PCS5787 – Ciência dos Dados
Ferramentas de Big Data

Representação de Dados e Arquitetura de Banco de dados não Relacionais

Prof. Dr. Pedro Luiz Pizzigatti Corrêa
pedro.correa@usp.br

Segundo semestre 2019

Agenda

Agenda

- Introdução
- Estruturas não normalizadas
- Estratégias de representação
- Arquiteturas de Aplicações e de Ferramentas de Big Data.

Introdução

Introdução

- Qual das imagens melhor representa um dado **normalizado** e um dado **não normalizado**?

Não normalizado

Normalizado

Adaptado de: MALAIKA, S.; NICOLA, M. **Data Normalization Reconsidered**. IBM. p. 40. 2012.

Introdução

- Não normalizado:
  - Mundo ‘real’;
  - Mais fácil entender;
  - Fácil de armazenar;
  - Pronto para o uso.

- Normalizado:
  - Visão idealizada;
  - Mais difícil de entender;
  - O armazenamento implica em decomposição;
  - Não está pronto para o uso (recomposição dos dados).

Introdução

- Quais elementos compõem a nota de pedido?

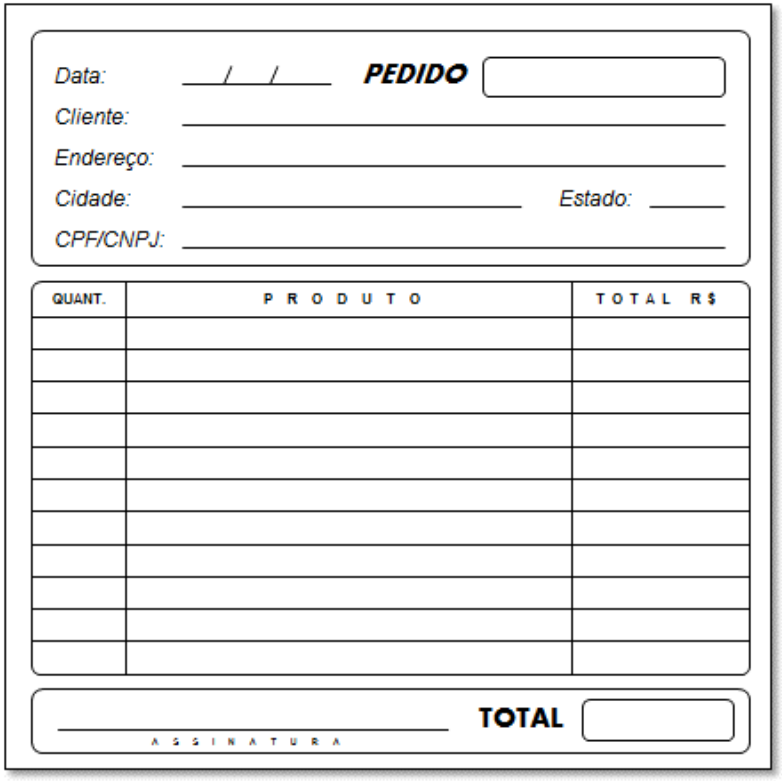

Data: ___/___/___ **PEDIDO** [ ]

Cliente: _____

Endereço: _____

Cidade: _____ Estado: _____

CPF/CNPJ: _____

QUANT.	PRODUTO	TOTAL R$

_____ **TOTAL** [ ]

ASSINATURA

- Cliente
- Produto
- Pedido
- Item do Pedido

Introdução

- Como armazenar os dados da nota de pedido:

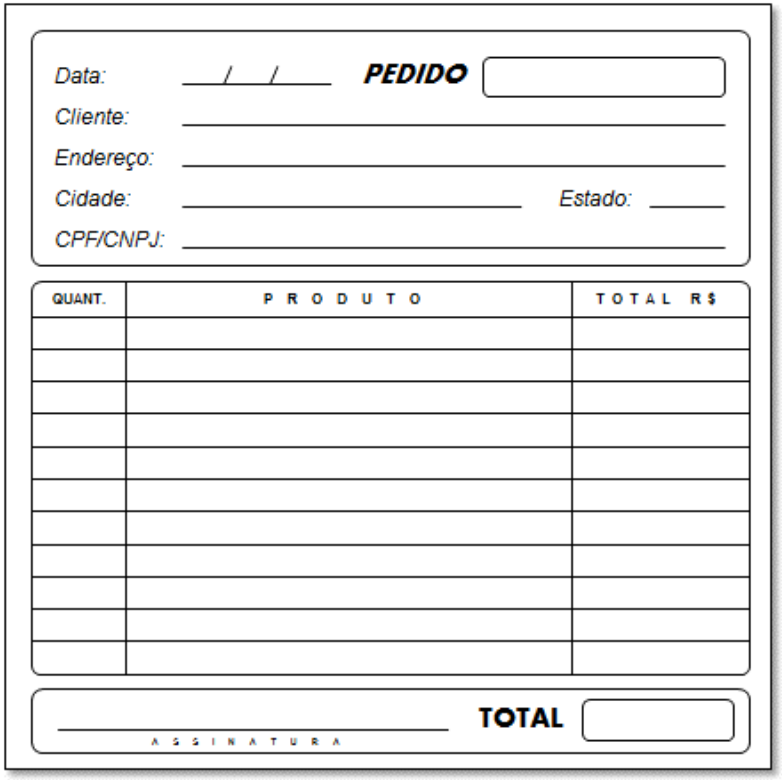

Data: __/__/__ **PEDIDO**

Cliente: _____

Endereço: _____

Cidade: _____ Estado: ____

CPF/CNPJ: _____

QUANT.	PRODUTO	TOTAL R$

_____ **TOTAL**

ASSINATURA

- Estruturas Normalizadas
  - Banco de dados relacionais
- Estruturas Não Normalizadas
  - Banco de dados não relacional
  - Arquivos texto

Introdução

- Como representar os dados da nota de pedido:

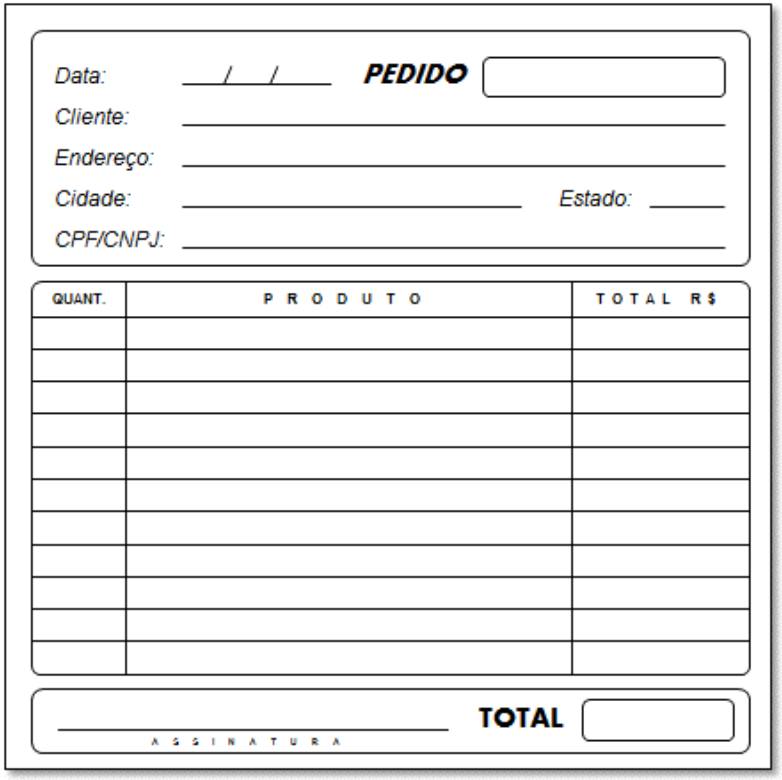
Data: ___/___/___ **PEDIDO**

Cliente: _____

Endereço: _____

Cidade: _____ Estado: _____

CPF/CNPJ: _____

QUANT.	PRODUTO	TOTAL R$

_____ **TOTAL**

ASSINATURA

- Estruturas Normalizadas
  - Relacionamento entre tabelas
- Estruturas Não Normalizadas
  - XML;
  - RDF;
  - JSON.

Agenda

- Introdução
- Estruturas não normalizadas
- Estratégias de representação
- Arquiteturas de Aplicações e de Ferramentas de Big Data.

Estruturas não normalizadas

Estruturas não normalizadas

- Dados em estruturas não normalizadas
  - Conceito de dados não normalizados:

    "Abordagem na qual a normalização é omitida deliberadamente para construção de modelos cujos dados sejam representados de forma mais próxima à sua estrutura no mundo real."

Adaptado de: ELMASRI, R.; NAVATHE, S. B. **Fundamentals of Database Systems**. 7ª Edição, Pearson, 2015.

