Ciência dos Dados e Big Data – organizações e sociedade direcionadas por dados

21 de setembro de 2020

Prof. Dr. Pedro Luiz Pizzigatti Corrêa - pedro.correa@usp.br
Departamento de Engenharia de Computação e Sistemas Digitais
Escola Politécnica da Universidade de São Paulo - EPUSP
Grupo de Pesquisa e Extensão em Big Data da EPUSP **wds.poli.usp.br**

Agenda

- Introdução
- Boas Práticas para a Gestão e Análise de Dados
- Exemplos de aplicações de Big Data
- Conclusão

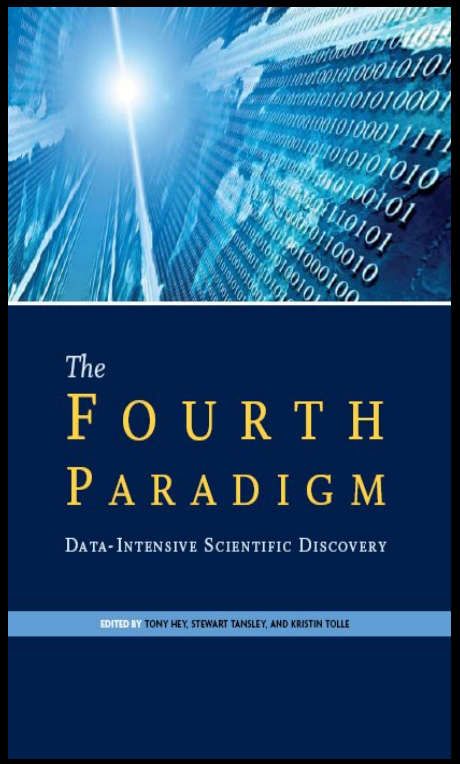

BIG WORLD

BIG PROBLEMS

BIG DATA

Image: NASA C 98-2815

Ciência dos Dados

- Em busca por uma definição formal sobre Ciência dos Dados, encontramos diversos trabalhos na literatura
  - Embora muito se discuta sobre a composição das atividades de Ciência dos Dados, o seu conceito ainda não é algo fundamentalmente estabelecido
- Para Zhu e Xiong (2015), há quatro vertentes (perspectivas) que buscam caracterizar Ciência dos Dados

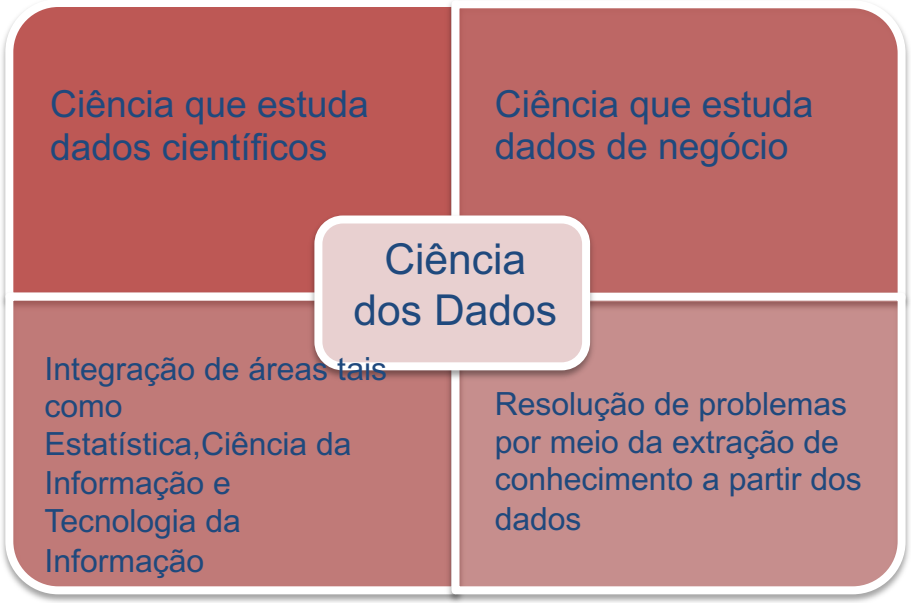

Ciência dos Dados

- Embora não haja consenso sobre a definição, encontramos como elemento comum em todas as propostas um processo de manipulação, processamento e análise de dados, que visa a descoberta de novos conhecimentos

- Para Alex Dehktyar (2016),
  - Ciência dos dados é uma disciplina que permite tratar o o ciclo de trabalho com os dados, considerando atividades que compreendem desde a aquisição dos dados, passando pela análise dos dados, até o processo de apresentação dos dados e obtenção de novos conhecimentos

