Band BBB Tec

Contexto de Big Data, Ciência de Dados e KDD

Fabrício J. Barth
Disciplina de Modelagem Descritiva e Preditiva
Pós-Graduação em Big Data e Analytics

Sempre houve:

Produção de informação
Geração de dados
Geração de conteúdo

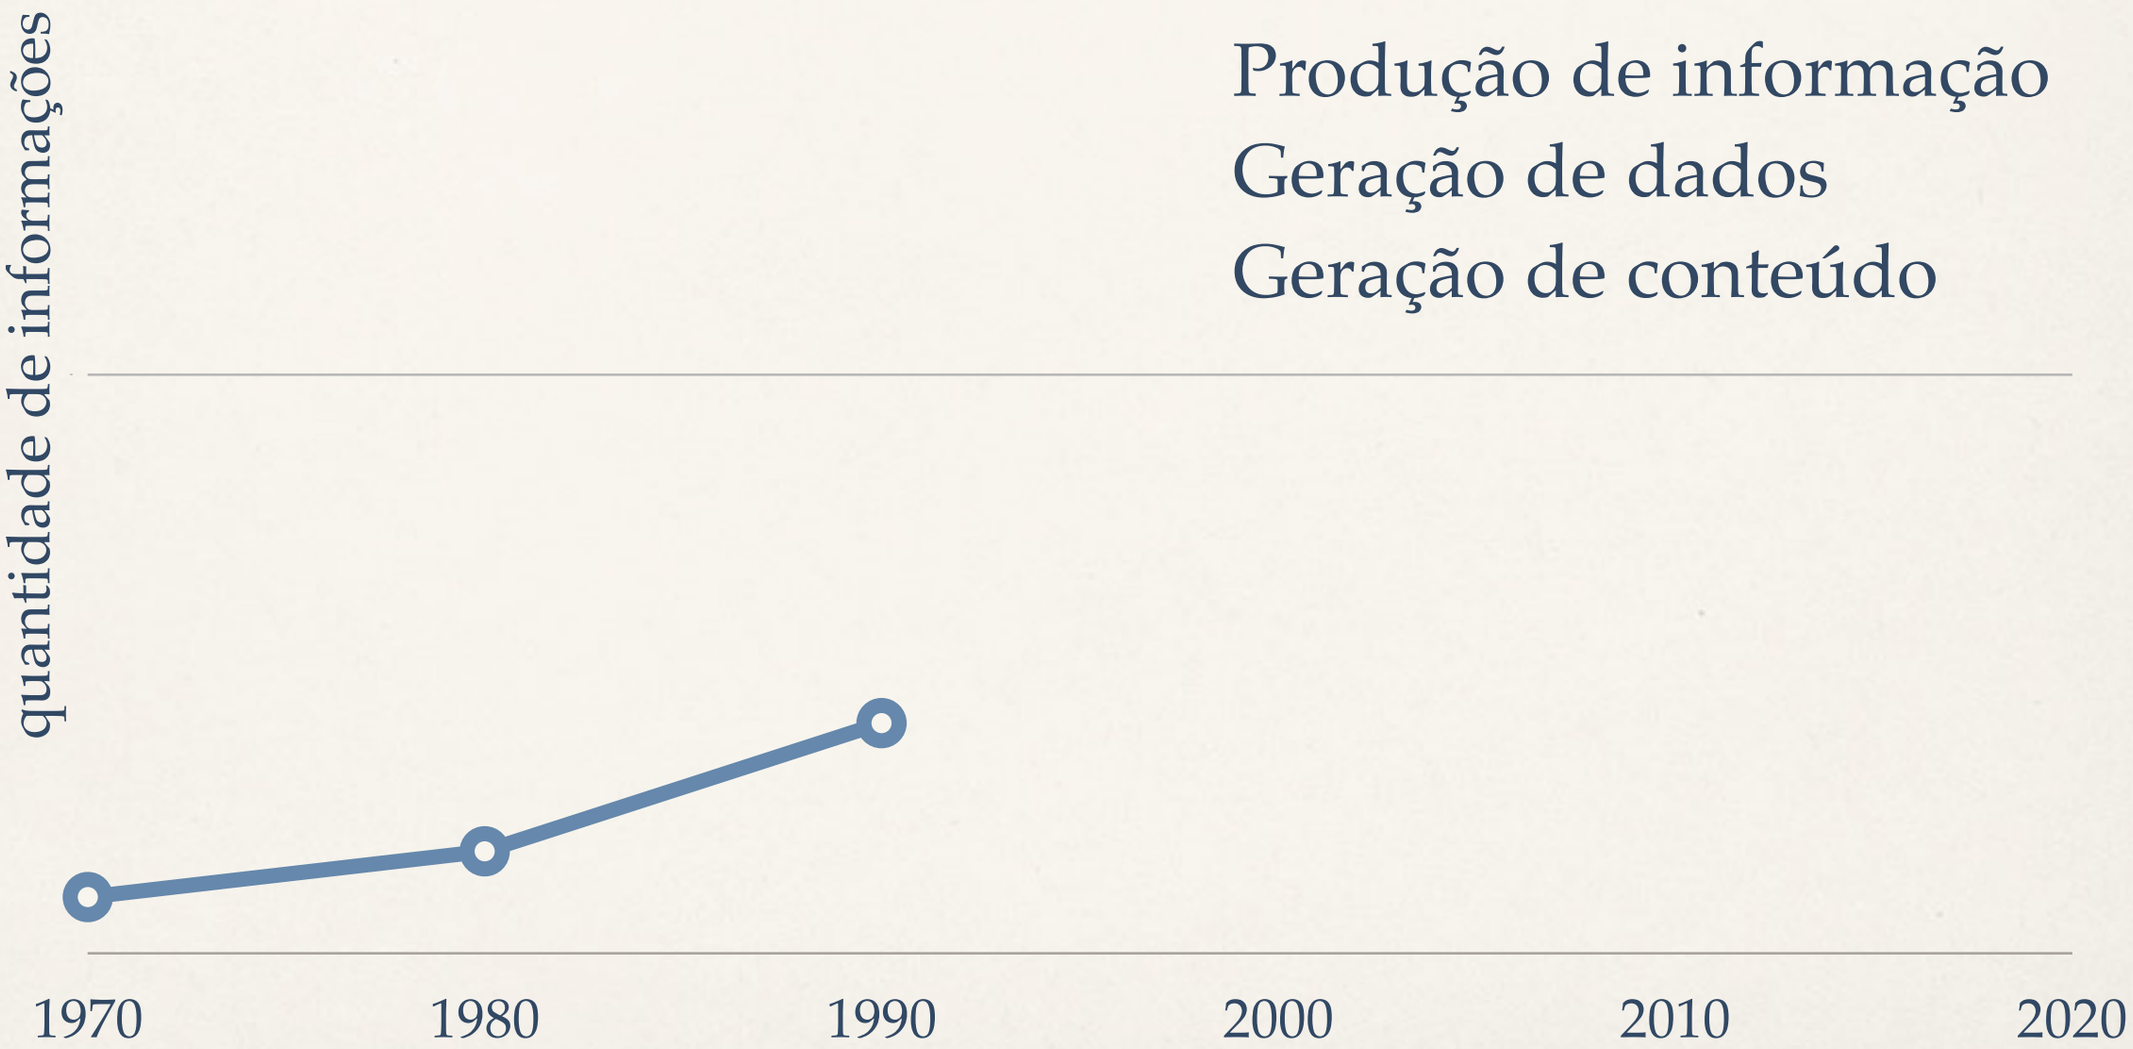

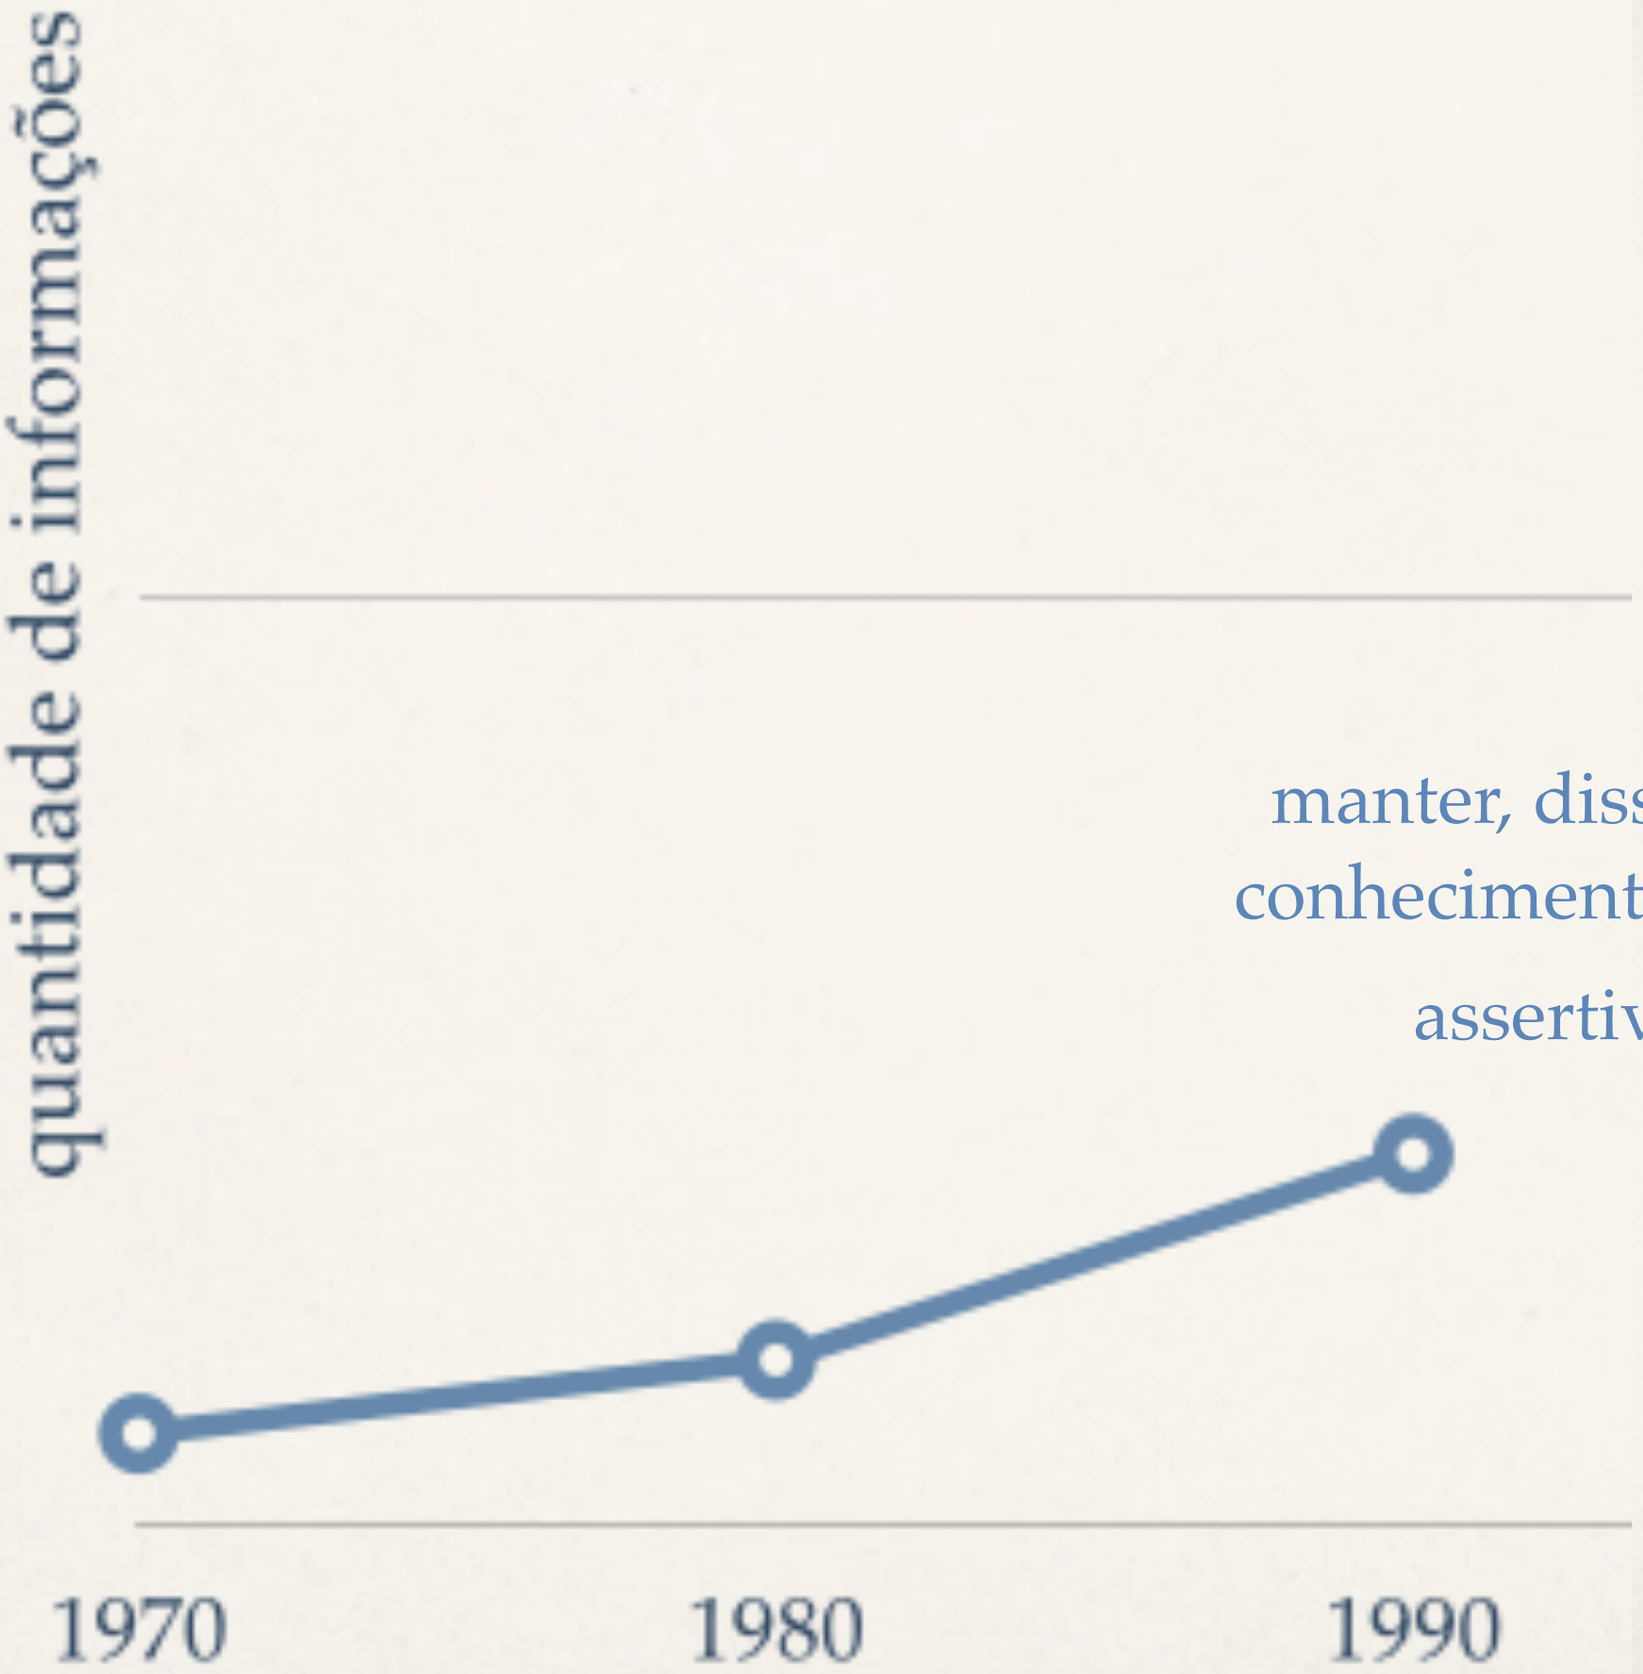

Sempre **desejou-se**:

sintetizar a informação

manter, disseminar, organizar, criar

conhecimento e tomar decisões mais

assertivas com base nos dados.

Métodos, processos e ferramentas

- Gestão de Conhecimento, Sistemas Especialistas e Mineração de Dados

- Sistemas Especialistas e Projetos de Mineração de Dados (Processo de Descoberta de Conhecimento) só funcionavam em cenários muito bem delimitados e utilizando dados muito bem tratados e estruturados.

- Também, manipular dados diferentes dos dados não estruturados não parecia ser algo relevante.

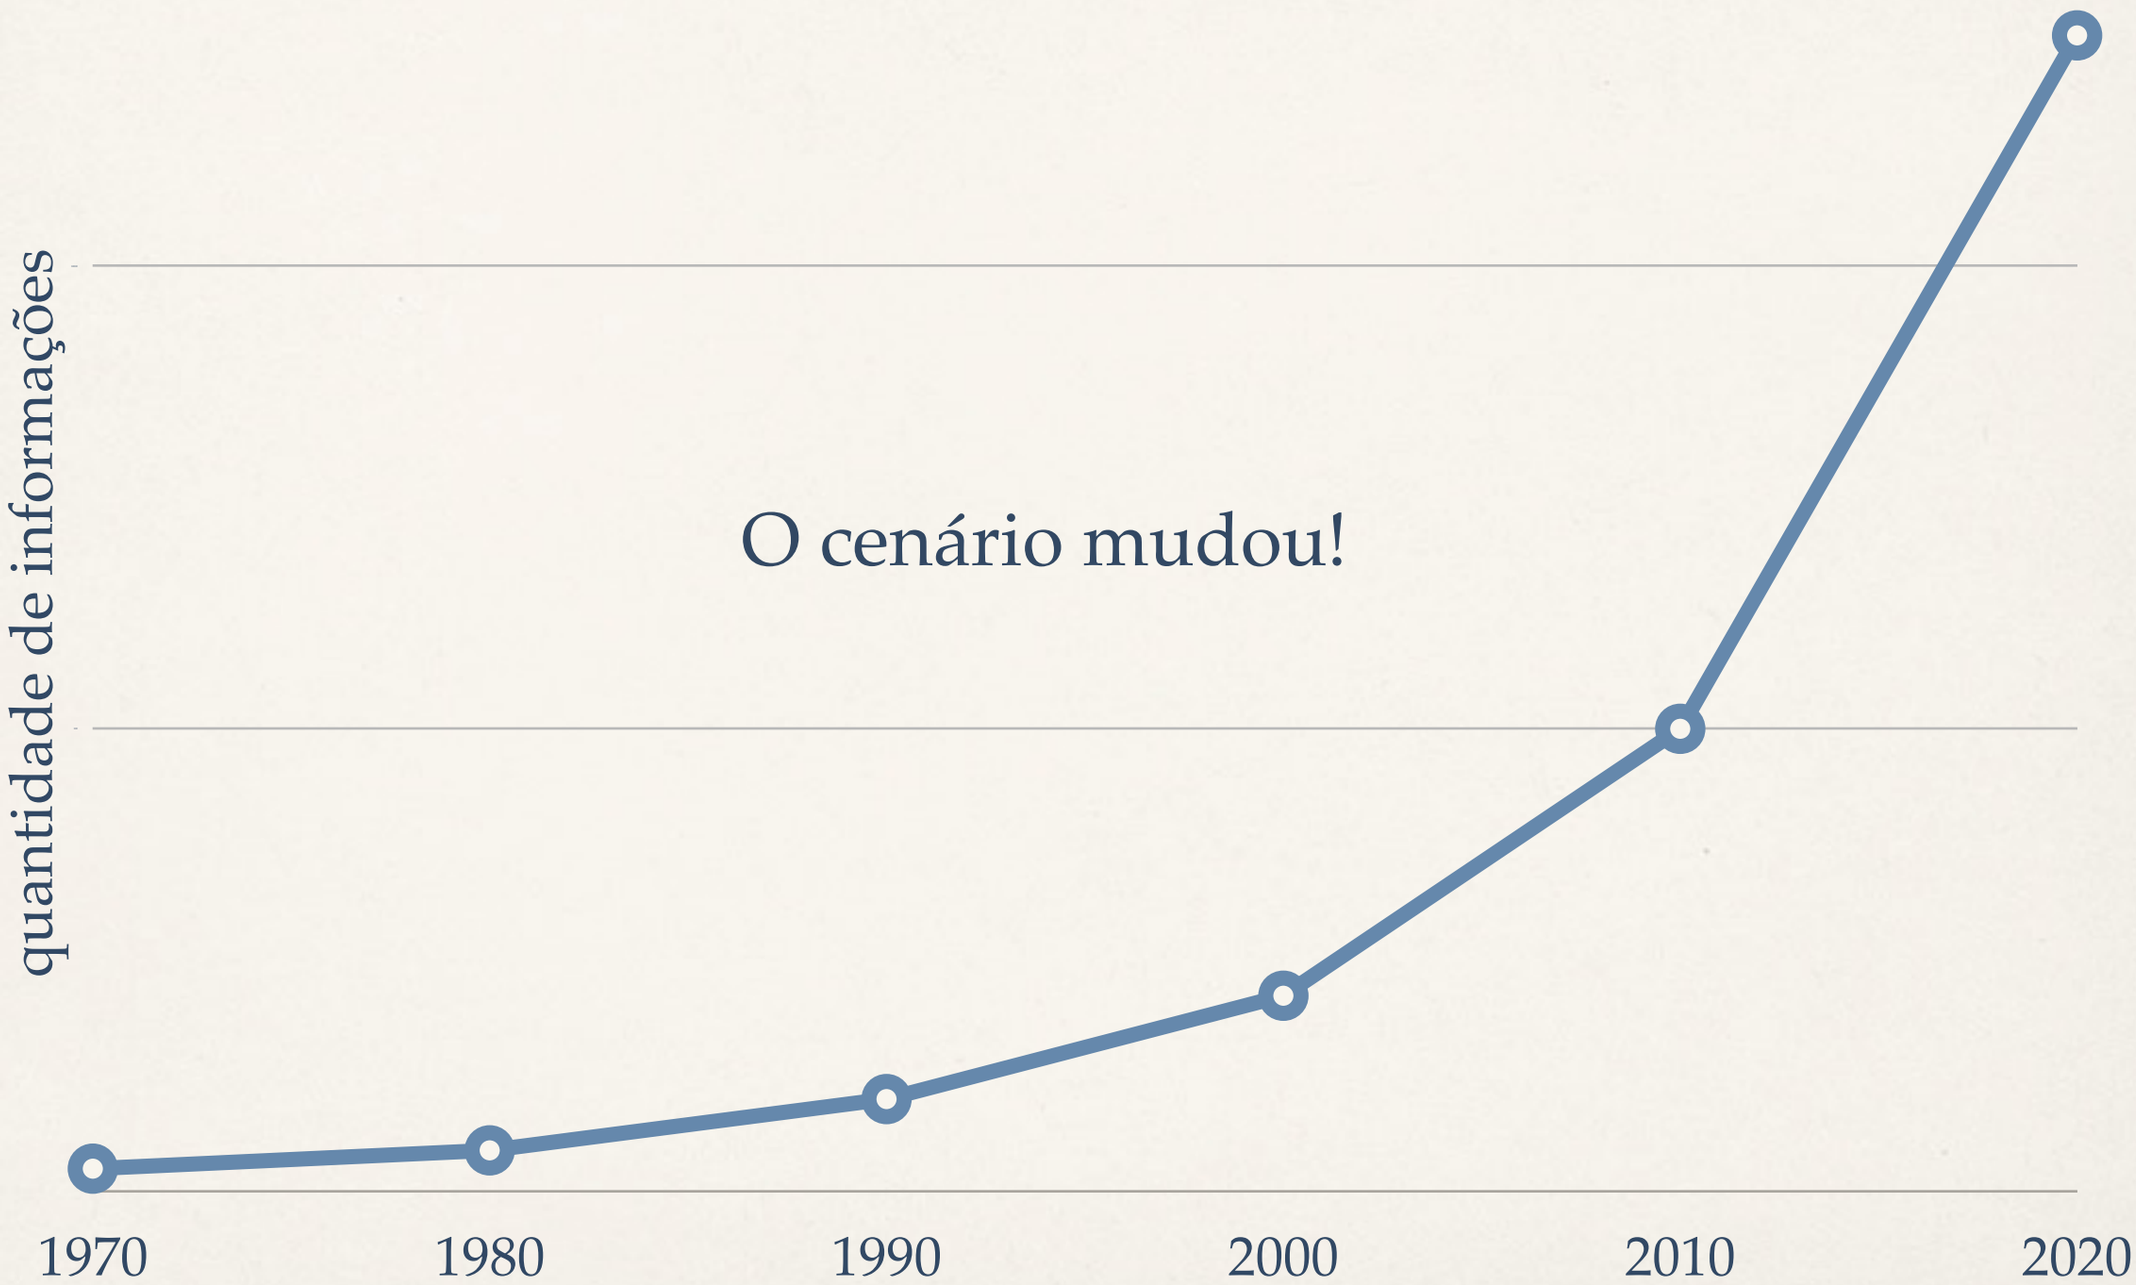
quantidade de informações
O cenário mudou!
1970
1980
1990
2000
2010
2020

NOVO CENÁRIO | PROGRESSÃO DOS DADOS ARMAZENADOS AO LONGO DO TEMPO