Estruturas não normalizadas

- Dados em estruturas não normalizadas
  - Conceito de dados normalizados:

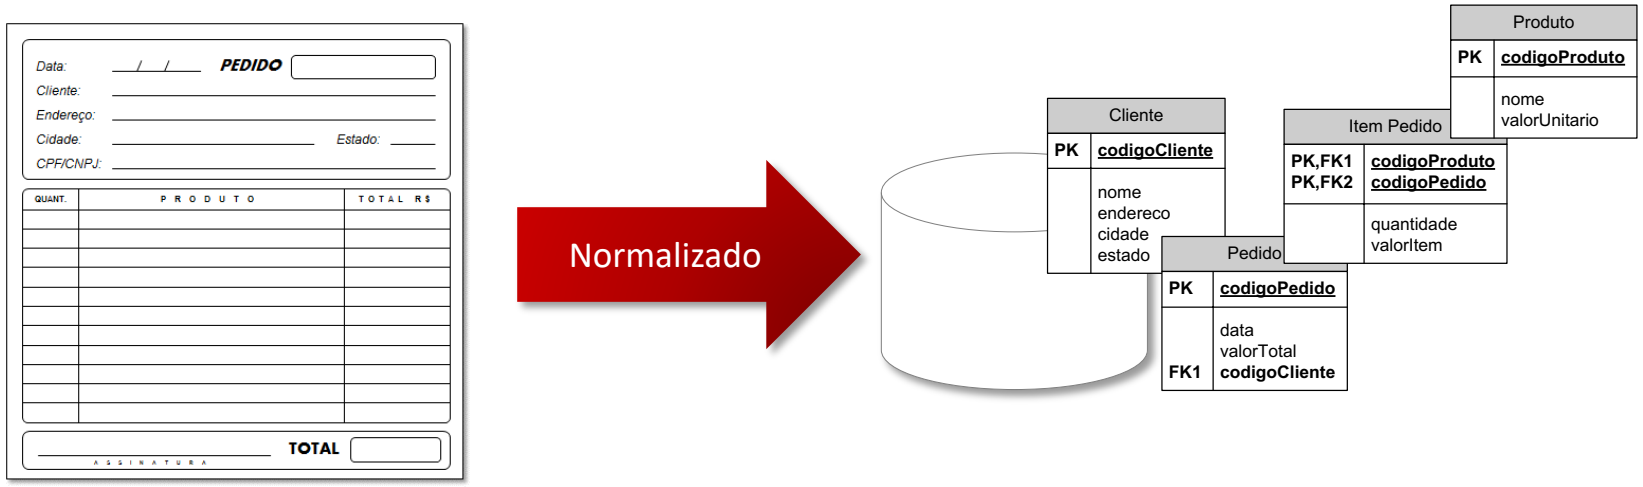

Estruturas não normalizadas

- Dados em estruturas não normalizadas
  - Conceito de dados não normalizados:

Estruturas não normalizadas

- Dados em estruturas não normalizadas
  - Construção do Modelo de Agregados:

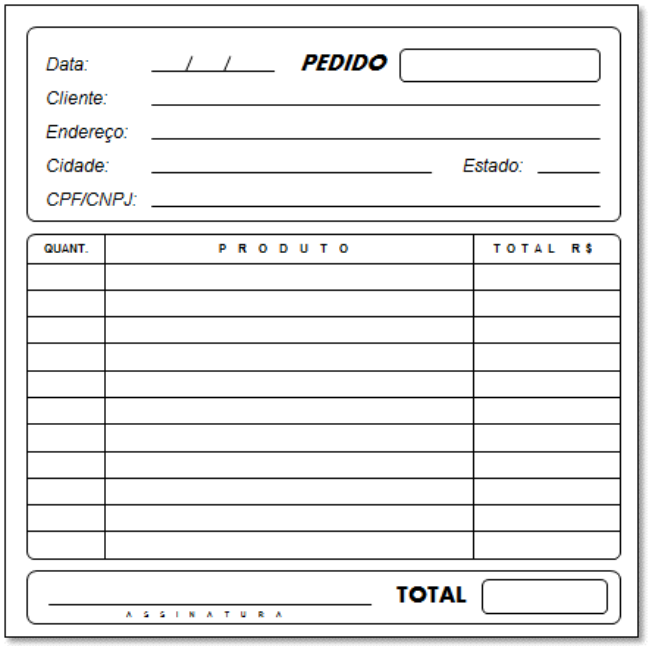

Diagrama de Classe

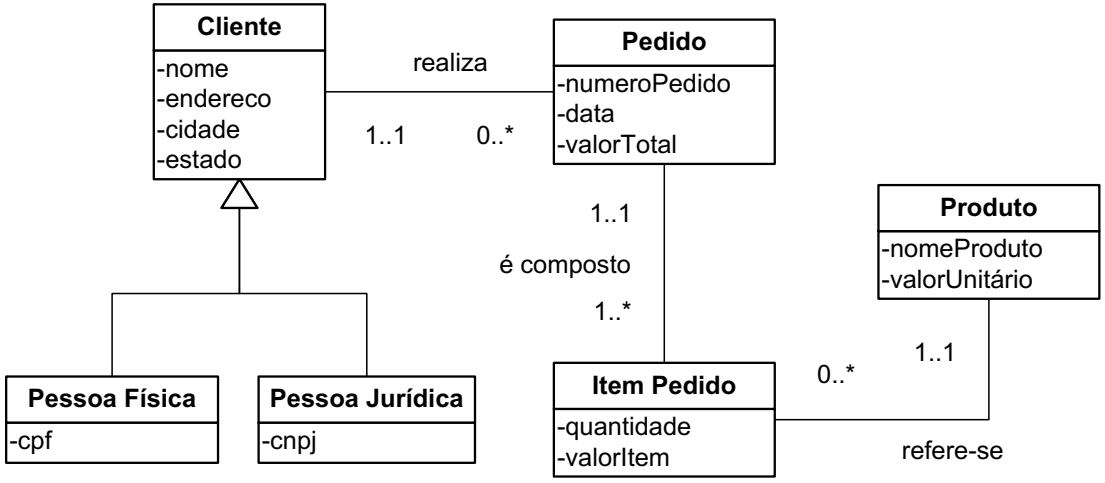

Estruturas não normalizadas

- Dados em estruturas não normalizadas
  - Construção do Modelo de Agregados:

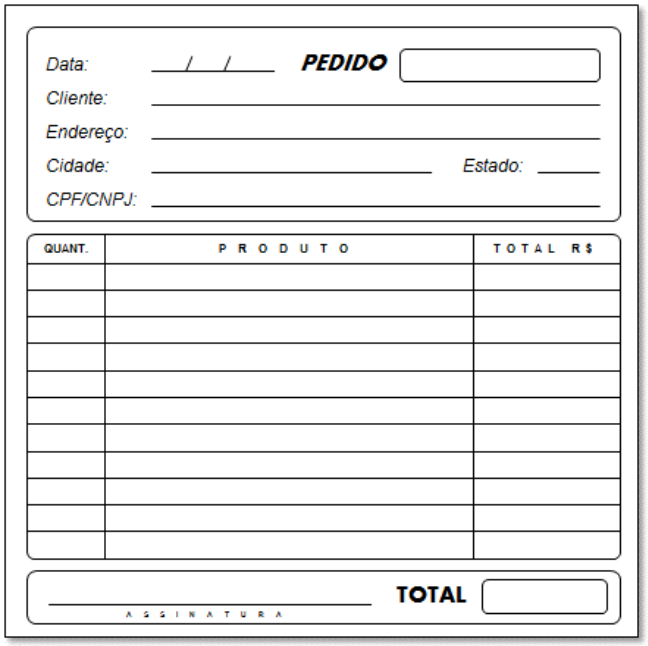

Modelo de Agregados

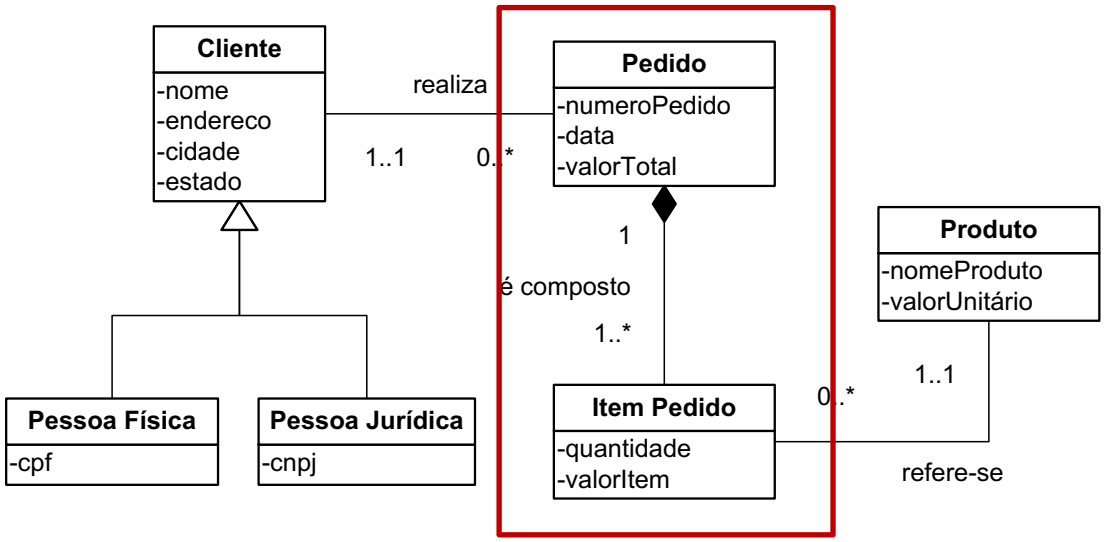

Estruturas não normalizadas

- Dados em estruturas não normalizadas
  - Construção do Modelo de Agregados:

Modelo de Agregados

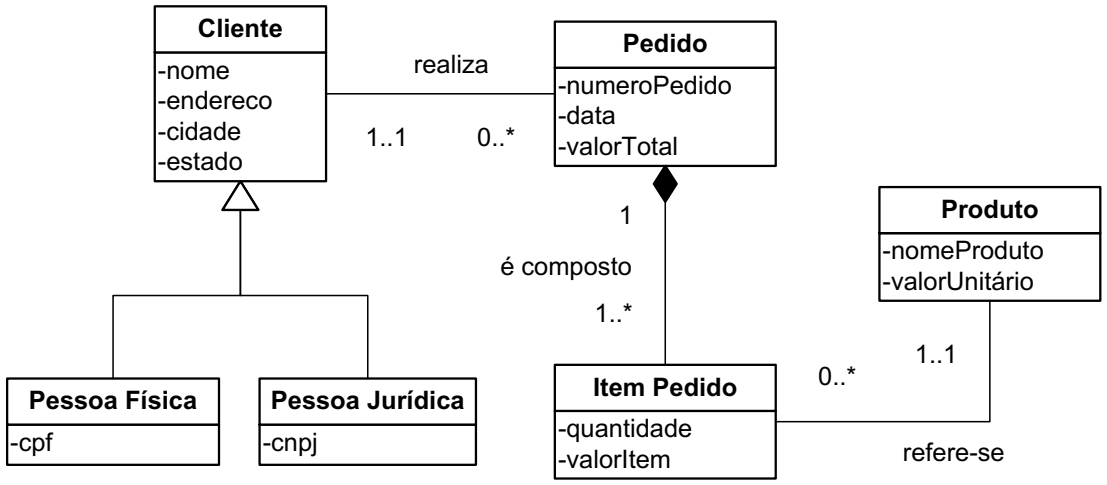

PEDIDO
Data Pedido
Numero Pedido
Valor Total
Nome Cliente
Endereço
Cidade
Estado
CPF / CNPJ
Quantidade de Itens
Item Pedido
Quantidade
Nome Produto
Valor Item

Agenda

- Introdução
- Estruturas não normalizadas
- Estratégias de representação
- Arquiteturas de Aplicações e de Ferramentas de Big Data.

