



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**



# Bancos de Dados Geográficos

Dr. Gilberto Ribeiro de Queiroz  
<[gribeiro@dpi.inpe.br](mailto:gribeiro@dpi.inpe.br)>



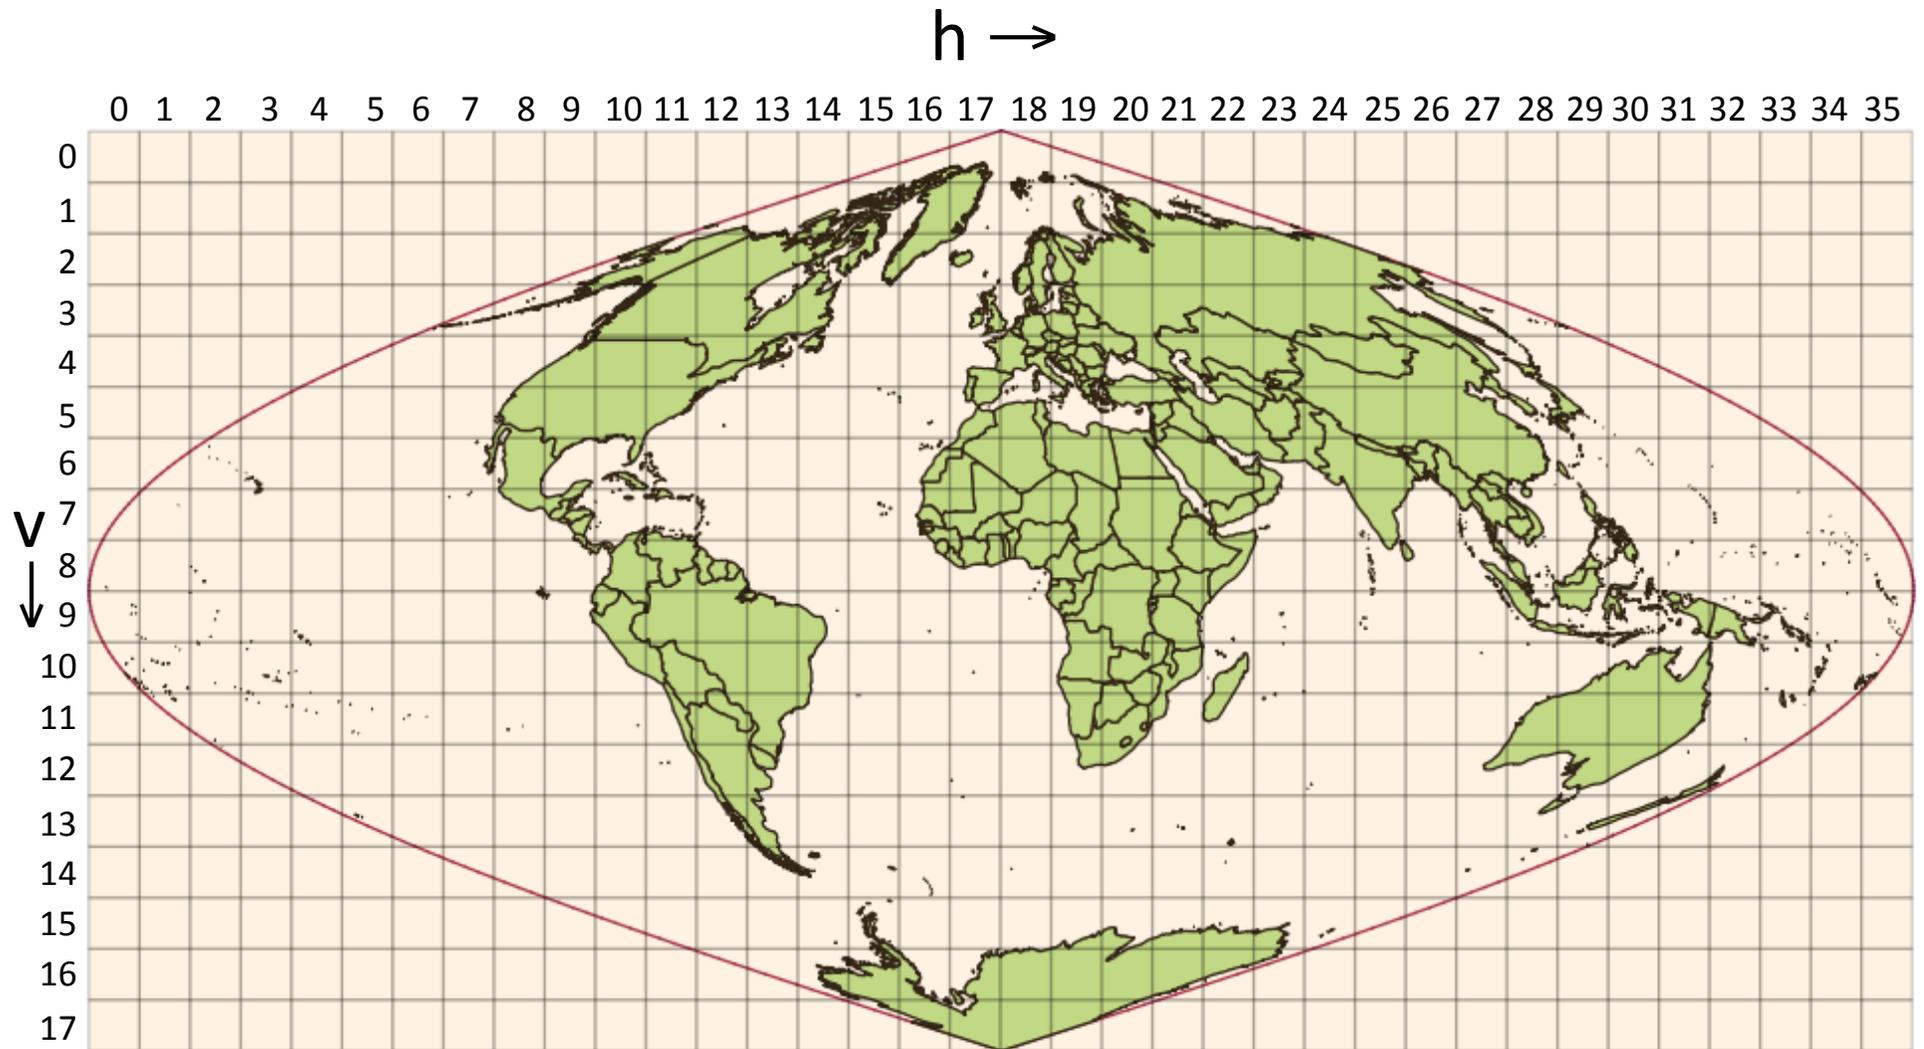
Divisão de Processamento de Imagens



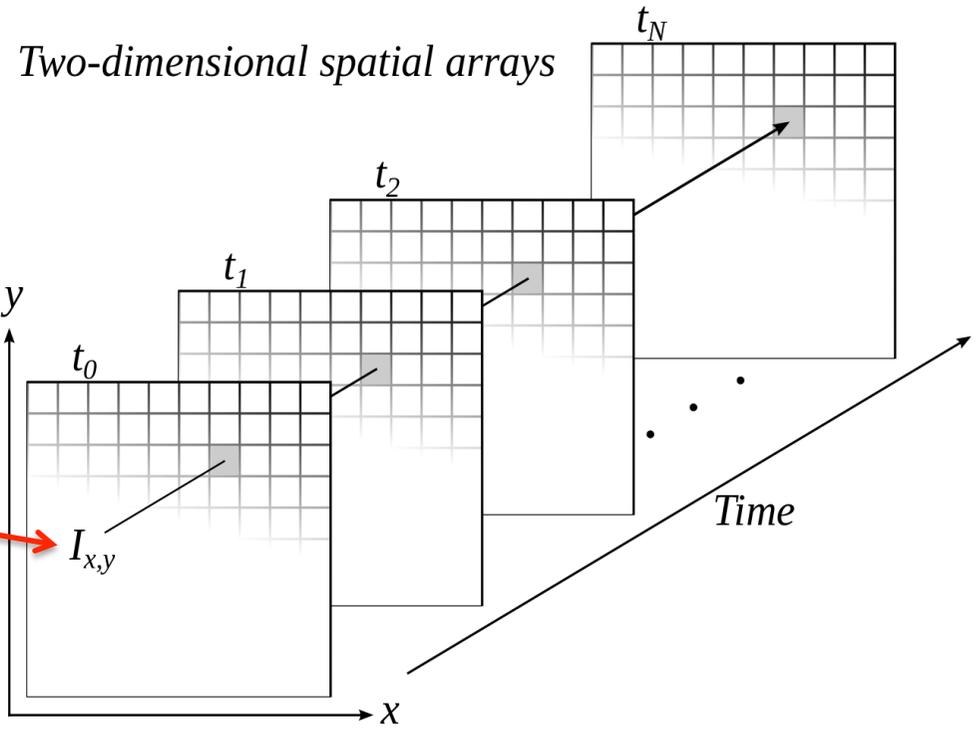
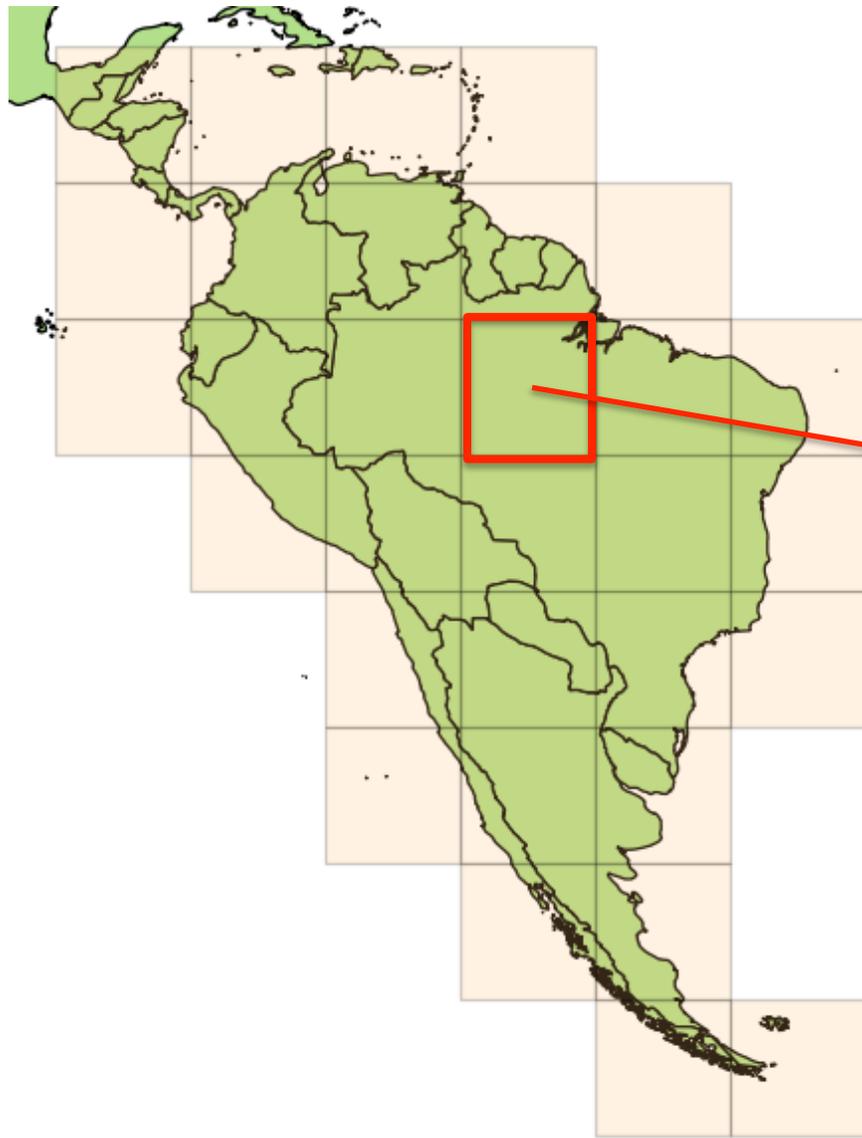