Tendência clara de crescimento dos dados desestruturados, também chamados de dados incertos (*uncertain data*, em inglês)

Gandour, F. O que muda com a computação cognitiva? Revista de ESPM, Set/Out de 2014.

- O cenário mudou!
- Mas o desejo ainda continua:
  - sintetizar
  - manter
  - disseminar
  - organizar
  - encontrar
  - tomar decisões baseadas em ….

Mas o desafio mudou

- Ficou mais complexo devido as características dos dados, da forma como eles são gerados e das novas necessidades dos usuários.
  - O volume de dados gerados é muito alto.
  - A velocidade com que eles são gerados e perdem a validade é muito rápida.
  - A variedade das fontes é bem diversificada (estruturada + não estruturada)
- Aparentemente, os usuários não querem mais saber do passado. Estão muito interessados no presente e futuro.

Alguns exemplos

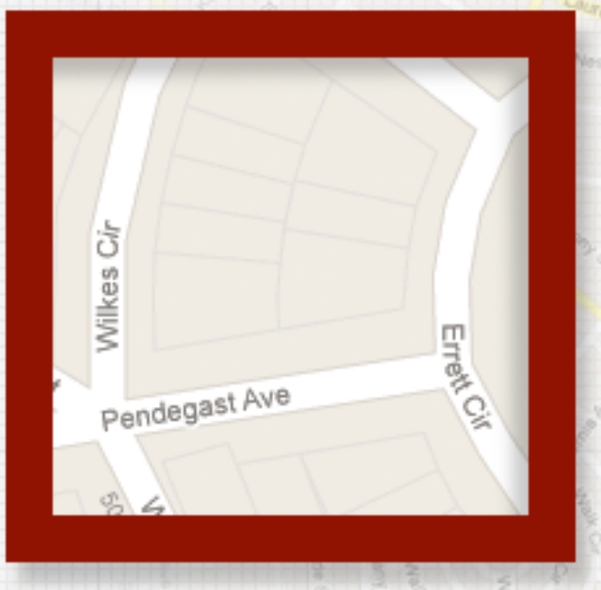

PredPol®

Predict Crime in Real Time®

PredPol provides targeted, real-time crime prediction designed for and successfully tested by officers in the field.