Estratégias de representação

Estratégias de representação

- Conceito de Modelo Canônico:
  - O modelo canônico refere-se à padronização de uma determinada **estrutura** de dados.

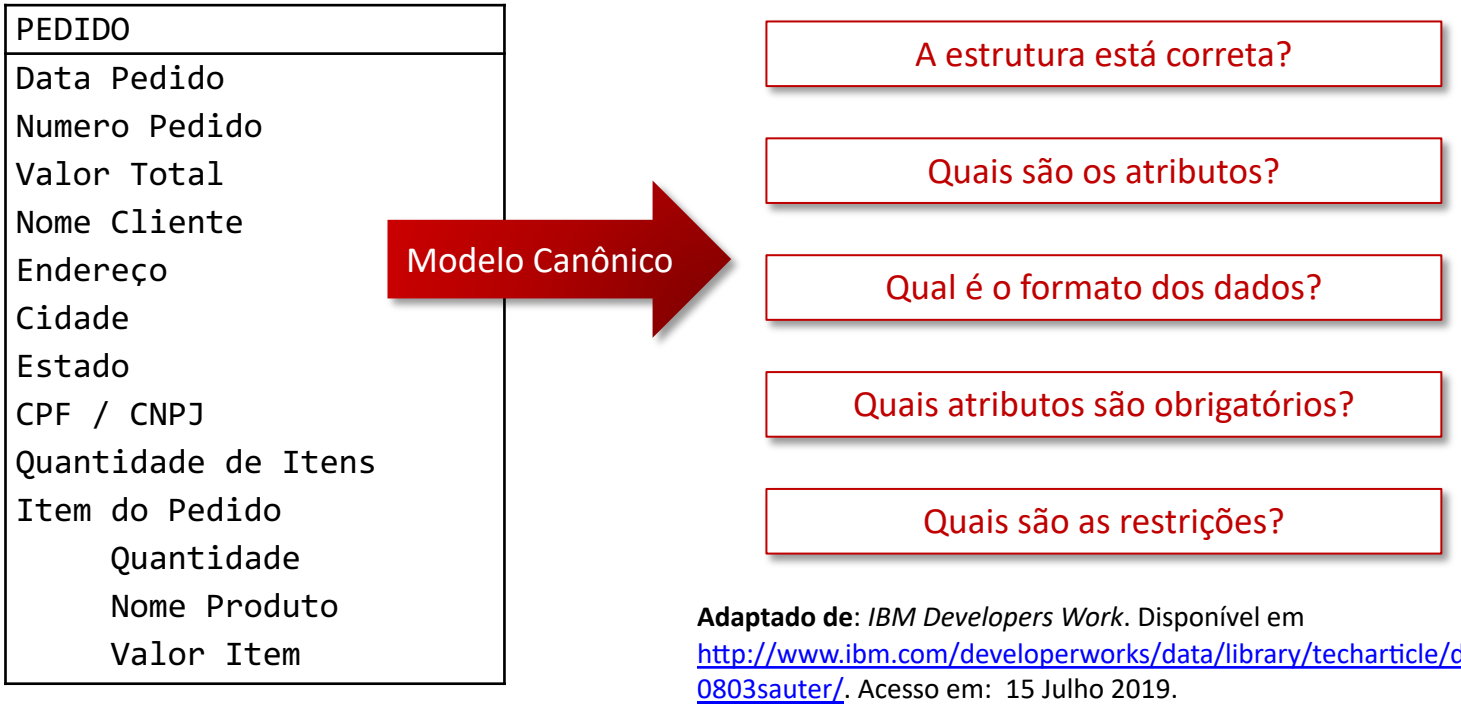

Adaptado de: *IBM Developers Work*. Disponível em http://www.ibm.com/developerworks/data/library/techarticle/dm-0803sauter/. Acesso em: 15 Julho 2019.

Estratégias de representação

- Conceito de Modelo Canônico:

PEDIDO
Data Pedido Numero Pedido Valor Total Nome Cliente Endereço Cidade Estado CPF / CNPJ Quantidade de Itens Item do Pedido Quantidade Nome Produto Valor Item

O Modelo Canônico equivale a um "**Contrato de Serviço**"

Modelo Canônico – Pedido		
Atributo	**Formato**	**Regra**
Data Pedido	Data	(dd/mm/aaaa)
Numero Pedido	Inteiro (10)	Obrigatório
Valor Total	Moeda (13,2)	Obrigatório
Nome Cliente	Texto (60)	Obrigatório
...	...	...
Item do Pedido	Lista 100 produtos	
Quantidade	Inteiro	Obrigatório e maior que zero
Nome Produto	Texto (20)	Depende de um produto para existir
Valor Item	Moeda (13,2)	Obrigatório e maior que zero

Estratégias de representação

- Estratégias de representação:
  - XML;
  - RDF;
  - JSON.

Arquivos XML

Estratégias de representação

- Arquivo XML (*eXtensible Markup Language*):
  - Linguagem de marcação recomendada pelo W3C para criação de documentos cujos dados estejam organizados de forma hierárquica.
  - Aplicações:
    - Banco de dados;
    - Interoperabilidade entre aplicações;
    - Utilização em WebServices;
    - Configuração de aplicativos;
    - Entre outros.

http://www.w3.org/

Estratégias de representação

- Arquivo XML (*eXtensible Markup Language*):

```
<raiz>
   <nó_1.0> valor </nó_1.0>
   <nó_2.0> valor </nó_2.0>
   <nó_3.0>
      <nó_3.1.0> valor </nó_3.1.0>
      <nó_3.2.0>
         <nó_3.2.1> valor </nó_3.2.1>
         <nó_3.2.2> valor </nó_3.2.2>
      </nó_3.2.0>
   </nó_3.0>
</raiz>
```

http://www.w3.org/

Estratégias de representação

- Arquivo XML (*eXtensible Markup Language*):
  - Legibilidade;
  - Flexibilidade (*tags* ilimitadas);
  - Autoexplicativa;
  - Formato hierárquico (um nó pode ter relações do tipo 1:N com outros nós).

http://www.w3.org/

Estratégias de representação

- Arquivo XML (*eXtensible Markup Language*):

Modelo de Agregados

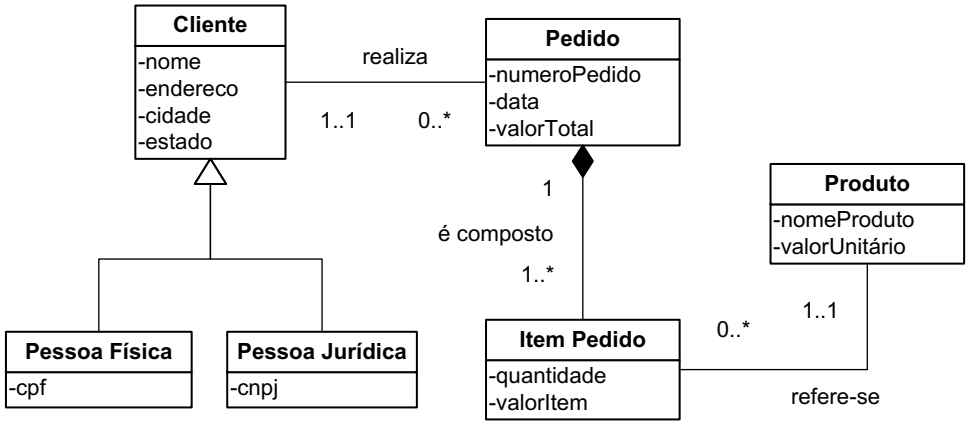


```
<pedido>
   <dataPedido> “21/12/2014” </dataPedido>
   <numeroPedido> 000001 </numeroPedido>
   <valorTotal> 224,59 </valorTotal>
   <nomeCliente> “João da Silva” </nomeCliente>
   <endereco> “Rua Trinta de Setembro, 20” </endereco>
   <cidade> “São Paulo” </cidade>
   <estado> “SP” </estado>
   <cpf> “490.005.340-60” </cpf>
   <cnpj> “” </cnpj>
   <qtdItens> 2 </qtdItens>
   <itemPedido>
      <produto>
         <codigoProduto> 0001 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Calca Jeans” </nomeProduto>
         <valorItem> 134,60 </valorItem>
      </produto>
      <produto>
         <codigoProduto> 0002 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Camiseta Preta” </nomeProduto>
         <valorItem> 89,99 </valorItem>
      </produto>
   </itemPedido>
</pedido>
```

Estratégias de representação

- Arquivo XSD (***X****ML* ***S****chema* ***D****efinition*):
  - Permite a definição da estrutura dos dados usados em documentos XML:
    - Define quais são os nós;
    - Determina a hierarquia dos nós;
    - Especifica os tipos de valores para cada nó;
    - Entre outros.