Ciência dos Dados - Processo

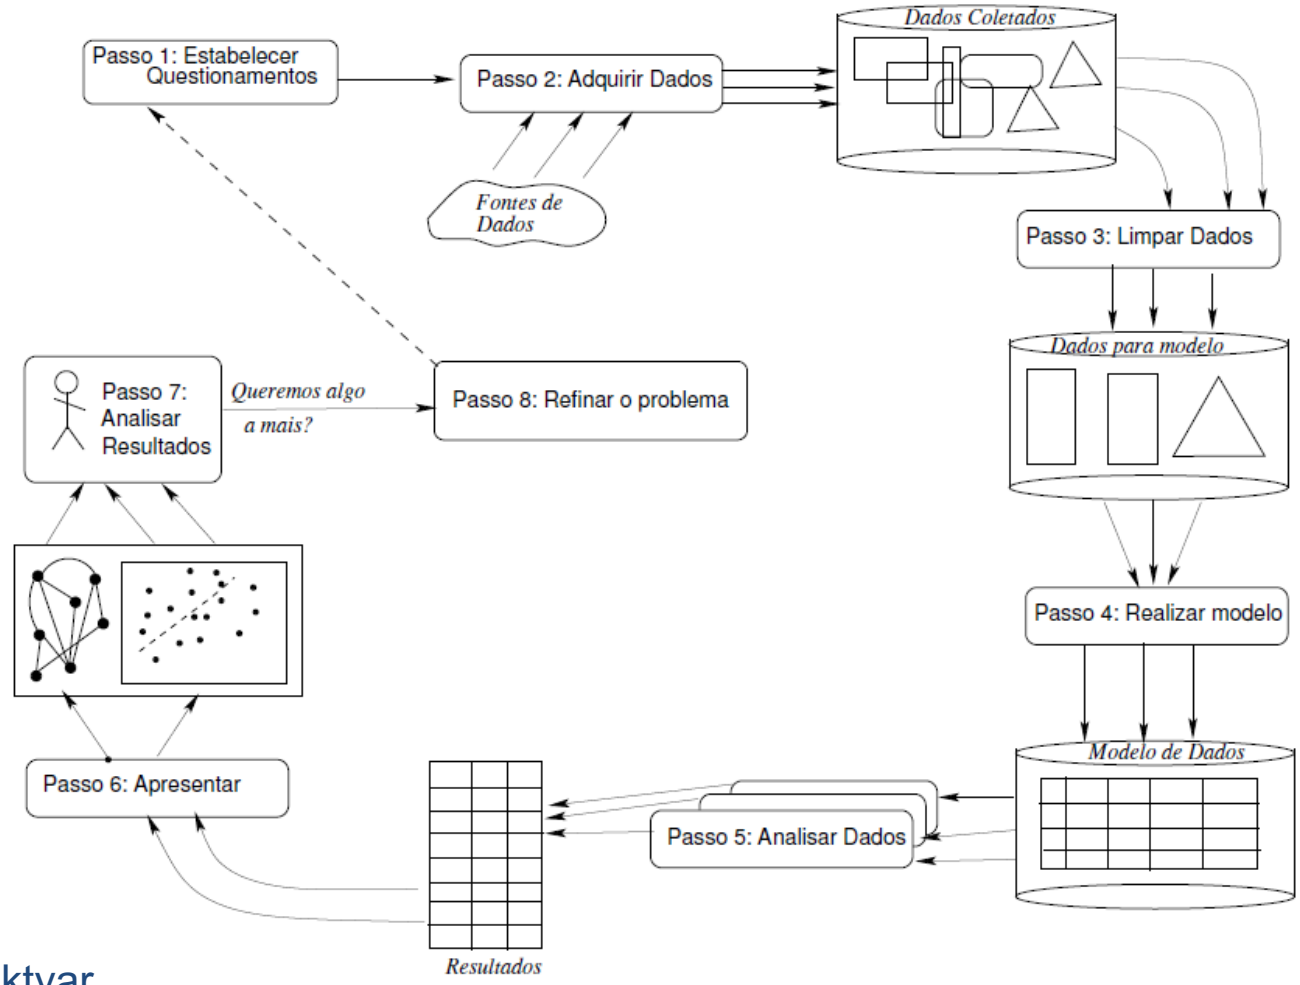

Cortesia: Alex Dehktyar

Gestão de Dados

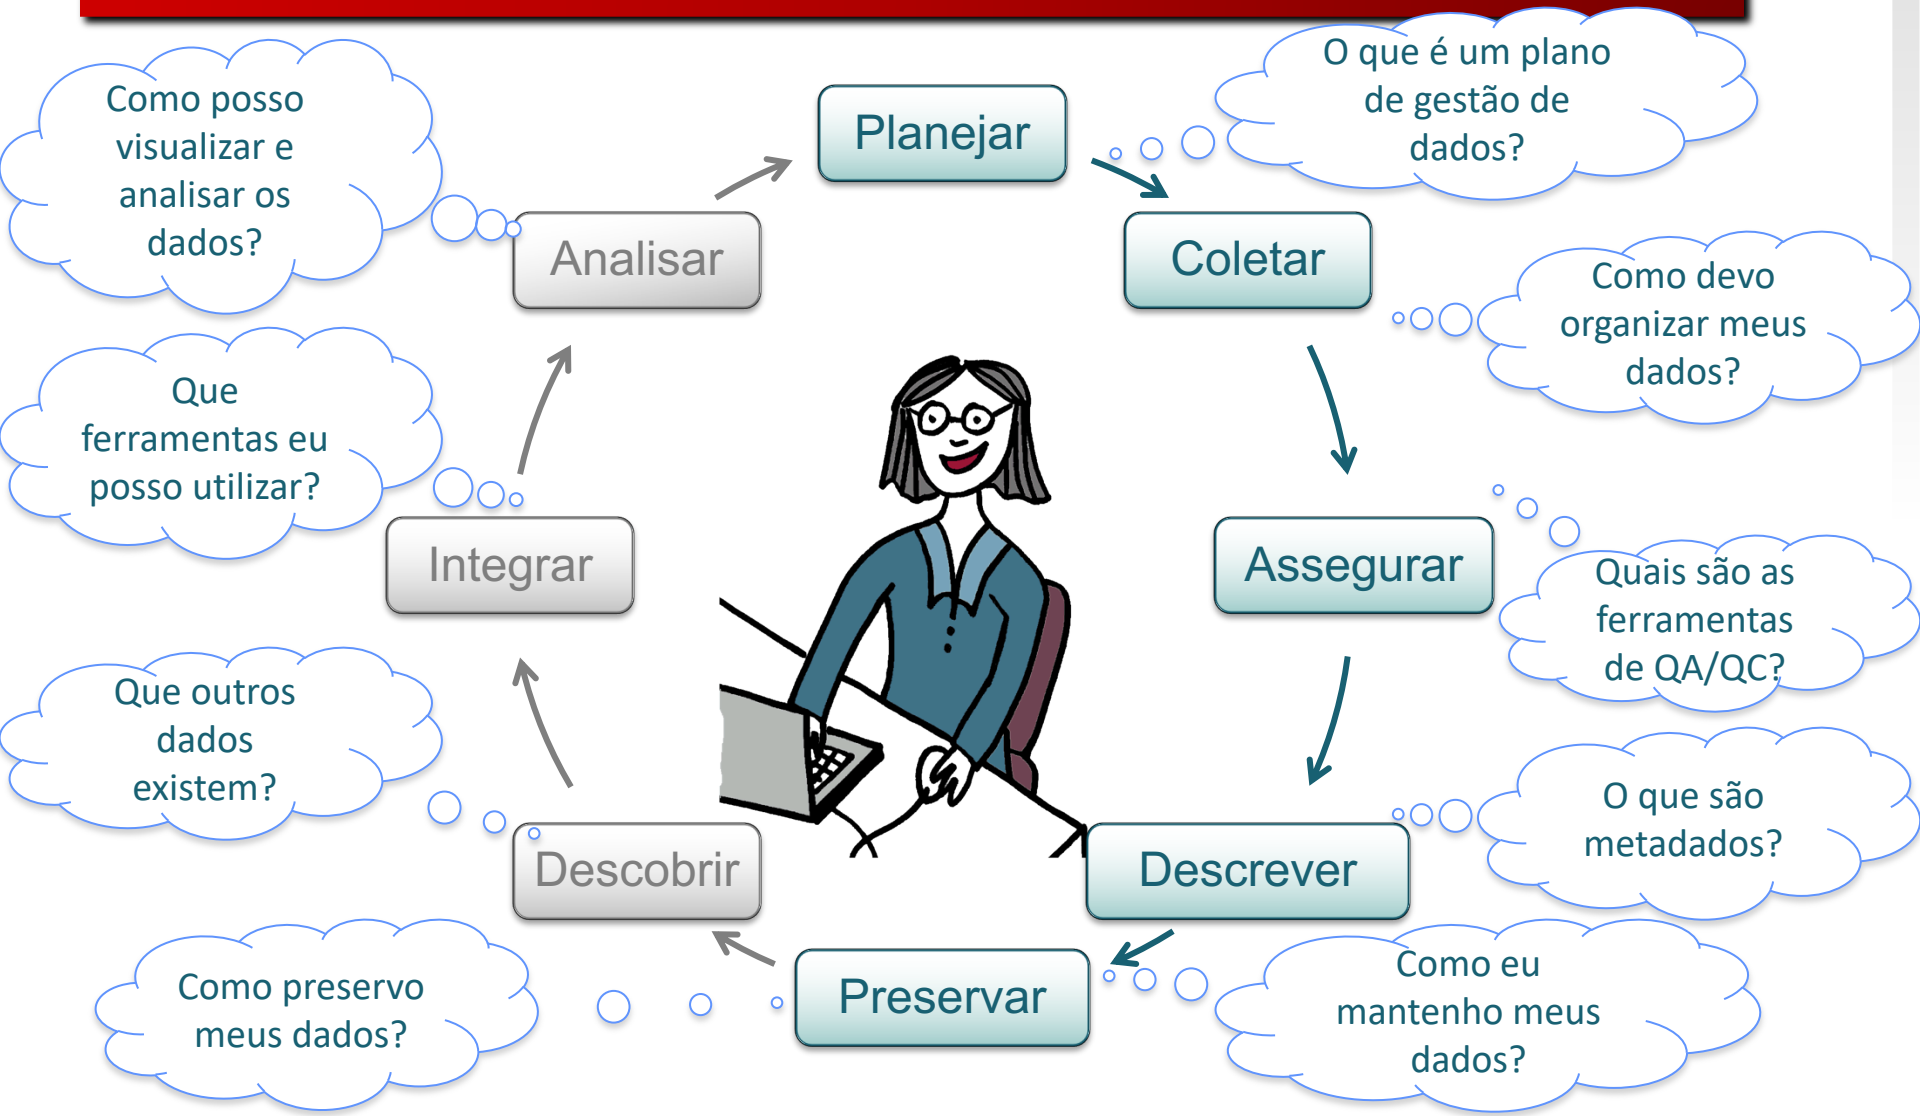

O que é Big Data ?

- ✓ É uma aplicação computacional de Ciência dos Dados que tem por objetivo analisar, extrair sistematicamente informações de grandes volumes de conjuntos de dados, para os quais técnicas computacionais tradicionais não são adequadas. Os desafios para gestão dos dados são classificados em 5V's (Chen et al., 2012, Kwon et al., 2014).

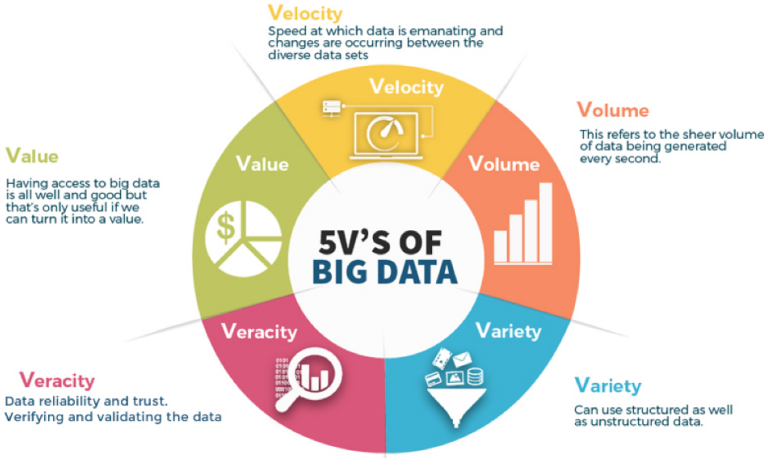

- ✓ Big data é um grande volume de dados, alta velocidade e alta variedade de ativos de informação que demandam formas inovadoras e econômicas de processamento de informações para melhor *insight* e tomada de decisões." ("Gartner IT Glossary, n.d.")

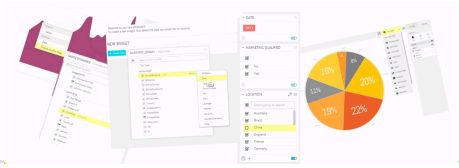

Requisitos para Big Data:

- Precisão
- Atualizado
- Pronto para análise

Quais são os dados ?

Coleções de registros ou medições que fornecem um registro de evidências do evento observado *"... qualquer informação que possa ser armazenada em formato digital, incluindo texto, números, imagens, vídeo ou filmes, áudio, software, algoritmos, equações, animações, modelos, simulações, etc. "*

Atributos gerais da Iinformação:

- Digital;
- Heterogêneo;
- Contextualizado;
- Valioso.

