


# Indexování XML v databázi PostgreSQL

Tomáš Pospíšil

Fakulta informačních technologií VUT v Brně  
Božetěchova 1/2

xpospi04@stud.fit.vutbr.cz


1. března 2012




- SELECT/UPDATE/DELETE nad strukturovaným datovým typem
- XPath/XQuery v DB
- Datově orientovaná XML vs dokumentově orientovaná XML
- DB jako úložiště XML dokumentů
- Sémantika XML dat (validace oproti schématům)
- Nativní XML DB x ORDMIS XML podpora




- XML datový typ
  - Uložení XML dokumentů (CLOB)
  - Indexace pouze pomocí XPATH dotazu
  - SQL/XML funkce (xmlcomment, xmlconcat, ...)
  - XML2 extension
  - LibXML 2 knihovna
- Chybějící podpora
  - Indexace XML
  - XML validace pomocí schémat DTD, XSD a RNG
  - XPath 2.0, XQuery
  - Datové typy a operace





- Stromová struktura  
(*pre\_order*, *post\_order*)
- Každá aktualizace vyžaduje přepočet



- Každý uzel je určen  $(order, size)$
- $order(x) < order(y)$  pro  $\forall$  synovské uzly  $y$  uzlu  $x$
- $order(x) + size(x) \geq order(y) + size(y)$
- $size$  lze volit libovolně, při splnění podmínek

# XISS/R implementace

Element table	Attributes table	Text table	Document table
<b>Document_ID</b> <b>Order</b> Size Tab_Name Depth Child_ID Next_ID Attr_ID	<b>Document_ID</b> <b>Order</b> Size Tab_Name Depth Parent_ID Next_ID Value	<b>Document_ID</b> <b>Order</b> Size Depth Parent_ID Next_ID Value	<b>Document_ID</b> <b>Document_ID</b> Name

- `xml_element_nodes` table
  - `xml_element_nodes_pkey` PRIMARY KEY, btree (`did`,  
`pre_order`, `size`)
  - `elem_tab_all_index` btree (`name`, `did`, `pre_order`, `size`)
  - `elem_tab_range_index` gist (`int4range(pre_order, pre_order + size)`)
- `xml_attribute_nodes` table
  - `xml_attribute_nodes_pkey` PRIMARY KEY, btree (`did`,  
`pre_order`)
  - `attr_tab_all_index` btree (`name`, `did`, `pre_order`)
- `xml_text_nodes` table
  - `xml_text_nodes_pkey` PRIMARY KEY, btree (`pre_order`, `did`)
  - `text_tab_index` btree (`parent_id`, `did`)

- xml2 extension
- Jazyk C, PL/pgSQL
- Použití inrange (vhodná operace <@ "is contained by")
- Nové datové typy DTD, XSD a RNG v PostgreSQL
- API knihovny LibXML 2




- Funkční modul v *contrib/xml2* rozšíření (README.txt)
- Dokumentace kódu v rámci oficiální dokumentace (SGML)
- Instalace
  - `./configure --with-libxml --with-libxslt`
  - `make contrib/xml2; make install`
  - `psql; CREATE EXTENSION xml2`
- <http://www.tomaspospisil.com>
- <git://github.com/killteck/indexing-xml.git>




XML	DTD (ms)	XML	XSD (ms)	XML	RNG (ms)
1	32,868	1	23,110	1	1,894
2	20,134	2	25,801	2	1,451
3	1,314	3	32,234	3	31,898
4	40,030	4	26,045	4	32,266
5	1,410	5	1,868	5	30,109

Tabulka: Časy validace pomocí DTD, XSD a RNG nad XML dokumenty cca 1 MB

- Rychlosť validácie v řádu ms
- Paměťová náročnost lineární (velikost XML dokumentu + validačních schémat)
- Core2Duo T9800 @ 2.93GHz, 4GB RAM, Hitachi 7200rpm@ext3



- Projekt implementovaný v rámci GSoC 2011
- Využití indexu pro XPath/SQL dotazování
- Návrh na nativní XML podporu, využití indexu
- Mentor Gregory Stark



- 8. ročník
- 5000 \$
- Výborná pracovní zkušenost (10 nabídek za 1 hod.)
- Spousta TODO v PostgreSQL