Estratégias de representação

- Arquivo XSD (***X**ML **S**chema **D**efinition*):

```
<pedido>
   <dataPedido> “21/12/2014” </dataPedido>
   <numeroPedido> 000001 </numeroPedido>
   <valorTotal> 224,59 </valorTotal>
   <nomeCliente> “João da Silva” </nomeCliente>
   <endereco> “Rua Trinta de Setembro, 20” </endereco>
   <cidade> “São Paulo” </cidade>
   <estado> “SP” </estado>
   <cpf> “490.005.340-60” </cpf>
   <cnpj> “” </cnpj>
   <qtdItens> 2 </qtdItens>
   <itemPedido>
      <produto>
         <codigoProduto> 0001 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Calca Jeans” </nomeProduto>
         <valorItem> 134,60 </valorItem>
      </produto>
      <produto>
         <codigoProduto> 0002 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Camiseta Preta” </nomeProduto>
         <valorItem> 89,99 </valorItem>
      </produto>
   </itemPedido>
</pedido>
```

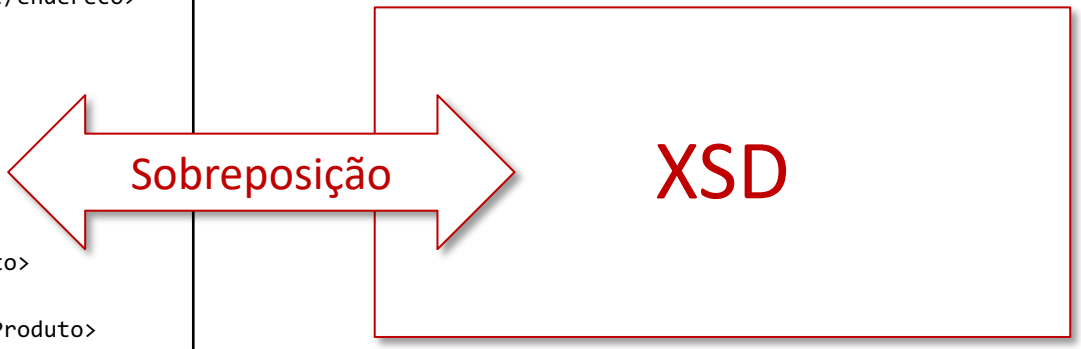

Estratégias de representação

- Arquivo XSD (***X**ML **S**chema **D**efinition*):

```
<pedido>
   <dataPedido> “21/12/2014” </dataPedido>
   <numeroPedido> 000001 </numeroPedido>
   <valorTotal> 224,59 </valorTotal>
   <nomeCliente> “João da Silva” </nomeCliente>
   <endereco> “Rua Trinta de Setembro, 20” </endereco>
   <cidade> “São Paulo” </cidade>
   <estado> “SP” </estado>
   <cpf> “490.005.340-60” </cpf>
   <cnpj> “” </cnpj>
   <qtdItens> 2 </qtdItens>
   <itemPedido>
      <produto>
         <codigoProduto> 0001 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Calca Jeans” </nomeProduto>
         <valorItem> 134,60 </valorItem>
      </produto>
      <produto>
         <codigoProduto> 0002 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Camiseta Preta” </nomeProduto>
         <valorItem> 89,99 </valorItem>
      </produto>
   </itemPedido>
</pedido>
```

```
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema">
<xs:element name="pedido">
  <xs:complexType>
    <xs:sequence>
      <xs:element type="xs:string" name="dataPedido"/>
      <xs:element type="xs:integer" name="numeroPedido"/>
      <xs:element type="xs:float" name="valorTotal"/>
      <xs:element type="xs:string" name="nomeCliente"/>
...
      <xs:element type="xs:integer"name="qtdItens"/>
      <xs:element name="itemPedido">
        <xs:complexType>
          <xs:sequence>
            <xs:element name="produto" maxOccurs=“100" minOccurs=“1">
              <xs:complexType>
                <xs:sequence>
                  <xs:element type="xs:integer" name="codigoProduto"/>
                  <xs:element type="xs:integer" name="quantidade"/>
                  <xs:element type="xs:string" name="nomeProduto"/>
                  <xs:element type="xs:float" name="valorItem"/>
                </xs:sequence>
              </xs:complexType>
            </xs:element>
          </xs:sequence>
        </xs:complexType>
...
```

Estratégias de representação

- Arquivo XSD (***X**ML **S**chema **D**efinition*):

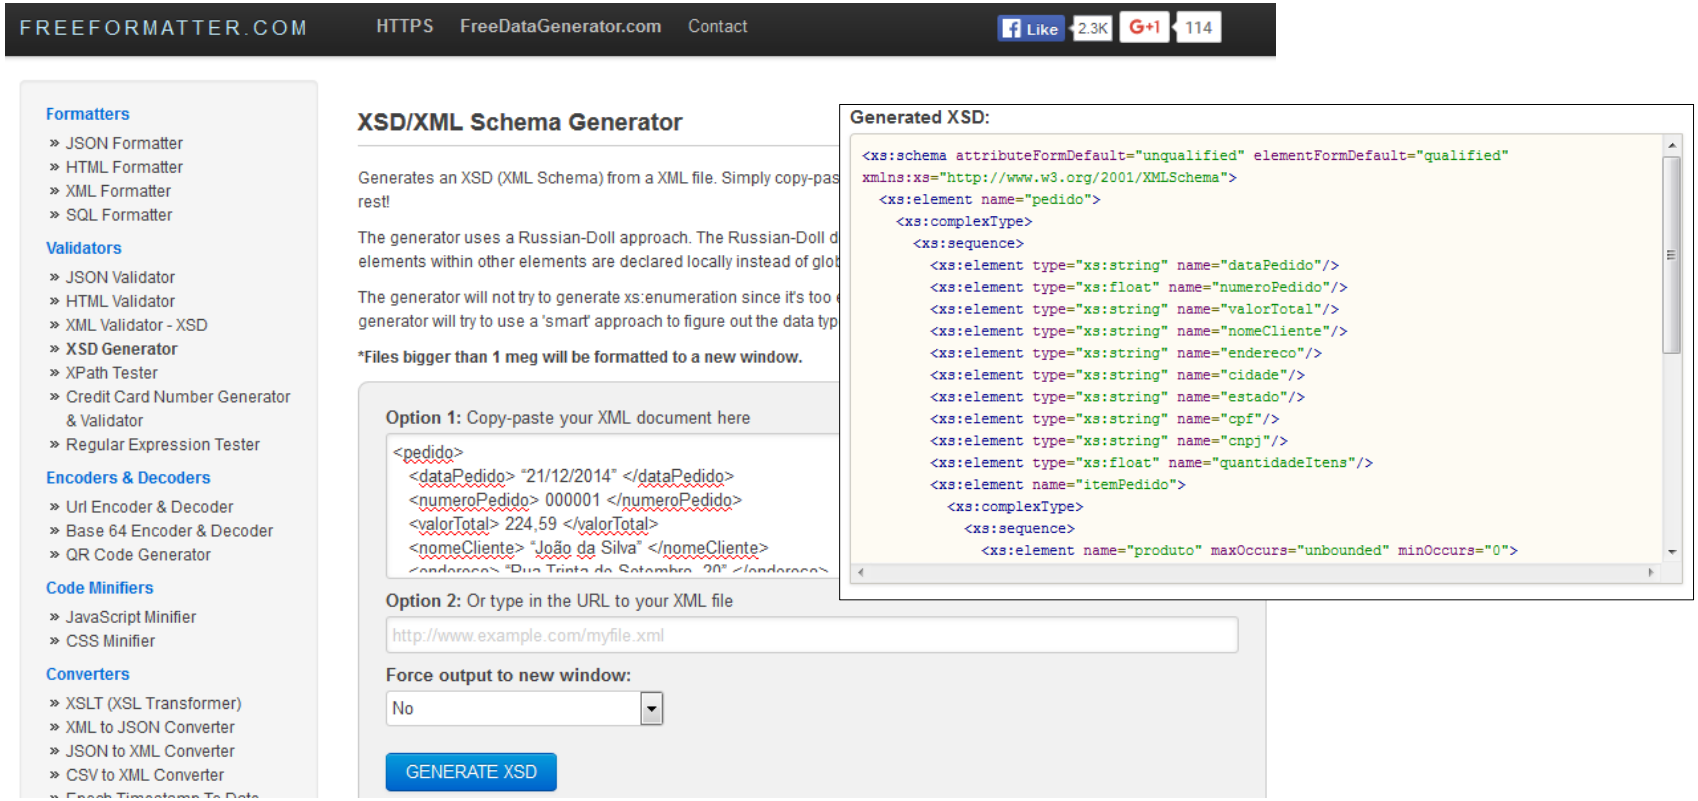

http://www.freeformatter.com/xsd-generator.html

Arquivos RDF

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):
  - Linguagem para representação e compartilhamento de informações na Web;
  - Utiliza URI (*Uniform Resource Identifier*) e XML para representar dados no formato de triplas:

```
(sujeito : predicado : objeto)
```

URI (Uniform Resource Identifier) – é um identificador usado para determinar a localização de um recurso na Internet. Este recurso pode ser um documento (URL), pode ser um elemento (URN) ou ambos.

http://www.w3.org/

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):
  - Linguagem para representação e compartilhamento de informações na Web;
  - Utiliza URI (*Uniform Resource Identifier*) e XML para representar dados no formato de triplas:

```
(sujeito : predicado : objeto)
```

  - As triplas podem ser representadas por grafos, de forma que o Sujeito e o Objeto sejam os nós, enquanto que o Predicado seja a conexão entre os nós.

http://www.w3.org/

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):

