XML

- Extensible Markup Language
  - 起源: SGML (Standard Generalized Markup Language) 1986
  - Web のHTML (Hyper Text Markup Language) と同様
  - W3C (World Wide Web Consortium) で規定(1998)
- 傾向
  - 近年、インターネットを経由して多くのデータがやり取り
    - 企業間(B2B)データのフォーマットとして多用
  - XML の形でデータを蓄積:XMLデータベース
    - 例
      - 論文データ: DBLP, ACM SIGMOD Record,
      - バイオ情報データ: TrEMBL, Swiss-Prot
      - …

Web サービス

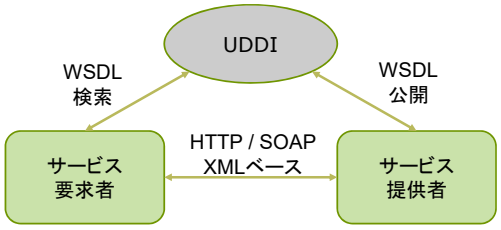

UDDI: Universal Description, Discovery and Integration
WSDL: Web Services Description Language
SOAP: Simple Object Access Protocol

XML基本シンタックス

- <start tag> と <end tag> で囲む
  - <title>Special Theory of Relativity</title>
- 階層構成 (属性も持つ)
  - NG:
    <author>Einstein<title></author>Relativity</title>
  - Well formed :

```
<article id="0123">
  <title>Special Theory of Relativity</title>
  <author>
    <f.name>Albert</f.name>
    <l.name>Einstein</l.name>
  </author>
</article>
```

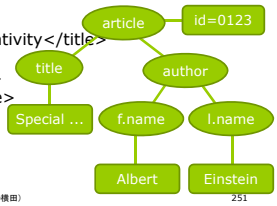

- 木構造になる

DTD

- Document Type Definition
  - XML ドキュメントの要素作成ルール
- 例：

```
<!DOCTYPE journal-db [
  <!ELEMENT journal (article)+>
  <!ELEMENT article (title, authors)>
  <!ELEMENT title (#PCDATA)>
  <!ELEMENT authors (author)+>
  <!ELEMENT author (f.name, l.name)>
  <!ELEMENT f.name (#PCDATA)>
  <!ELEMENT l.name (#PCDATA)>
  <!ATTLIST article id IDREFS #REQUIRED>
]>
```


RDB と XML-DB

- RDB:
  - テーブル：スキーマが固定
    - 全てのタプルが全属性を持つことを前提（空は null 値）
  - 各要素はアトミック
    - 第一正規形を前提
  - よく利用される問い合わせ言語: SQL
- XML-DB
  - 半構造：スキーマに自由度がある
  - 階層構造：要素としてさらに要素の階層を含める
  - 問い合わせ言語: Xpath, XQuery

XPath

- XML ドキュメント中から階層をたどりデータを探し出すための言語
  - XPath 1.0 1999 に W3C より開発
  - XPath 2.0 現在の版
- 1つ以上のノードとそれに含まれるデータを選択
  - 木構造の場所情報で表現
    - 軸（axis）:: node-test [predicate]
  - axis: child, descendant, parent, following-sibling, …
  - /child::articles/child::article/child::authors/child::author /child::l.name
- 簡略化
  - /articles/article/authors/author/l.name
  - /articles//l.name[Einstein]
  - //article[@id="0123"]

XQuery

- XML データのための問い合わせ言語
  - W3C により開発
  - XPath 2.0 の拡張
    - Xpath の Path 表現を利用
  - XML データの照会に合わせた出力整形の機能を持つ
    - 新たな XML ドキュメントを作成
    - SQL が新たなテーブルを作成するのに対応
- シンタックス
  - FLWOR
    - FOR, LET, WHERE, ORDER BY, RETURN

