

# Big Data Integration

## Tópicos Emergentes

Kellyton Brito

[kellyton.brito@gmail.com](mailto:kellyton.brito@gmail.com)

IN1137 - Integração de Dados

Centro de informática - UFPE

Novembro / 2016

# Agenda

- Introdução a Big Data
- Big Data Integration: Principais Tópicos
- Big Data Integration: Tópicos Emergentes
  - CrowdSourcing
  - Seleção de Fontes
  - Profiling de Fontes
- Tópico de Discussão:
  - Big data e governos

# Introdução a Big Data

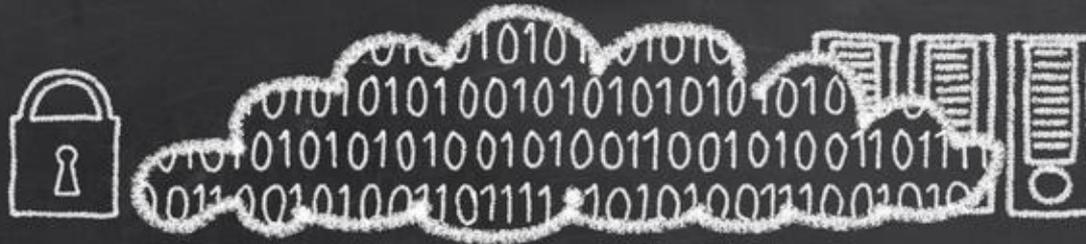
*“Big Data é o termo utilizado para descrever grandes volumes de dados e que ganha cada vez mais relevância à medida que a sociedade se depara com um aumento sem precedentes no número de informações geradas a cada dia”.*

*IBM (2014)*

# Introdução a Big Data

- **Volume:** Número (quantidade) de dados manipulados e posteriormente analisados.
- **Velocidade:** Velocidade em que os dados são gerados e armazenados, e idealmente processados.
- **Variedade:** Diversos tipos de dados provenientes de varias fontes, sendo eles estruturados ou não estruturados.
- **Veracidade:** Confiabilidade e precisão dos dados obtidos.
- **Valor:** Vantagem que a análise dos dados podem oferecer

# Introdução a Big Data



# BIG DATA



**VOLUME**  
DATA SIZE



**VELOCITY**  
SPEED OF CHANGE



**VARIETY**  
DIFFERENT FORMS  
OF DATA SOURCES



**VERACITY**  
UNCERTAINTY OF  
DATA

# Big Data Integration – Principais Tópicos

1. Alinhamento de Esquemas
  - Esquemas distintos, mesmo significado?
2. Resolução de Entidades
  - Quais registros são referentes à mesma entidade (e quais são referentes a entidades distintas)
3. Fusão de Dados
  - Qual valor realmente reflete a realidade?