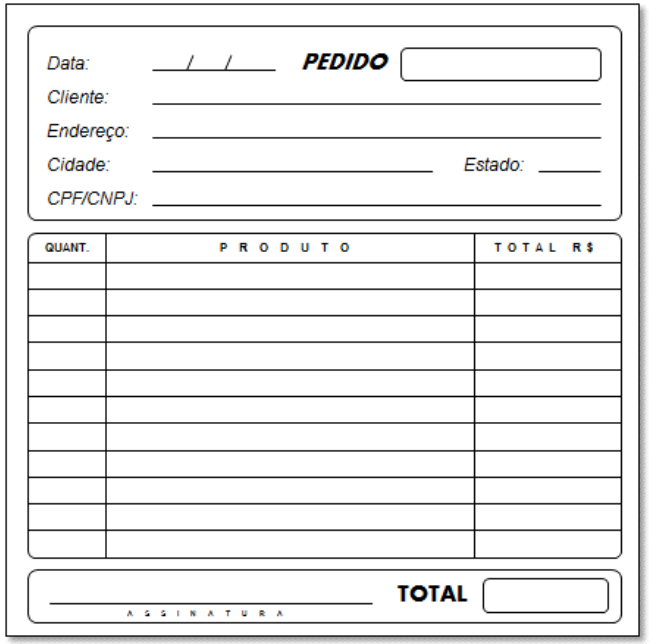

SUJEITO	PREDICADO	OBJETO
pedido	tem	numeroPedido
pedido	tem	dataPedido
pedido	tem	valorTotal
pedido	tem	nomeCliente
pedido	tem	enderecoCliente
...	...	...
pedido	tem	itemPedido
pedido	tem	qtdItens
produto	é	itemPedido
nomeCliente	temValor	“João da Silva”
dataPedido	temValor	21/12/2014
numeroPedido	temValor	0001
qtdItens	temValor	2
produto	tem	codigoProduto
codigoProduto	temValor	0001
produto	tem	nomeProduto
nomeProduto	temValor	“Calça Jeans”
...	...	...

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):

SUJEITO	PREDICADO	OBJETO
pedido	tem	numeroPedido
pedido	tem	dataPedido
pedido	tem	valorTotal
pedido	tem	nomeCliente
pedido	tem	enderecoCliente
...	...	...
pedido	tem	itemPedido
pedido	tem	qtdItens
produto	é	itemPedido
nomeCliente	temValor	“João da Silva”
dataPedido	temValor	21/12/2014
numeroPedido	temValor	0001
qtdItens	temValor	2
produto	tem	codigoProduto
codigoProduto	temValor	0001
produto	tem	nomeProduto
nomeProduto	temValor	“Calça Jeans”
...	...	...

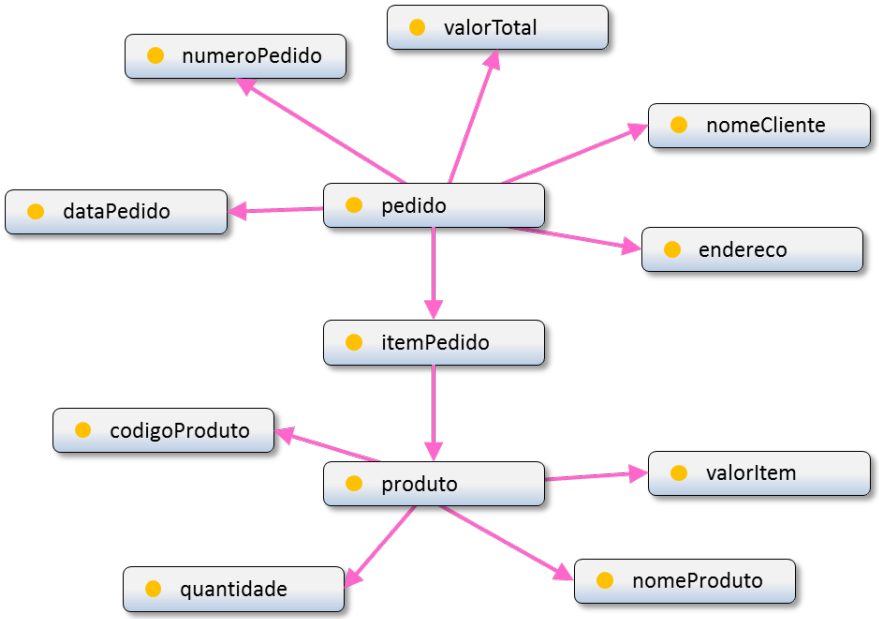

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):

```
<pedido>
   <dataPedido> “21/12/2014” </dataPedido>
   <numeroPedido> 000001 </numeroPedido>
   <valorTotal> 224,59 </valorTotal>
   <nomeCliente> “João da Silva” </nomeCliente>
   <endereco> “Rua Trinta de Setembro, 20” </endereco>
   <cidade> “São Paulo” </cidade>
   <estado> “SP” </estado>
   <cpf> “490.005.340-60” </cpf>
   <cnpj> “” </cnpj>
   <qtdItens> 2 </qtdItens>
   <itemPedido>
      <produto>
         <codigoProduto> 0001 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Calca Jeans” </nomeProduto>
         <valorItem> 134,60 </valorItem>
      </produto>
      <produto>
         <codigoProduto> 0002 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Camiseta Preta” </nomeProduto>
         <valorItem> 89,99 </valorItem>
      </produto>
   </itemPedido>
</pedido>
```

```
<?xml version="1.0" encoding="utf-8" ?>
<rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
         xmlns:ns0="dataPedido"
         xmlns:ns1="numeroPedido"
         xmlns:ns2="valorTotal"
         xmlns:ns3=“nomeCliente"
         xmlns:ns4=“endereco"
...
         xmlns:ns16="valorItem">

  <rdf:Description rdf:nodeID="genid1">
    <rdf:type rdf:resource="http://njh.me/pedido"/>
    <ns0:dataPedido> “21/12/2014” </ns0:dataPedido>
    <ns1:numeroPedido> 000001 </ns1:numeroPedido>
    <ns2:valorTotal> 224,59 </ns2:valorTotal>
    <ns3:nomeCliente> “João da Silva” </ns3:nomeCliente>
    <ns4:endereco> “Rua Trinta de Setembro, 20” </ns4:endereco>
    <ns5:cidade> “São Paulo” </ns5:cidade>
    <ns6:estado> “SP” </ns6:estado>
    <ns7:cpf> “490.005.340-60” </ns7:cpf>
    <ns8:cnpj> “” </ns8:cnpj>
    <ns9:qtdItens> 2 </ns9:qtdItens>
    <ns10:itemPedido>
      <rdf:Description>
        <rdf:type rdf:resource="http://njh.me/produto"/>
...
```

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):

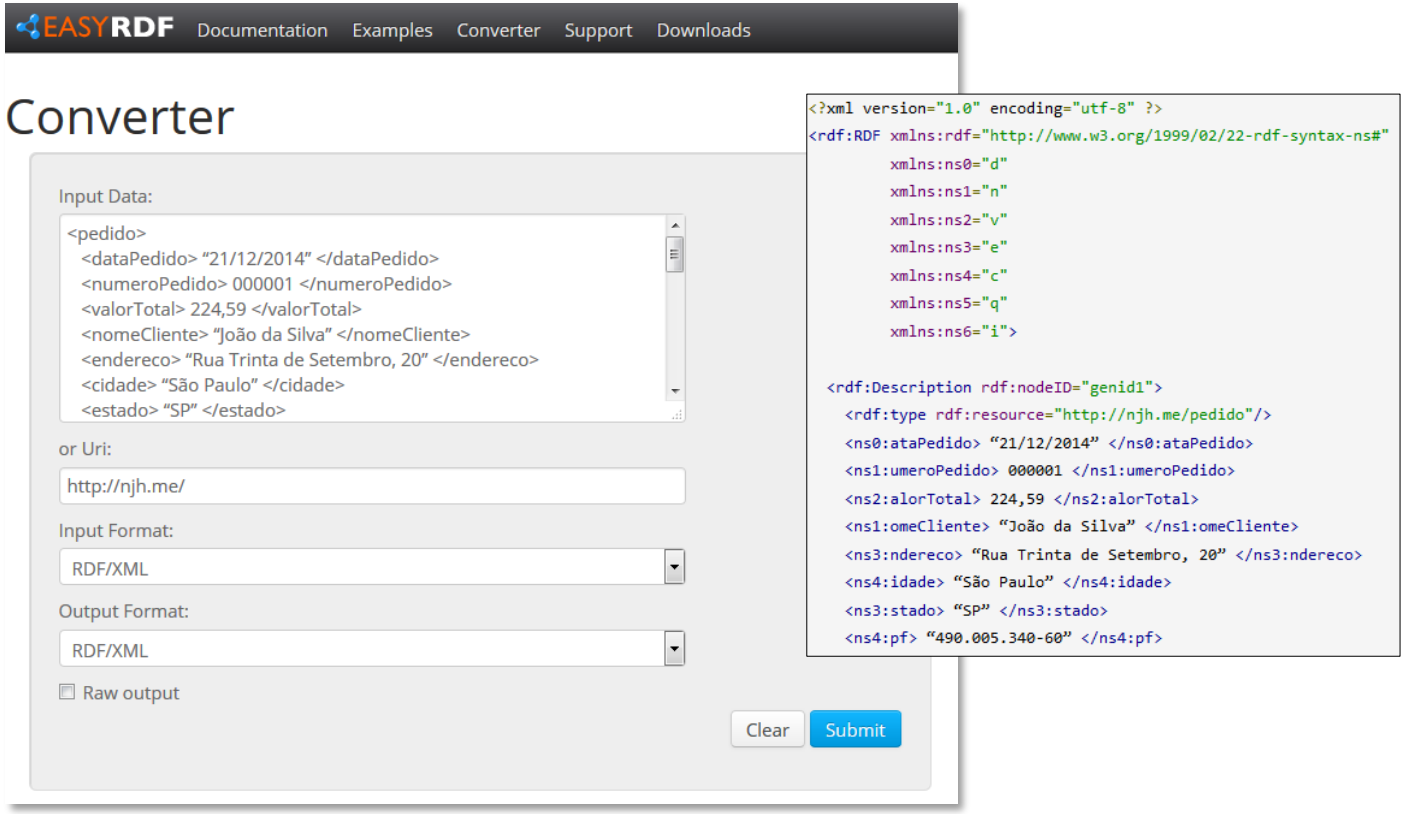

http://www.easyrdf.org/converter

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):

