

Traitement de données semi-structurées à large échelle

Master DAC – Bases de Données Large Echelle

Mohamed-Amine Baazizi

baazizi@ia.lip6.fr

Novembre 2018

Contexte

- Données semi-structurées
 - très répandues : crawl api, datasets publiques, ...
 - flexibilité, pas de schema pré-établi (ou a posteriori)
 - imbrication sur plusieurs niveaux, structure variable
 - difficiles à manipuler et à cerner
- JSON : modèle le plus répandu
 - syntaxe plus simple de XML
 - exprime à la fois une séquence de tuples ou de valeurs (avec un array) et un ensemble de tuples (avec un record)
- quelques extensions utilisent
 - Map (tableaux associatifs)
 - Bags (arrays sans la notion d'ordre)

JSON : modèle de données et langage de schémas

- Data model

- Valeurs atomiques : null, bool, number, string
- records : ensemble de paires (clé,valeur)
- arrays : séquence de valeurs

- Schema language

- pas de standard, propre à chaque système
- quelques similitudes et un candidat en lice (JSON-Schema) pour définir un schéma a priori
- expressivité variable : utilisation d'expression régulière, opérateur d'union, comptage, négation

```
{  
  "email" : "abc@ef",  
  "first" : "li",  
  "coord" : [{  
    "lat" : 45,  
    "long" : 12  
  }],  
  "last" : null  
}
```

un objet JSON

Cas Spark

- Langage de schéma
 - types de base : boolean, numeric (integer, decimal, ...), String, null, timestamp
 - type tableau : ArrayType(element, containsNull)
 - type object : StructType(List [StructField])
 - StructField(name, type, nullable)
 - type tableau associatif : MapType (keyType, valueType, valueContainsNull)
- Inférence du schéma pour une collection
 - deux étapes : inférer le type de chaque objet puis fusionner les types
 - tous les attributs marqués comme optionels (nullable=true)
 - inférer String lorsque la collection est hétérogène (différentes sortes de types)
- Stockage des données : relationnel étendu
 - types imbriqués SparkSQL : Objet, Tableau, Tableau Associatif
 - Génération de tables SparkSQL guidée par le schéma
 - Schéma automatiquement inféré lorsqu'il n'est pas fourni
 - utilisation des null pour indiquer l'absence d'attributs
- Interrogation semblable à l'objet-relationnel
 - algèbre Dataset + navigation dans la structure imbriquée à l'aide de la notation pointée
 - dés-imbrication (unnest) ou groupement (nest)
 - analyse statique pour inférer le type de chaque expression

Inférence du schéma et Stockage

```
{
  "person" : {
    "firstname" : "Melena",
    "lastname" : "RYZIK",
    "role" : "reported",
    "rank" : 1,
    "organization" : ""
  }
}
{
  "person" : {
    "firstname" : "other",
    "lastname" : "ABCD",
    "rank" : 1,
    "organization" : "OO"
  }
}
```

Collection de 2 objets

```
testNyt: org.apache.spark.sql.DataFrame
scala> testNyt.printSchema
root
|-- person: struct (nullable = true)
|   |-- firstname: string (nullable = true)
|   |-- lastname: string (nullable = true)
|   |-- organization: string (nullable = true)
|   |-- rank: long (nullable = true)
|   |-- role: string (nullable = true)
```

*role devrait être le
seul attribut
optionnel*

```
scala> testNyt.show
```

person
[Melena, RYZIK, , 1, reported]
[other, ABCD, OO, 1,]

de type
SparkSQL Struct

```
scala> testNyt.select("person.*").show
```

firstname	lastname	organization	rank	role
Melena	RYZIK		1	reported
other	ABCD	OO	1	null

Inférence du schéma et Stockage

```
{
  "first" : "al",
  "coord" : [],
  "last" : "jr"
}
{
  "first" : "al",
  "coord" : null,
  "last" : "jr"
}
{
  "email" : "abc@ef",
  "first" : "li",
  "coord" : {
    "lat" : 45,
    "long" : 12
  },
  "last" : null
}
```

Collection de 3 objets

```
scala> test.printSchema
```

```
root
```

```
|-- coord: string (nullable = true)
```

```
|-- email: string (nullable = true)
```

```
|-- first: string (nullable = true)
```

```
|-- last: string (nullable = true)
```

```
scala> test.show
```

de type
SparkSQL String



coord	email	first	last
[]	null	al	jr
null	null	al	jr
{"long":12,"lat":45}	abc@ef	li	null

*impossible de récupérer
long et lat sans parsing
préalable*

Inférence du schéma et Stockage


```
{
  "person" : [
    {
      "firstname" : "Melena",
      "lastname" : "RYZIK",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    },
    {
      "firstname" : "derba",
      "lastname" : "OKYZ",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    }
  ]
}
{
  "person" : [
    {
      "firstname" : "other",
      "lastname" : "ABCD",
      "rank" : 1,
      "organization" : "OO"
    }
  ]
}
```