SEE PREDICTIVE POLICING IN ACTION. LOS ANGELES, CALIFORNIA

LEARN MORE

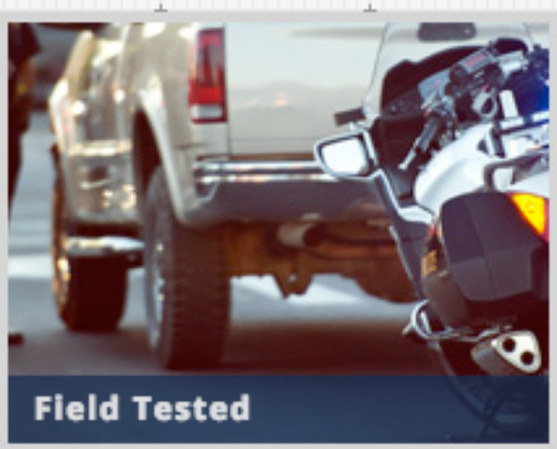

Entrada: 13 milhões de registros históricos sobre crimes em LA.
Saída: determinar quando um crime irá acontecer.

USGS
science for a changing world

USGS Home
Contact USGS
Search USGS

Earthquake Hazards Program

Home | About Us | Contact Us

EARTHQUAKES | HAZARDS | LEARN | PREPARE | MONITORING | RESEARCH





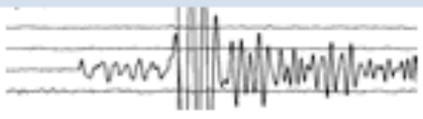


nehrp

The USGS Earthquake Hazards Program is part of the National Earthquake Hazards Reduction Program (NEHRP), established by Congress in 1977. We monitor and report earthquakes, assess earthquake impacts and hazards, and research the causes and effects of earthquake.

Latest Earthquakes

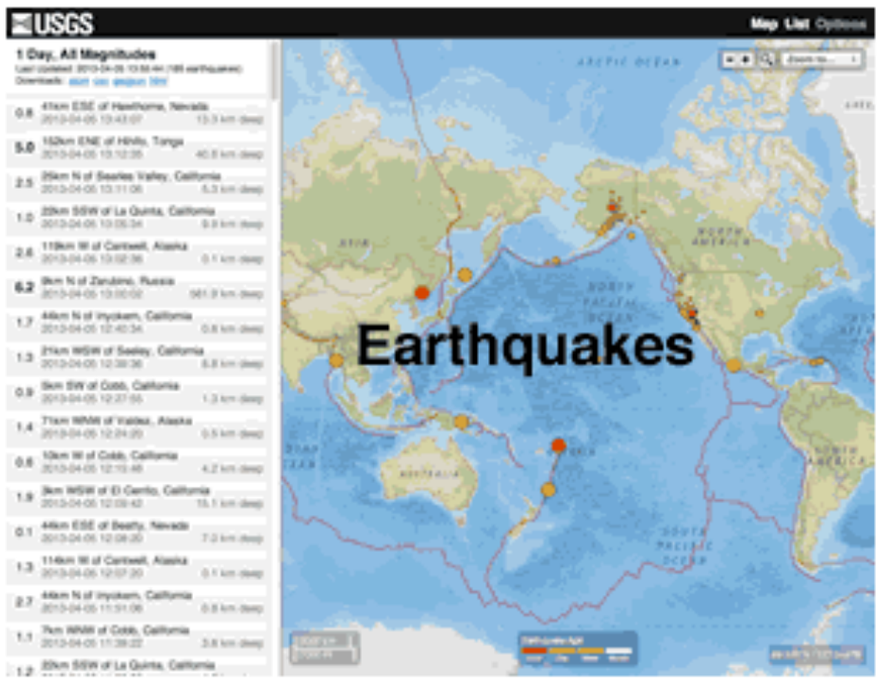

View recent events or search for past earthquakes. Optimized for mobile and desktop.

Real-time Feeds & Notifications

Get real-time earthquake notifications ser you using a number of popular mediums: Feeds, Email, Twitter, etc…

Significant Earthquakes

Past 30 Days

6.6 98km WSW of Mutis, Colombia
2013-08-13 15:43:15 UTC 12.0 km deep

4.9 9km SSW of Volcano, Hawaii
2013-08-11 15:54:05 UTC 31.8 km deep

5.9 13km E of Chabu, China
2013-07-21 23:45:56 UTC 9.8 km deep

6.5 46km ESE of Blenheim, New Zealand
2013-07-21 05:09:31 UTC 14.0 km deep

Significant Earthquake Archive

Featured Items

2

Man-Made Earthquakes

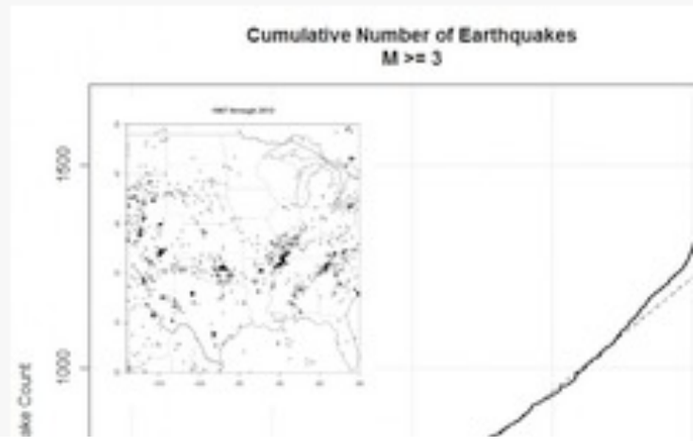

Entrada: rede de sensores que cobre todo o mundo

Saída: determinar quando um terremoto irá acontecer

Just For Today

Browse Recommended

Recommendations Books

Arts & Photography
Audible Audiobooks
Bargain Books
Biographies & Memoirs
Books on CD
Business & Investing
Calendars
Children's Books
Christian Books & Bibles
Comics & Graphic Novels
Computers & Technology
Cookbooks, Food & Wine
Crafts, Hobbies & Home
Education & Reference
Gay & Lesbian
Health, Fitness & Dieting
History

These recommendations are based on items you own and more.

view: **All** | New Releases | Coming Soon

1. 

Machine Learning for Hackers
by Drew Conway (February 22, 2012)
Average Customer Review: ★★★½☆ (21)
In Stock

List Price: ~~$39.99~~
Price: $26.48
74 used & new from $21.90

Add to Cart | Add to Wish List

I own it | Not interested | ☆☆☆☆☆ Rate this item
Recommended because you added **Data Mining with R** to your Wishlist and more (Fix this)

2. 

Mining the Social Web: Analyzing Data from Facebook, Twitter, LinkedIn, and Other Soci
by Matthew A. Russell (February 8, 2011)
Average Customer Review: ★★★★½ (23)
In Stock

List Price: ~~$39.99~~
Price: $26.48
84 used & new from $20.00

Add to Cart | Add to Wish List

I own it | Not interested | ☆☆☆☆☆ Rate this item
Recommended because you added **Data Mining with R** to your Wishlist and more (Fix this)

Entrada: milhões de itens e milhões de usuários

Saída: recomendar itens com acurácia alta para os usuários (clientes)


Colombia
Suriname
Quito
Canton
Roraima
Amapá
Ecuador
Amazonas
camilagaban 2013-08-15 18:17:21 BRT
Suspeitas que eu to com dengue :(
Brazil
Peru
Acre
Pernambuco
Lima
Rondônia
Tocanti
Alagoas
Mato
Grosso
Bahia
Salvador
Sergipe
Brasilia
Minas
Gerais
Bolivia
Nuestra
Señora