Cortesia: Profa. Dra. Suzie Allard (University of Tennessee)

Problema: Volume de Dados

International Data Corporation (IDC):

- A informação no mundo está mais que dobrando, está dobrando cada dois anos (30 Zettabytes em 2018);
- O número de arquivos está crescendo mais rápido que a capacidade de armazenamento. Nos próximos 5 anos esses arquivos irão crescer num fator de 8;
- O número de pessoas na área de IT responsável por esses dados irá crescer "suavemente";

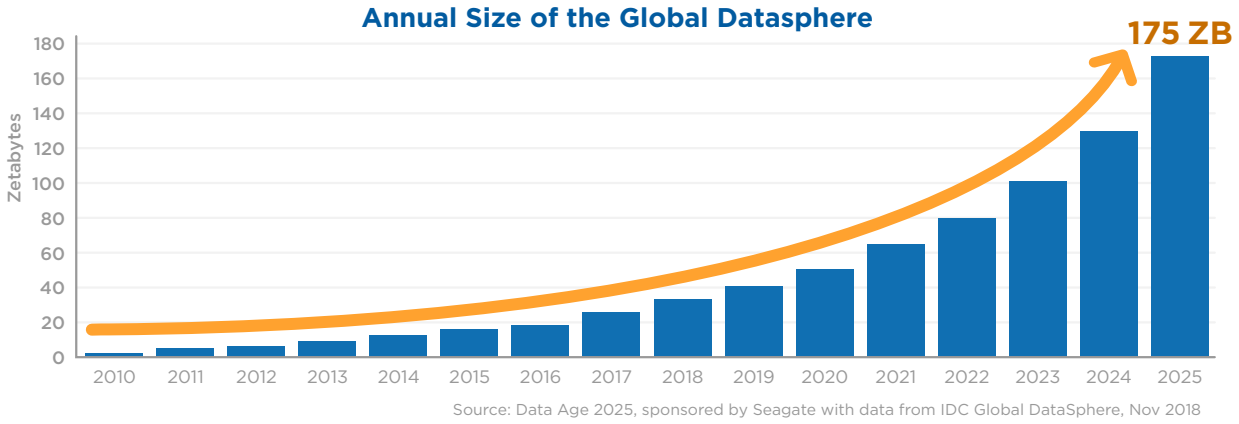

Problema que conhecemos muito bem !

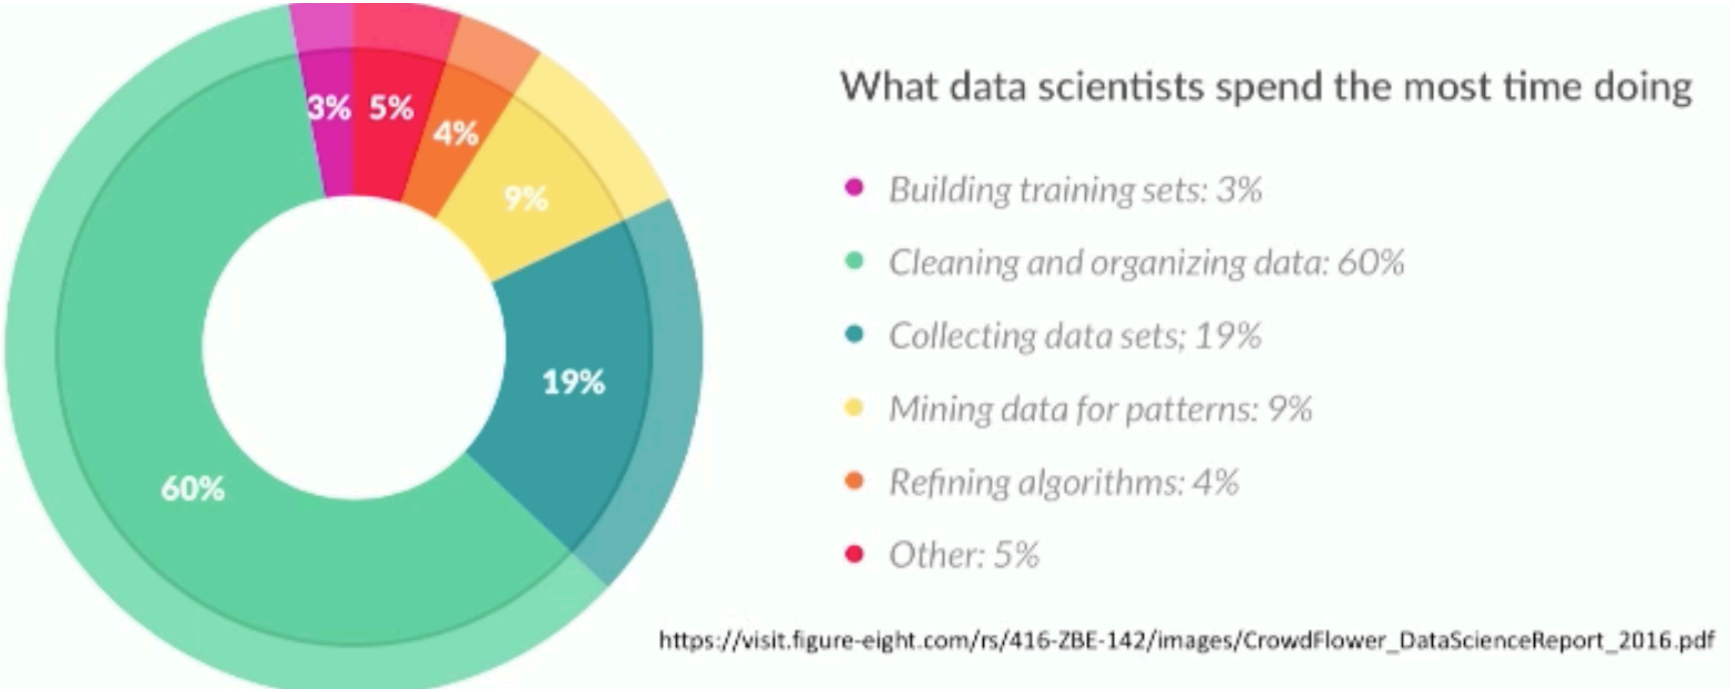

- 60% em atividades na organização e limpeza dos dados;
- 12% em atividades de pré-processamento
- 9% em atividades de análise

Imagine o seguinte cenário:

CEO: “Nós Precisamos aumentar nossas vendas"

Marketing Manager: **“**Quais outros produtos podemos vender ?**"**

IT Manager: “Com nosso atual *backlog* estimo que teremos essa informação em ***1 mês***"

Marketing Manager: “1 mês ? Nós ***já temos esses dados*** em nossos sistemas ?"

IT Manaager: “Nós já temos, mas ***não na correta estrutura*** para responder essa questão !"

CEO: “Só preciso aumentar as vendas!"

Agenda

- Introdução
- Boas Práticas para a Gestão de Dados
- Aplicações na área de Big Data
- Conclusão