Collection de 2 objets

```
scala> testNyt.printSchema
root
|-- person: array (nullable = true)
|   |-- element: struct (containsNull = true)
|   |   |-- firstname: string (nullable = true)
|   |   |-- lastname: string (nullable = true)
|   |   |-- organization: string (nullable = true)
|   |   |-- rank: long (nullable = true)
|   |   |-- role: string (nullable = true)
```

```
scala> testNyt.show(truncate=false)
```

de type
SparkSQL Array<Struct>



person
[[Melena, RYZIK, , 1, reported], [derba, OKYZ, , 1, reported]]
[[other, ABCD, OO, 1,]]

Interrogation

```
{
  "person" : {
    "firstname" : "Melena",
    "lastname" : "RYZIK",
    "role" : "reported",
    "rank" : 1,
    "organization" : ""
  }
}
{
  "person" : {
    "firstname" : "other",
    "lastname" : "ABCD",
    "rank" : 1,
    "organization" : "OO"
  }
}
```

Collection de 2 objets

```
scala> testNyt.show
```

person
[Melena, RYZIK, , 1, reported]
[other, ABCD, OO, 1,]

```
scala> testNyt.select("person.*").show
```

firstname	lastname	organization	rank	role
Melena	RYZIK		1	reported
other	ABCD	OO	1	null

Utilisation de l'algèbre Dataset : select, where, join, ...
<https://spark.apache.org/docs/...org.apache.spark.sql.Dataset>

Interrogation

```
{
  "person" : [
    {
      "firstname" : "Melena",
      "lastname" : "RYZIK",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    },
    {
      "firstname" : "derba",
      "lastname" : "OKYZ",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    }
  ]
}
{
  "person" : [
    {
      "firstname" : "other",
      "lastname" : "ABCD",
      "rank" : 1,
      "organization" : "OO"
    }
  ]
}
```

Collection de 2 objets

```
scala> testNyt.show(truncate=false)
```

person
[[Melena, RYZIK, , 1, reported], [derba, OKYZ, , 1, reported]]
[[other, ABCD, OO, 1,]]

```
scala> testNyt.select(explode_outer($"person")).show(truncate=false)
```

col
[Melena, RYZIK, , 1, reported]
[derba, OKYZ, , 1, reported]
[other, ABCD, OO, 1,]

explode dés-imbrique le contenu d'une colonne de type `ArrayType<T>` en retournant une colonne de type `T`

Interrogation

```
{
  "person" : [
    {
      "firstname" : "Melena",
      "lastname" : "RYZIK",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    },
    {
      "firstname" : "derba",
      "lastname" : "OKYZ",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    }
  ]
}
{
  "person" : [
    {
      "firstname" : "other",
      "lastname" : "ABCD",
      "rank" : 1,
      "organization" : "OO"
    }
  ]
}
```

Collection de 2 objets

```
scala> testNyt.show(truncate=false)
```

person
[[Melena, RYZIK, , 1, reported], [derba, OKYZ, , 1, reported]]
[[other, ABCD, OO, 1,]]

```
scala> testNyt.select($"person",explode($"person")).show(truncate=false)
```

person	col
[[Melena, RYZIK, , 1, reported], [derba, OKYZ, , 1, reported]]	[Melena, RYZIK, , 1, reported]
[[Melena, RYZIK, , 1, reported], [derba, OKYZ, , 1, reported]]	[derba, OKYZ, , 1, reported]
[[other, ABCD, OO, 1,]]	[other, ABCD, OO, 1,]

Interrogation

```
{
  "person" : [
    {
      "firstname" : "Melena",
      "lastname" : "RYZIK",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    },
    {
      "firstname" : "derba",
      "lastname" : "OKYZ",
      "role" : "reported",
      "rank" : 1,
      "organization" : ""
    }
  ]
}
{
  "person" : [
    {
      "firstname" : "other",
      "lastname" : "ABCD",
      "rank" : 1,
      "organization" : "OO"
    }
  ]
}
```

Collection de 2 objets

?



Nécessite l'imbrication dans le select

```
{
  "role" : "reported",
  "persons" : [
    {
      "firstname" : "Melena",
      "lastname" : "RYZIK",
      "rank" : 1,
      "organization" : ""
    },
    {
      "firstname" : "derba",
      "lastname" : "OKYZ",
      "rank" : 1,
      "organization" : ""
    }
  ]
}
```

Bilan

- Expressivité limitée du langage de schéma et du langage de requêtes
 - pas de distinction entre attributs optionnels et obligatoires
 - n'exprime pas l'union : `String + [ ] + {long: String, lat: String}`
 - quid de l'accès indexé aux éléments d'un Array et de l'imbrication dans le select?
- Autres pistes
 - Extensions SQL : *SQL++* de AsterixDB, *N1QL* de Couchbase, *SQL* de Apache Drill
 - Langages propriétaires : *Aggregation Pipelines* de Mongo, *JSONiq* de Zorba
 - Plusieurs connecteurs possibles avec Spark