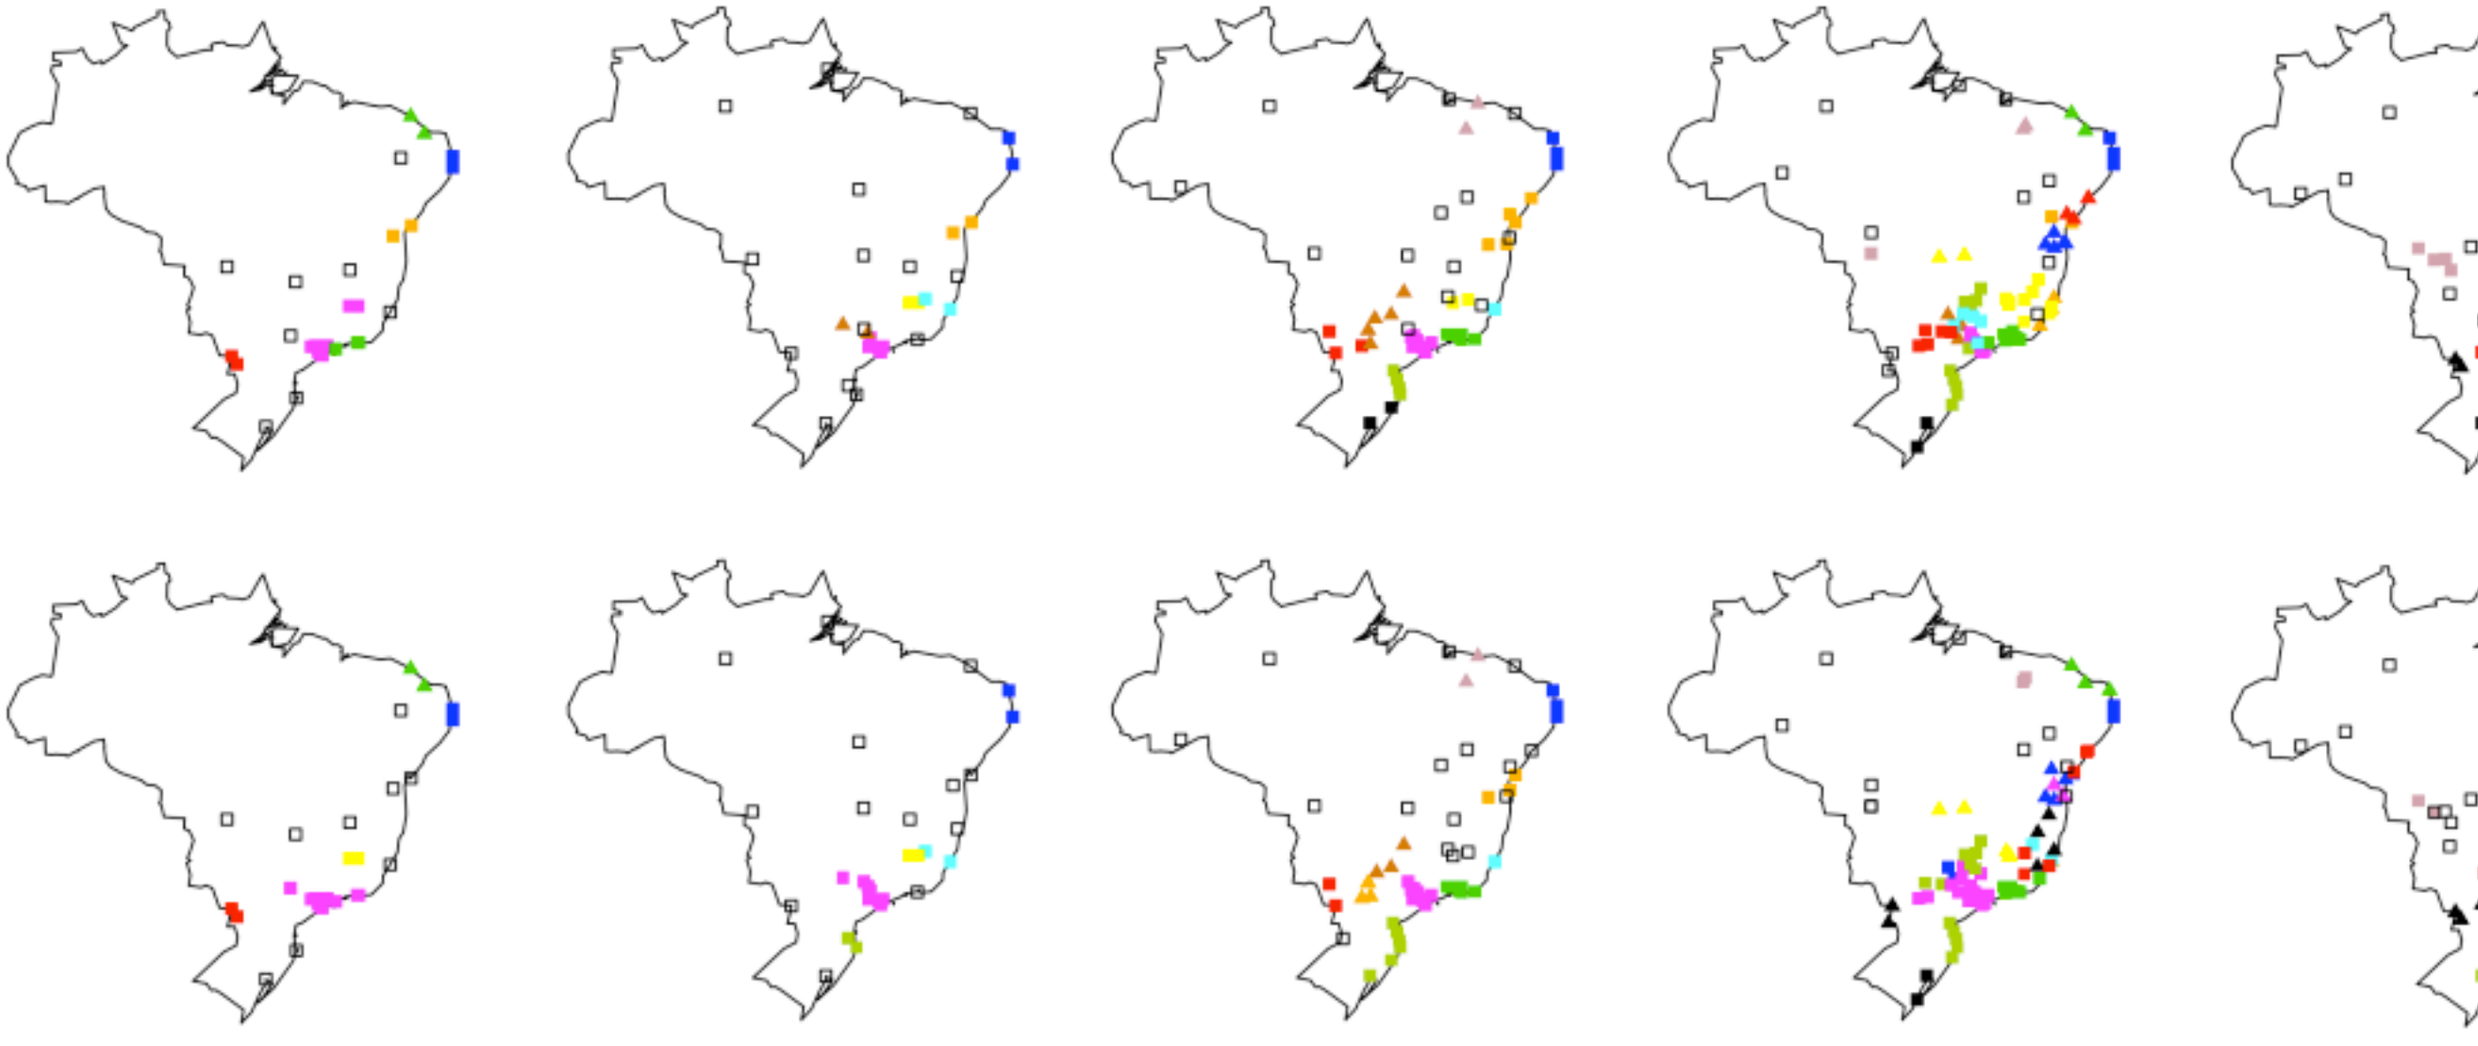

Yelp Recruiting Competition

Finished

Wednesday, March 27, 2013 — Jobs • 352 teams — Sunday, June 30, 2013

Dashboard

Home
- Data
- Make a submission

Information
- Description
- Evaluation

Competition Details » Get the Data » Make a submission

How many "useful" votes will a Yelp review receive? Show off your skills to land an interview for a position on a Yelp data mining team!

opSys! Mineração de Opinião em conteúdo Web - V2 - Mozilla Firefox

Arquivo Editar Exibir Histórico Favoritos Ferramentas Ajuda

http://www.opsys.com.br/index.php

Control panel - Web... Meus Mapas - Mind... Registro.br - Autent... Yahoo! Search BOS... Yahoo! Developer N... Technology Rev

Diigo related:UOti-1rv3XgJ:schola Bookmark Highlight Send Read Later Unread Recent Add

opSys! Mineração de Opinião e...

Meus Sets

- Análise de Investimentos
- Eleições 2010
- Criar Novo

Empresas / Entidades

- BRADESCO
- GERDAU
- PETROBRAS
- USIMINAS
- VALE R DOCE

Feeds

- Abril.com - Economia
- BBCBrasil.com | Tópicos | Economia
- Direto do Pregão
- estadao.com.br - Últimas notícias
- Folha Online - Dinheiro - Principal
- G1 Economia e Negócios