**Discussão:** Existe algum problema com o projeto do suporte Raster dos atuais SGBD-R?

Como lidar com os requisitos de aplicações de EO que podem necessitar como entrada dados massivos?

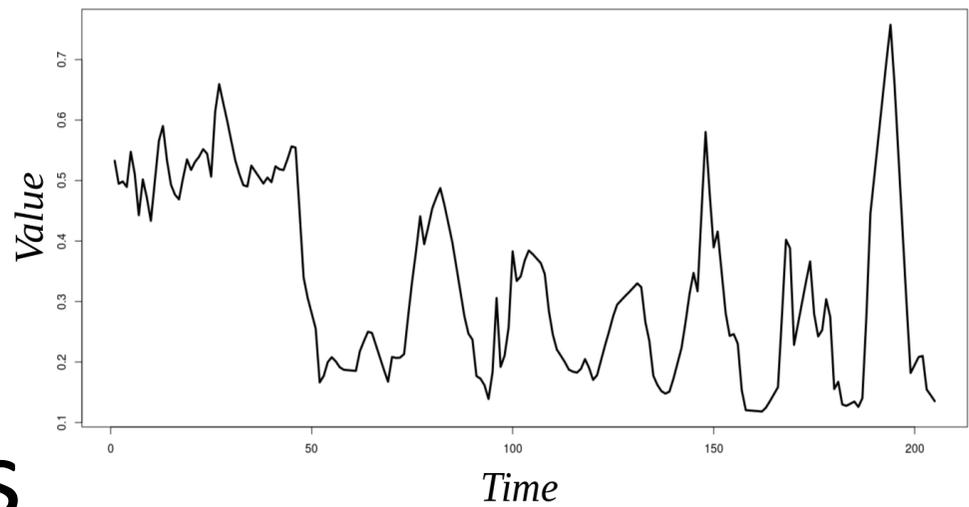
# MODIS: Grade Sinusoidal



Fonte: Adpatado de [http://nsidc.org/data/modis/data\\_summaries/landgrid.html](http://nsidc.org/data/modis/data_summaries/landgrid.html)

