

Systemy rozproszone danych strukturalnych

Seminarium Systemy Rozproszone 2010/2011

Marcin Walas

21 kwietnia 2011

NoSQL


NoSQL to określenie na systemy zarządzania bazami danych, które różnią się od klasycznych RDBMSes w pewien sposób.

- z reguły nie mają ustalonych schematów tabelarycznych
- unikają operacji typu join
- dobrze się skalują

Dlaczego o tym na seminarium z Systemów Rozproszonych?

- dużo danych
- wysokie wymagania dostępności
- skalowanie się
- czyli, idziemy w chmurę

Odrobinka historii



Rodzaje systemów danych strukturalnych

Będziemy po trochu zajmować się wieloma systemami:

- document stores (CouchDB, MongoDB, OrientDB)
- graph stores (Triplestores: Virtuoso)
- key-value stores (Dynamo, Cassandra)
- object databases (Loxim)
- tabular stores (BigTable, Mnesia)
- tuple stores (Jini, Apache River - JavaSpaces)

Przypomnienie

ACID - wymagania transakcyjne

- atomowość
- spójność
- izolacja
- trwałość

Twierdzenie **CAP** (Brewer'a)

System rozproszony nie może jednocześnie zapewnić:

- spójności
- dostępności
- odporności na podziały

Document stores

Dokumenty, czyli:

- JSON
- xml

Potencjalne zastosowania

- CMS'y
- szybkie systemy raportujące
- prosty model danych i łatwa do wymuszenia spójność między dokumentami

CouchDB



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

Napisany w Erlangu, zorientowany na dokumenty system
bazodanowy


- JSON
- brak schematu - NoSQL!
- klucz-wartość + dowolne załączniki
- replikacja, widoki, map-reduce
- SpiderMonkey - zapytania w JavaScript
- RESTful

CouchDB

Przykład

- widoki - funkcje mapujące stają się indeksami
- ACID

CouchDB - Architektura



<http://horicky.blogspot.com/2008/10/couchdb-implementation.html>


CouchDB - ACID

Własności:

- baza się nie wyłącza - dokonuje zapisów inkrementacyjnych - można ją “ubijać”,
- czytelnicy i pisarze nigdy nie czekają,
- spójność danych tylko w obrębie jednego dokumentu,
- zserializowane “update’y” są zapisywane na dysku,
- Multi-Version Concurrency Control
- dokumenty indeksowane w b-drzewach,
- kompaktowanie danych na dysku - co jakiś czas.

<http://couchdb.apache.org/docs/overview.html>

CouchDB - replikacja



CouchDB - rozproszenie

- load balancing
- replikacja
- plotkowanie zmian

Wbrew temu, co zapewniają twórcy,

problem jednak w tym, że trzeba tutaj tak naprawdę zewnętrznego systemu użyć.

MongoDB



Różnice w porównaniu z CouchDB:



- w testach - niewielki bardzo nadrzut nad RAM,
- ... bo możliwa utrata danych - głównie “persystencja” w RAM,
- napisana w C++,

Produkcja:


- 
- 

Przykład

MongoDB - replikacja



MongoDB - sharding




OrientDB



- baza dokumentów,
- napisana w Javie,
- posiada także cechy graph database - związki między dokumentami można definiować,
- częściowo ustalony schemat dokumentów - klasy,
- szybkie trawersowanie dokumentów,
- ograniczony SQL,
- transakcyjność nie tylko w obrębie dokumentu

OrientDB - architektura

Orient DB - Local Storage




For more information visit: <http://www.orienttechnologies.com>

OrientDB - clustering

Single server


Server #1 starts and send the signal to the network
After a timeout no server answer, so no cluster is available
Server #1 listens for other server nodes



OrientDB - clustering

Second server


Server #2 starts and send the signal to the network
Server #1 catches the signal and connect to Server #2
Server #1 is the Leader



OrientDB - clustering

Share db


DBA requests a sharing of database to Server #1 in synchronous mode
Server #1 exports the db and send it via streaming to Server #2
When aligned, Server #2 is a synchronous copy of Server #1
Server #1 and #2 are **Always Consistent**



OrientDB - clustering

Server #2 crashes


Server #1 catches it thanks to the heart-beat
Server #1 logs changes while Server #2 is unavailable



OrientDB - clustering

Server #2 resurrects


- Server #2 launch the presence in the network
- Server #1 catches the signal and re-connect to Server #2
- Server #1 checks if Server #2's database is consistent
- Then start to synchronize last changes to Server #2
- Server #2 returned up & running



OrientDB - clustering

Server #1 crashes

Server #2 catches by checking last heart-beat received
Server #2 is the new Leader of the cluster



Erlang



- wpływ na jego rozwój miał Prolog
- stworzony dla obliczeń współbieżnych/rozproszonych
- podobno coś z niego zaczerpnęła Scala i Clojure (wielowątkowy Lisp)
- luźno implementuje CSP
- bazuje na “zielonych wątkach”

Erlang - kawałek kodu

Dlaczego warto na to poświęcić chwilę?

Podobne rzeczy w **Go** od Google'a oraz **Scala**.

Scala - kawałek kodu

Scala - **Aktorzy**


Możliwi zieloni lub ciężkie, systemowe wątki.

No i bardziej Java-way-of-life, jak ktoś lubi.

Więcej tutaj na przykład:

<http://www.infoq.com/news/2008/06/scala-vs-erlang>

Yaws - Yet another web server



przepustowość (KBytes/second) vs. obciążenie
zaczepnięte z <http://www.sics.se/joe/apachevsyaws.html>

Postęp...