Status

Todos *Últimas 50 notícias* Todas

Sumário

12420 24% 58% 16% 7 dias atualizar

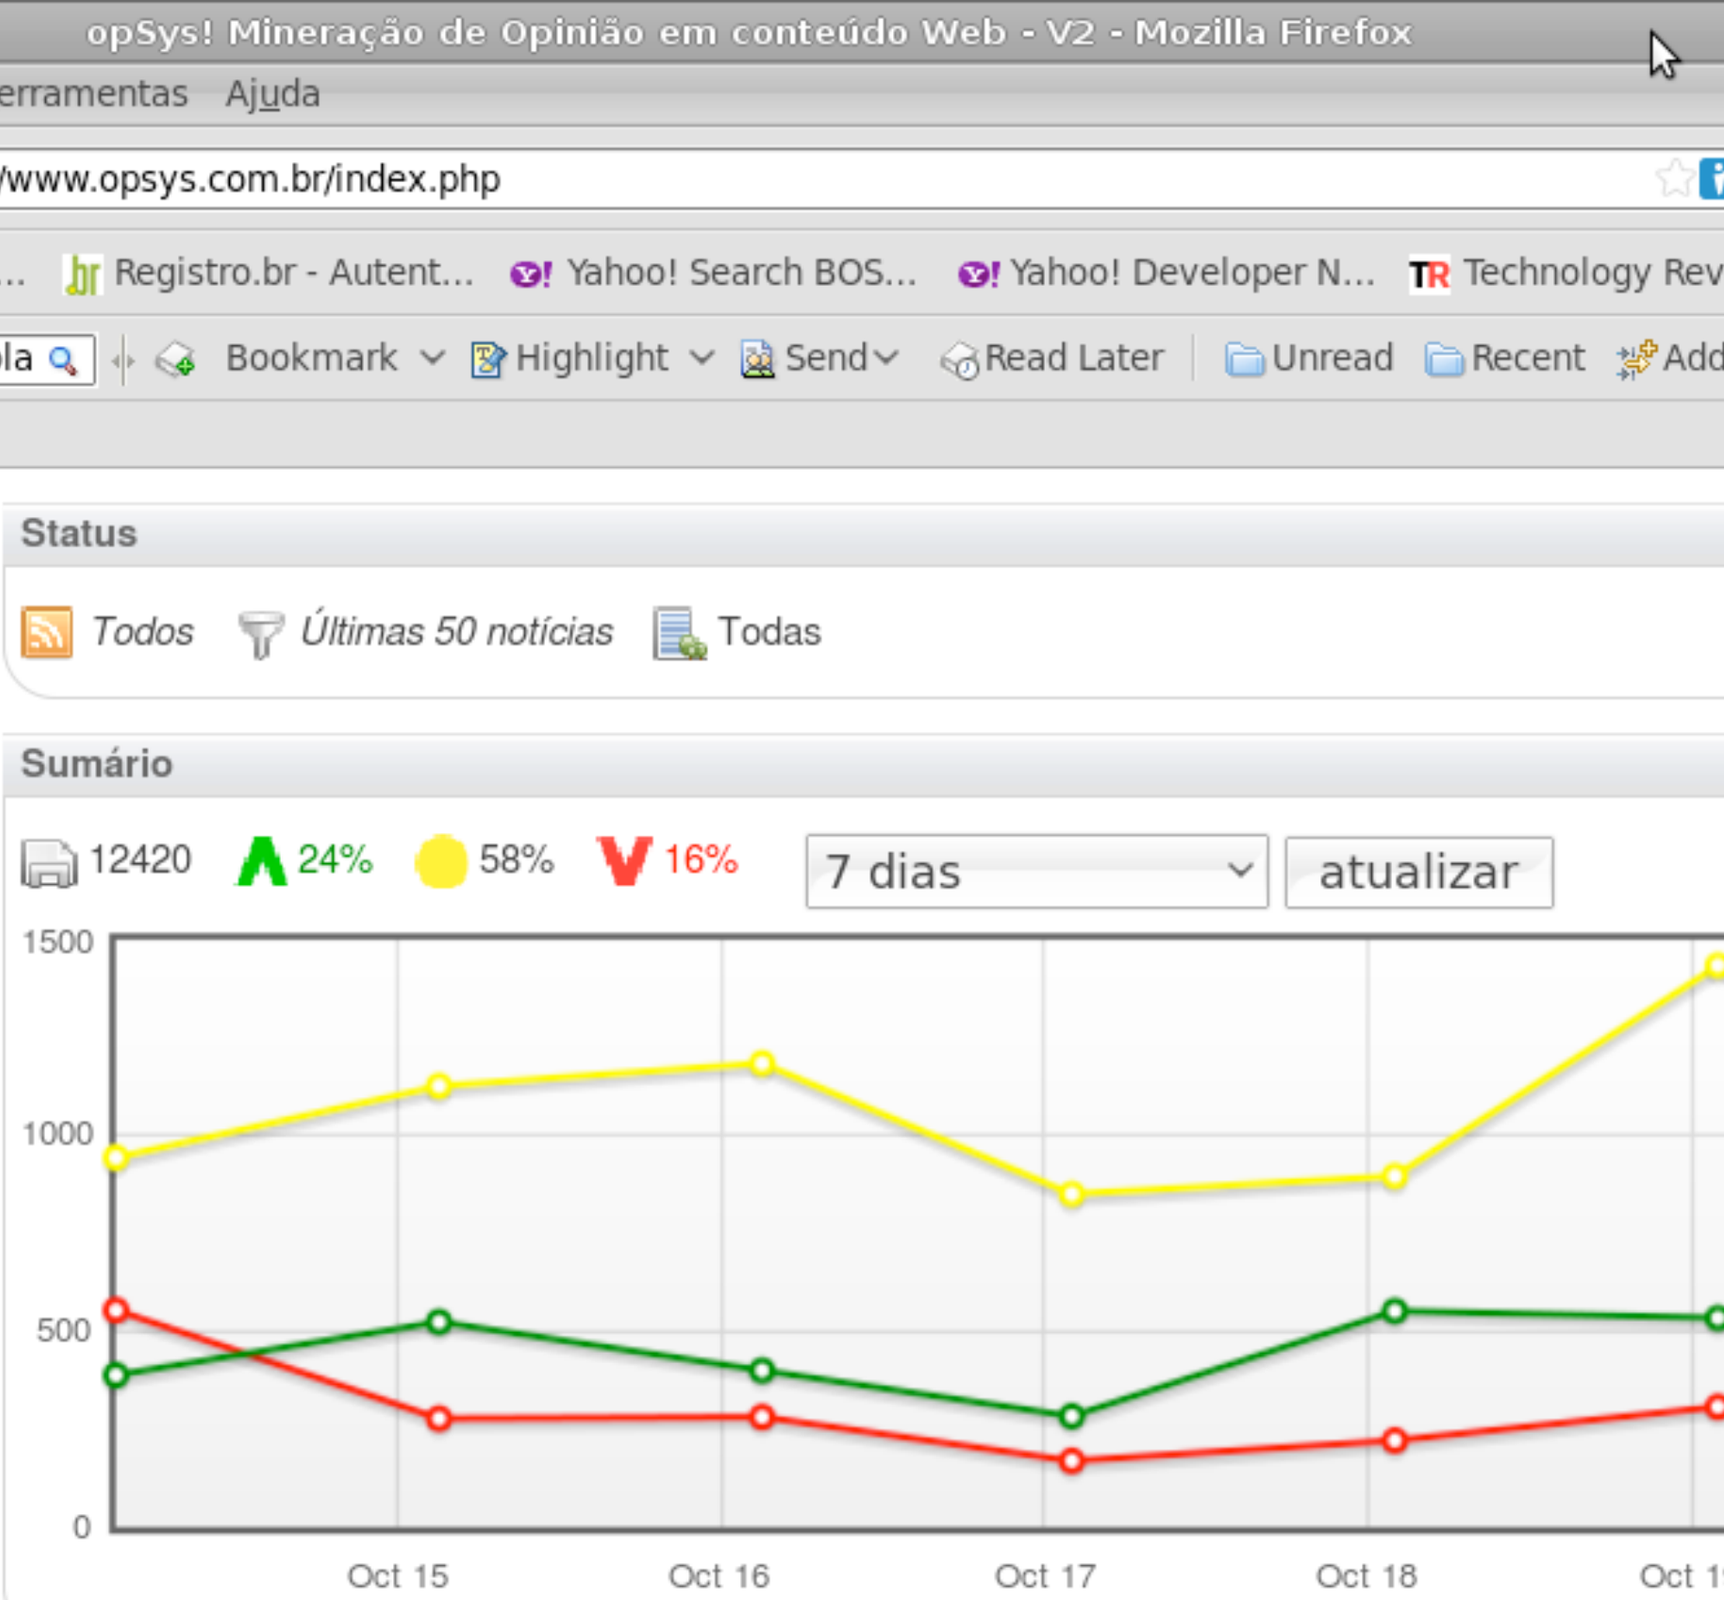

Noticias filtradas

Data/Hora	Titulo

Concluído

Criar rôbos que compram e vendem ações

WINTON

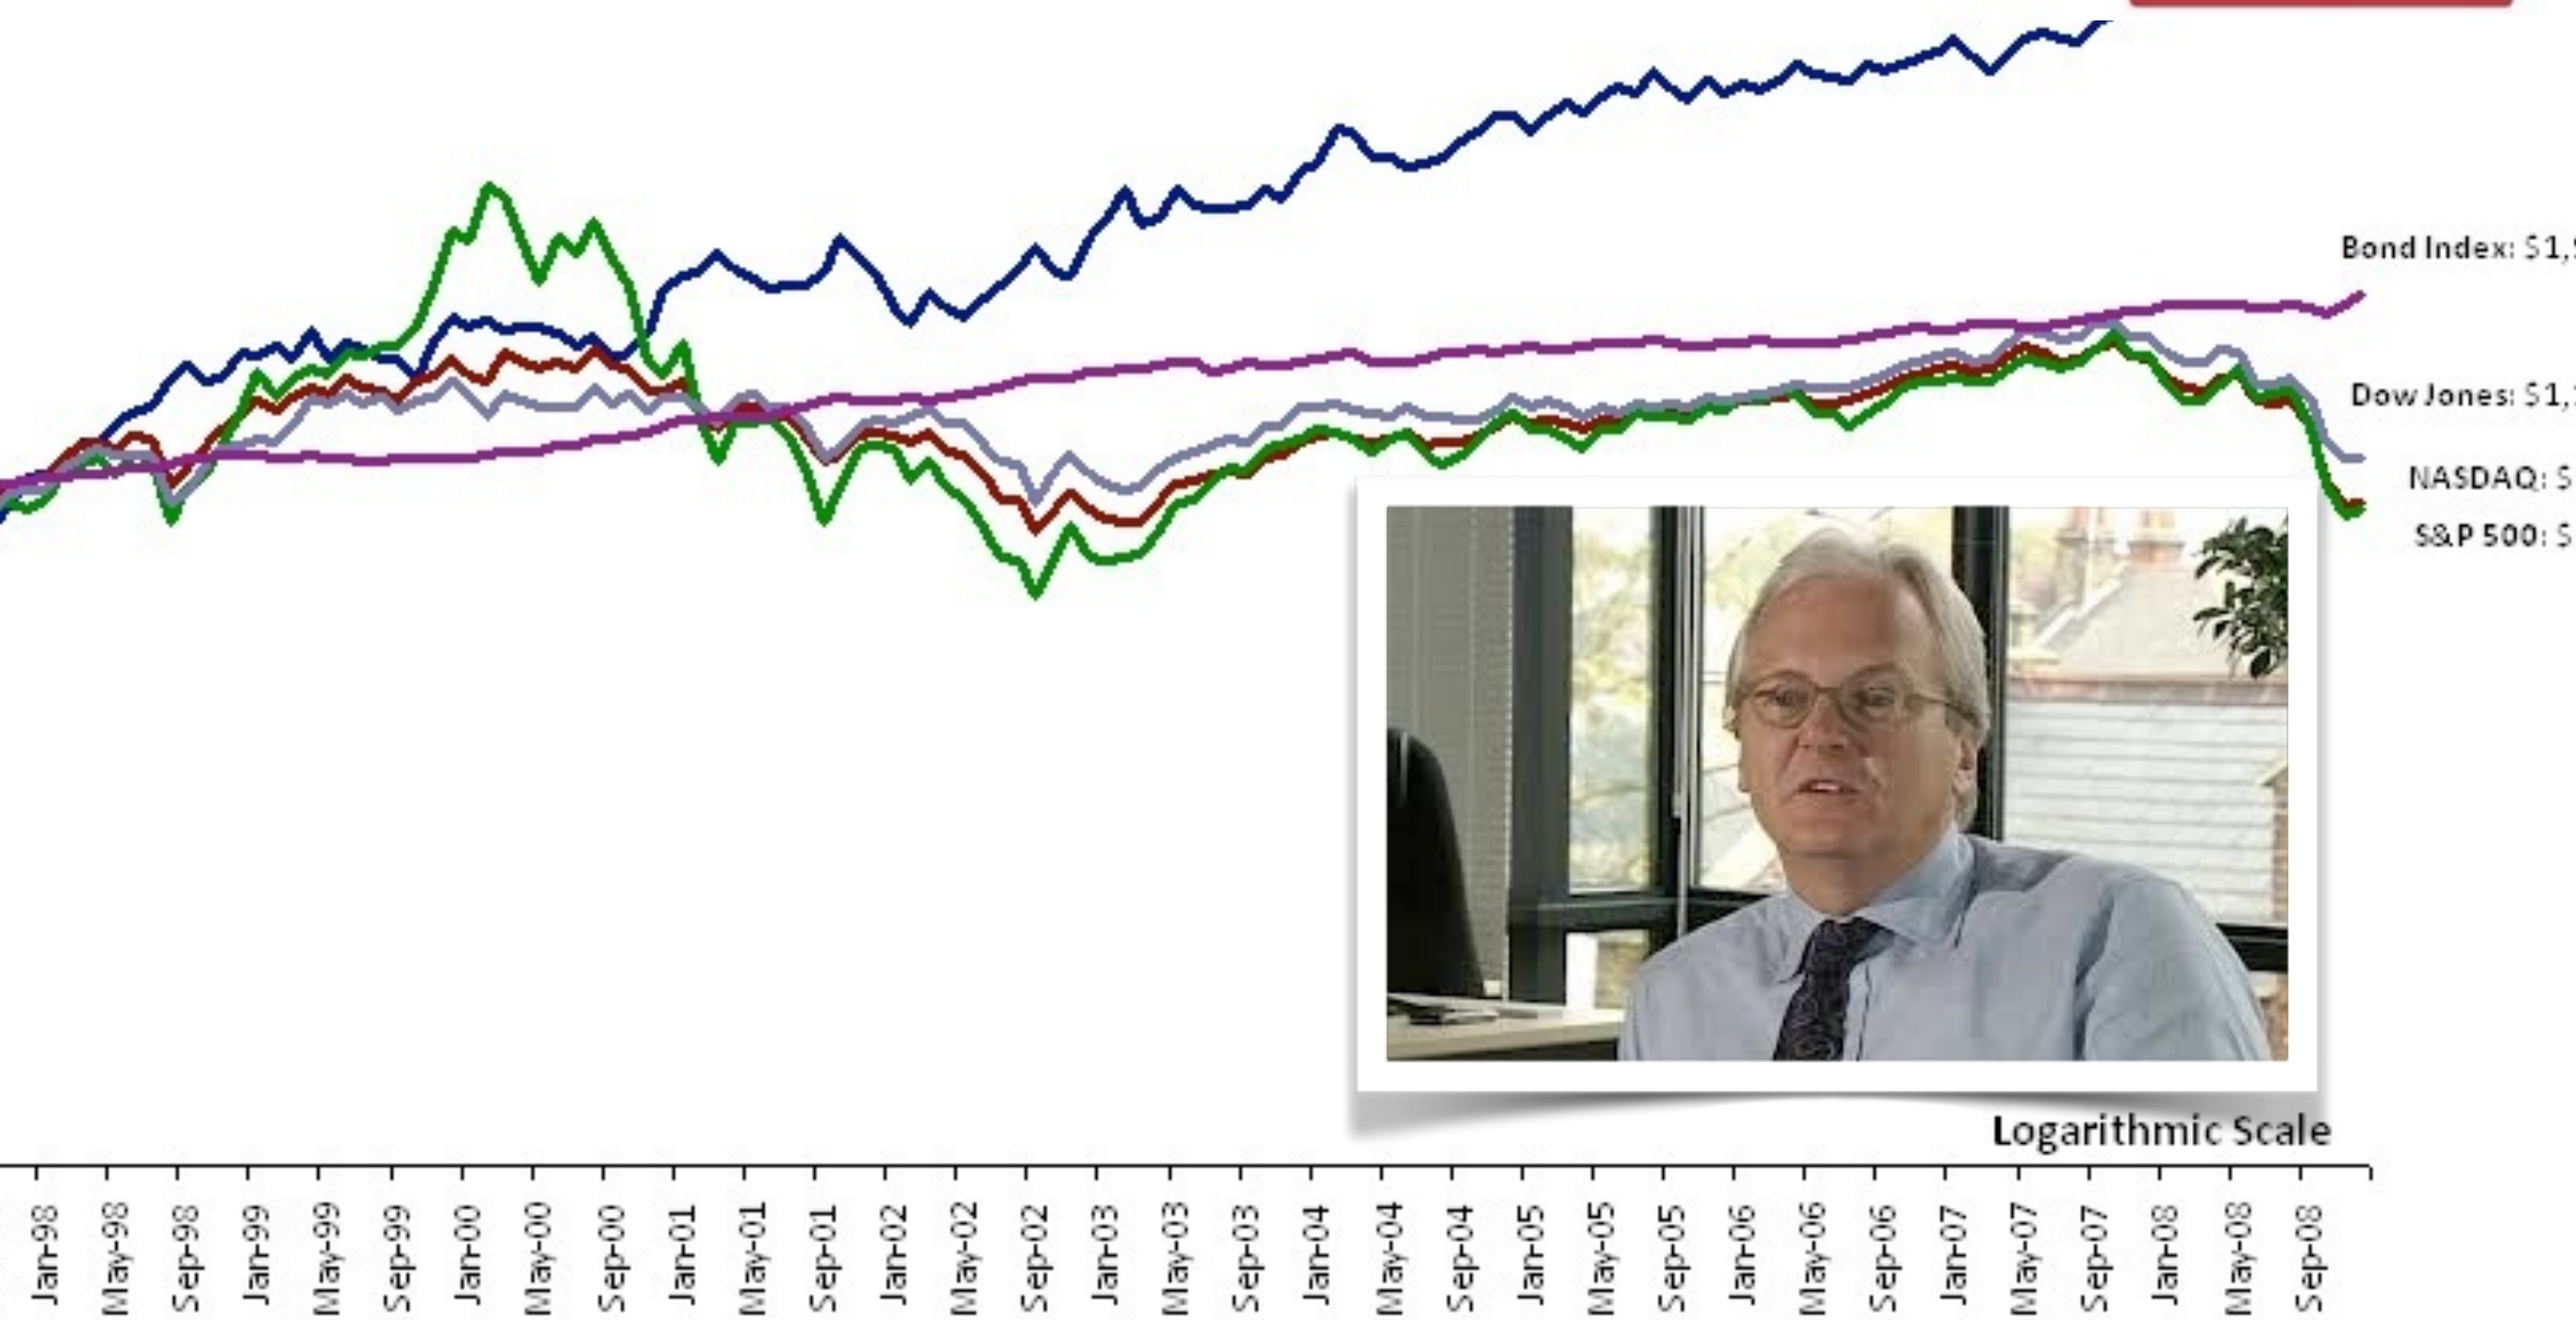

O que estes projetos têm em comun?

- **Manipulam grandes volumes de informação**

- **Outros exemplos de grandes volumes de informação:**
  - **A380: Heathrow - JFK: 640 TBs de log**
  - **Twitter: 12+ TBs of tweet every day**
  - **Facebook: 25+ TBs of log data every day**

O que estes projetos têm em comun?

- **A origem dos dados é muito variada.**

Mobile Sensors

Social Media

Video Surveillance

Video Rendering

READING METERS
EVERY 15 MINS.
IS 3,000X MORE
DATA INTENSIVE

Smart Grids

Geophysical Exploration

Medical Imaging

Gene Sequencing

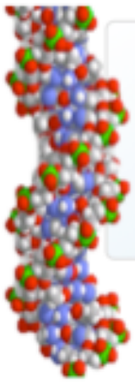

COST TO SEQUENCE
ONE GENOME
HAS FALLEN FROM
$100M IN 2001
TO $10K IN 2011

O que estes projetos têm em comun?

Queremos modelos preditivos

Outros exemplos

- Identificar comportamento anômalo (i.e., fraudes, falhas)
- Sumarizar tendências de publicações de artigos e patentes sobre um determinado tema.
- Sumarizar e filtrar notícias relevantes.
- Sumarizar a opinião expressa na Web sobre a sua empresa.
- Identificar padrões de navegação em sites.
- Identificar conteúdo impróprio em sites.

