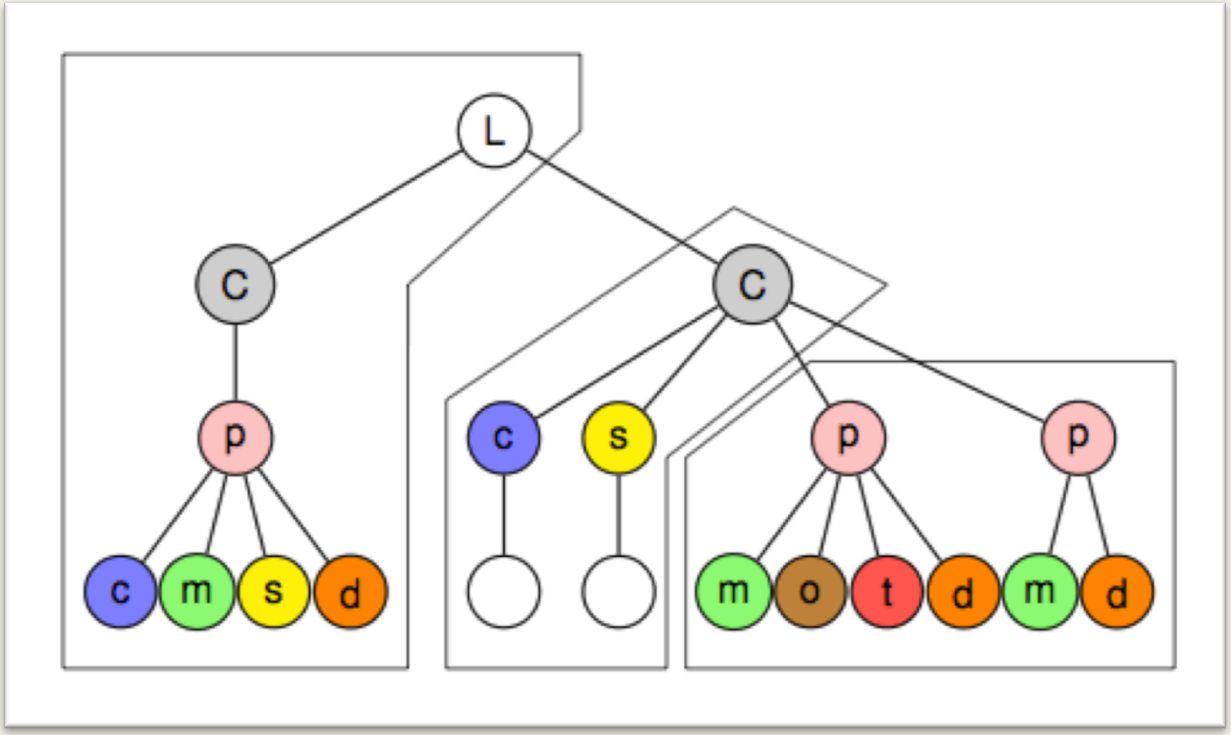

- A (pre-order) traversal groups as many nodes as possible within the current page
- When the page is full, a new page is used to store nodes encountered next

Traversal-based fragmentation

- Pros:
  - Simple and space-effective
  - It works regardless of the data structure