# Tópicos Emergentes:

Crowdsourcing  
Source Selection  
Source Profiling

# Tópicos Emergentes:

***Crowdsourcing***

Source Selection

Source Profiling

# CrowdSourcing

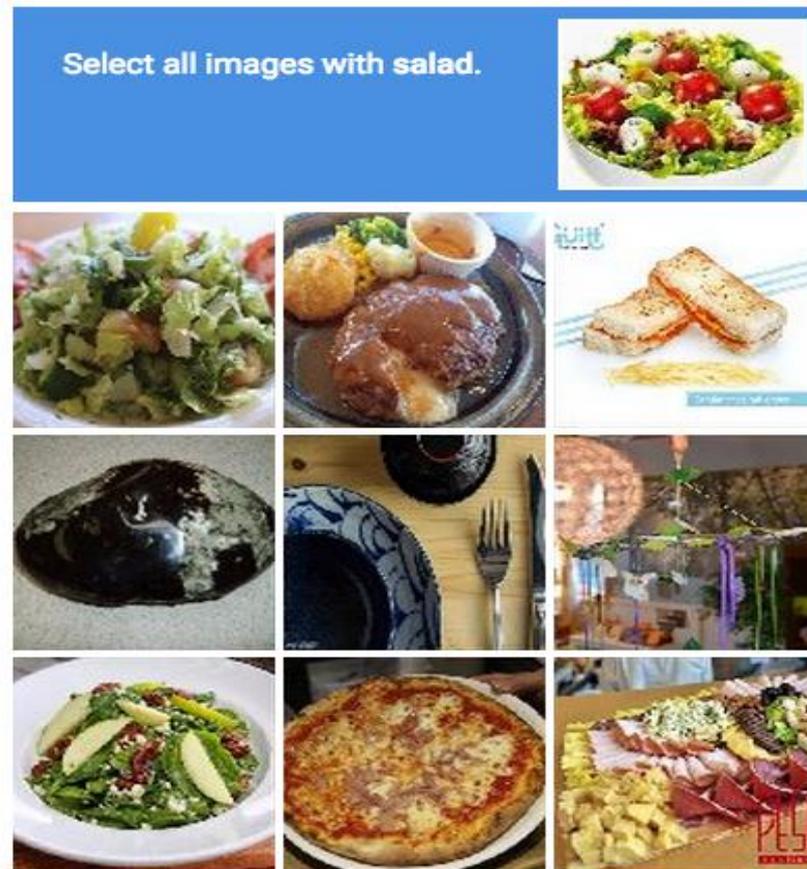
**Definition 5.1** (Crowdsourcing Systems) A system is a *crowdsourcing system* if it enlists a crowd of humans to help solve a problem defined by the system owners, and if in doing so, it addresses the following four fundamental challenges: How to recruit and retain users? What contributions can users make? How to combine user contributions to solve the target problem? How to evaluate users and their contributions?

# CrowdSourcing

- O que há por trás do reCaptcha?