Ciência de Dados (Data Science)

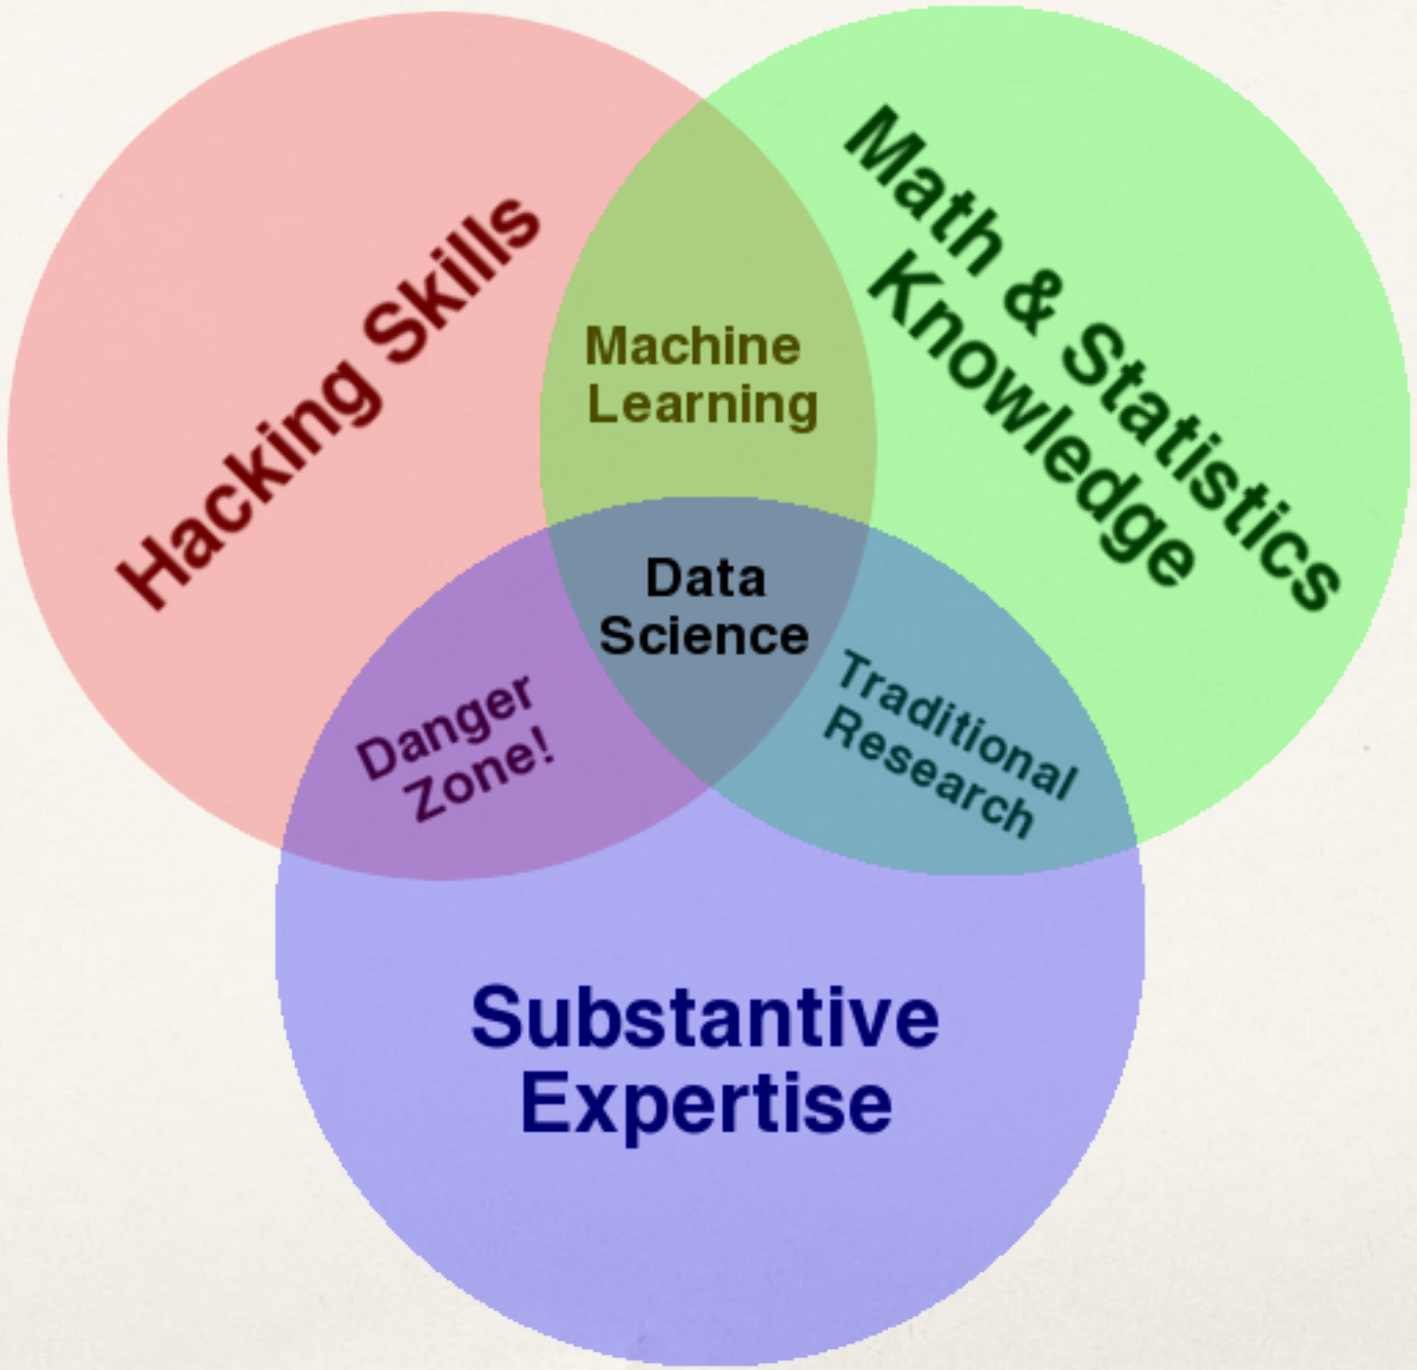

Cientísta de Dados (Data Scientist)

- Data Scientist: The sexiest job of the 21st Century. Harvard Business Review.

- Data Scientist applies advanced analytical tools and algorithms to generate predictive insights and new product innovations that are a direct result of the data.

Processo de Descoberta de Conhecimento

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

Qual é a pergunta?

É possível classificar espécies do gênero iris levando em consideração apenas o tamanho das plantas?

Iris virginica

Iris setosa

Iris versicolor

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

Qual é a pergunta?

Aquisição e pré-processamento dos dados

```
> data(iris)
> head(iris)
  Sepal.Length Sepal.Width Petal.Length Petal.Width Species
1          5.1         3.5          1.4         0.2  setosa
2          4.9         3.0          1.4         0.2  setosa
3          4.7         3.2          1.3         0.2  setosa
4          4.6         3.1          1.5         0.2  setosa
5          5.0         3.6          1.4         0.2  setosa
6          5.4         3.9          1.7         0.4  setosa
>
>
> sapply(iris,class)
Sepal.Length  Sepal.Width Petal.Length  Petal.Width      Species
   "numeric"    "numeric"    "numeric"    "numeric"     "factor"
```

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

Qual é a pergunta?

Aquisição e pré-processamento dos dados

Análise exploratória

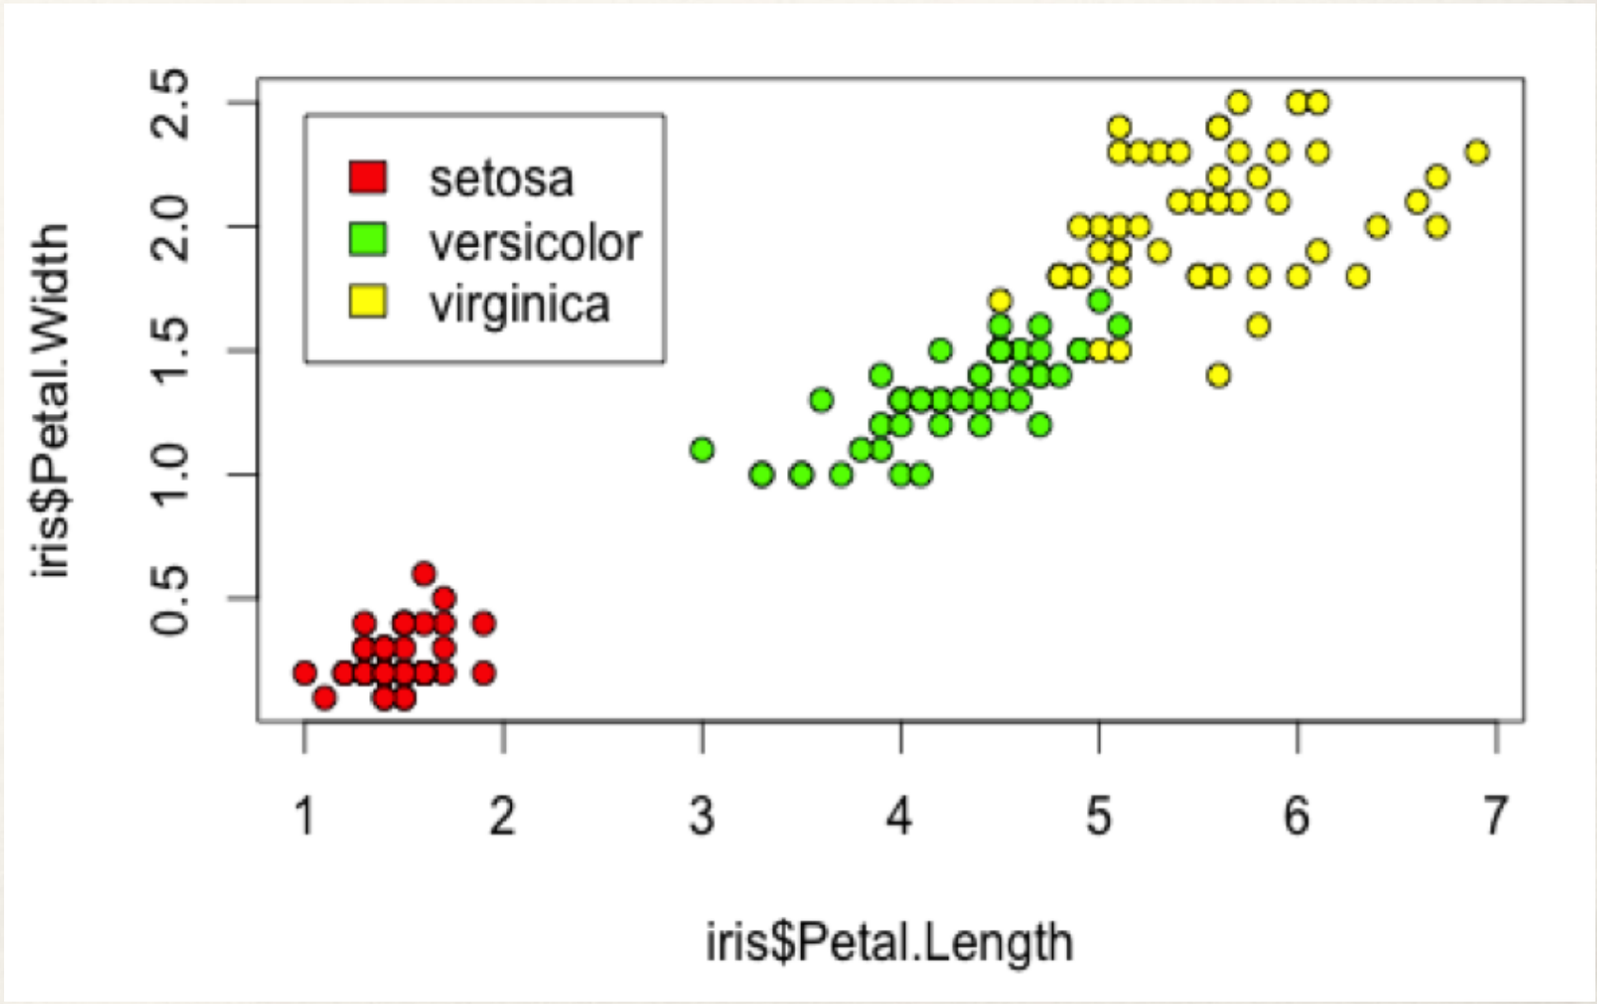

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

Qual é a pergunta?