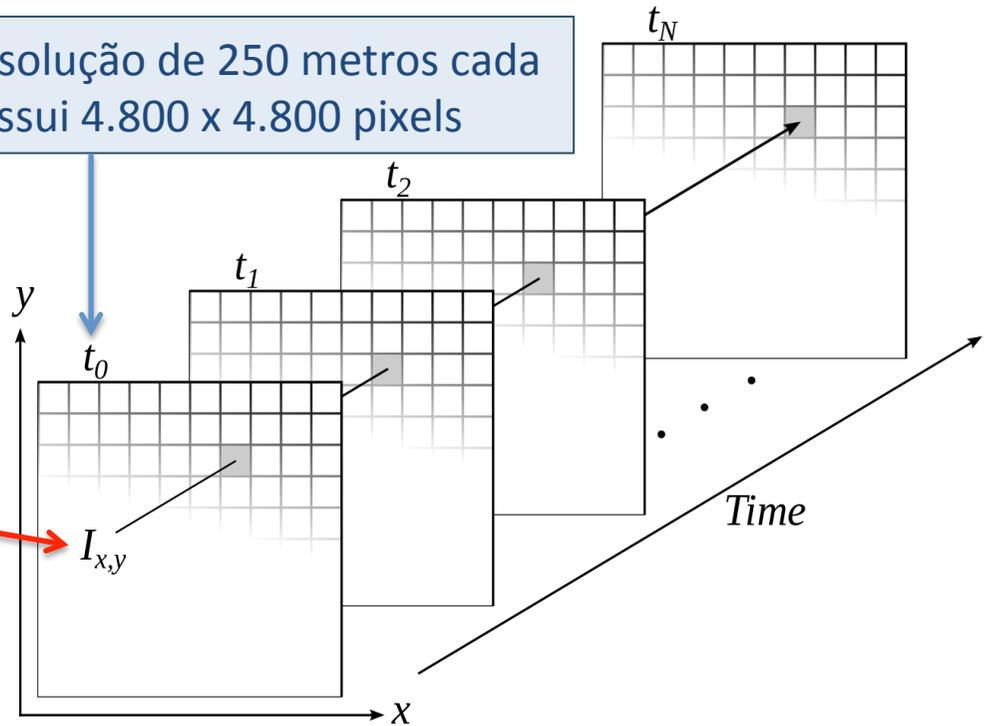
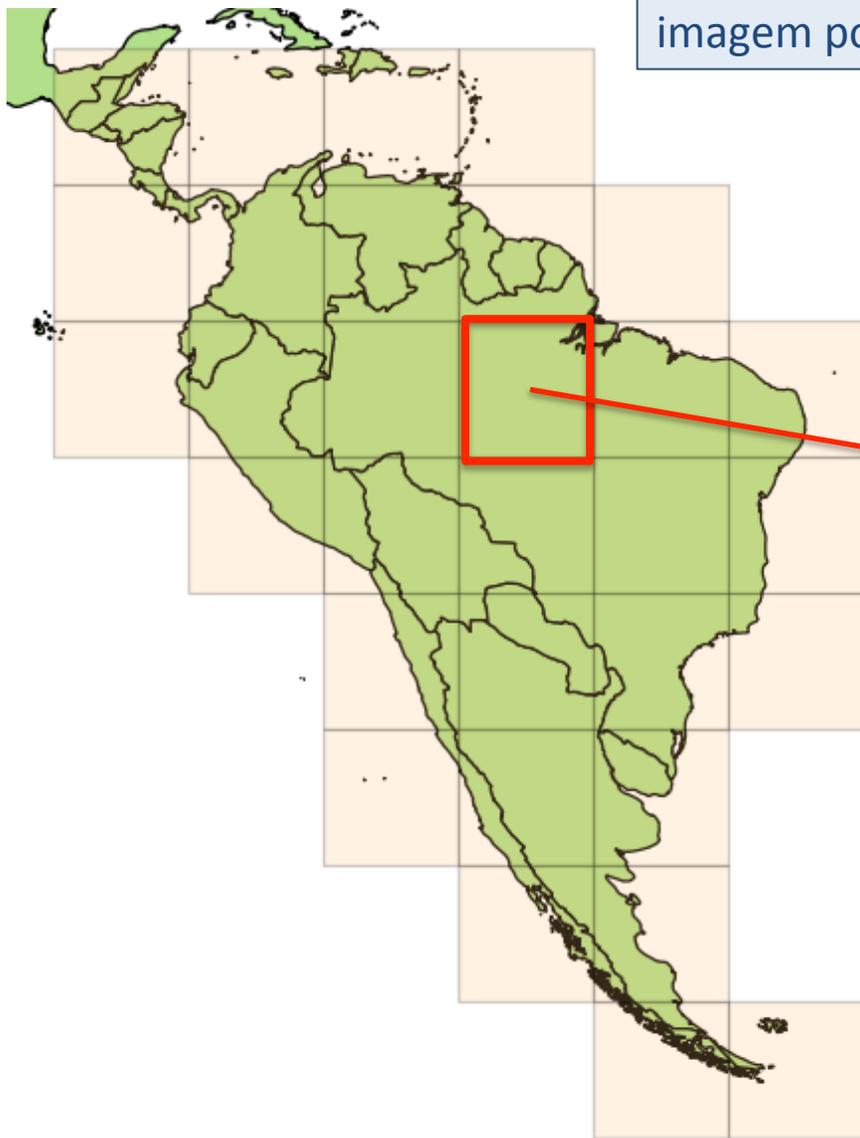