XQuery の FLWOR の例

```
for $x in doc("journal-db.xml")//article
let $a := $x/authors/author
where $x/year < 1930
order by $x//l.name descending
return
<articles-before-1930>
<title>{$x/title}</title>
<author>{$a/l.name, $a/f.name}</author>
</articles-before-1930>
```


出力イメージ

```
<articles-before-1930>
  <title>Special Theory of Relativity</title>
  <author>Einstein, Albert </author>
</articles-before-1930>
<articles-before-1930>
  <title>Uncertainty Principle</title>
  <author>Heizenberg, Werner</author>
</articles-before-1930>
```

XML データを格納する方法

- Native XML DB
  - XML の構造をそのまま蓄積
    - 例: Tamino
  - RDBMS で開発された多数の機能が利用できない
    - 含むトランザクション管理
- RDBMS を利用して格納
  - XML の一つのかたまりを文字列として RDB の要素として格納
    - DB2 等はこのアプローチ
    - XML の構造情報（親子関係等）は文字列を変換しないとわからない
      - RDB の検索機能だけでは構造情報は扱えない
  - XML の DTD の定義を RDB のスキーマに対応させて格納
    - B2B で転送される多くの情報は形式が一定
    - 半構造としての自由度は扱えない
      - 構造を自由に変更して中に階層構造を埋め込めない
  - XML の木構造の要素にラベルとつけて、要素をタプルとして格納
    - ラベルを工夫することで木構造の情報を使った検索が可能（変換は必要）

2019/6/6 データベース（©横田） 258

XML 格納の例

	Journal	
	<article id="0123"> <title>Special Theory of Relativity</title> <author> <f.name>Albert</f.name> <l.name>Einstein</l.name> </author> </article>	
	<article id="56789"> <title>Uncertainty Principle</tit <author> <f.name>Werner</f.name> <l.name>Heizenberg</l.name> </author> </article>	

<m.name>Karl</m.name>

id	title	f.name	l.name	m.name?
01234	Special Theory of Relativity	Albert	Einstein	
56789	Uncertainty Principle	Werner	Heizenberg	

XML ラベリング手法

- 分割して格納した要素から、XML の構造情報を抽出して、再構築するためのラベル
  - XPath、XQuery、キーワード検索等、多くのアプリケーションで利用するための情報
- 導かれるべき情報
  - 包含関係（親子）、兄弟間の順番、ノードの深さ等
- アプローチ
  - 前順・後順（ Preorder-Postorder: PP）法
  - Dewey 順（Dewey Order: DO）法

2019/6/6 データベース（©横田） 260

前順・後順（PP）法

- 全ノードに前順（根から始め、左の部分木を先に走査）の番号と、後順（一番左の部分木の左端から走査）の番号を付与
  - 子孫関係は、以下の式で判別
    祖先の前順番号＜子孫の前順番号　かつ
    祖先の後順番号＞子孫の後順番号

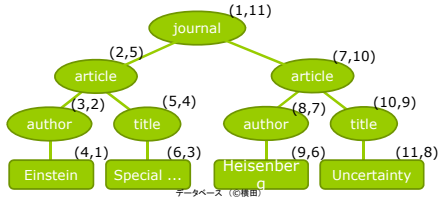

Dewey 順（DO）法

- ノードを（親のノード番号）.（子のノード番号）で表現
  - もともとは、図書館の書誌分類用のコード
    - 各分野の中でさらに小分類するために '.' を利用
    - 各分野、分類に10進数を割り当て

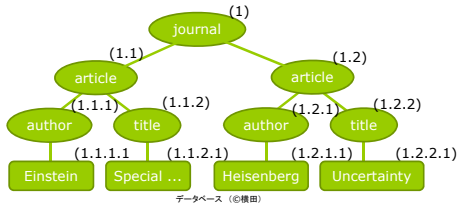

RDB へのラベル付ノード格納

Node	Pre	Post
journal	1	11
article	2	5
author	3	2
Einstein	4	1
title	5	4
Special ...	6	3
article	7	10
author	8	7
Hesenberg	9	6
title	10	9
Uncertainty	11	8