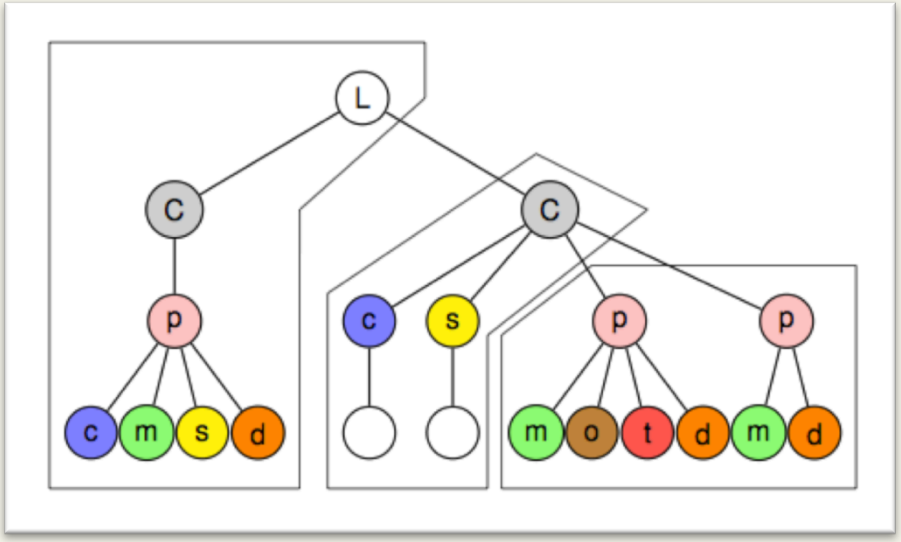

- Cons:
  - Unpredictable partitioning…
  - …leads to unpredictable performances
  - Updates are hard

Edge relation

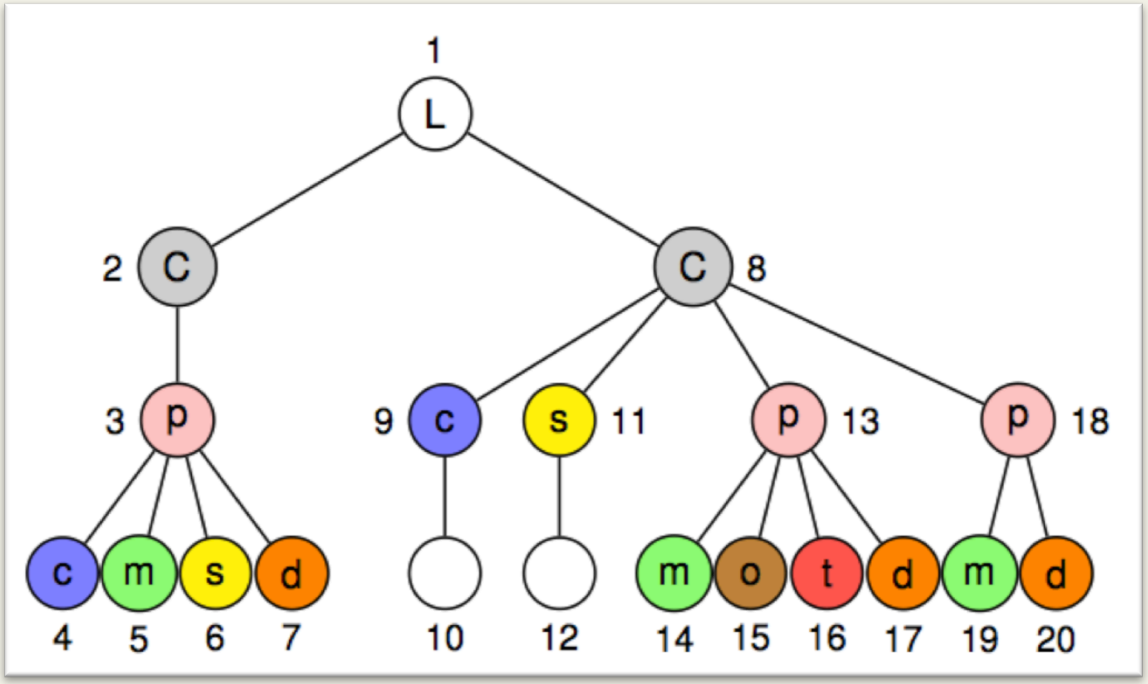

pid	cid	clabel
-	1	CD-library
1	2	CD
2	3	performance
3	4	composer
3	5	composition
3	6	soloist
3	7	date
1	8	CD
...	...	...