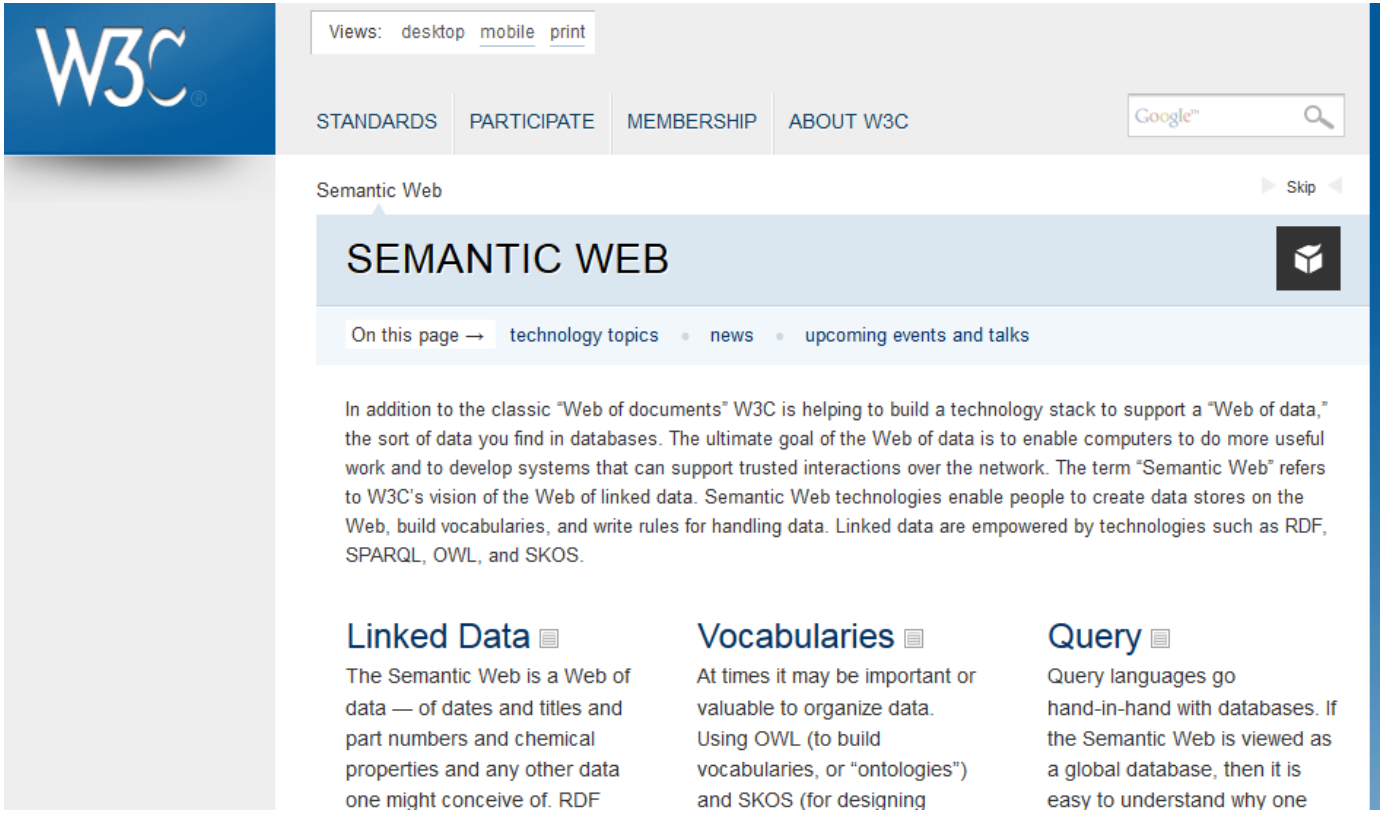

https://www.w3.org/standards/semanticweb/

Estratégias de representação

- Arquivo RDF (***R**esource **D**escription **F**ramework*):
  - Flexibilidade;
  - Estrutura de grafos;
  - Interoperabilidade entre aplicações;
  - Não há separação entre dados e estruturas;
  - É mais complexo do que o XML puro;
  - Demanda mais recursos de máquina para manipulação.

http://www.w3.org/

Arquivos JSON

Estratégias de representação

- Arquivo JSON (***JavaScript Object Notation***):
  - Subconjunto da notação JavaScript, utilizado na serialização de dados entre sistemas computacionais;
  - É independente de linguagem, podendo ser analisado e processado por aplicações escritas em C, .NET, Java, entre outros;
  - Usado por APIs e Web Services para expor dados na Internet.

http://www.json.org

Estratégias de representação

- Arquivo JSON (***JavaScript Object Notation***):
  - Estrutura básica:

```
    “elemento_01” : valor
```

```
{
    “elemento_01” : valor ,
    “elemento_02” : valor ,
      ...
    “elemento_NN” : valor
}
```

http://www.json.org

Estratégias de representação

- Arquivo JSON (***JavaScript Object Notation***):
  - Estrutura básica:

```
{
   “raiz” : {
        “elemento_01” : valor ,
        “elemento_02” : valor ,
         ...                  ,
        “elemento_NN” : valor
    }
}
```

http://www.json.org

Estratégias de representação

- Arquivo JSON (***JavaScript Object Notation***):
  - Estrutura básica:

```
{
   “raiz” : {
        “elemento_01” : valor ,

        “lista_01”    : [
                         “subitem_01” : valor ,
                         “subitem_02” : valor ,
                          ...                 ,
                         “subitem_NN” : valor
                        ]
    }
}
```

http://www.json.org

Estratégias de representação

- Arquivo JSON (***Java**Script **O**bject **N**otation*):

```
<pedido>
   <dataPedido> “21/12/2014” </dataPedido>
   <numeroPedido> 000001 </numeroPedido>
   <valorTotal> 224,59 </valorTotal>
   <nomeCliente> “João da Silva” </nomeCliente>
   <endereco> “Rua Trinta de Setembro, 20” </endereco>
   <cidade> “São Paulo” </cidade>
   <estado> “SP” </estado>
   <cpf> “490.005.340-60” </cpf>
   <cnpj> “” </cnpj>
   <qtdItens> 2 </qtdItens>
   <itemPedido>
      <produto>
         <codigoProduto> 0001 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Calca Jeans” </nomeProduto>
         <valorItem> 134,60 </valorItem>
      </produto>
      <produto>
         <codigoProduto> 0002 </codigoProduto>
         <quantidade> 1 </quantidade>
         <nomeProduto> “Camiseta Preta” </nomeProduto>
         <valorItem> 89,99 </valorItem>
      </produto>
   </itemPedido>
</pedido>
```

```
{
   "dataPedido": "21/12/2014",
   "numeroPedido": "000001",
   "valorTotal": "224,59",
   "nomeCliente": "João da Silva",
   "endereco": "Rua Trinta de Setembro, 20",
   "cidade": "São Paulo",
   "estado": "SP",
   "cpf": "490.005.340-60",
   "cnpj": "",
   "qtdItens": "2",
   "itemPedido": [
      {
         "codigoProduto": "0001",
         "quantidade": "1",
         "nomeProduto": "Calca Jeans",
         "valorItem": "134,60"
      },
      {
         "codigoProduto": "0002",
         "quantidade": "1",
         "nomeProduto": "Camiseta Preta",
         "valorItem": "89,99"
      }
   ]
}
```

Estratégias de representação

- Arquivo JSON (***JavaScript Object Notation***):