Avaliação da Gestão de Dados

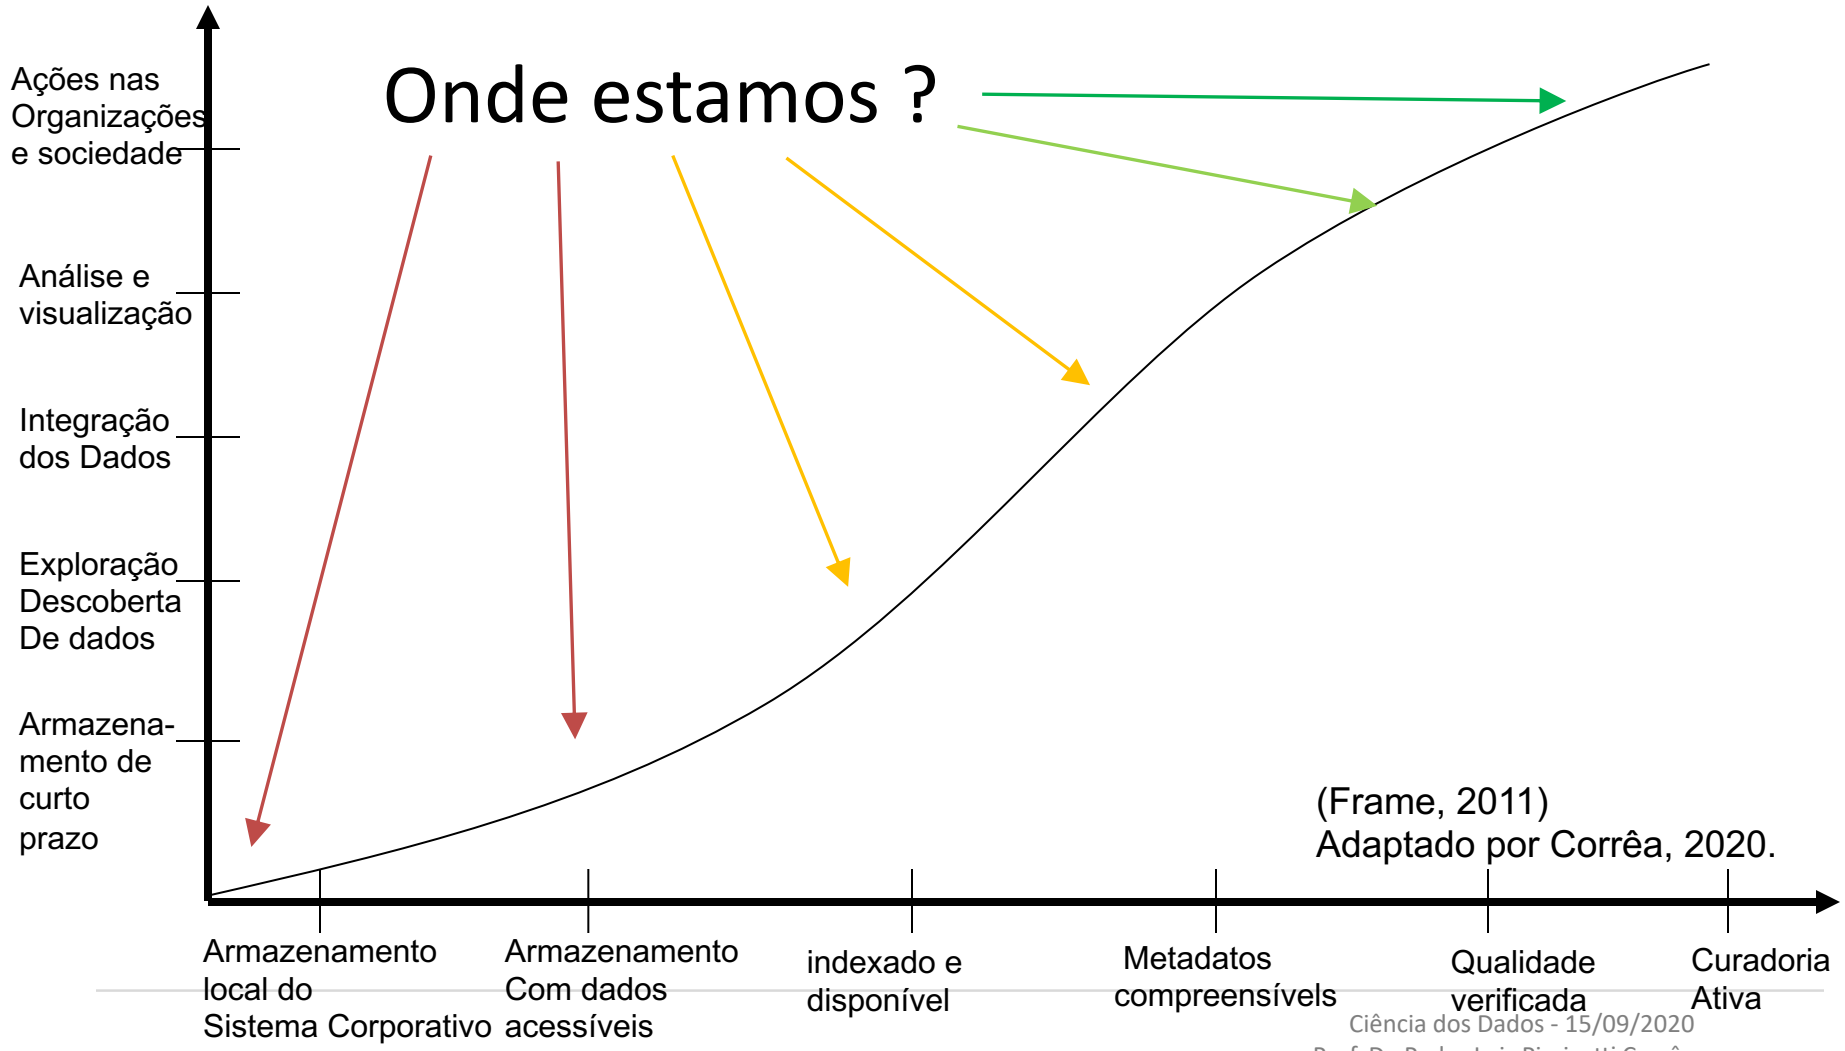

Modelo de Maturidade

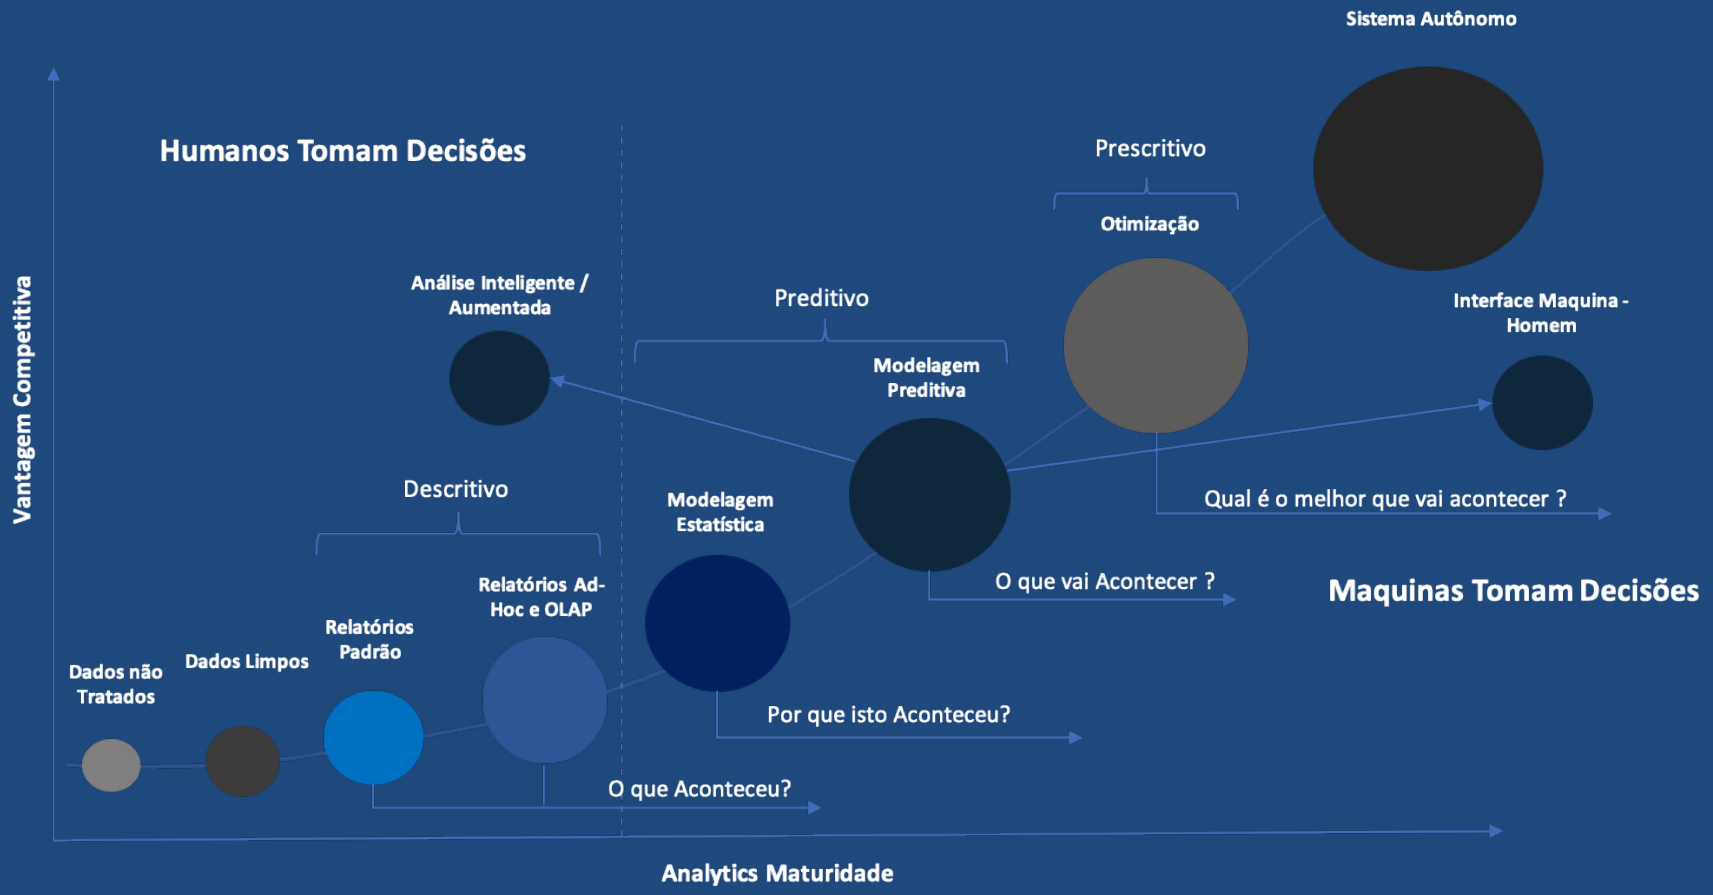

Framework Organizacional de TI - DataLab

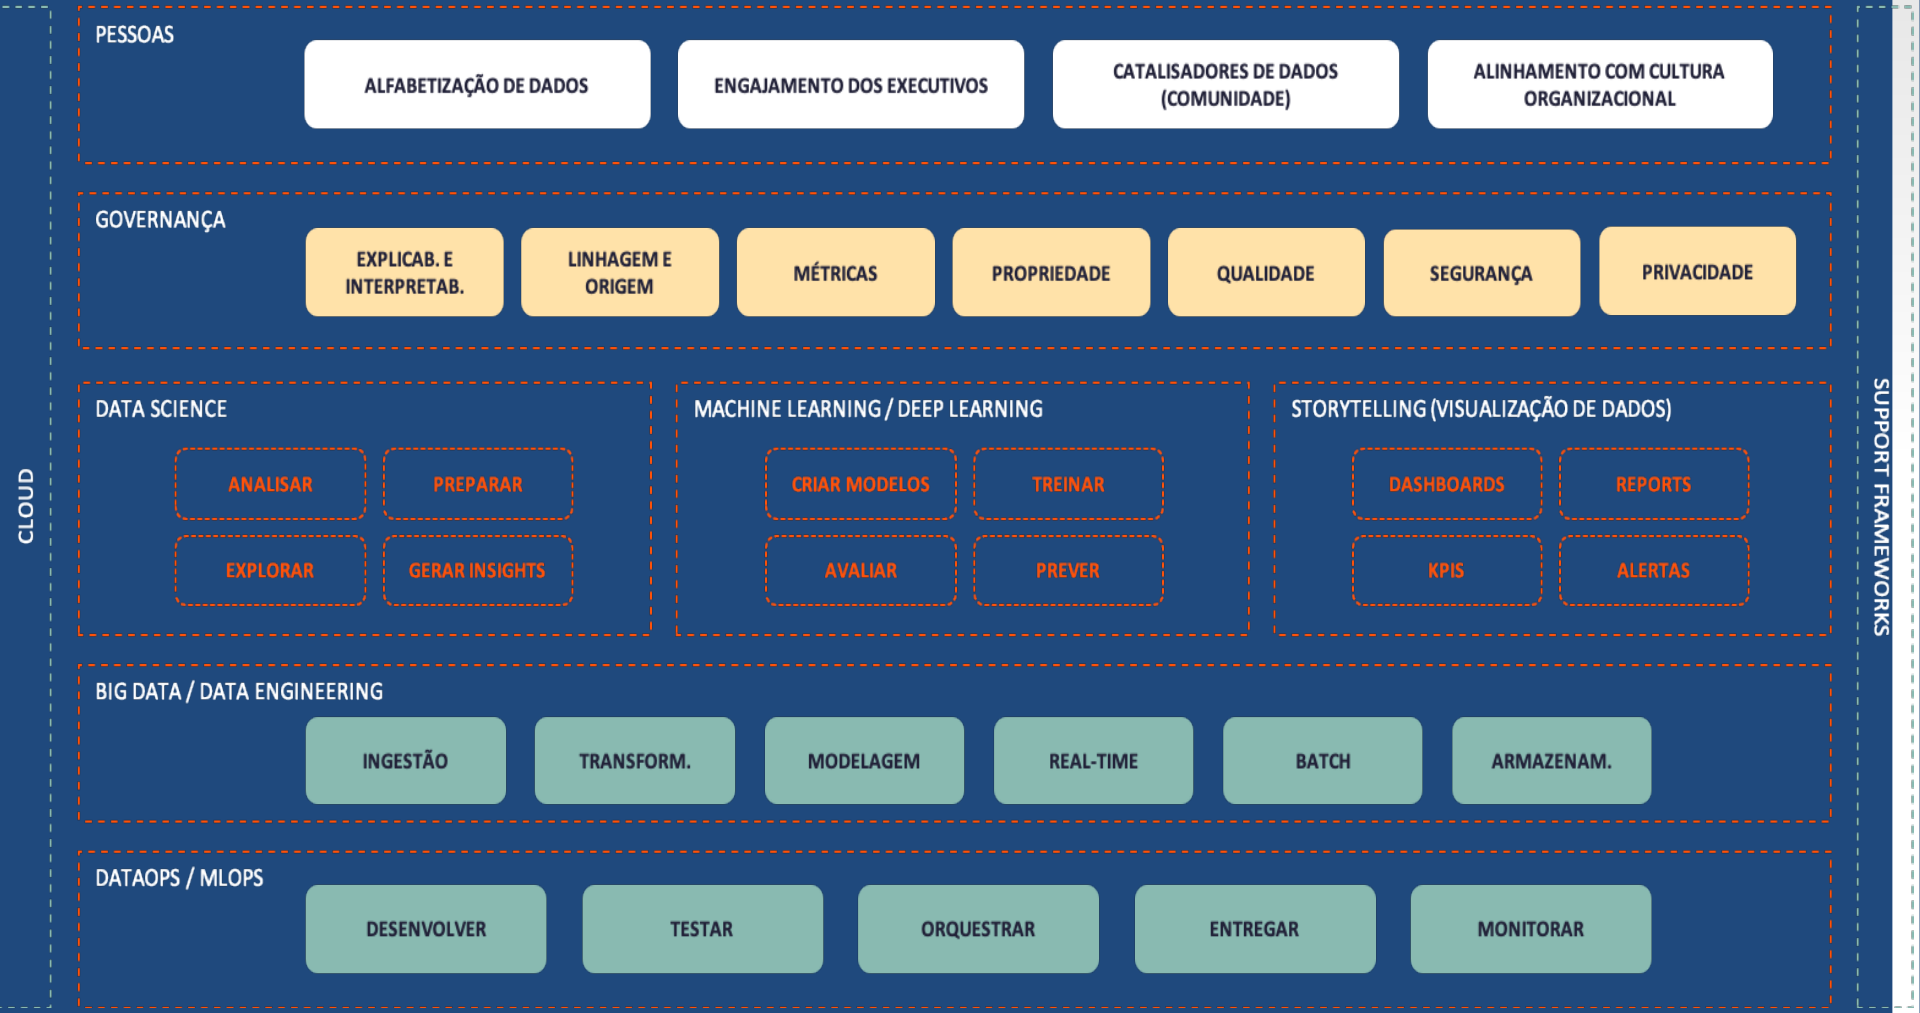

FAIR Data Principles
to be Findable, Accessible, Interoperable and Re-Usable

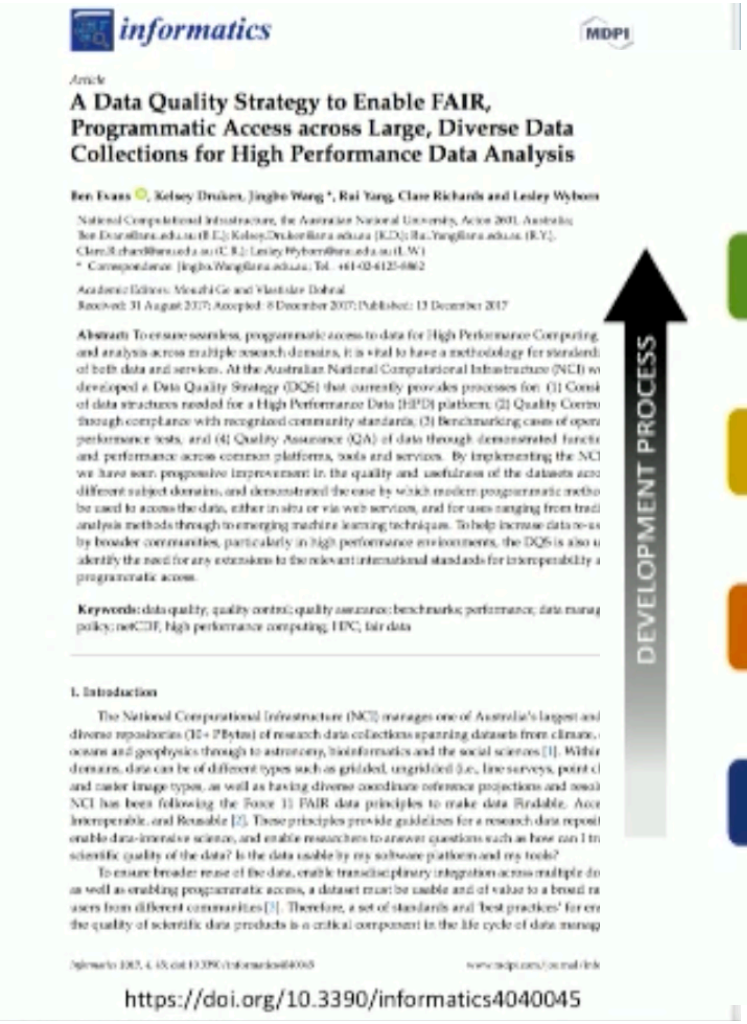

informatics

MDPI

Article

A Data Quality Strategy to Enable FAIR, Programmatic Access across Large, Diverse Data Collections for High Performance Data Analysis

Ben Evans, Kelsey Druken, Jingbo Wang *, Rui Yang, Clare Richards and Lesley Wyborn

National Computational Infrastructure, the Australian National University, Acton 2601, Australia; Ben.Evans@anu.edu.au (B.E.); Kelsey.Druken@anu.edu.au (K.D.); Rui.Yang@anu.edu.au (R.Y.); Clare.Richards@anu.edu.au (C.R.); Lesley.Wyborn@anu.edu.au (L.W.)
* Correspondence: Jingbo.Wang@anu.edu.au; Tel.: +61-02-6125-6862

Academic Editors: Wenzhi Cao and Vladislav Bohrial
Received: 31 August 2017; Accepted: 8 December 2017; Published: 13 December 2017

Abstract: To ensure seamless, programmatic access to data for High Performance Computing and analysis across multiple research domains, it is vital to have a methodology for standardized of both data and services. At the Australian National Computational Infrastructure (NCI) we developed a Data Quality Strategy (DQS) that currently provides processes for: (1) Consistency of data structures needed for a High Performance Data (HPD) platform; (2) Quality Control through compliance with recognized community standards; (3) Benchmarking cases of operational performance tests; and (4) Quality Assurance (QA) of data through demonstrated functionality and performance across common platforms, tools and services. By implementing the NCI DQS we have seen progressive improvement in the quality and usefulness of the datasets across different subject domains, and demonstrated the ease by which modern programmatic methods can be used to access the data, either in situ or via web services, and for uses ranging from traditional analysis methods through to emerging machine learning techniques. To help increase data re-use by broader communities, particularly in high performance environments, the DQS is also used to identify the need for any extensions to the relevant international standards for interoperability and programmatic access.