Aquisição e pré-processamento dos dados

Análise exploratória

Modelagem

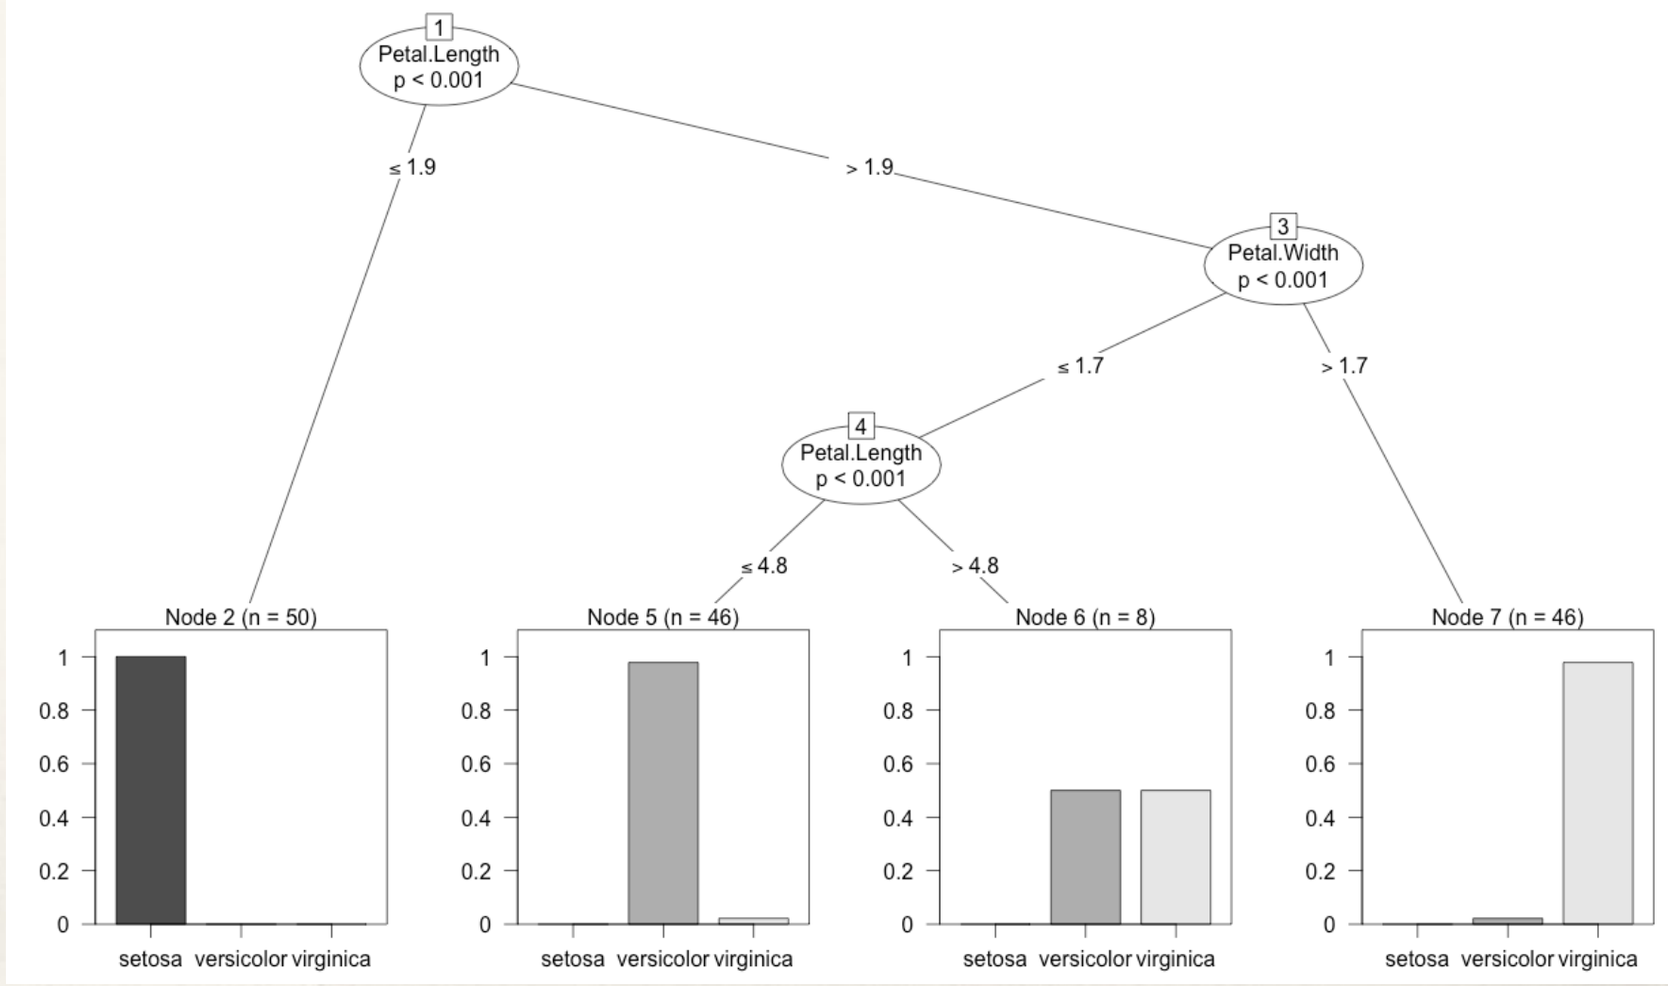

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

Qual é a pergunta?

Aquisição e pré-processamento dos dados

Análise exploratória

Modelagem

Avaliação do modelo

```
> table(predict(model,iris), iris$Species)

             setosa versicolor virginica
  setosa         50          0         0
  versicolor      0         49         5
  virginica       0          1        45
```

Acurácia do modelo?

Quantidade falsos positivos?

Falsos negativos?

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

- Qual é a pergunta?
- Aquisição e pré-processamento dos dados
- Análise exploratória
- Modelagem
- Avaliação do modelo
- Entrega