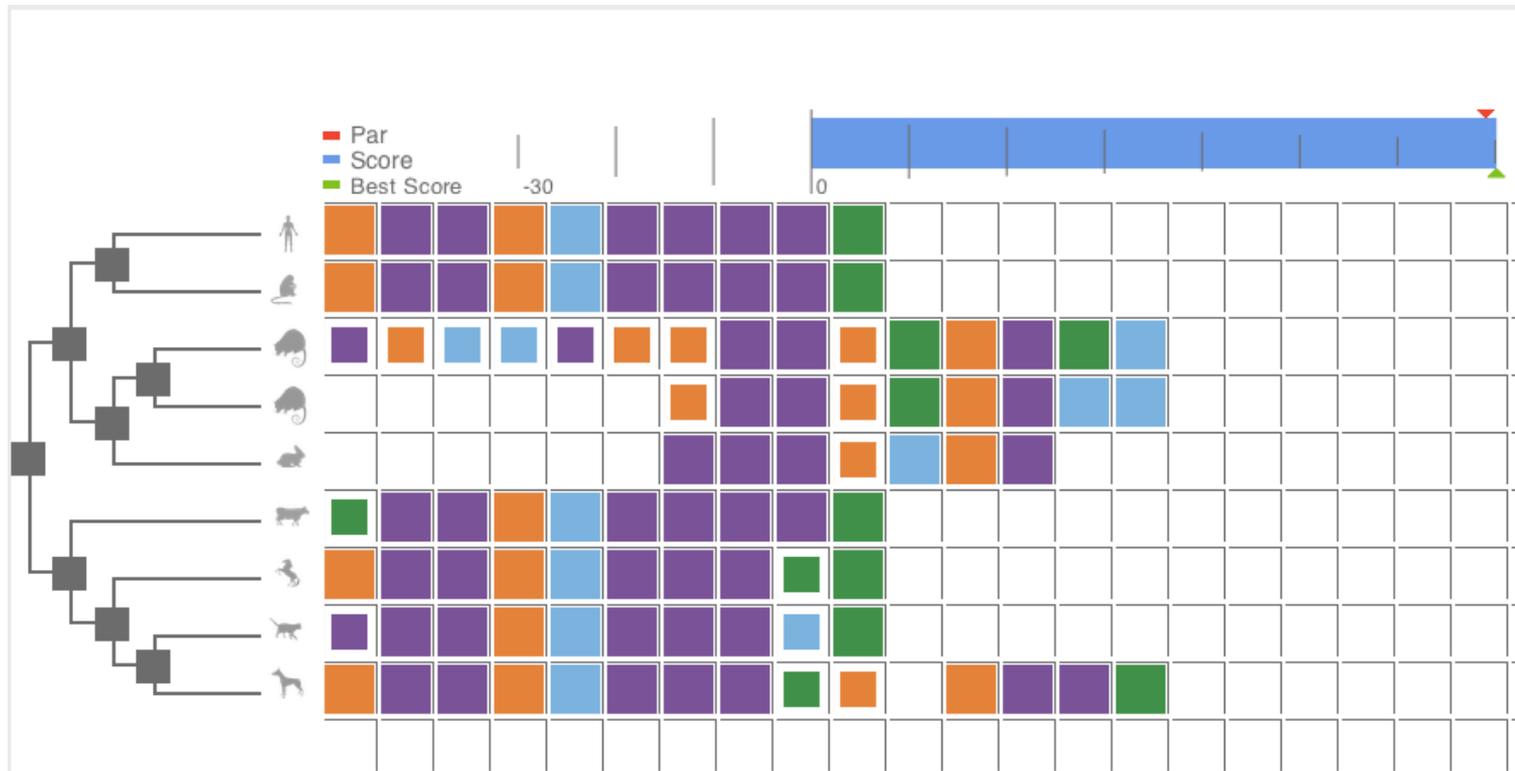


*reCaptcha: Tough on bots Easy on humans*



# Crowdsourcing

- Sequenciamento de DNA “jogando”
  - <http://phylo.cs.mcgill.ca/>



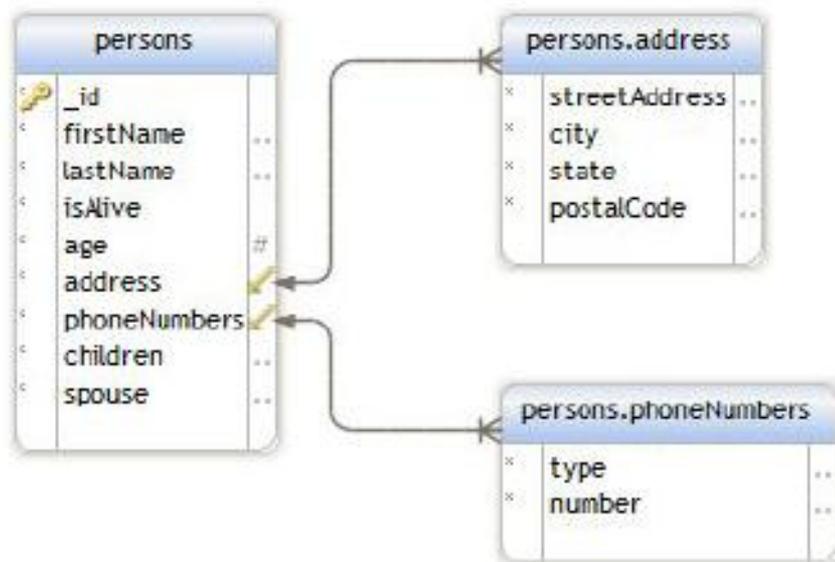
# Crowdsourcing

- Sequenciamento de DNA “jogando”
- Pessoas melhores do que o melhor algoritmo:

*“The gamers produced roughly 350,000 solutions to various MSA problems, beating the accuracy of alignments from MULTIZ in roughly 70 per cent of the sequences they manipulated”*

# Alinhamento de Esquemas

- Alinhamento de Esquemas (by Helton)