Temporal variation at the point  $x, y$

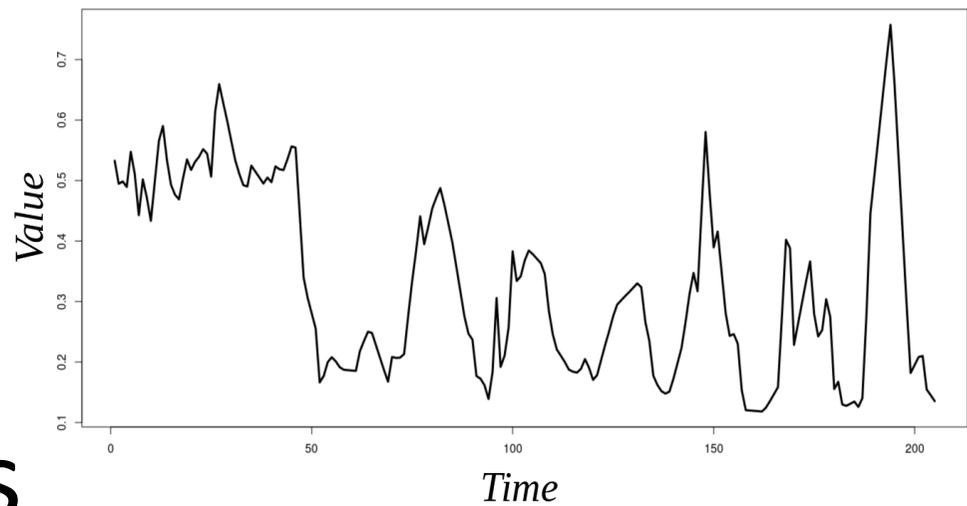


# MODIS Time Series

Obs.: Na resolução de 250 metros cada imagem possui 4.800 x 4.800 pixels



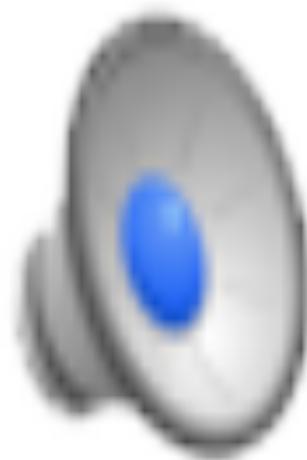