- Each node is given a unique identifier
- The document is stored as one relation representing a set of edges

Edge relation

- Pros:
  - Easy to add/remove nodes
  - Scalable (just add records)

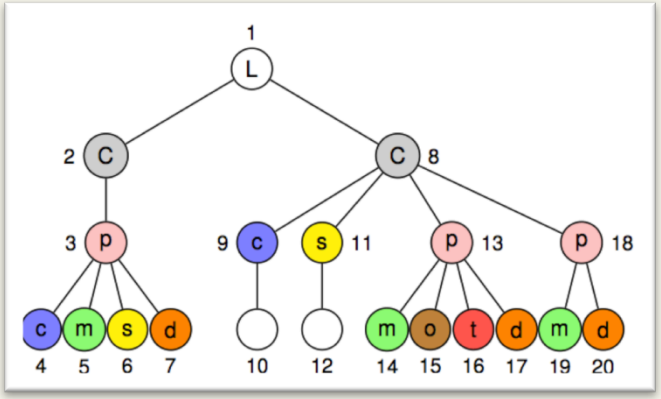

- Cons:
  - Queries may require many joins
  - One join for each level to be explored
    - /CD-library/CD/performance→ 2 joins
    - /CD-library//composer → ???

pid	cid	clabel
-	1	CD-library
1	2	CD
2	3	performance
3	4	composer
3	5	composition
3	6	soloist
3	7	date
1	8	CD
...	...	...

Element-partitioned edge relations

CD-library

pid	cid
-	1

CD

pid	cid
1	2
1	8

performance

pid	cid
2	3
8	13
8	18

composer

pid	cid
3	4
8	9

- Same as before, but one edge relation for each element

Element-partitioned edge relations

- Pros:
  - Saves some space
  - Saves the I/O needed to find elements with the same name (now grouped)
- Cons:
  - Queries still require many joins
  - Less scalable than before
    - A relation is added for each element name

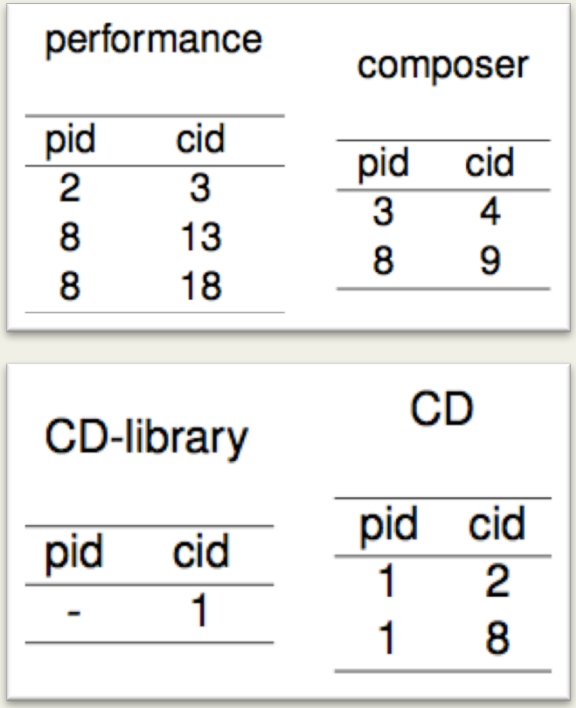

performance

pid	cid
2	3
8	13
8	18

composer

pid	cid
3	4
8	9

CD-library

pid	cid
-	1

CD

pid	cid
1	2
1	8

Path-partitioned fragmentation

/CD-library:

pid	cid
-	1

/CD-library/CD:

pid	cid
1	2
1	8

/CD-library/CD/composer:

pid	cid
3	4

/CD-library/CD/performance/composer:

pid	cid
8	9

path
/CD-library
/CD-library/CD
/CD-library/CD/performance
/CD-library/CD/performance/composer
...

- One relation for each distinct path in the document
- Another relation containing all unique paths

Path-partitioned fragmentation

- Pros:
  - Fast query evaluation (saves some joins)
    - 1) Scan the paths relation to identify matching paths
    - 2) For each such path, scan the corresponding relation
  - Good for structured data
- Cons:
  - Requires a relation for each path
    - Bad match for unstructured data
    - Hard to scale

Logical optimization

Logical optimization

- Rewriting queries exploiting two concepts:
  - Query containment
  - Query equivalence

- Goals:
  - Discover more efficient equivalent queries
  - Determine if views can be used
  - Reuse cached results from previous queries

Logical optimization

- Discover relations between queries:
  - Some are always true
  - Some are true only in specific settings (e.g. observing DTD)

- Ex.:
  1. //player
  2. /teams/team/players/player
  3. /teams/team/players/player[goals]