- Aborda desafio da ambiguidade semântica
- Visa compreender quais atributos têm o mesmo significado entre os esquemas

# Alinhamento de Esquemas

- **Alinhamento de Esquemas (by Helton)**
  - Embora existam abordagens e plataformas que tratam da integração de dados em Big Data, isto ainda não é algo tão trivial de se fazer
  - Ainda existe um amplo espaço para o desenvolvimento e pesquisa de novas tecnologias que facilitem a integração destas fontes de dados de forma mais automatizada

*E se fizermos alinhamento de esquemas baseado em crowdsourcing?*

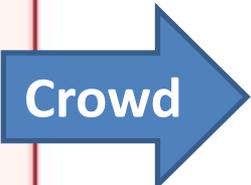


# Schema Mapping Suggestions

state	2	LOC1.STATE
phones	2	PHONE
email	2	EMAIL
address	2	LOC1.ADDRESS
title	2	TITLE
description	2	DESCRIPTION
images	2	IMAGE1
moreinfo link	2	WEBSITE
city	2	CITY
siteurl	2	WEBSITE

Threshold

zipcode	0.7	ZIP
lat	0.7	LATITUDE
amenities	0.6	DESCRIPTION
lon	0.5	LONGITUDE
activities	0.5	DESCRIPTION
fax	0.1	





# Crowdsourcing + Alinhamento de Esquemas

- Questões Importantes
  - Problema:
    - Muitas interações humanas para validar todas as possibilidades
  - Relações transitivas reduzem a quantidade de confirmações
    - Se A e B se referem à mesma entidade **and** B e C se referem à mesma entidade, **then** A e C se referem à mesma entidade
    - Desenvolvimento de estratégias sequenciais e paralelas



# Crowdsourcing + Alinhamento de Esquemas

- Desafios do Crowdsourcing ainda existem
  - Como recrutar e manter usuários?
  - Quais contribuições os usuários podem e querem fazer?
  - Como avaliar os usuários e suas contribuições?

# Tópicos Emergentes:

Crowdsourcing

***Source Selection***

Source Profiling

# Seleção de Fontes

- Vantagens de muitas fontes de dados:
  - Aumento da cobertura
  - Aumento da acurácia
  - Aumento da redundância
  - ...
- Essas fontes tem um **custo**  
**Balaceamento de custo x benefício é necessário**