Temporal variation at the point  $x, y$



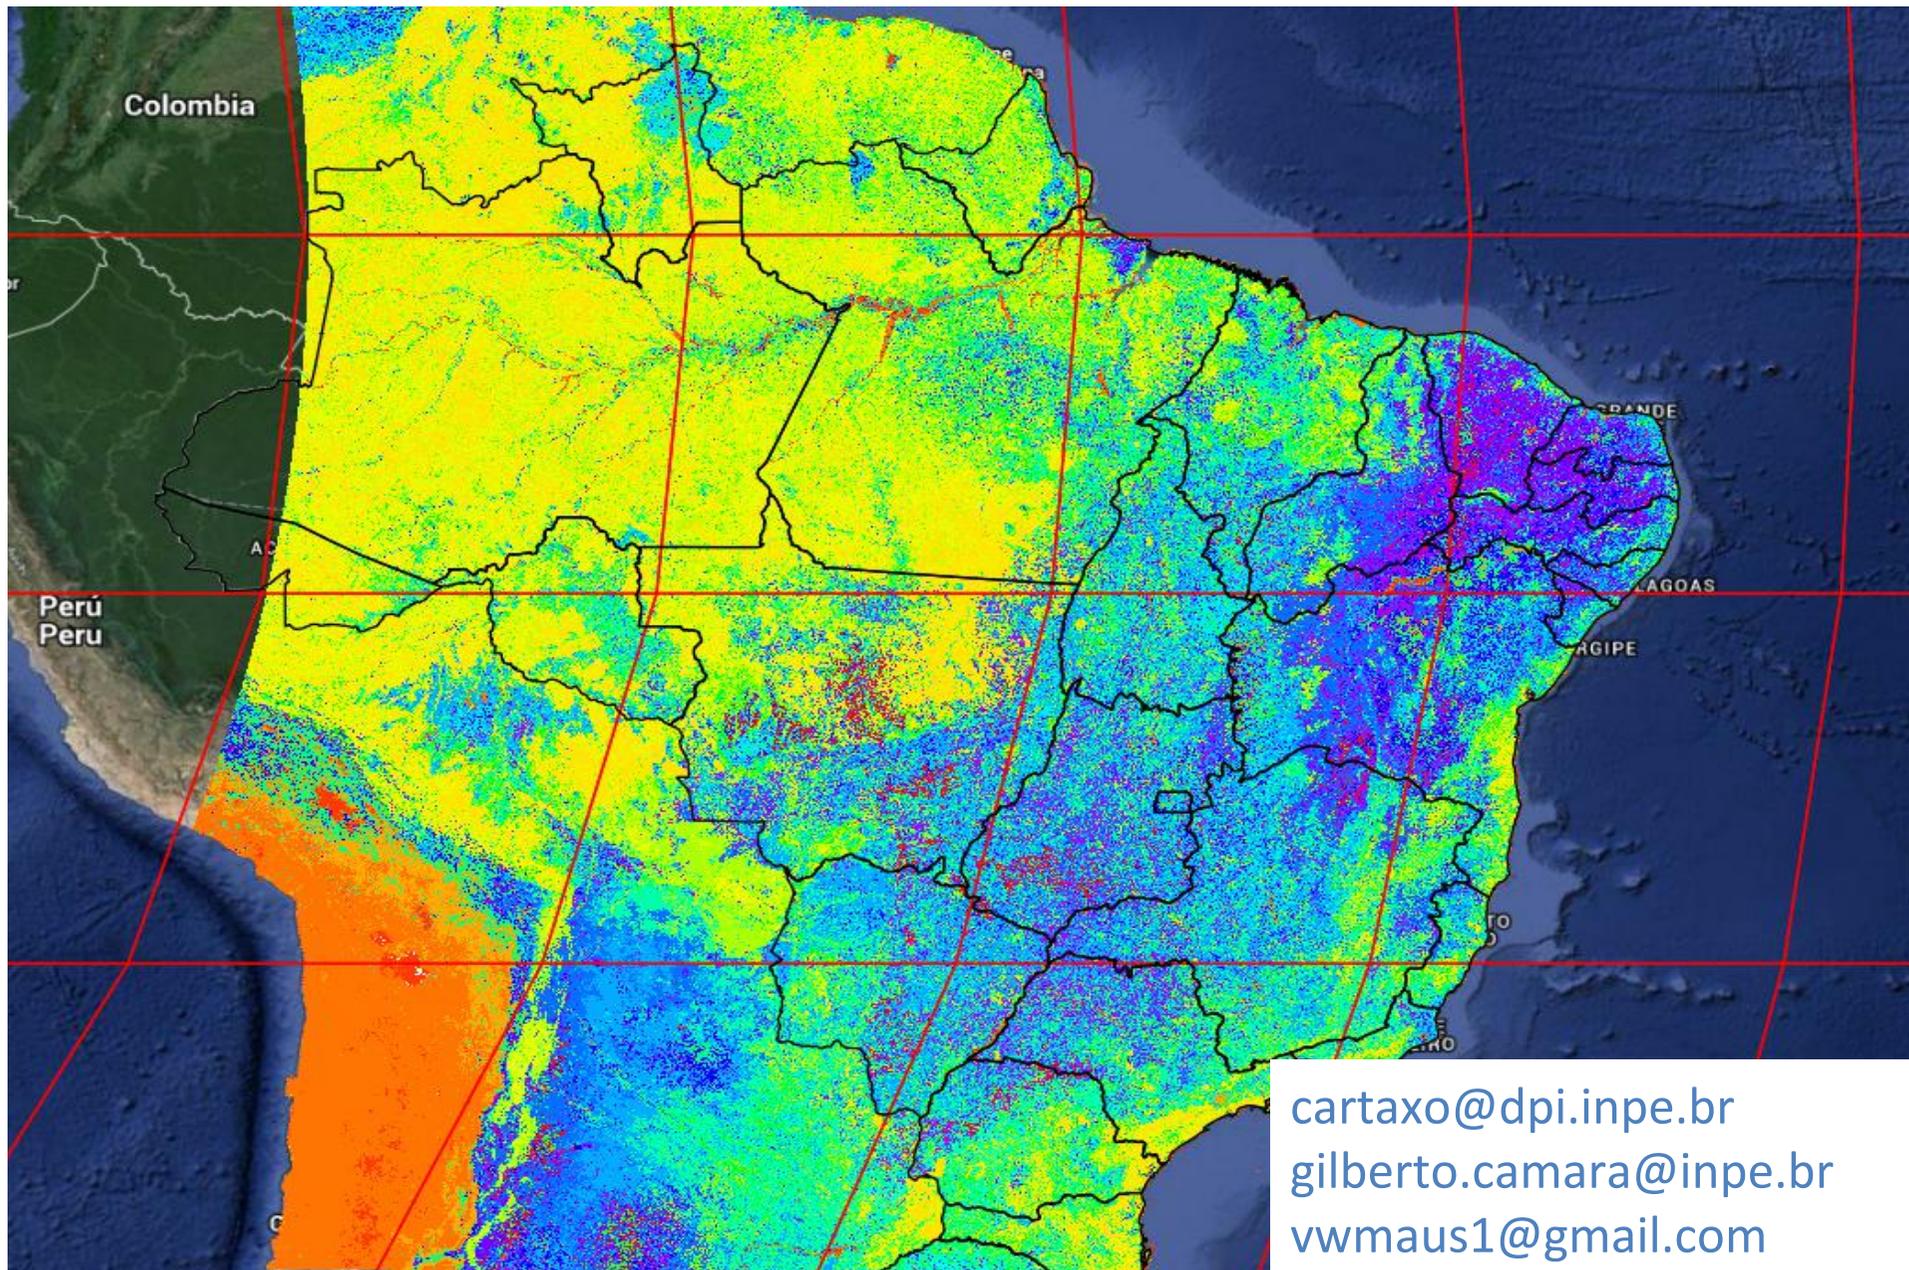
# MODIS Time Series

Quais são os desafios?

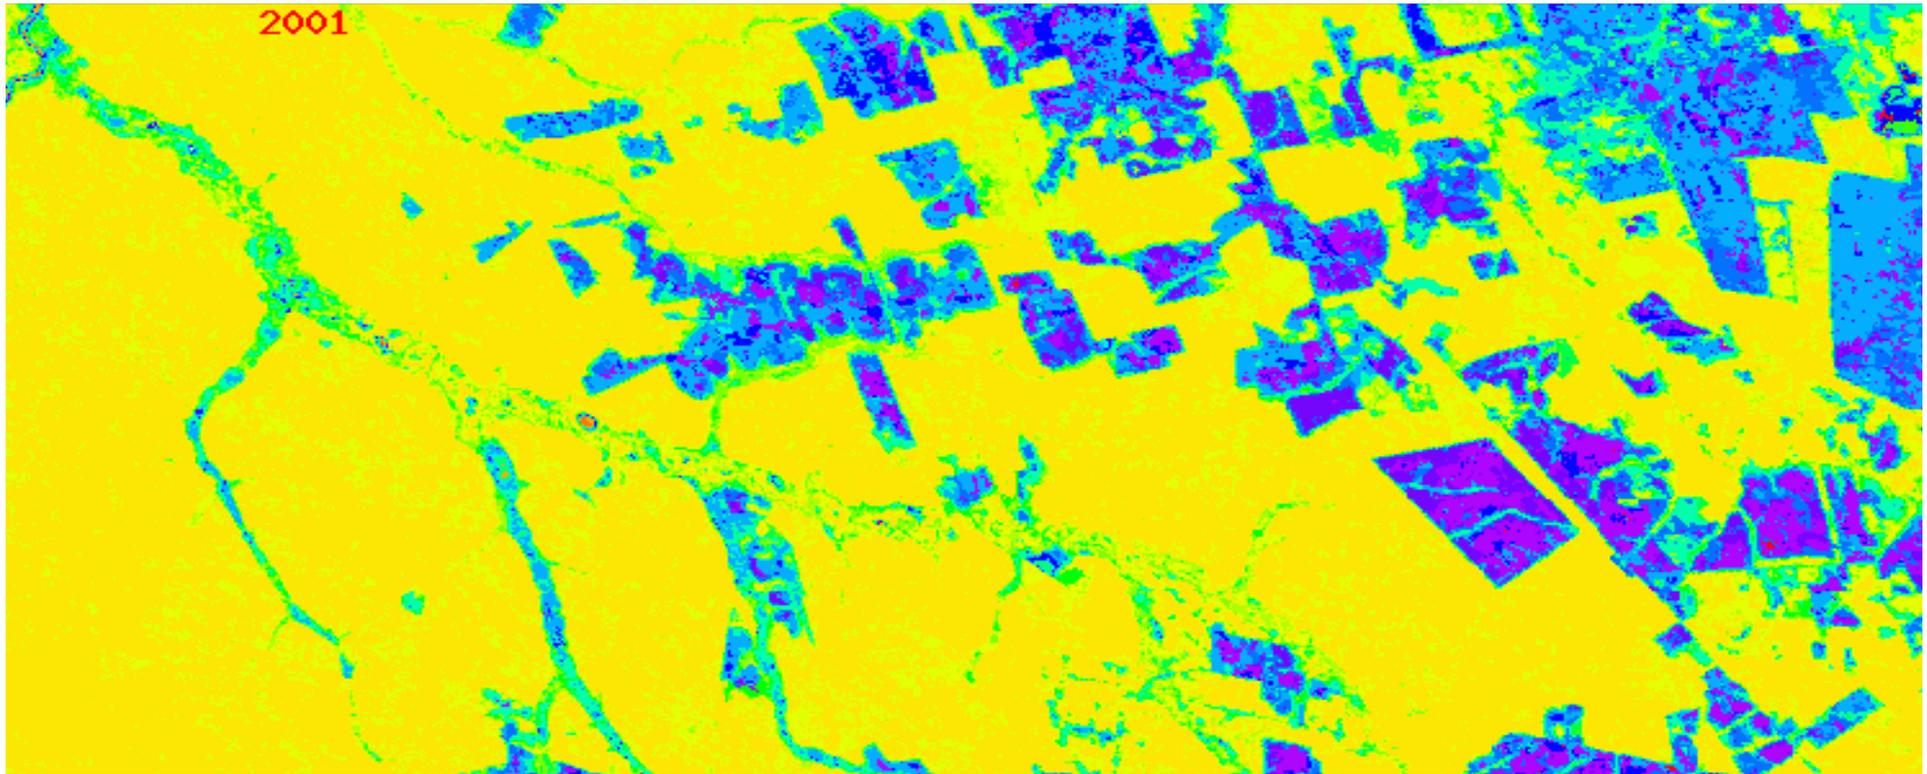
# Exemplo: Mapa de Vegetação Global de Fevereiro de 2000 a Fevereiro de 2014