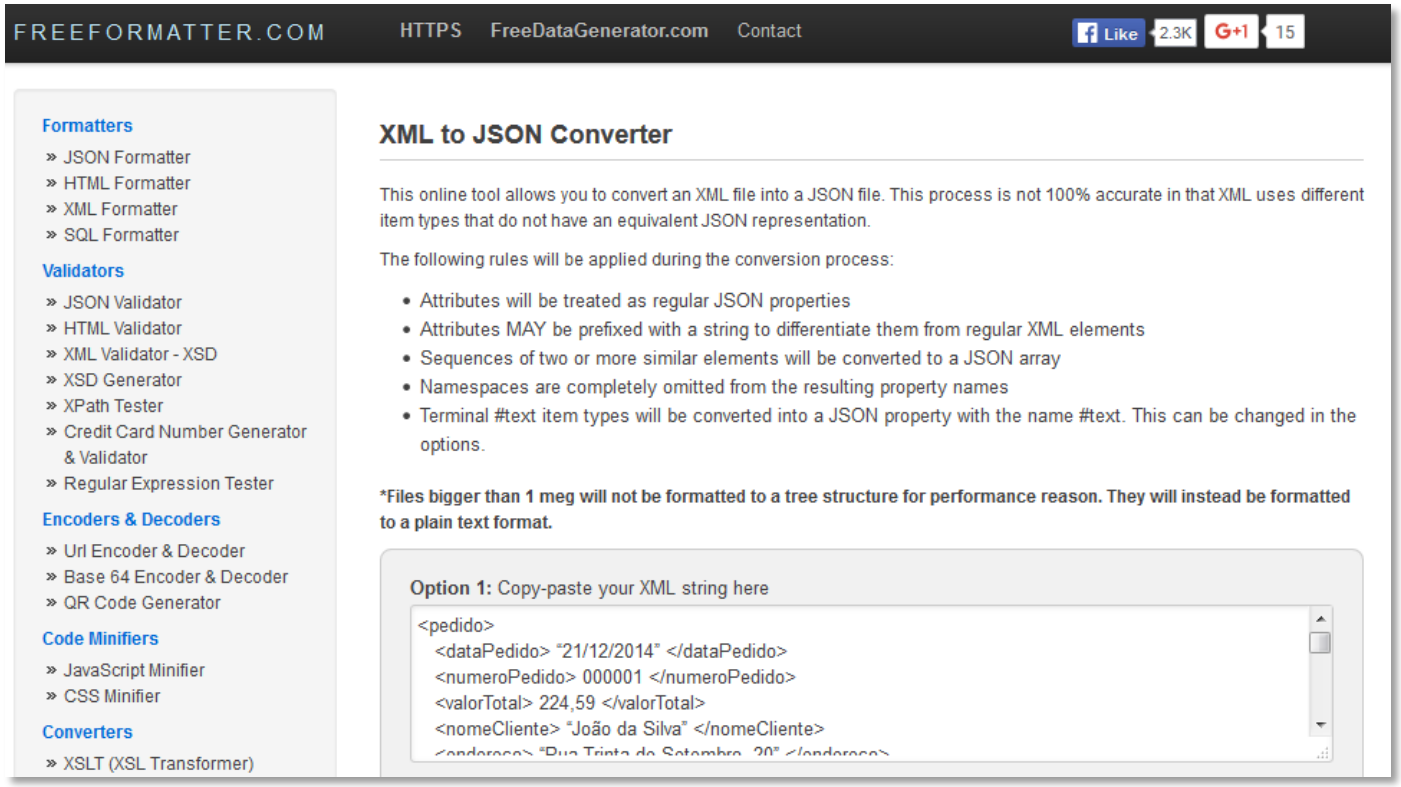

http://www.freeformatter.com/xml-to-json-converter.html

Estratégias de representação

- Arquivo JSON (***Java**Script **O**bject **N**otation*):

Formatted JSON:


```
"nomeCliente": "João da Silva",
"endereco": "Rua Trinta de Setembro, 20",
"cidade": "São Paulo",
"estado": "SP",
"cpf": "490.005.340-60",
"cnpj": "",
"qtdItens": "2",
"itemPedido": [
   {
      "codigoProduto": "0001",
      "quantidade": "1",
      "nomeProduto": "Calca Jeans",
      "valorItem": "134,60"
   },
   [
```

Estratégias de representação

- Arquivo JSON (***JavaScript Object Notation***):

Viewer | Text | JSON Viewer

Paste | Copy | Format | Remove white space | Clear | Load JSON data


```
{
  "pedido": {
       "dataPedido": "21/12/2014",
       "numeroPedido": "000001",
       "valorTotal": "224,59",
       "nomeCliente": "João da Silva",
       "endereco": "Rua Trinta de Setembro, 20",
       "cidade": "São Paulo",
       "estado": "SP",
       "cpf": "490.005.340-60",
       "cnpj": "",
       "qtdItens": "2",
       "itemPedido": [
            {
                 "codigoProduto": "0001",
                 "quantidade": "1",
                 "nomeProduto": "Calca Jeans",
                 "valorItem": "134,60"
       },
            {
                 "codigoProduto": "0002",
                 "quantidade": "1",
                 "nomeProduto": "Camiseta Preta",
                 "valorItem": "89.99"
       }
    ]
  }
}
```


Viewer | Text | JSON Viewer

- JSON
  - pedido
    - dataPedido : "21/12/2014"
    - numeroPedido : "000001"
    - valorTotal : "224,59"
    - nomeCliente : "João da Silva"
    - endereco : "Rua Trinta de Setembro, 20"
    - cidade : "São Paulo"
    - estado : "SP"
    - cpf : "490.005.340-60"
    - cnpj : ""
    - qtdItens : "2"
    - itemPedido
      - 0
        - codigoProduto : "0001"
        - quantidade : "1"
        - nomeProduto : "Calca Jeans"
        - valorItem : "134,60"
      - 1
        - codigoProduto : "0002"
        - quantidade : "1"
        - nomeProduto : "Camiseta Preta"
        - valorItem : "89.99"

http://jsonviewer.stack.hu

Estratégias de representação

- JSON Schema:
  - Assim como no XML, é possível definir qual a estrutura e o tipo dos dados usados em arquivos JSON:
    - Definição dos atributos;
    - Definição da ordem dos atributos;
    - Definição dos tipos de dados
    - Regras;
    - Entre outros.

http://www.json.org

Estratégias de representação

- JSON Schema:

```
{
   "dataPedido": "21/12/2014",
   "numeroPedido": "000001",
   "valorTotal": "224,59",
   "nomeCliente": "João da Silva",
   "endereco": "Rua Trinta de Setembro, 20",
   "cidade": "São Paulo",
   "estado": "SP",
   "cpf": "490.005.340-60",
   "cnpj": "",
   "qtdItens": "2",
   "itemPedido": [
      {
         "codigoProduto": "0001",
         "quantidade": "1",
         "nomeProduto": "Calca Jeans",
         "valorItem": "134,60"
      },
      {
         "codigoProduto": "0002",
         "quantidade": "1",
         "nomeProduto": "Camiseta Preta",
         "valorItem": "89,99"
      }
   ]
}
```

```
{ "$schema": "http://json-schema.org/draft-04/schema#",
  "type": "object",
  "properties": {
    "pedido": {
      "type": "object",
      "properties": {
        "dataPedido": { "type": "string" },
        "numeroPedido": { "type": “integer" },
        "valorTotal": { "type": “float" },
        "nomeCliente": { "type": "string" },
        "endereco": { "type": "string" },
        "cidade": { "type": "string" },
        "estado": { "type": "string" },
        "cpf": { "type": "string" },
        "cnpj": { "type": "string" },
        "qtdItens": { "type": “integer" },
        "itemPedido": { "type": "array",
          "items": {"type": "object", "properties":
           {  "codigoProduto": { "type": “integer" },
              "quantidade": { "type": “integer" },
              "nomeProduto": { "type": "string" },
              "valorItem": { "type": “float" }
           }, "required": [  "codigoProduto", "quantidade",
                             "nomeProduto", "valorItem" ] } }},
      "required": ["dataPedido", "numeroPedido", "valorTotal",
                   "nomeCliente", "endereco", "cidade", "estado",
                   "cpf", "cnpj", "qtdItens", "itemPedido" ]    }
  },  "required": [ "pedido" ]
}
```

Estratégias de representação

- JSON Schema:

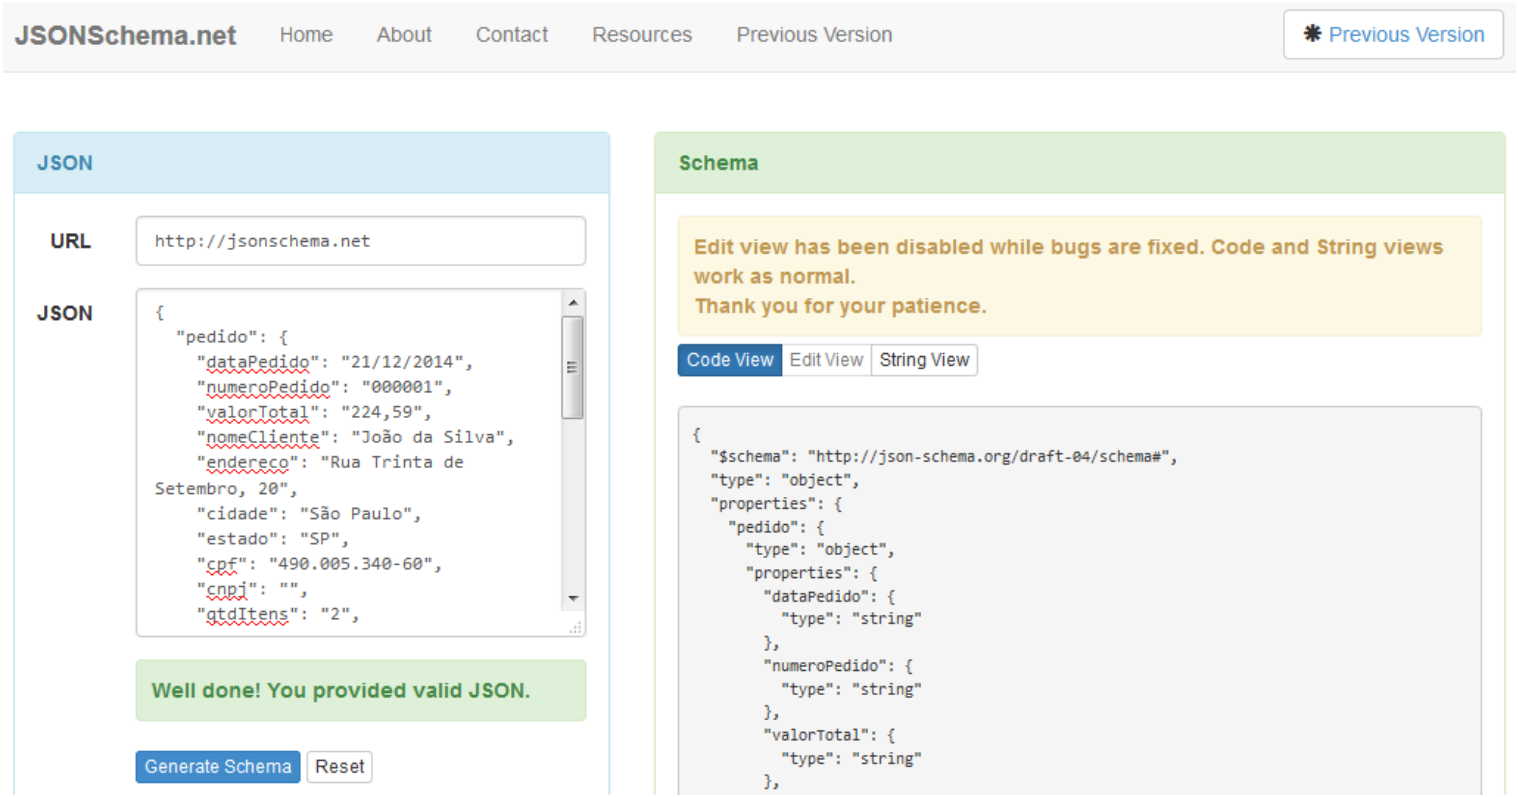

http://jsonschema.net

Agenda

- Introdução
- Estruturas não normalizadas
- Estratégias de representação
- Arquiteturas de Aplicações e de Ferramentas de Big Data.