Keywords: data quality; quality control; quality assurance; benchmarks; performance; data management policy; netCDF; high performance computing; HPC; fair data

1. Introduction

The National Computational Infrastructure (NCI) manages one of Australia's largest and most diverse repositories (10+ PBytes) of research data collections spanning datasets from climate, ocean and geophysics through to astronomy, bioinformatics and the social sciences [1]. Within these domains, data can be of different types such as gridded, ungridded (i.e., line surveys, point clouds) and raster image types, as well as having diverse coordinate reference projections and resolutions. NCI has been following the Force 11 FAIR data principles to make data Findable, Accessible, Interoperable, and Reusable [2]. These principles provide guidelines for a research data repository to enable data-intensive science, and enable researchers to answer questions such as how can I trust the scientific quality of the data? Is the data usable by my software platform and my tools?

To ensure broader reuse of the data, enable transdisciplinary integration across multiple domains as well as enabling programmatic access, a dataset must be usable and of value to a broad range of users from different communities [3]. Therefore, a set of standards and 'best practices' for ensuring the quality of scientific data products is a critical component in the life cycle of data management

https://doi.org/10.3390/informatics4040045

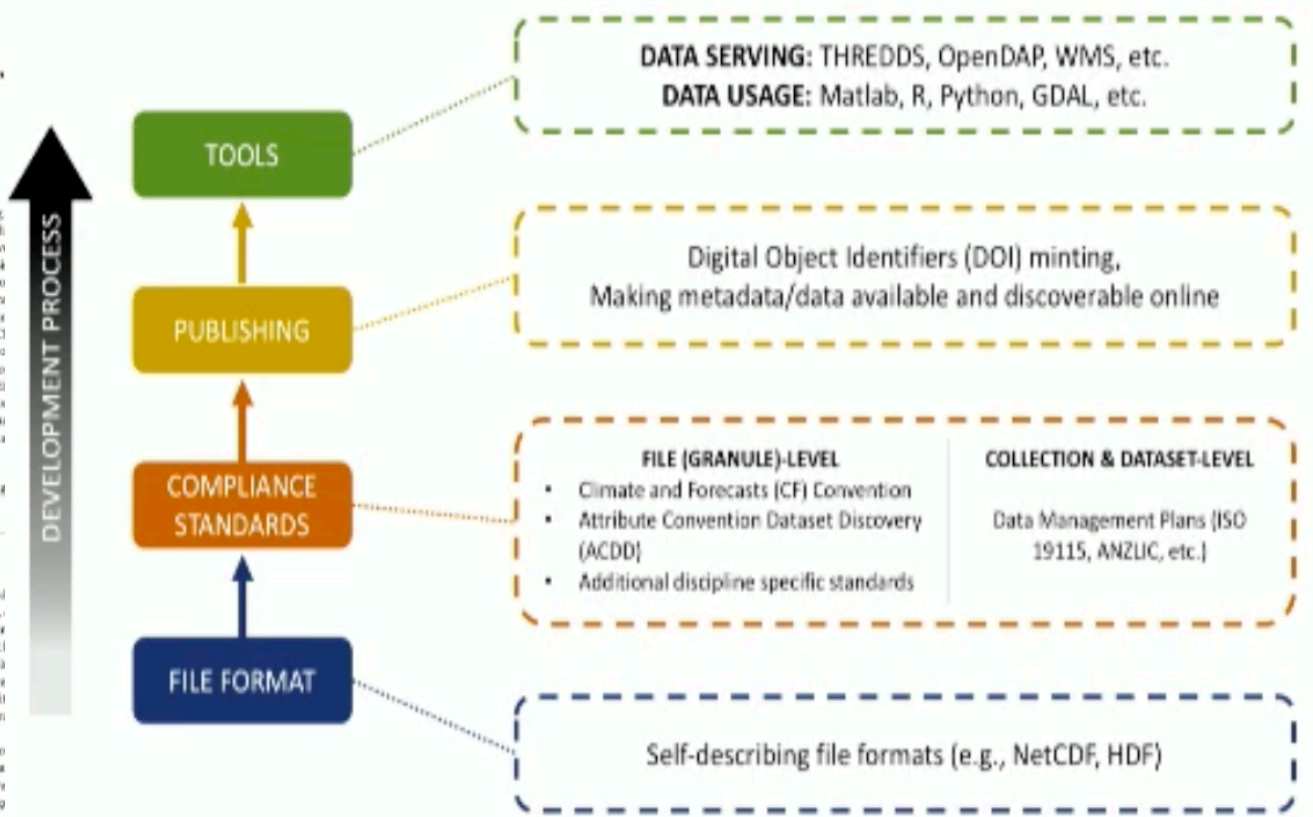

Confiabilidade para reuso dos dados

- Se alguém entregar seus dados, o que é necessário para convencê-lo que os dados estão corretos ?
- Se requer um sistema complexo para executá-lo e que não tem acesso, o que precisa para confiar dos dados ? Você conhece quais são as suposições e dependências existentes ?
- Quanto você poderá confiar que os mesmo dado estará disponível por um longo período de tempo ?

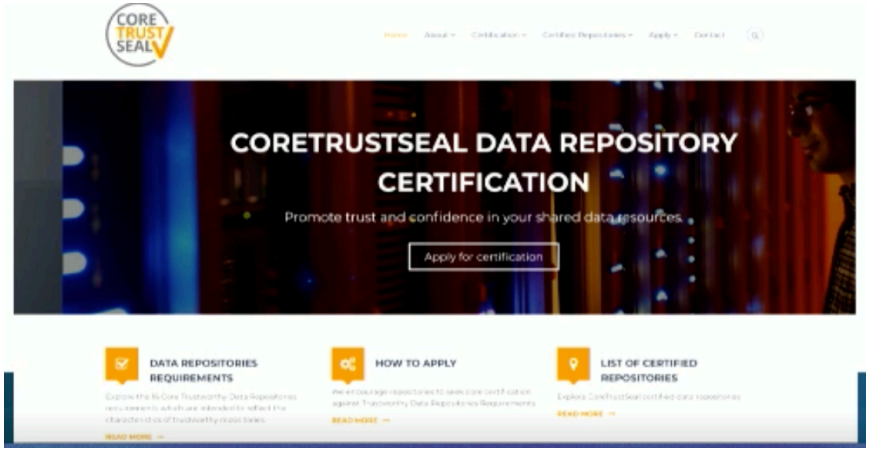

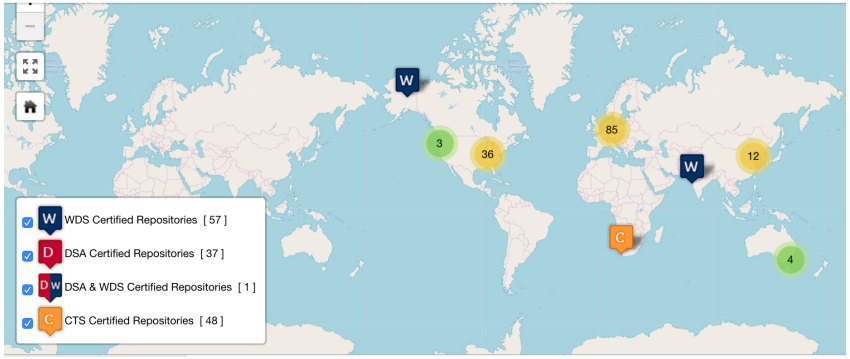

Arquitetura de Big Data

Projeto Hadoop

- 2003

The Google File System

Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung

Google*

→ hadoop HDFS

- 2004

MapReduce: Simplified Data Processing on Large Clusters

Jeffrey Dean and Sanjay Ghemawat

jeff@google.com, sanjay@google.com

Google, Inc.