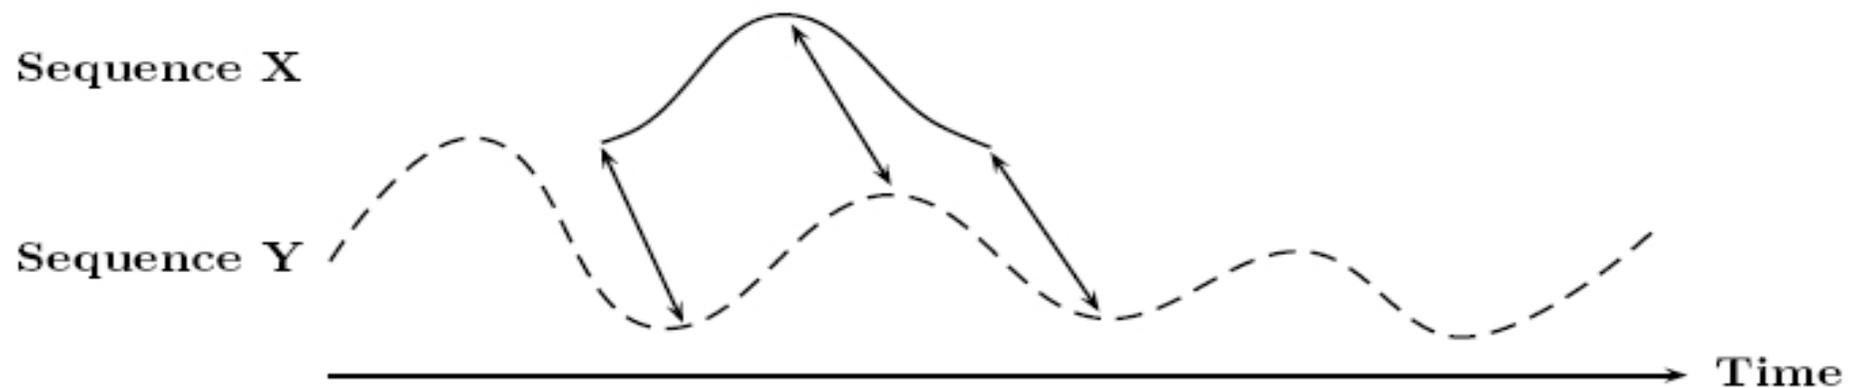
Fonte: [NASA Earth Observatory](#) (23 de Abril , 2014)



# Temporal Land Cover Classification

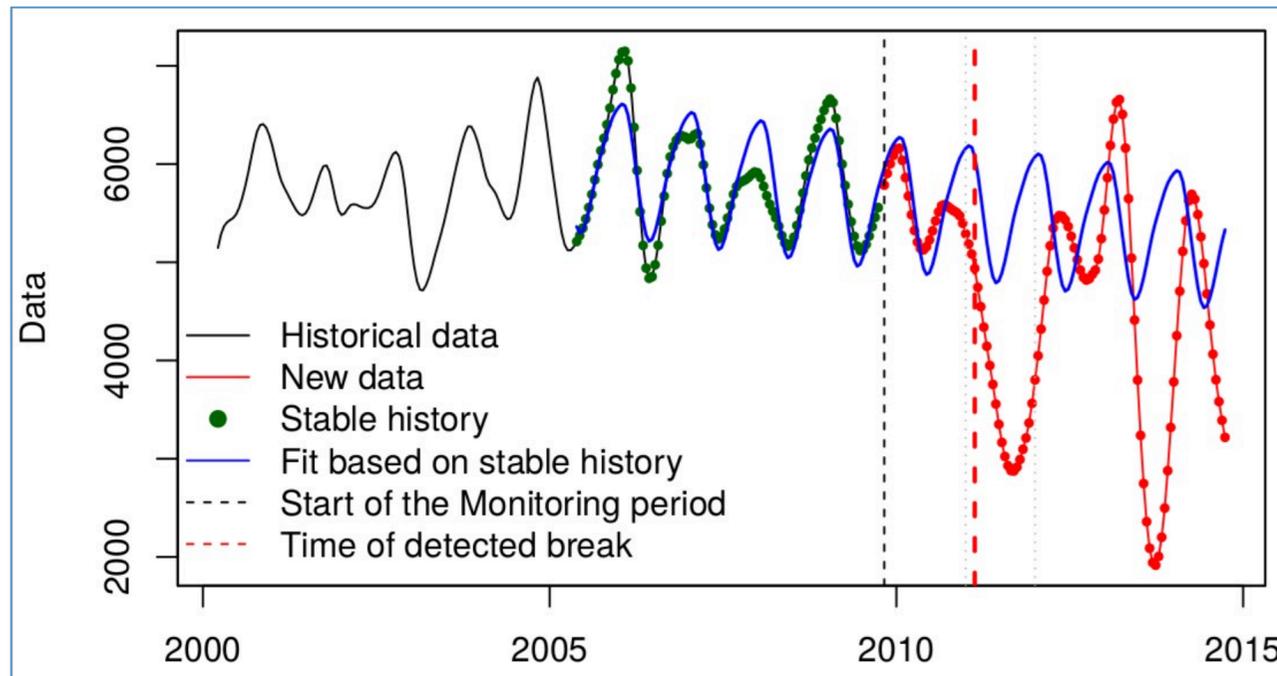


Basic Problem: identify a signature on a time series



Approach: use Dynamic Time Warping (DTW)

# Automated Real-Time Deforestation Monitoring With Satellite Image Time Series



Breaks For  
Additive  
Season and  
Trend (BFAST)

Christopher Stephan  
([c\\_step03@uni-muenster.de](mailto:c_step03@uni-muenster.de))