Arquitetura de Big Data

Projeto Hadoop

- 2003

The Google File System

Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung

Google*

- 2004

MapReduce: Simplified Data Processing on Large Clusters

Jeffrey Dean and Sanjay Ghemawat

jeff@google.com, sanjay@google.com

Google, Inc.

- 2006

Bigtable: A Distributed Storage System for Structured Data

Fay Chang, Jeffrey Dean, Sanjay Ghemawat, Wilson C. Hsieh, Deborah A. Wallach
Mike Burrows, Tushar Chandra, Andrew Fikes, Robert E. Gruber

{fay,jeff,sanjay,wilsonh,kerr,m3b,tushar,fikes,gruber}@google.com

Google, Inc.

Abstract

gtable is a distributed storage system for managing
tured data that is designed to scale to a very large

achieved scalability and high performance, but Big
provides a different interface than such systems. Big
does not support a full relational data model; inste

Projeto Hadoop

- ***MapReduce*** é um paradigma de programação paralela para processamento distribuído proposto pelo Google.
  - ***MAP*** é o processo de mapear/dividir a requisição
  - ***REDUCE*** é o processo de agrefação do resultado

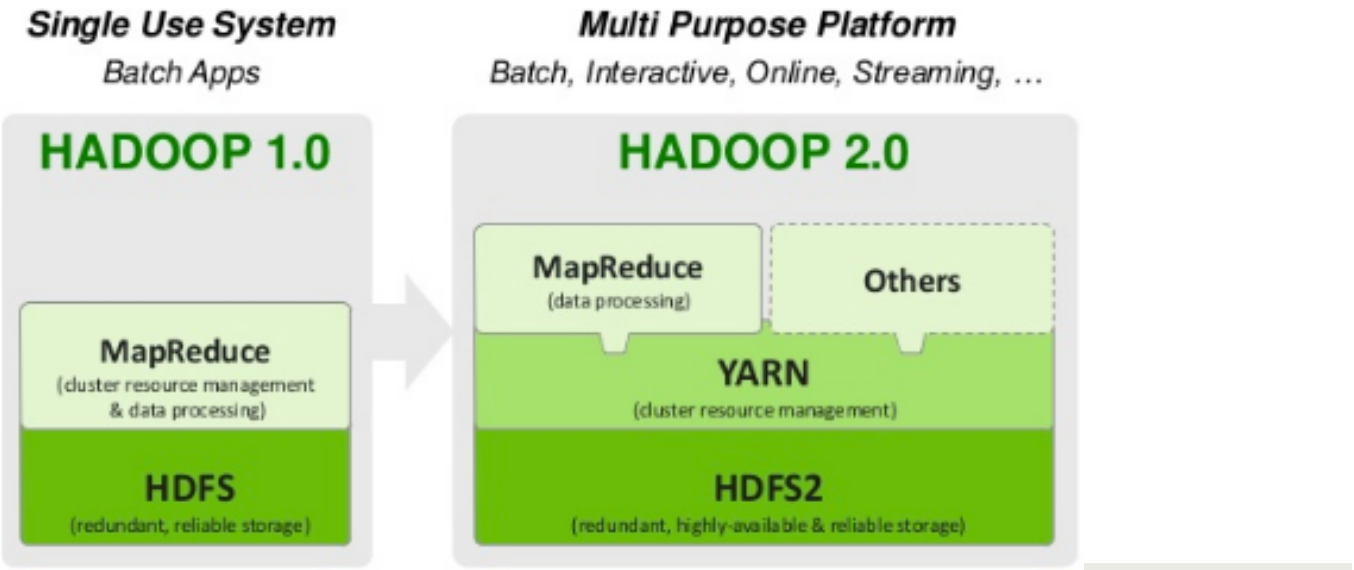

Arquitetura/Ecossistema Hadoop

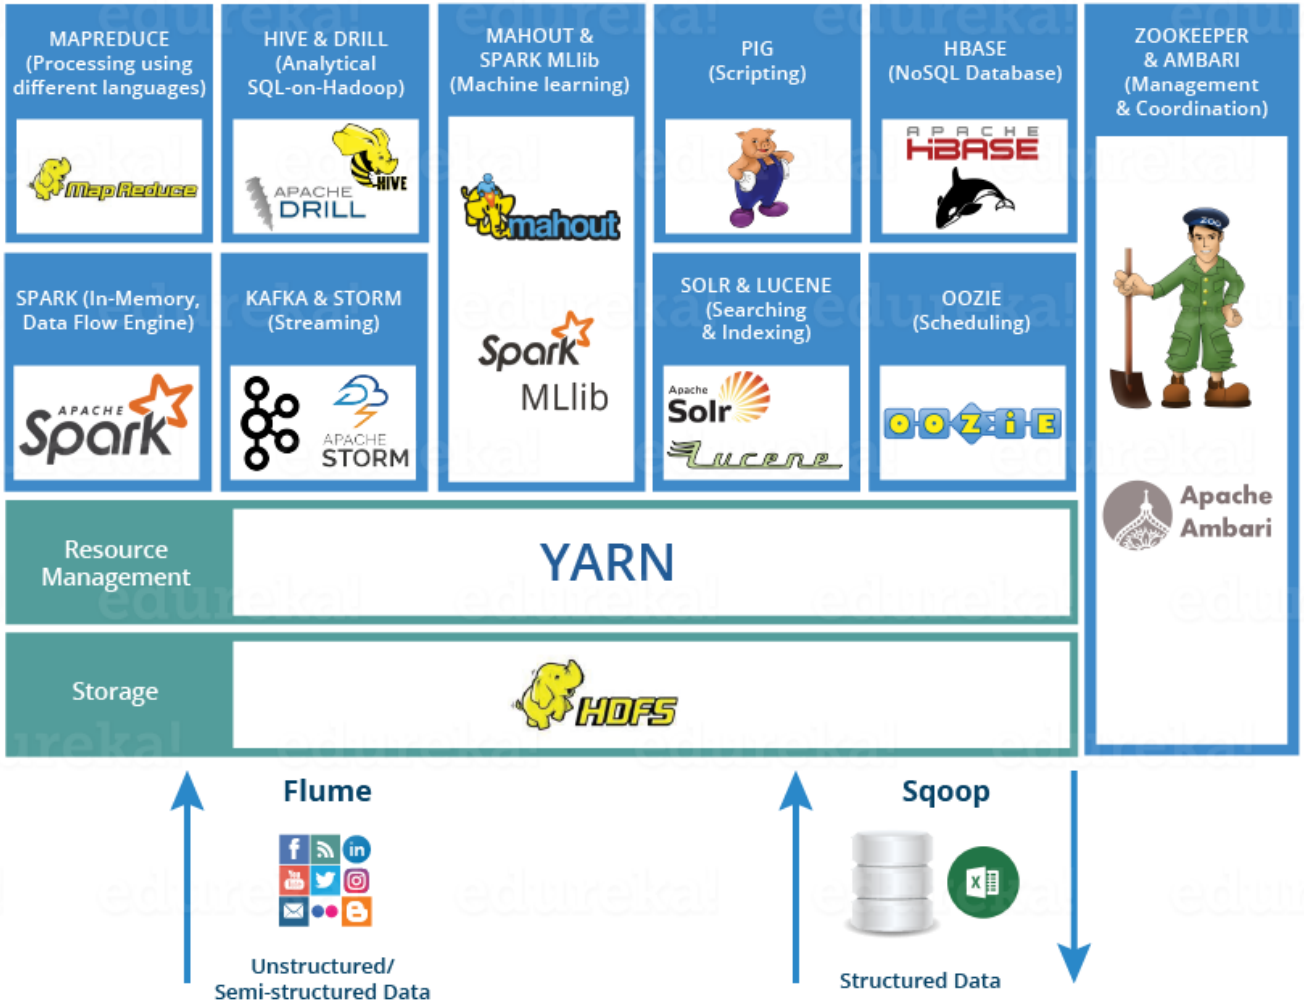

Distribuições Hadoop

Agenda

- Introdução
- Estruturas não normalizadas
- Estratégias de representação
- Arquiteturas de Aplicações e de Ferramentas de Big Data.

Aplicações Big Data.

Exemplo de Aplicações

Overview

- Tornar a estimativa de tempo de retorno/normalização no serviço de fornecimento de serviço mais preciso e específico para cada tipo de instalação ou tipo de equipamento.
- Priorizar os clientes através de determinadas regras para que, caso haja alguma falha no fornecimento, o tempo de retorno/normalização sejam comunicados de forma pró-ativa através de RPA (Robot Process Automation).

Exemplo de Aplicações

- Para o tempo de retorno/normalização foram selecionados 5 (cinco) modelos de regressão;
- Para a priorização de clientes foram selecionados 2 (dois) modelos de scoring.

Exemplo de Aplicações

Lições aprendidas

- Aumentar janela de tempo para treinamento dos modelos;
- Aumentar a base de instalações binarizadas de acordo com as ocorrências (reduzir tempo de processamento);
- Notebook de score para re-treino automatico de acordo com a performance do modelo em operação.

Conceitos de Big Data

Representação de Dados e Arquitetura de Banco de dados não Relacionais

Prof. Dr. Pedro Luiz Pizzigatti Corrêa
pedro.correa@usp.br

Segundo semestre 2019