

ProjectLA

バックエンドの技術解説

RDFを使った三つ組みデータの格納

2013/03/14

クラウド・テクノロジー研究部会 リーダー

荒本道隆

(アドソル日進株式会社)

何故、RDFか？

- 断片的なデータを相互につなぎたい
 - RDFは主語・述語・目的語の三つ組構造で表現
 - 目的語と主語に同じ値を設定して、それぞれをつなぐ
- 属性を事前に決定できない
 - RDFはスキーマレスなので、柔軟に対応できる
 - RDFは多様な情報を関係性で表現できる
- 大量のデータを蓄積・分析したい
 - RDFは構造が単純なので、コンピュータ・パワーが活きる


バックエンドの概要

- アプリに、JSON+HTTPを使ったAPIを提供
- 格納はRDF形式
- 検索はSPARQL(RDFクエリ言語)を使用

- RDF: Resource Description Framework
 - 2008年にW3C勧告となった
 - 代表的な使用例
 - RSS (RDF site summary) 0.9, RSS1.0
 - **DBpedia**
- 主語、述語、目的語の3つの要素で表現
 - 主語 (Subject) : URI
 - <http://aitc.jp/project/2013/projectLA/person/1>
 - 述語 (Predicate) : URI
 - <http://aitc.jp/project/2013/projectLA/person#name>
 - 目的語 (Object) : 値
 - 「先端太郎」




- 目的語 (Object) と主語 (Subject) に同じ値を入れる



The Linking Open Data cloud diagram
<http://richard.cyganiak.de/2007/10/lod/>


- この部分をRDFにする場合



- 識別できるようにIDを追加



- これをそのままRDFにすると問題がある




- データがこうなる

主語	述語	目的語
1	氏名	先端太郎
先端太郎	住所	東京都港区


- 同姓同名が居ると、区別がつかない

区別可能にするには


- 元




- IDを追加するパターン



- IDと空白ノードを追加するパターン




- モデル



- データ

主語	述語	目的語
1	氏名	先端太郎
1	住所	東京都港区

- モデル



- データ

主語	述語	目的語
1	Node	b1
b1	氏名	先端太郎
b1	住所	東京都港区

- RDFとCassandraの比較
 - 主語 (Subject) ← KEY
 - 述語 (Predicate) ← Column
 - どちらもスキーマレス
 - どちらも主語 (Key) + 述語 (Column) でユニーク
 - 目的語 (Object) ← Value



- 主語の名前空間 ← Column Family
 - 名前空間を変えることで、異なるデータを混在
 - <http://aitc.jp/project/2013/projectLA/person/1>
 - <http://aitc.jp/project/2013/projectLA/content/1>

RDFの実装: Jena

- Apacheのプロジェクトの1つ
 - <http://jena.apache.org/>
- Java製フレームワーク
 - Semantic Webアプリケーションを構築
 - RDFデータを読み、書き、処理するためのAPI
 - ファイルシステム
 - RDB (Oracle, MS-SQLServer, DB2, PostgreSQL, MySQL, Derby, H2, HSQLDB)
 - RDFとOWLを使ったルールベースの推論エンジン
 - OWL: Web Ontology Language
 - SPARQLのクエリーエンジン
 - RDFデータを公開するためのサーバ

AITC
先進IT活用推進コンソーシアム



抽象化したAPIを作成


- やり取りするフォーマット
 - JSON形式
 - JSON $\leftrightarrow$ RDFの変換ライブラリを作成
 - この変換ライブラリの出来がキーになりそう
- インターフェイスはREST(HTTP)
 - 細かい部分はSenchaのデフォをそのまま採用
 - 悩む手間が省ける
 - APIの種類はそんなに多くないはず
 - 検索は様々なフィルタ条件が必要

- 格納
 - － JSONをPOSTする
 - 内部でJSON→RDFに変換
 - － 登録と更新の区別
 - Idが無い: 新規登録
 - Idがある: 更新

- JSON

```
{
  "person": {
    "username": "aitc", "gender": "male", "locale": "ja_JP",
    "checkedin": [
      {"id": "1"}, {"id": "2"}
    ]
  }
}
```


- 新規追加後のRDF




- ユーザー情報は単なる更新ではない
 - 投稿した時点のユーザー状態を履歴として残す
 - contextをhistoryContextに書き換えるためのSPARQL

```
DELETE { <http://a/person/p00001> <http://a/person#context> ?o }  
INSERT { <http://a/person/p00001> <http://a/person#contextHistory> ?o }  
WHERE { <http://a/person/p00001> <http://a/person#context> ?o }
```

- 更新後のRDF



- コンテンツとの関連



- 取得
 - － GETするとJSONを返す
 - SPARQLでXMLを取得し、JSONに変換する
 - － 取得時には、様々な付加情報を追加


- 登録時

```
{  
  "person": {  
    "username": "aitc", "gender": "male", "locale": "ja_JP",  
    "checkIned": [  
      {"id": "1"}, {"id": "2"},  
    ],  
  },  
}
```


- 取得時

```
{  
  "person": {  
    "id": "p00001",  
    "username": "aitc", "gender": "male", "locale": "ja_JP",  
    "checkIned": [  
      {"id": "1", "title": "3.11 首都圏。帰宅する方法は何？"},  
      {"id": "2", "title": "3.11災害状況"},  
    ],  
  },  
}
```


システム構成



システム構成－現在開発中



システム構成ー今後の予定



- JSON $\Leftrightarrow$ RDFは、ある程度パターン化できそう
 - O/Rマッピングよりは、かなり大変
- RDFで格納する事で、複雑な関連性を表現
 - 図化することで、理解も容易
- 集計が大変そうなので、クラウド技術が必須