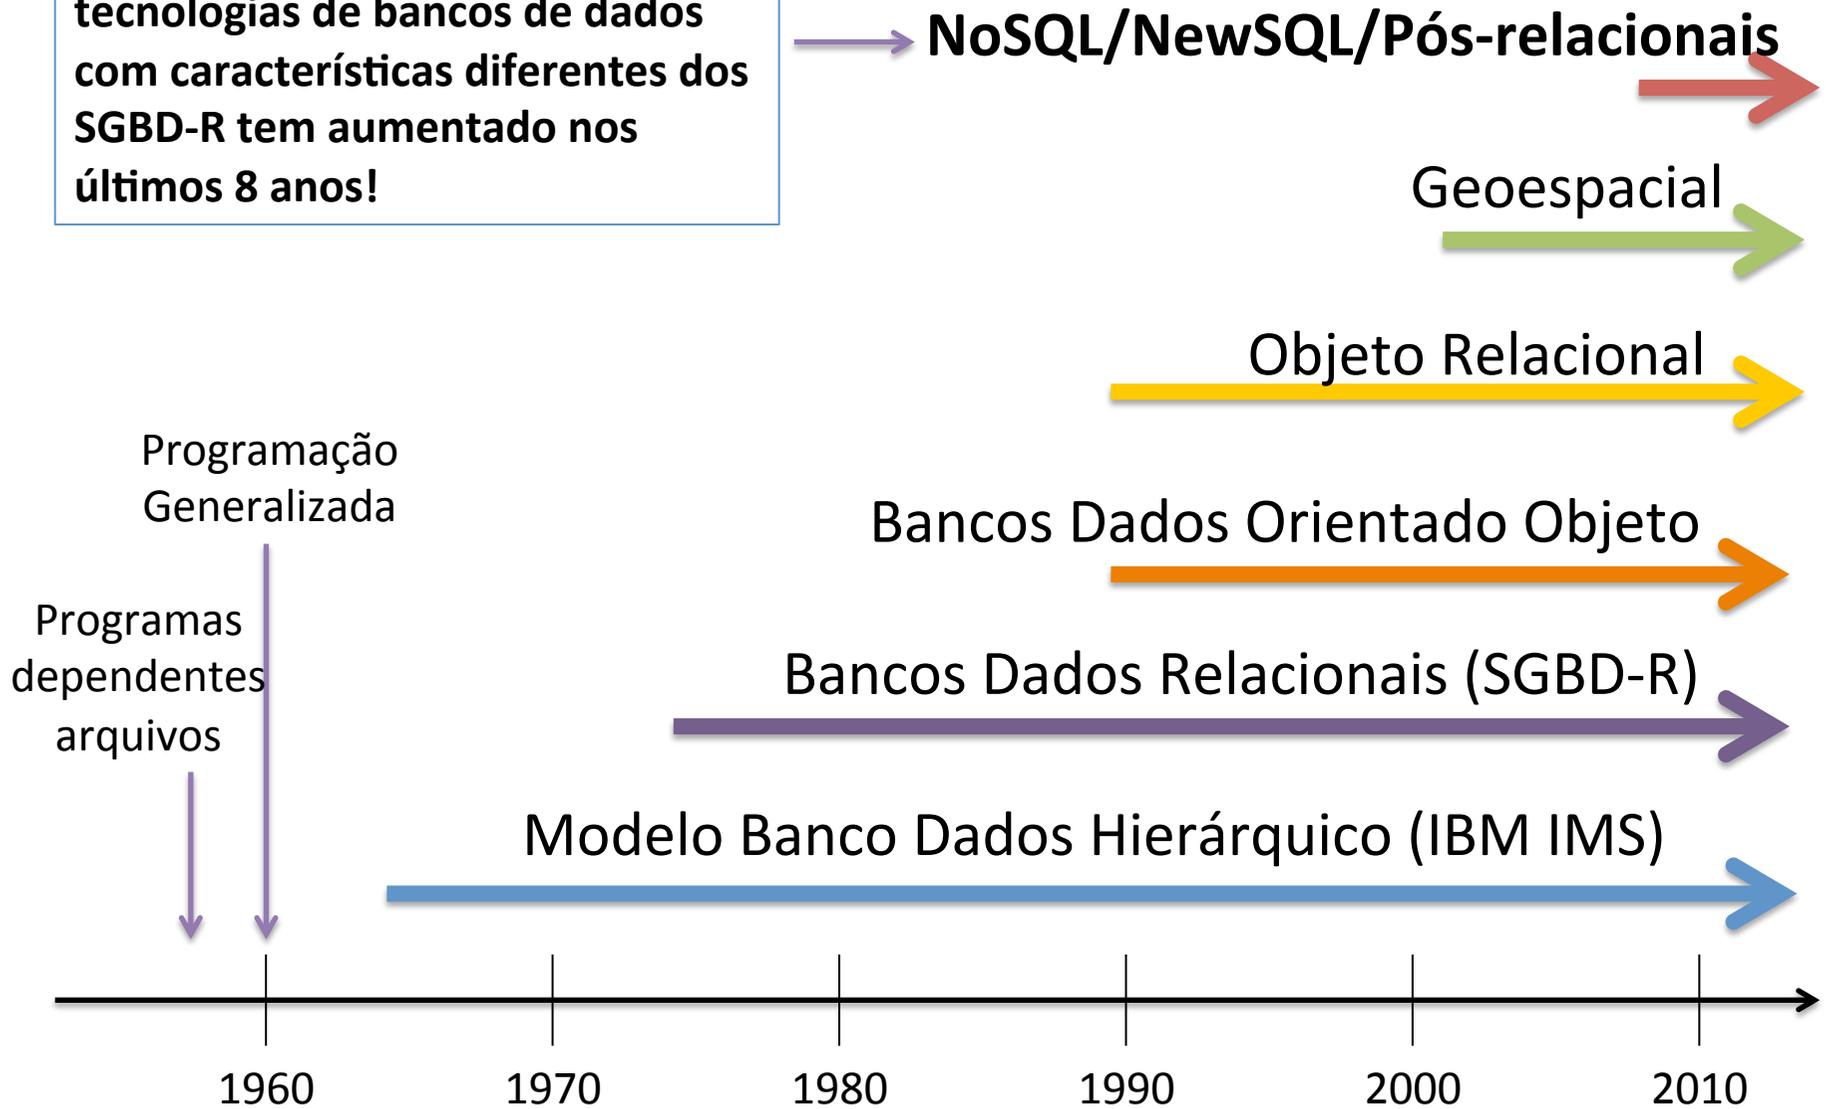
Como fornecer melhor infraestrutura  
computacional para nossos pesquisadores?

# Como lidar com big geospatial data?

Satellites: Landsat, Terra, Aqua, Sentinel  
(Time Series of Remote Sensing Imagery)

# Evolução das Tecnologias de Bancos Dados

Interessante: o número de tecnologias de bancos de dados com características diferentes dos SGBD-R tem aumentado nos últimos 8 anos!



# O “cardápio” de opções aumentou?

- *Sistemas Não-Relacionais* ou *Not Only SQL* ou *Pós-relacionais*:
  - <http://nosql-database.org/>
  - <https://en.wikipedia.org/wiki/NoSQL>
- Diferentes modelos de dados:
  - Document Oriented: MongoDB, CouchDB;
  - Column Stores: Cassandra;
  - Graph Databases: OrientDB, Neo4J;
  - Array Databases: SciDB, Rasdaman.
- Nem todos são baseados no paradigma de transações ACID.
- Escalabilidade: Horizontal x Vertical

# Dados Científicos

Sensoriamento Remoto

Os dados utilizados em diversas áreas da  
Ciência encontram-se na forma de  
**Arrays**

Arrays = Matrizes

## Solução 2: Usando um Array Database

rasdaman

SciDB

## Solução 2: Usando um Array Database

rasdaman

SciDB 

# Novas Tecnologias de Bancos de Dados para Dados Matriciais

## Array Databases

“Arrays as first class citizens”



Source: [Wikipedia](#)

ACM Turing Award (2014)

## SciDB

“SciDB is an open-source analytical database oriented toward the data management needs of scientists.”