Będziemy po trochu zajmować się wieloma systemami:


- **document stores (CouchDB, MongoDB, OrientDB)**
- graph stores (Triplestores: Virtuoso)
- key-value stores (Dynamo, Cassandra)
- object databases (Loxim)
- tabular stores (BigTable, Mnesia)
- tuple stores (Jini, Apache River - JavaSpaces)

Triplestores

Bazy danych zorientowane na przechowywanie informacji w postaci RDF - etykietowanych grafów.

- wiele projektów upiorów
- trochę prac teoretyków

Status sieci semantycznej



A może ten graf się po prostu nie stosuje do niczego związanego ze sztuczną inteligencją?

Resource Description Framework


```
<?xml version="1.0"?>
<RDF>
<Description about="http://pl.wikipedia.org/wiki/Wikipedysta:Kozik">
  <autor>Krzysztof Kozłowski</autor>
  <utworzono>1 Maja 2009</utworzono>
  <zmodyfikowano>1 Stycznia 2010</zmodyfikowano>
</Description>
</RDF>
```

Opis świata w postaci:

- podmiotu,
- orzeczenia/predykatu (własność)
- dopełnienia/obiektu (wartość)

Dużo trójek - stąd triplestores.

Resource Description Framework



Virtuoso




- uniwersalny serwer - czyli nas interesuje tylko kawałeczek
- komercyjny, jest wersja Open Source
- duży produkt: SQL, XML, WebDAV, federacje, SOAP


Używa tego:




Architektura



Architektura



Przykład - DBPedia



Przy okazji


- Freebase - ze storage grafowym od Metaweb,
- google-refine

WolframAlpha



Czy ktoś nie wie, co to jest?

Lub to:



A New Kind of Science?

Automaty komórkowe:

- proste algorytmy,
- ewolucja,
- samoaplikacja

Wolfram Alpha:

- oparty na Mathematica - flagowy produkt Wolfram Research,
- **nie jest** wyszukiwarką sematyczną,
- wizualizuje zgromadzoną wiedzę, przez składanie prostych algorytmów,
- podobny do Cyc [sajk]

OpenCyc

- rozpoczęty w 1984 roku,
- podobno zbudowanie “zdrowego rozsądku” zajęłoby 350 man-years,
- podobny do Lisp’a

Niestety, najciekawsze dla nas rzeczy są “zrób to sam”

- jest komunikacja sieciowa,
- ale ostatecznie i tak trzeba to pisać ręcznie.

gridMathematica

Wolfram gridMathematica 7 SERVER

PARALLEL COMPUTATIONS MADE EASY ACROSS A NETWORK

- load-balancing,
- parametryzowany scheduling zadań,
- durability: po awarii powinien system wrócić sam do pracy,
- obsługa klastrów, gridów, możliwość użycia zwykłych, tanich maszyn,

Produkt komercyjny, więc tak naprawdę nic nie wiadomo...

Postęp...

Będziemy po trochu zajmować się wieloma systemami:

- **document stores (CouchDB, MongoDB, OrientDB)**
- **graph stores (Triplestores: Virtuoso)**
- key-value stores (Dynamo, Cassandra)
- object databases (Loxim)
- tabular stores (BigTable, Mnesia)
- tuple stores (Jini, Apache River - JavaSpaces)

Przestrzeń krotek

Co to?

- wielki shared memory,
- proces wkłada krotkę,
- inny proces wkłada krotkę pasującą do zapytania

Implementacje

- JavaSpaces
- PyLinda - prosta impl
- GigaSpaces - komercyjne, też .NET


Javaspaces

- zamiast krotek - obiekty dziedziczące po *Entry*,
- mamy wielki worek na obiekty,
- najczęściej używane w trybie Master-Slave,
- raczej bez persystencji obiektów


Operacje:

- write,
- read,
- take,
- notify

Javaspaces



Javaspaces



Javaspaces - przykład

```
import net.jini.core.entry.*;

public class MessageEntry implements Entry {
    public String content;

    public MessageEntry() {
    }

    public MessageEntry(String content) {
        this.content = content;
    }

    public String toString() {
        return "MessageContent: " + content;
    }
}
```

Javaspaces - przykład

```
JavaSpace space = getSpace();  
MessageEntry msg = new MessageEntry();  
msg.content = "Hello there";  
space.write(msg, null, Lease.FOREVER);
```


Javaspaces - przykład

```
MessageEntry template = new MessageEntry();  
// template content field = NULL, match everything  
MessageEntry output = (MessageEntry) space.read(template, null,  
                                                    Long.MAX_VALUE);
```

Apache River



- kiedyś Jini,
- framework do budowy systemów rozproszonych,
- zawiera implementację Javaspaces,
- bardziej rozwinięte JRMI,
- automatyczne wykrywanie usług,
- SOA - Service Oriented Architecture,

Komunikacja

Przez protokół JERI. Implementacje JERI:

- TCP,
- SSL,
- HTTP,
- HTTPS,
- Kerberos-TCP

Od małego do dużego...

- **Najmniejszy:** usługa i klient
- **Średni:** usługa, klient, rejestr
- **Największy:** usługa, klient, rejestr, serwer klas

Apache River - co zapewnia

Peter Deutsch z Sun Labs *Eight Fallacies of Distributed Computing*:

- The network is reliable
- Latency is zero
- Bandwidth is infinite
- The network is secure
- Topology doesn't change
- There is one administrator
- Transport cost is zero
- The network is homogeneous

Apache River - co zapewnia

Jini tak naprawdę odnosi się częściowo do wszystkich tych założeń,

- niezależność od protokołu - wiele implementacji, można dopisać własną (:)!),
- niezależność od lokalizacji, można przenosić usługi bez wiedzy klientów,
- eliminacja powiązań - może wiele implementacji tej samego interface'u współistnieć w sieci,
- automatyczny tuning wydajności

Pytania?

Bardzo dziękuję za uwagę.