Tree patterns

- Given a Xpath query it is possible to define a tree pattern

- For /teams/team[sponsor= “Roma”]/players/player

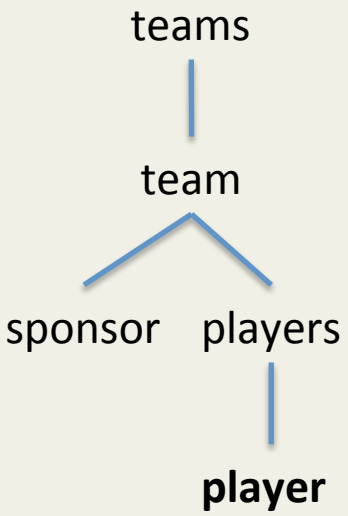

Tree patterns

- Why tree patterns?
- It is easy to observe when two query are equals and when one query is contained in another

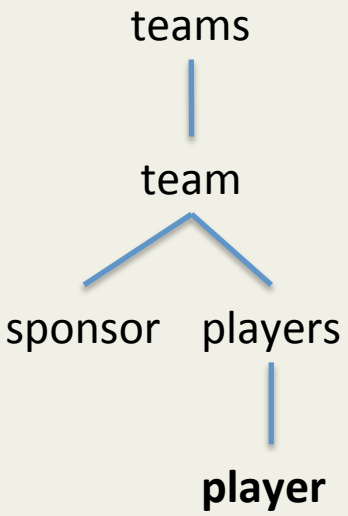

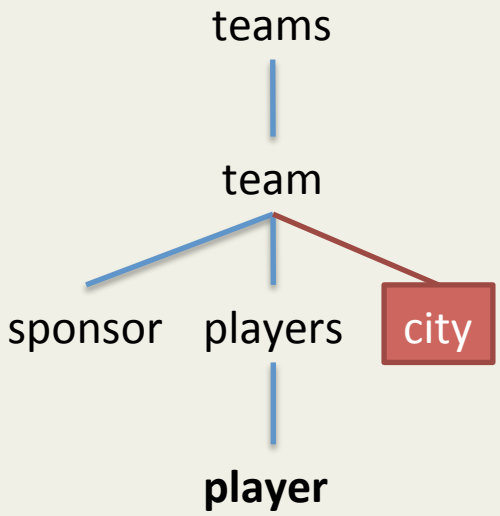

Logical optimization

- Some relations are always true
- Other relations are true only in specific settings (observing DTD)

- /bookstore/book contains(or equals) /bookstore/book[isbn] (always)

- If books always has isbn (REQUIRED on DTD) the relation is equal

Logical optimization

- Working with minimal size XPath means evaluating fewer “expressions” (and not useful)
- E.g. //player[number][role][name][stats], if the player has always a number, a role, a name and stats it is useless computing [x].
- Equivalent to //player

XPath Exercises

How to test them:

- **Eclipse** plugin
- Extensions for **Firefox** and **Chrome**

Instance: Studenti

```
<?xml version="1.0" encoding="UTF-8"?>
<studenti>
    <studente matricola=”281283">
        <corsostudi>Ingegneria Informatica</corsostudi>
        <anagrafica>
            <cognome>Rossi</cognome>
            <nome>Luca</nome>
            <eta>24</eta>
        </anagrafica>
        <esami>
            <esame corso=”Sistemi Informativi">
                <data><gg>28</gg><mm>05</mm><aa>2012</aa></data>
                <voto>29</voto>
            </esame>
        </esami>
    </studente>
   …
</studenti>
```

Problems

1. **dati anagrafici degli studenti che hanno sostenuto l'esame di "Sistemi Informativi"**
2. cognomi degli studenti che hanno preso più di 28 al corso di "Analisi"
3. matricola degli studenti che hanno meno di 20 anni e hanno sostenuto l'esame di "Chimica"
4. età degli studenti che hanno sostenuto più di 5 esami
5. età media degli studenti di Ingegneria Informatica
6. l'ultimo esame passato dagli studenti di Ingegneria Informatica