- Relatórios Estáticos
- Relatórios Dinâmicos
- Aplicativos

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

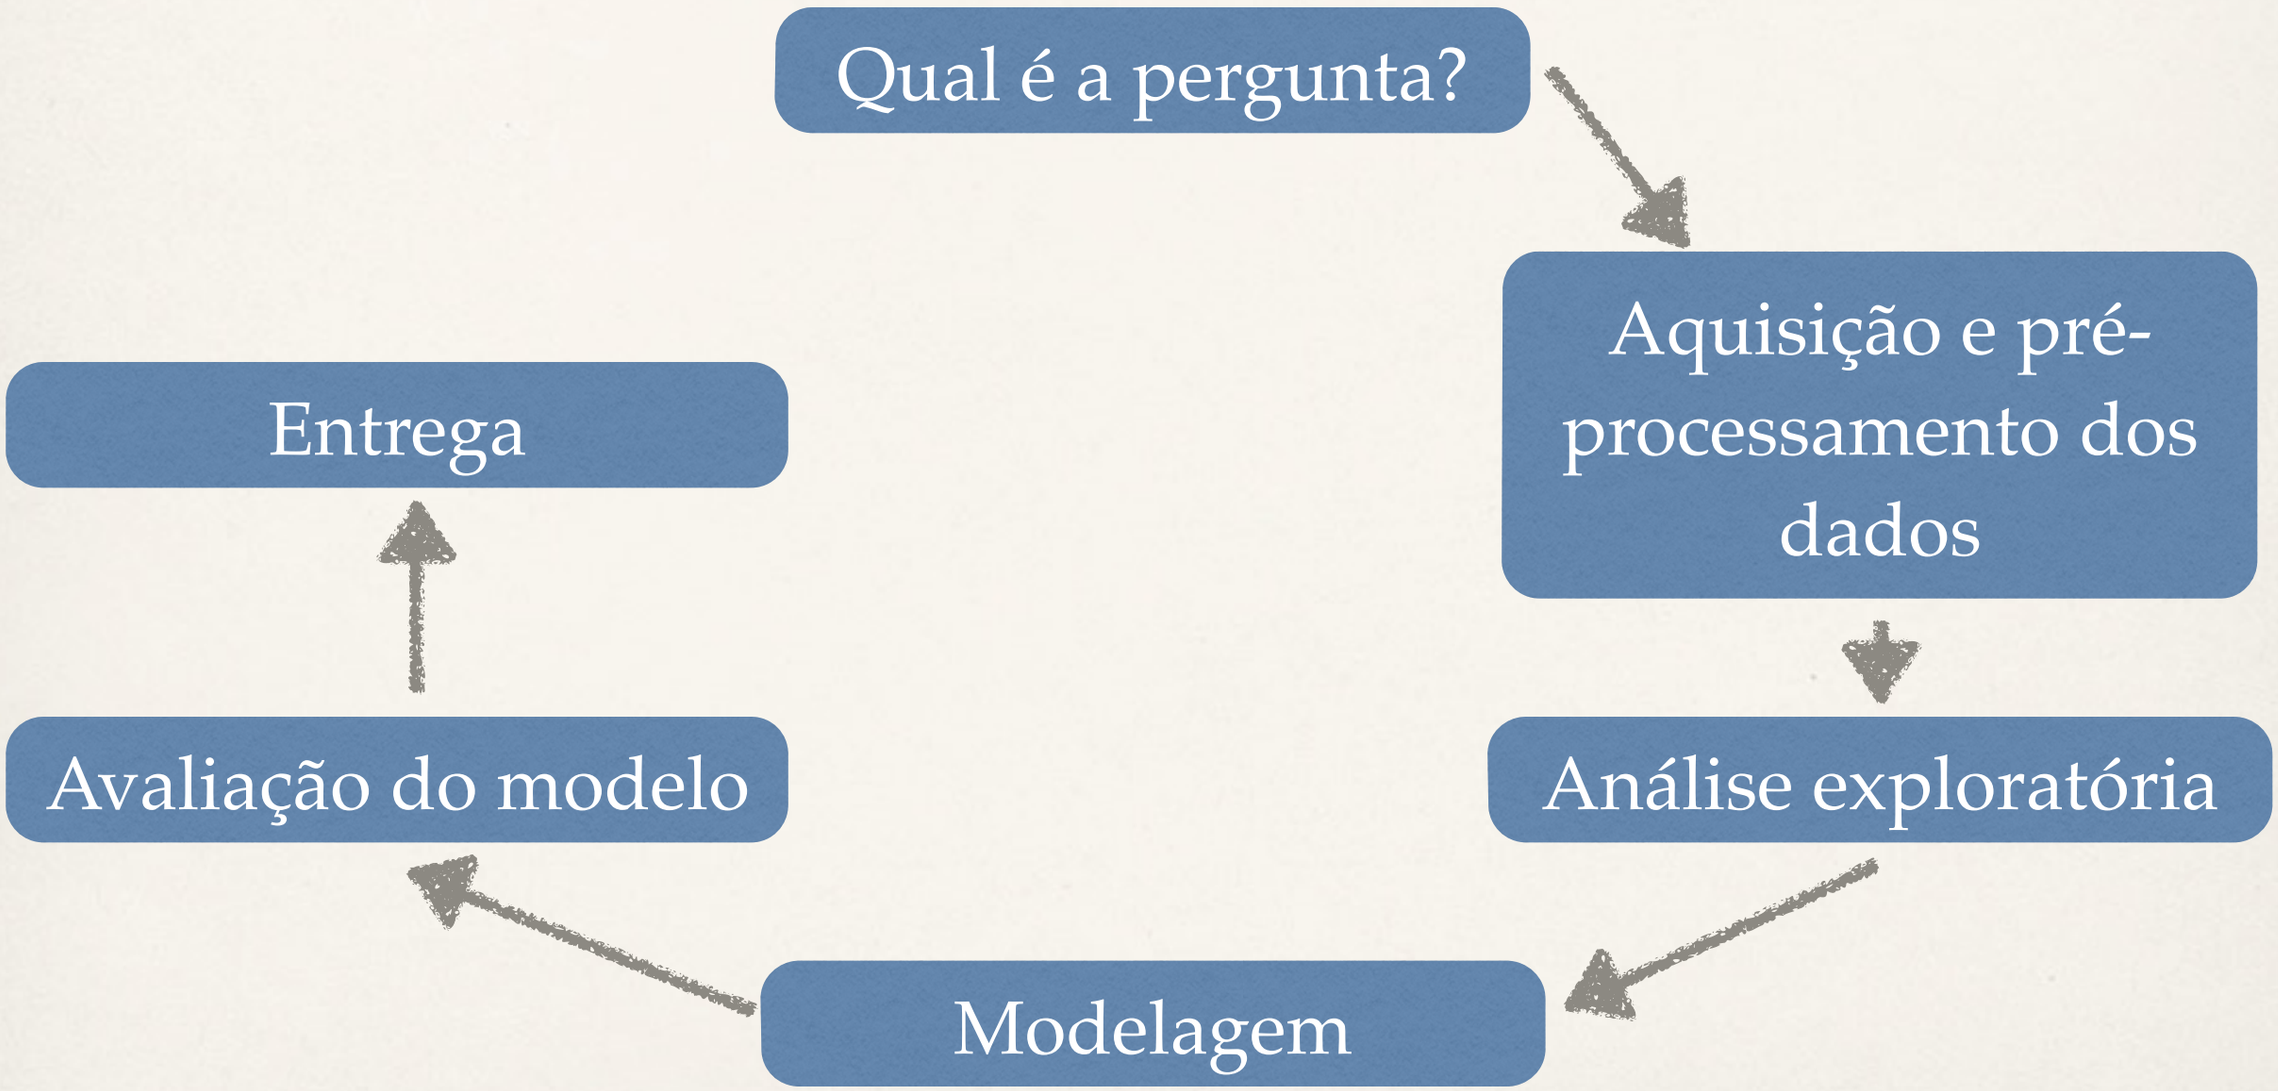

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

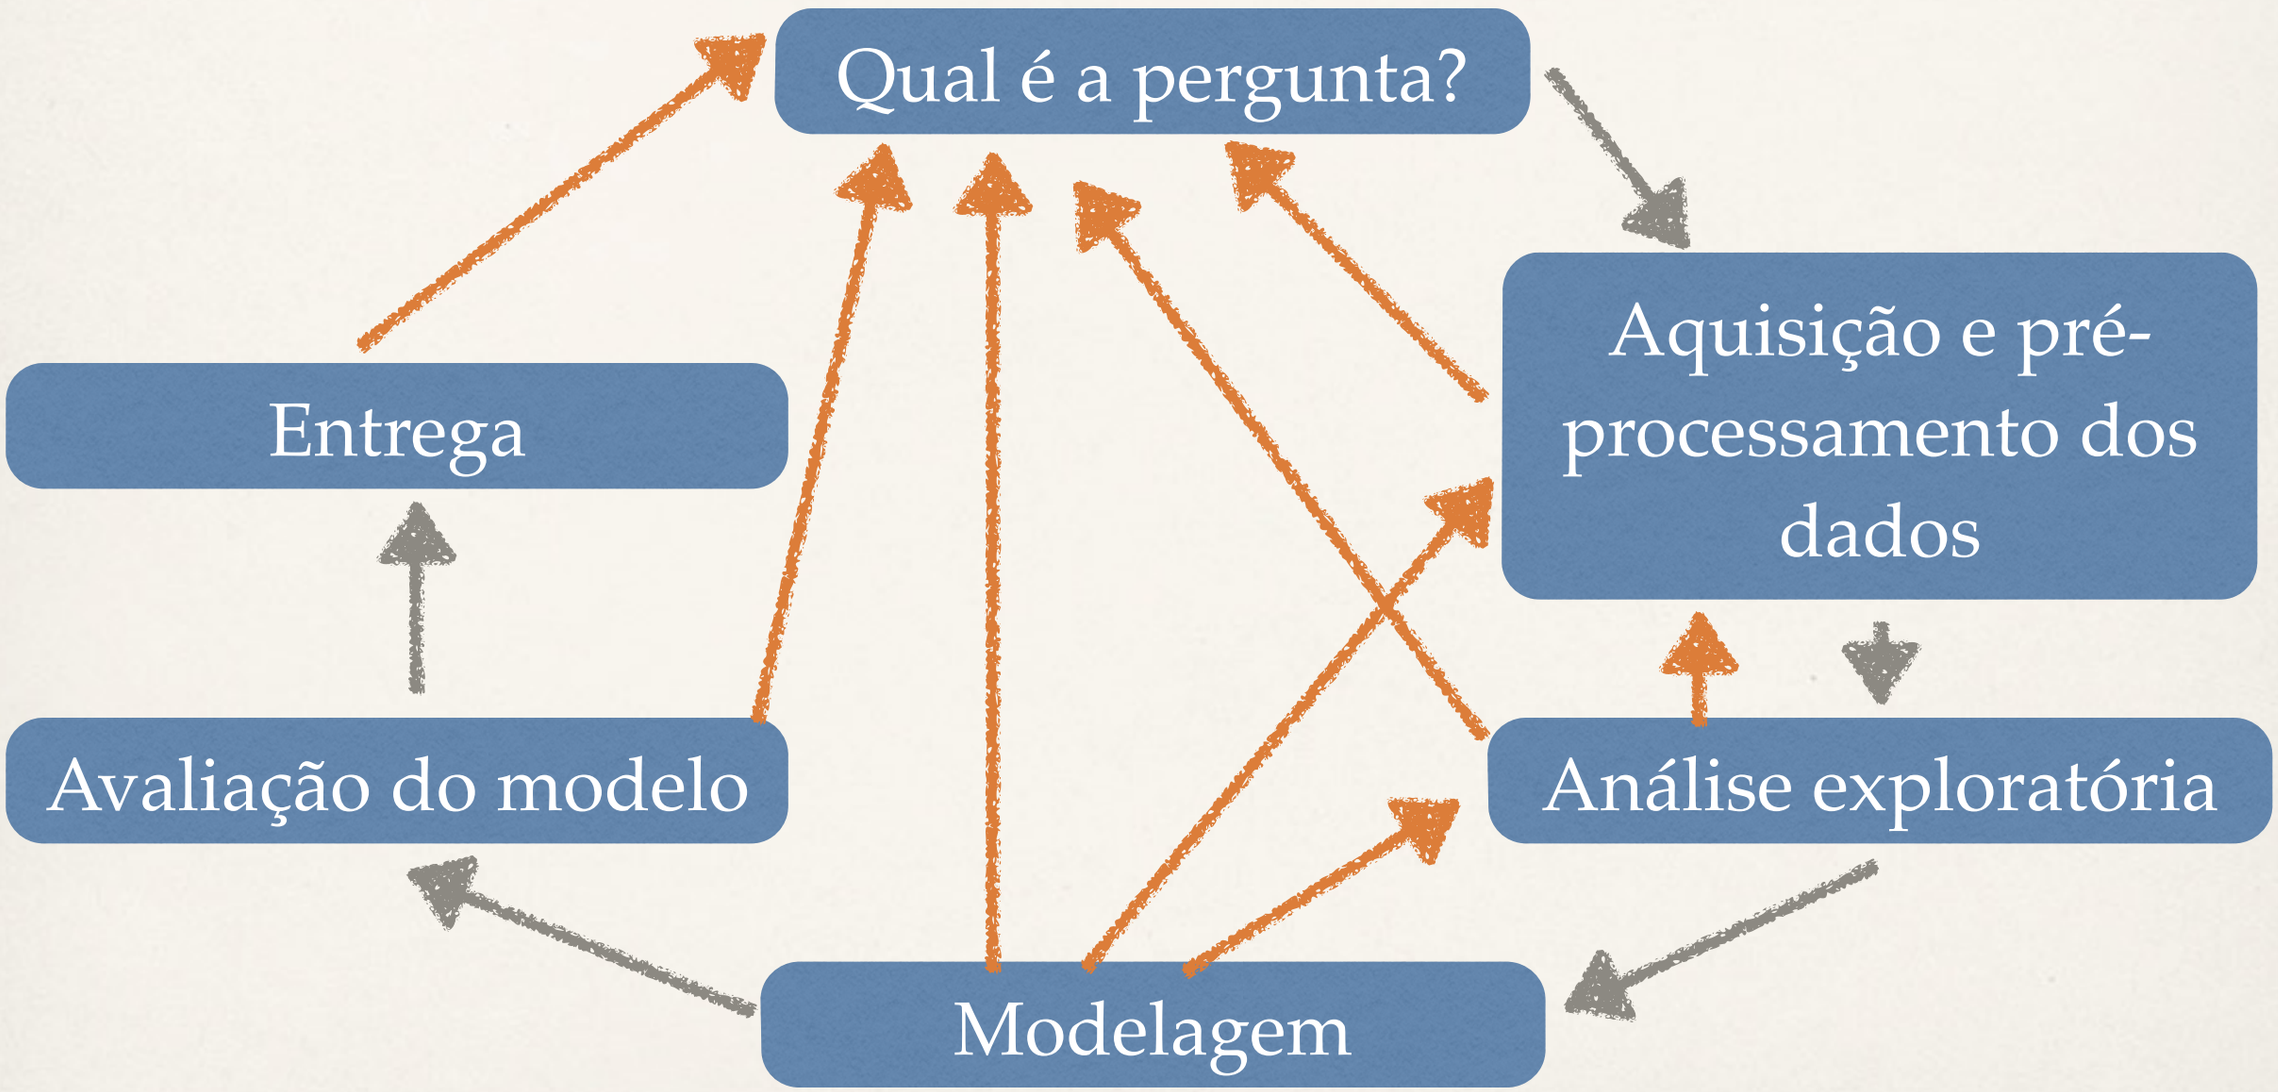

Processo de Descoberta de Conhecimento (KDD - Knowledge Discovery in Databases)

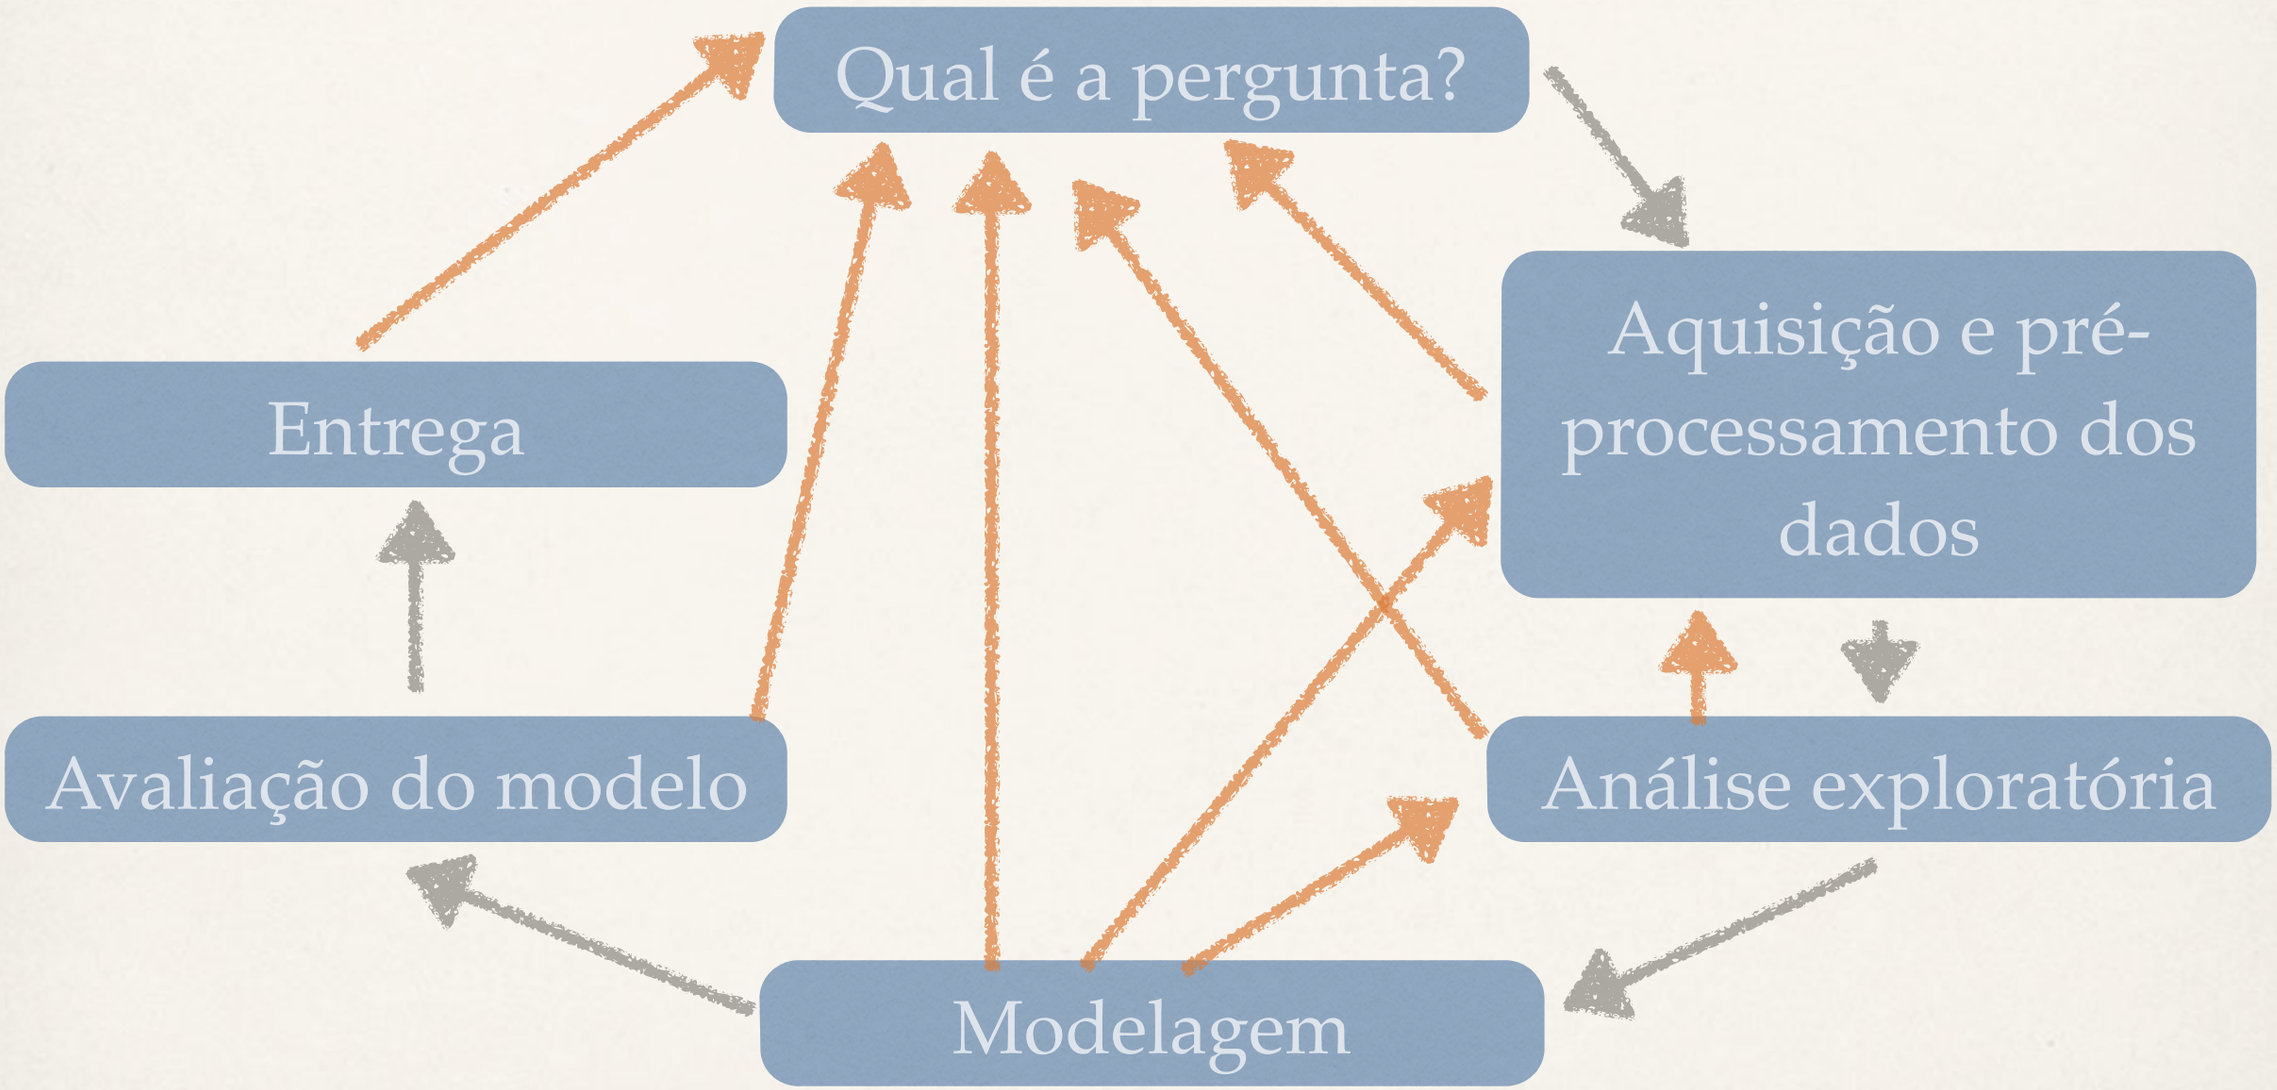

Este processo pode ser suportado por diversas ferramentas, entre elas: R, SPSS, RapidMiner, Tableau, Weka, Matlab, Octave, Python, Julia,…

Leitura sugerida

- Capítulos 1, 2 e 3 do livro EMC Education Services, editor. Data Science and Big Data Analytics: Discovering, Analysing, Visualizing and Presenting Data. John Wiley & Sons, 2015.

- Demais materiais da disciplina estão em:

  - http://fbarth.net.br/cursoBigData

Próximo assunto: compreender melhor a etapa de modelagem