→ hadoop MapReduce

- 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

→ APACHE HBASE

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

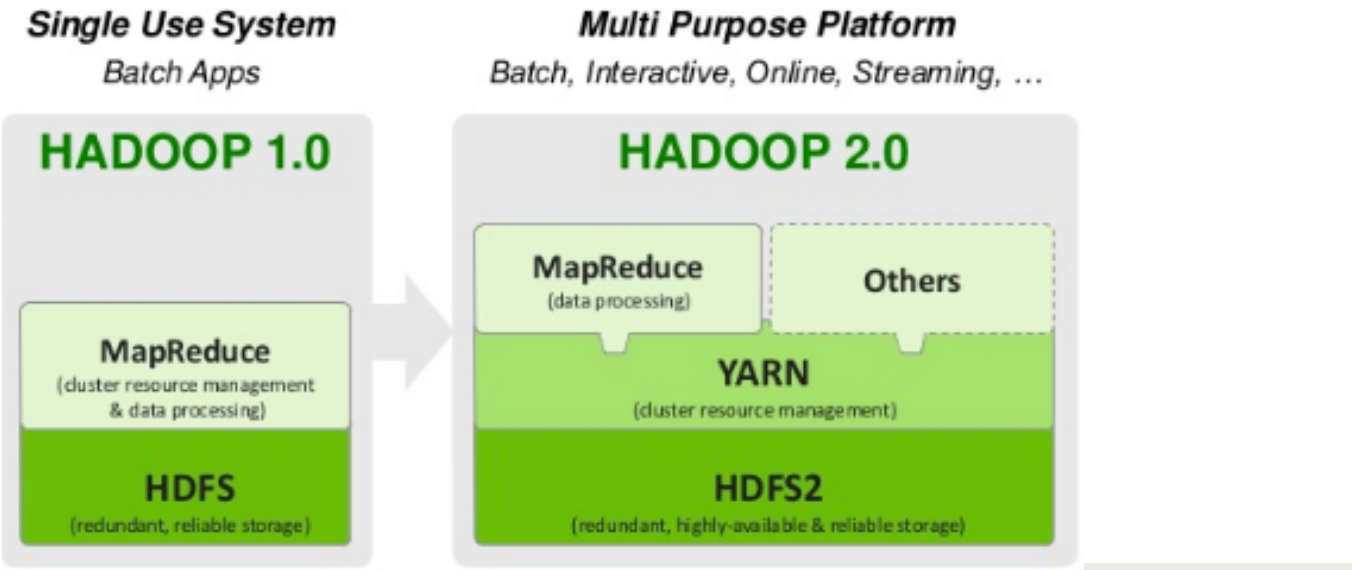

Arquitetura/Ecossistema Hadoop

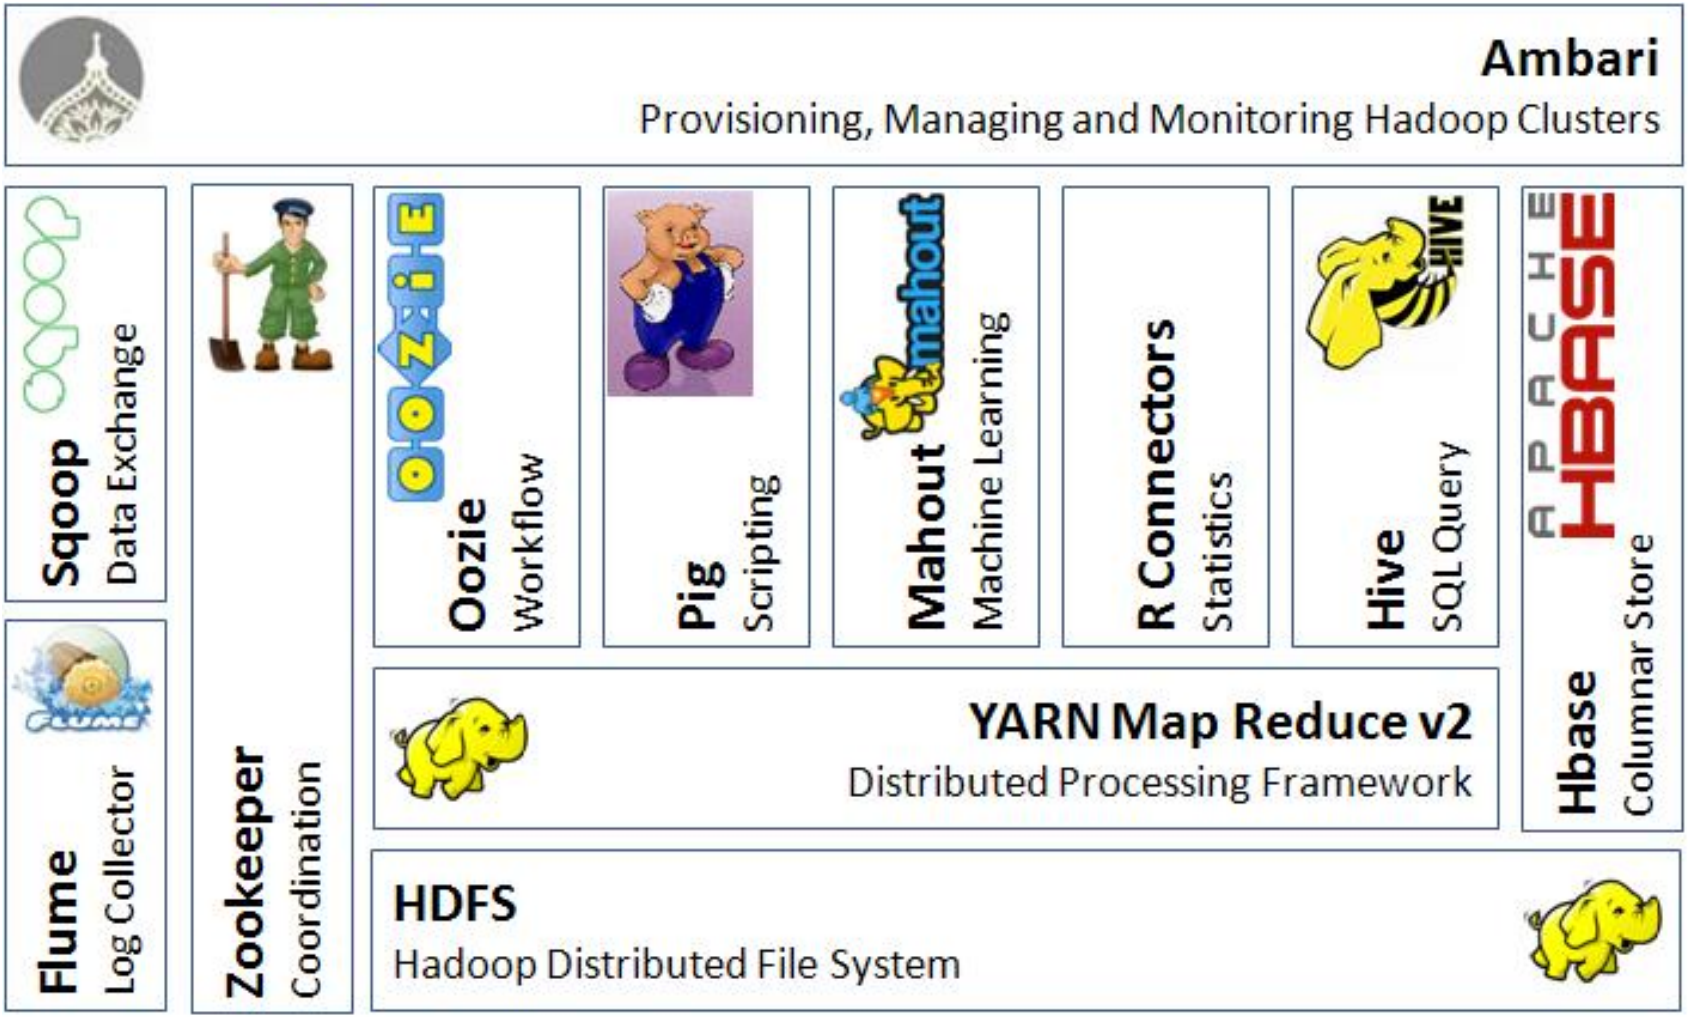

Distribuições Hadoop

Agenda

- Introdução
- Boas Práticas para a Gestão de Dados Científicos
- Aplicações de Big Data
- Conclusão

Aplicações de Big Data

Financeiro	Transações Dados Cadastrais Credit Bureau Índices Econômicos	Credit Score Customer Behavior Prevenção a Fraudes Risco de Crédito Previsão de Inadimplência
Saúde	Prontuário Médico Histórico de Exames Dados familiares	Diagnóstico preditivo Descoberta de doenças e tratamentos Prevenção de epidemias Efeitos adversos de tratamentos
Vendas e Marketing	Transações Hábitos de consumo Personas	Recomendação de Produtos Lançamento de Produtos Segmentação de Clientes Churn Analysis

Aplicações de Big Data

Indústria	**Sensores** **Apontamentos de Produção** **Controle de Qualidade**	**Manutenção Preventiva** **Otimização da produção com base nas Vendas** **Nível de estocagem**
Recrutamento / People Analytics	**Histórico de Projetos** **Tempo de Permanência** **Referências anteriores** **Soft Skills** **Transcrição de Entrevistas**	**Fit entre funcionário e empresa** **"Tempo de vida" estimado** **Plano de Carreira** **Melhor alocação de recursos**
Educação	**Histórico de notas** **Frequência** **Participação em aula** **Atividades extra-curriculares**	**Programas individualizados de ensino** **Predição de evasão escolar**

The Atmospheric Radiation Measurement (ARM) Facility
Data and Computing Management (DoE/USA)

Objetivo do ARM:

fornecer uma detalhada e precisa descrição da atmosfera da terra em diversos regimes climáticos para resolver as incertezas no clima e nos modelos dos sistemas terrestres que direcionam o desenvolvimento de soluções sustentáveis para a Energia e desafios ambientais.