Solutions

1. //studente[.//esame/@corso = "Sistemi Informativi"]/anagrafica

Problems

1. dati anagrafici degli studenti che hanno sostenuto l'esame di "Sistemi Informativi"
2. **cognomi degli studenti che hanno preso più di 28 al corso di "Analisi"**
3. matricola degli studenti che hanno meno di 20 anni e hanno sostenuto l'esame di "Chimica"
4. età degli studenti che hanno sostenuto più di 5 esami
5. età media degli studenti di Ingegneria Informatica
6. l'ultimo esame passato dagli studenti di Ingegneria Informatica

Solutions

1. //studente[.//esame/@corso = "Sistemi Informativi"]/anagrafica
2. //studente[.//esame[voto>28 and @corso = "Analisi"]]/anagrafica/cognome

Problems

1. dati anagrafici degli studenti che hanno sostenuto l'esame di "Sistemi Informativi"
2. cognomi degli studenti che hanno preso più di 28 al corso di "Analisi"
3. **matricola degli studenti che hanno meno di 20 anni e hanno sostenuto l'esame di "Chimica"**
4. età degli studenti che hanno sostenuto più di 5 esami
5. età media degli studenti di Ingegneria Informatica
6. l'ultimo esame passato dagli studenti di Ingegneria Informatica

Solutions

1. //studente[.//esame/@corso = "Sistemi Informativi"]/anagrafica
2. //studente[.//esame[voto>28 and @corso = "Analisi"]]/anagrafica/cognome
3. //studente[anagrafica/eta < 20 and .//esame/@corso="Chimica"]/@matricola

Problems

1. dati anagrafici degli studenti che hanno sostenuto l'esame di "Sistemi Informativi"
2. cognomi degli studenti che hanno preso più di 28 al corso di "Analisi"
3. matricola degli studenti che hanno meno di 20 anni e hanno sostenuto l'esame di "Chimica"
4. **età degli studenti che hanno sostenuto più di 5 esami**
5. età media degli studenti di Ingegneria Informatica
6. l'ultimo esame passato dagli studenti di Ingegneria Informatica

Solutions

1. //studente[.//esame/@corso = "Sistemi Informativi"]/anagrafica
2. //studente[.//esame[voto>28 and @corso = "Analisi"]]/anagrafica/cognome
3. //studente[anagrafica/eta < 20 and .//esame/@corso="Chimica"]/@matricola
4. //studente[count(.//esame)>5]/anagrafica/eta

Problems

1. dati anagrafici degli studenti che hanno sostenuto l'esame di "Sistemi Informativi"
2. cognomi degli studenti che hanno preso più di 28 al corso di "Analisi"
3. matricola degli studenti che hanno meno di 20 anni e hanno sostenuto l'esame di "Chimica"
4. età degli studenti che hanno sostenuto più di 5 esami
5. **età media degli studenti di Ingegneria Informatica**
6. l'ultimo esame passato dagli studenti di Ingegneria Informatica

Solutions

1. //studente[.//esame/@corso = "Sistemi Informativi"]/anagrafica
2. //studente[.//esame[voto>28 and @corso = "Analisi"]]/anagrafica/cognome
3. //studente[anagrafica/eta < 20 and .//esame/@corso="Chimica"]/@matricola
4. //studente[count(.//esame)>5]/anagrafica/eta
5. avg(//studente[corsostudi = "Ingegneria Informatica"]/anagrafica/eta)

Problems

1. dati anagrafici degli studenti che hanno sostenuto l'esame di "Sistemi Informativi"
2. cognomi degli studenti che hanno preso più di 28 al corso di "Analisi"
3. matricola degli studenti che hanno meno di 20 anni e hanno sostenuto l'esame di "Chimica"
4. età degli studenti che hanno sostenuto più di 5 esami
5. età media degli studenti di Ingegneria Informatica
6. **l'ultimo esame passato dagli studenti di Ingegneria Informatica**

Solutions

1. //studente[.//esame/@corso = "Sistemi Informativi"]/anagrafica
2. //studente[.//esame[voto>28 and @corso = "Analisi"]]/anagrafica/cognome
3. //studente[anagrafica/eta < 20 and .//esame/@corso="Chimica"]/@matricola
4. //studente[count(.//esame)>5]/anagrafica/eta
5. avg(//studente[corsostudi = "Ingegneria Informatica"]/anagrafica/eta)
6. //studente[corsostudi="Ingegneria Informatica"]//esame[last()]