# Seleção de Fontes

- Incluir mais fontes não necessariamente melhora o resultado

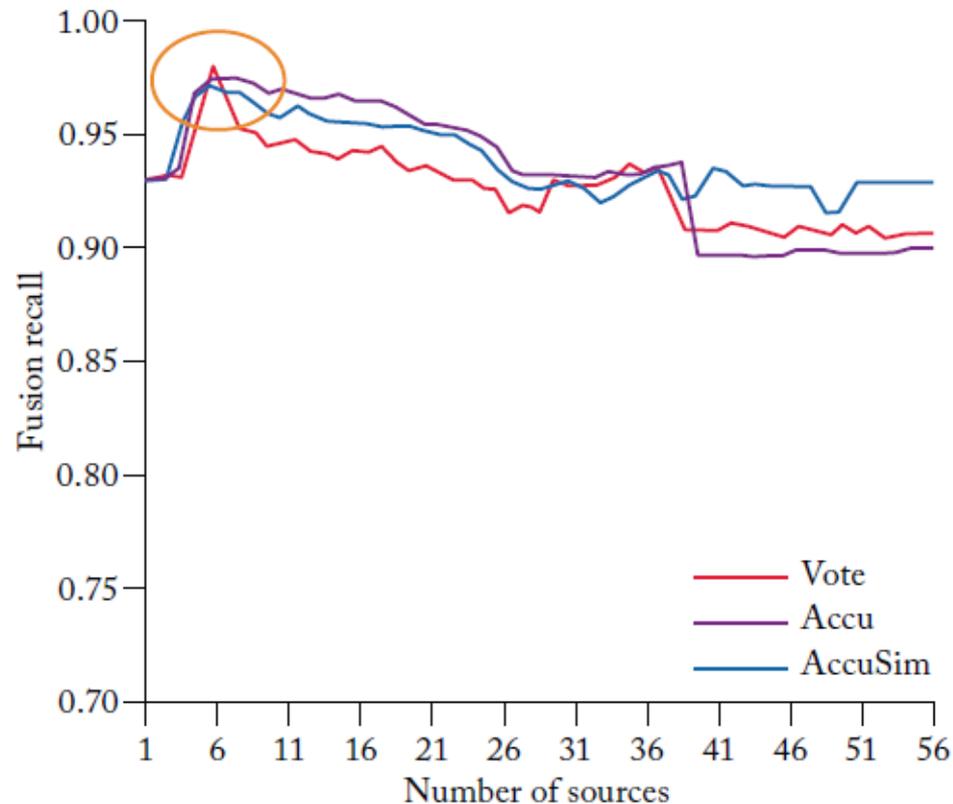


FIGURE 5.2: Fusion result recall for the Stock domain [Li et al. 2012].

# Seleção de Fontes

- Baseado em métricas de custo x benefício
- Problema (e solução) de otimização:
  - Dado um custo máximo, qual conjunto de fontes maximiza o resultado
  - Desejando um benefício mínimo de  $X$ , qual conjunto de fontes maximiza o resultado?

# Seleção de Fontes

- Baseado em métricas de custo x benefício
- Nova abordagem:
  - Continue adicionando fontes até o benefício marginal ser menor que o custo marginal.
  - ou seja*
  - Dado um custo máximo, qual conjunto de fontes provê o maior lucro?

# Seleção de Fontes

- Questões importantes:
  - Algoritmo guloso pode não ter bons resultados
    - Fontes marginais podem dar máximos retornos
    - Problema NP-Completo
  - Seleção das fontes ocorre antes da integração real.
    - Como estimar o custo e benefício de integrar cada fonte?

*The work on source selection is still in its infancy*

- Desafios
  - Propostas atuais consideram fontes independentes
  - Definição e estudos de métricas eficientes de custo x benefício

# Tópicos Emergentes:

Crowdsourcing

Source Selection

**Source Profiling**

# Source Profiling

*Dada a grande quantidade de fontes, como descobrir as fontes que contém dados realmente relevantes e tem a qualidade suficiente para uma dada tarefa?*

# Source Profiling

- Estrutura, semântica e conteúdo bem entendidos -> Sem problemas
  - Mas não é o mundo real

Objetivo:

***Ajudar os usuários a entender o conteúdo das fontes, antes mesmo da decisão sobre o que será integrado***

# Source Profiling

- Propostas em 2 etapas:
  1. Relacionar a fonte de dados com fontes de conhecimento (Freebase, Google knowledge graph, Probase, Yago, etc)
  2. Definir a qualidade dos dados baseado em critérios específicos

# Source Profiling

- Abordagens atuais tratam basicamente
  - Sumários estatísticos sobre estrutura e conteúdo das fontes
  - Tentativa de dar uma visão geral do conteúdo dos dados
- Basicamente abordagens de reengenharia
- Desafios:
  - Abordagens atuais tratam basicamente fontes relacionais e estáticas

# Big Data e Governos

# Big Data and Government

- Como os governos podem tirar proveito de Big Data
- E o que eles não deveriam fazer?
- Agenda:
  - National Priorities
  - Real-time analysis
  - ICT Big Brothers
    - Privacy?

# Relatório e Referências

- Relatório e referências disponível em

<http://bit.ly/2gVC81o>

# Big Data Integration

## Tópicos Emergentes

Kellyton Brito

[kellyton.brito@gmail.com](mailto:kellyton.brito@gmail.com)

IN1137 - Integração de Dados

Centro de informática - UFPE

Novembro / 2016