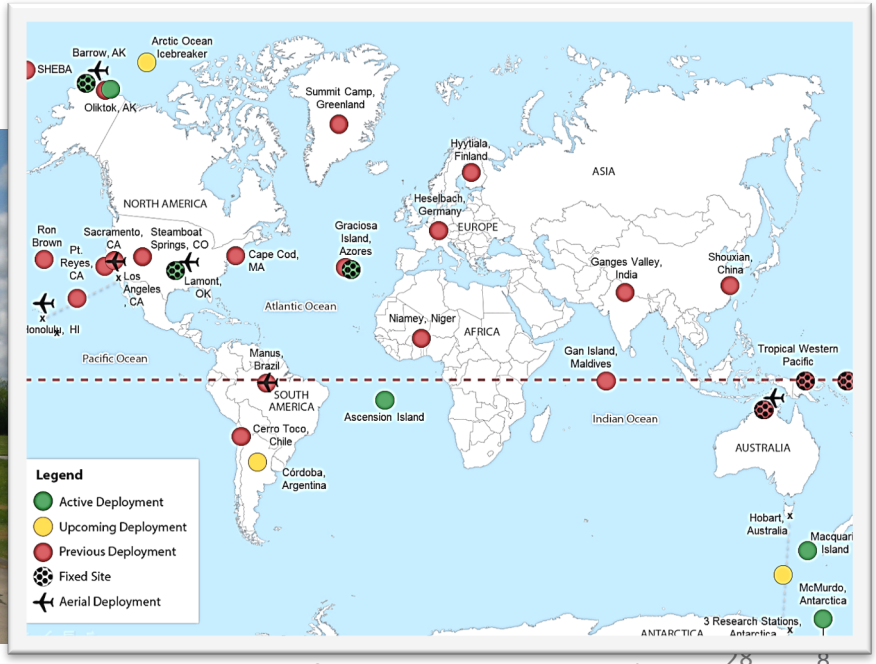

ARM GOAMAZON

http://www.arm.gov/sites/amf/mao/
http://campaign.arm.gov/goamazon2014/

This view shows the location of the Manacapuru, Brazil, ARM Mobile Facility.

G-1 Research Aircraft in Manaus

AMF1 Site in Manacapuru

ATTO: Amazon Tall Tower Observatory

Exemplo de aplicações: Projeto avaliação do impacto socioeconomic das Unidades de Conservação

A deep-learning approach to predict socioeconomic indicators using satellite ~~im~~agery

Case of study: Vale do Ribeira

FAPESP – Brazil, NSF – EUA, France and Japan
https://parsecproject.org/

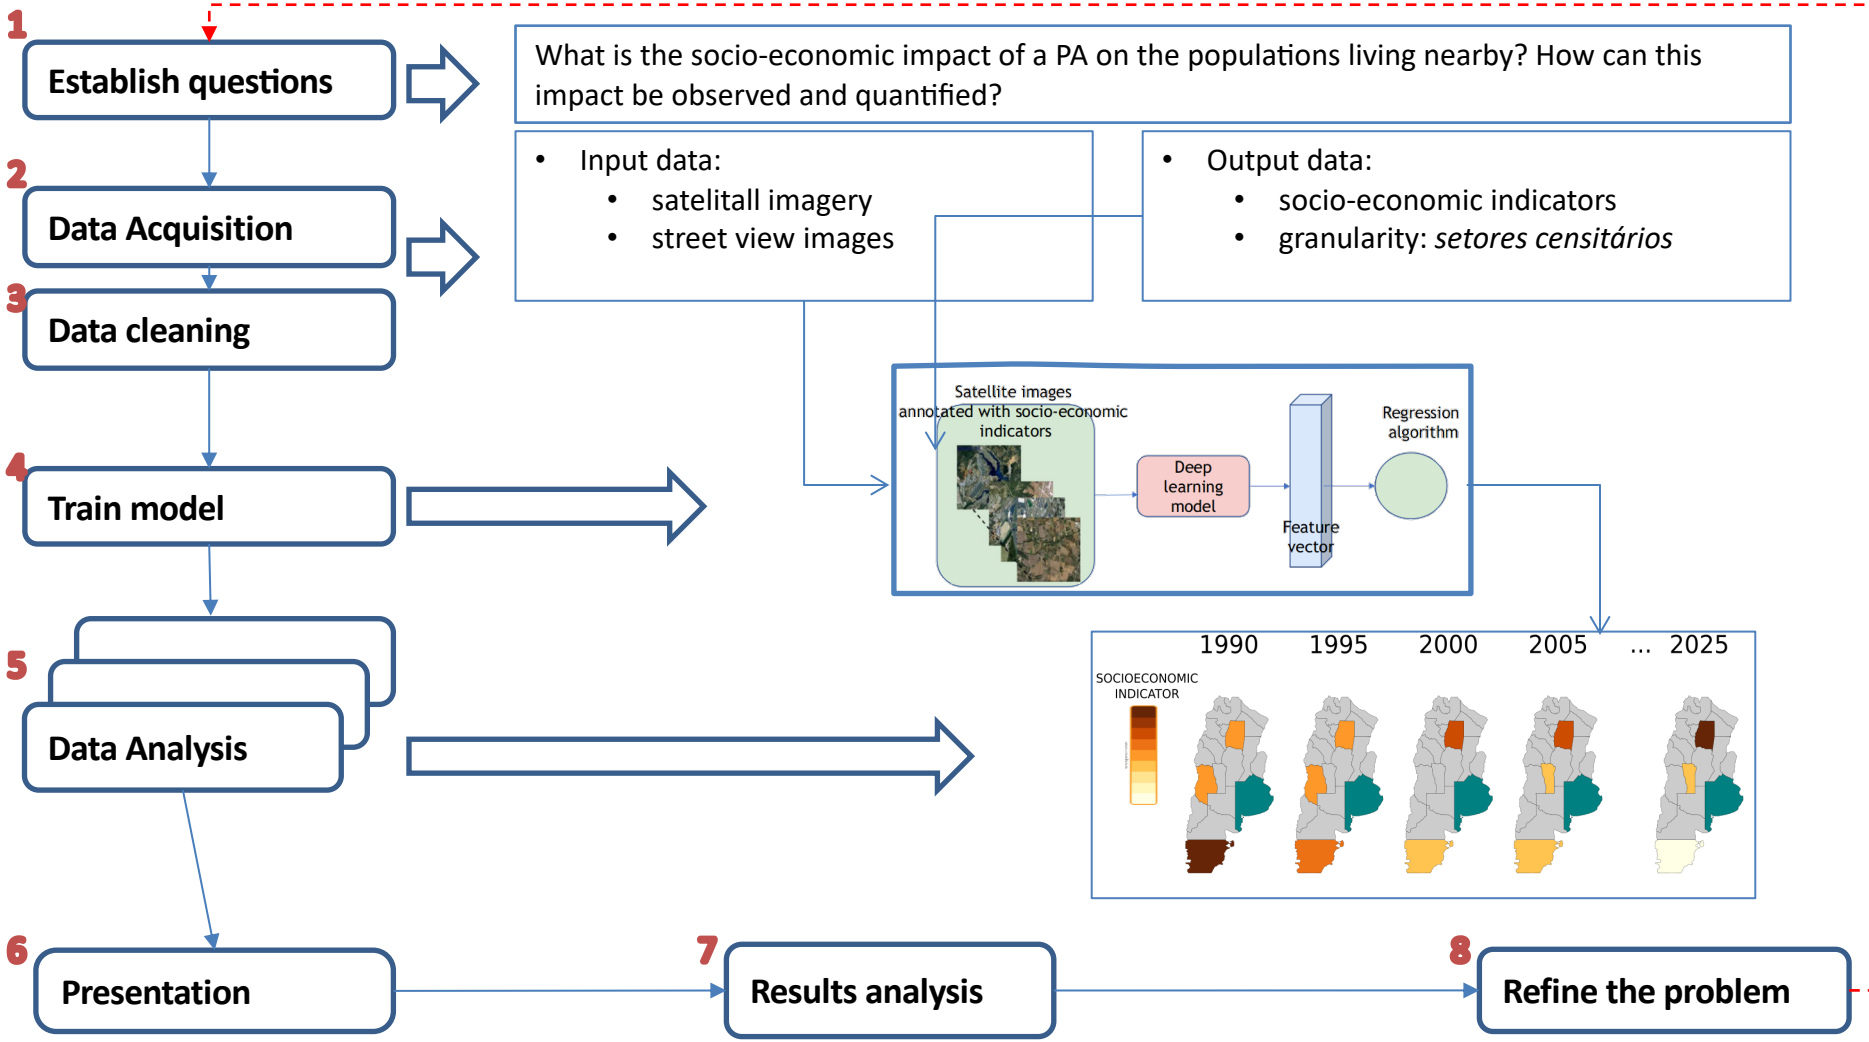
1
Establish questions
What is the socio-economic impact of a PA on the populations living nearby? How can this impact be observed and quantified?
2
Data Acquisition
• Input data:
• satelitall imagery
• street view images
• Output data:
• socio-economic indicators
• granularity: setores censitários
3
Data cleaning
4
Train model
Satellite images annotated with socio-economic indicators
Deep learning model
Feature vector
Regression algorithm
5
Data Analysis
1990
1995
2000
2005
... 2025
SOCIOECONOMIC INDICATOR
6
Presentation
7
Results analysis
8
Refine the problem

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.

Ciência dos Dados e Big Data – organizações e sociedade direcionadas por dados

21 de setembro de 2020

Prof. Dr. Pedro Luiz Pizzigatti Corrêa - pedro.correa@usp.br
Departamento de Engenharia de Computação e Sistemas Digitais
Escola Politécnica da Universidade de São Paulo - EPUSP
Grupo de Pesquisa e Extensão em Big Data da EPUSP **wds.poli.usp.br**