Node	Dewey
journal	1
article	1.1
author	1.1.1
Einstein	1.1.1.1
title	1.1.2
Special ...	1.1.2.1
article	1.2
author	1.2.1
Hesenberg	1.2.1.1
title	1.2.2
Uncertainty	1.2.2.1

ノード（部分木）挿入時の問題 (PP)

- ノードあるいは部分木を途中に挿入しようとすると、その祖先と右側の部分木の番号を全て修正する必要がある
  - 連続した番号の利用を前提としているため

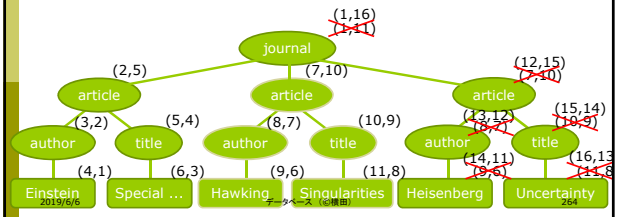

ノード（部分木）挿入時の問題(DO)

- DO の場合も同様の問題が発生
  - 挿入された部分木の祖先は変更の必要がないが、右側は変更する必要がある

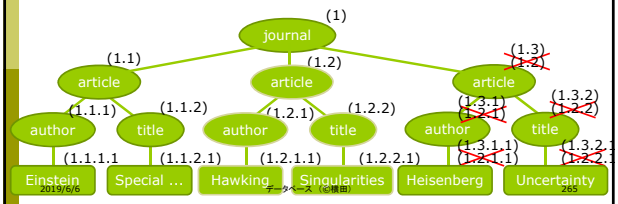

問題解決方

- いくつかの方法が提案されている
- 数値に予めインターバルを入れる方法
  - SPARSE [Eda et al. 2002]
  - QRS (浮動小数点を利用) [Amagasa et al. 2002]
  - インターバルを使い切る可能性
- 制限の無い方法
  - DO-VLEI Code [ICDE 2005]
  - ORDPATH [O'Neil et al. 2004]

VLEI Code [ICDE2005]

- Variable Length Endless Insertable コード
- 定義
  - 1 で始まるビットシーケンス
  - 次の条件を満足: $1\cdot\{0|1\}^*$ $\quad v\cdot 0\cdot\{0|1\}^* < v < v\cdot 1\cdot\{0|1\}^*$
  - 例
    - 10<1<11
    - 100<10<101<1<110<11<111
- いかなる連続する VLEI コード v_l と v_r の間に新しいコード v を以下の式により作成することができる
  - IF $l(v_l) \le l(v_r)$ then $v = v_r \cdot 0$ else $v = v_l \cdot 1$
    ($l(v)$ is v's length)
  - 例: *1<11* -> *1<110<11*

DO-VLEI [ICDE2005, IEICE2009]

- VLEI コードを DO 法に適用
  - 挿入に際し、他のラベルを変更する必要がない
- ドットも含めてバイナリーシーケンスに変更可能
  - ".1" → (11), "1" → (10), "0" → (0)
  - 例: "1.10.11" → (10 11 0 11 10)

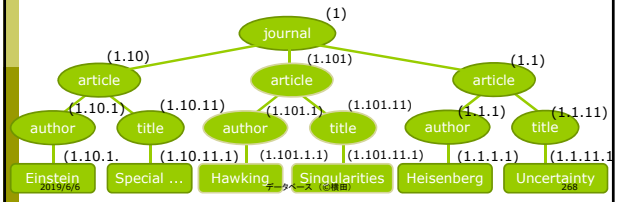

ORDPATH [SIGMOD 2004]

- Use only positive odd numbers for initial labeling
  - Based on Dewey-Order numbers
- Negative integers and even numbers are used for insertion operations
- Used in Microsoft SQL Server 2005

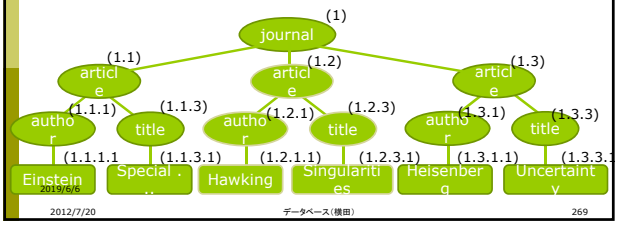

RDF

- RDF: Resource Description Framework
- トリプル <Subject, Predicate, Object>で表現
  - Subject: 資源(Resource)の実体
  - Predicate: 実体のプロパティを示す
  - Object: プロパティの値(Resource か Literal)
- トリプルの集合でグラフ構造を構築
  - Subject と Object がノード
  - Predicate が辺

RDF によるグラフ構造の例

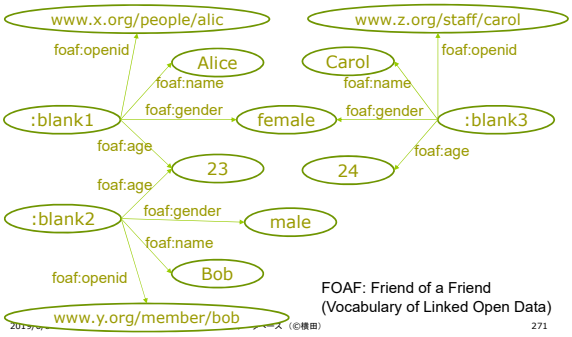

FOAF: Friend of a Friend
(Vocabulary of Linked Open Data)

SPARQL Query Language

- 再帰的定義 (W3C)
  - SPARQL Protocol and RDF Query Language
- <S, P, O> のパターンマッチ
- Example

```
PREFIX foaf: <http://xmlns.com/foaf/0.1/>
SELECT ?x
WHERE {?y  foaf:name ?x
       ?y  foaf:age 23}
```

Graph Match by SPRQL

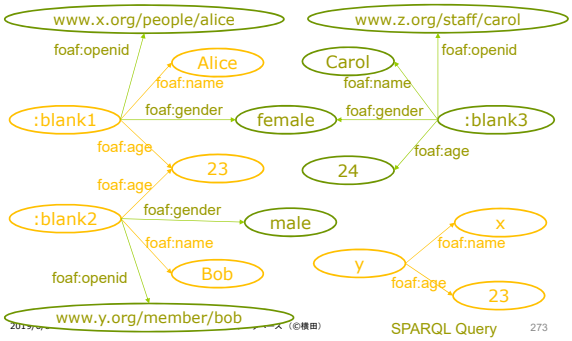

SPARQL Query

Image of Self Join

Subject	Predicate	Object
:blank1	foaf:name	Alice
:blank1	foaf:gender	female
:blank1	foaf:age	23
:blank1	foaf:openid	www.x.org/...
:blank2	foaf:name	Bob
:blank2	foaf:gender	male
:blank2	foaf:age	23
:blank2	foaf:openid	www.y.org/...
:blank3	foaf:name	Carol
:blank3	foaf:gender	female
:blank3	foaf:age	24
:blank3	foaf:openid	www.z.org/...

⋈

Subject	Predicate	Object
:blank1	foaf:name	Alice
:blank1	foaf:gender	female
:blank1	foaf:age	23
:blank1	foaf:openid	www.x.org/...
:blank2	foaf:name	Bob
:blank2	foaf:gender	male
:blank2	foaf:age	23
:blank2	foaf:openid	www.y.org/...
:blank3	foaf:name	Carol
:blank3	foaf:gender	female
:blank3	foaf:age	24
:blank3	foaf:openid	www.z.org/...