(Stonebraker et al., 2011)

# O que é o SciDB?

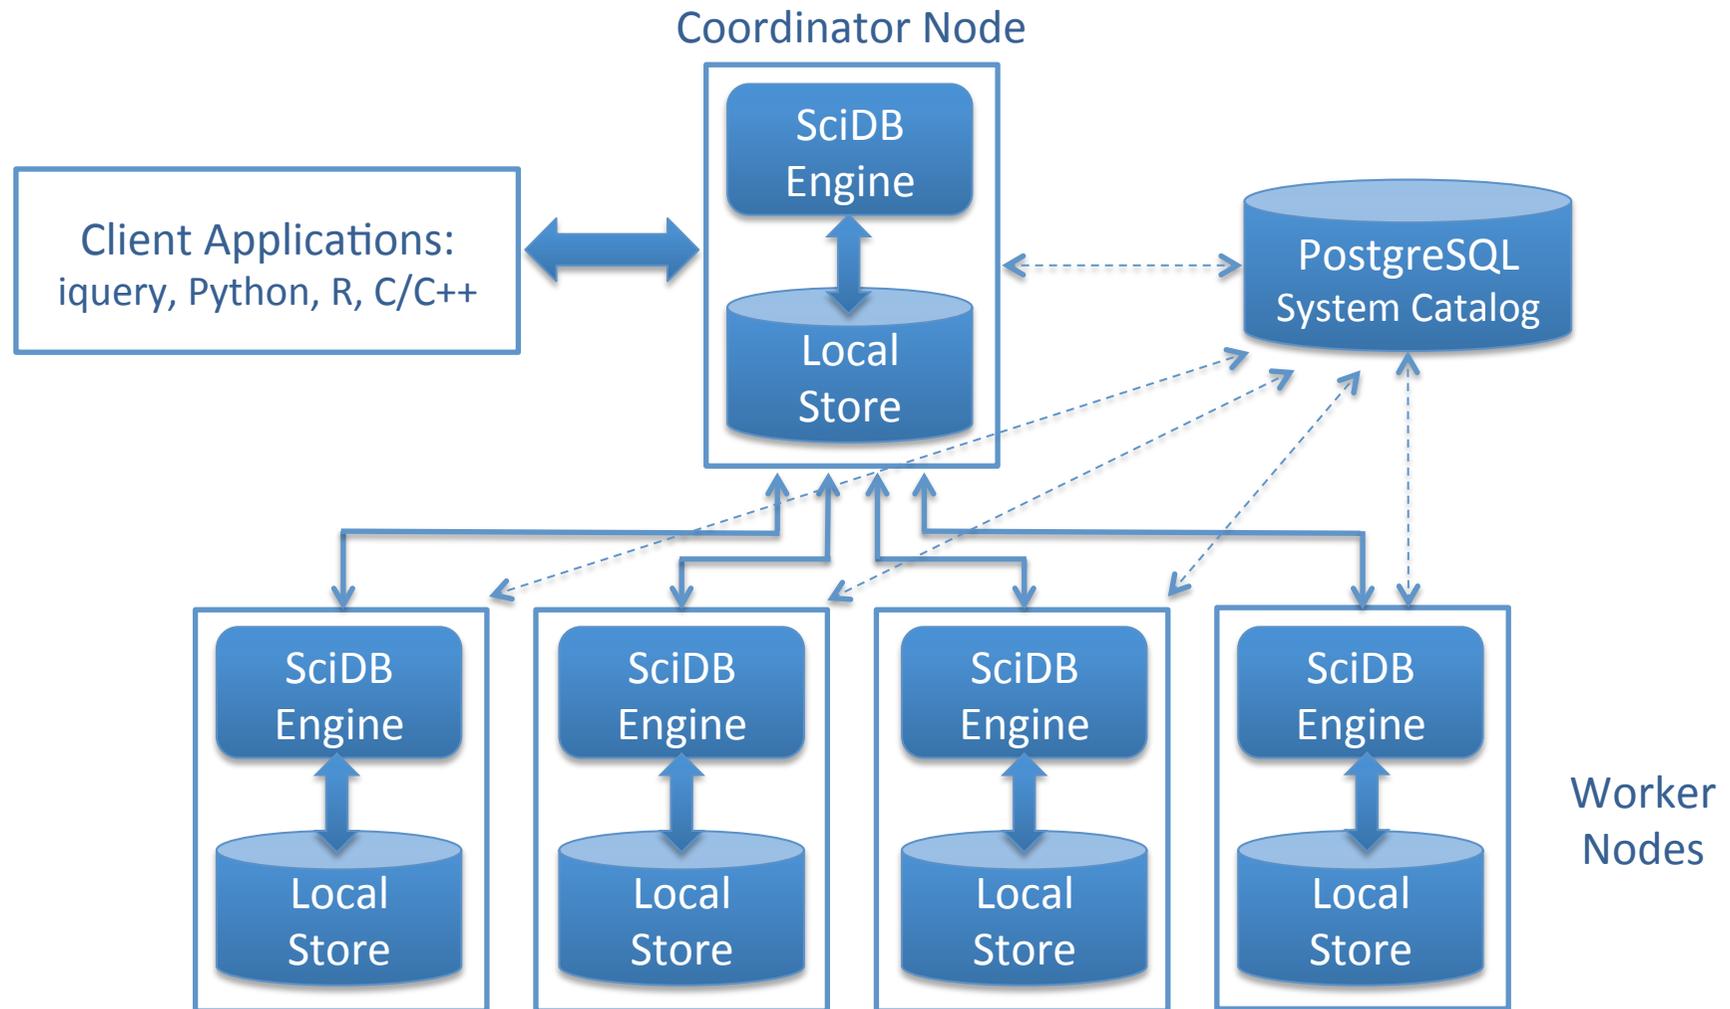
- Mix de plataforma para gerenciamento e análise de dados
- Array Database:
  - O modelo de dados trata de “Arrays” e não de “Tabelas”:
    - Array = Nome + Definição de Atributos das Células + Dimensões
  - Linguagem de consulta é baseada em um álgebra de arrays:
    - AQL and AFL: filter, aggregation, join
- Projetado para trabalho em *clusters*:
  - Opção: arquitetura *shared nothing*

# SciDB

- Site: <http://www.paradigm4.com>
- License: AGPL v3.
- Version: 15.7.
- Currently supported platforms:
  - Linux: Ubuntu 12.04 e 14.04, RHEL 6, CentOS 6.
- Principal desenvolvedor: Paradigm4.
- Código fonte encontra-se disponível como pacotes tar.gz:
  - Community Edition: não há acesso aberto ao repositório de código fonte .
  - Enterprise Edition: acesso SVN/GIT.

Instância

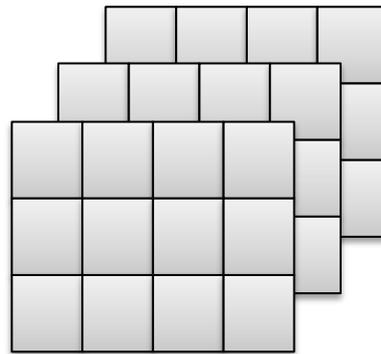
# Arquitetura



Source: Adapted from PARADIGM4

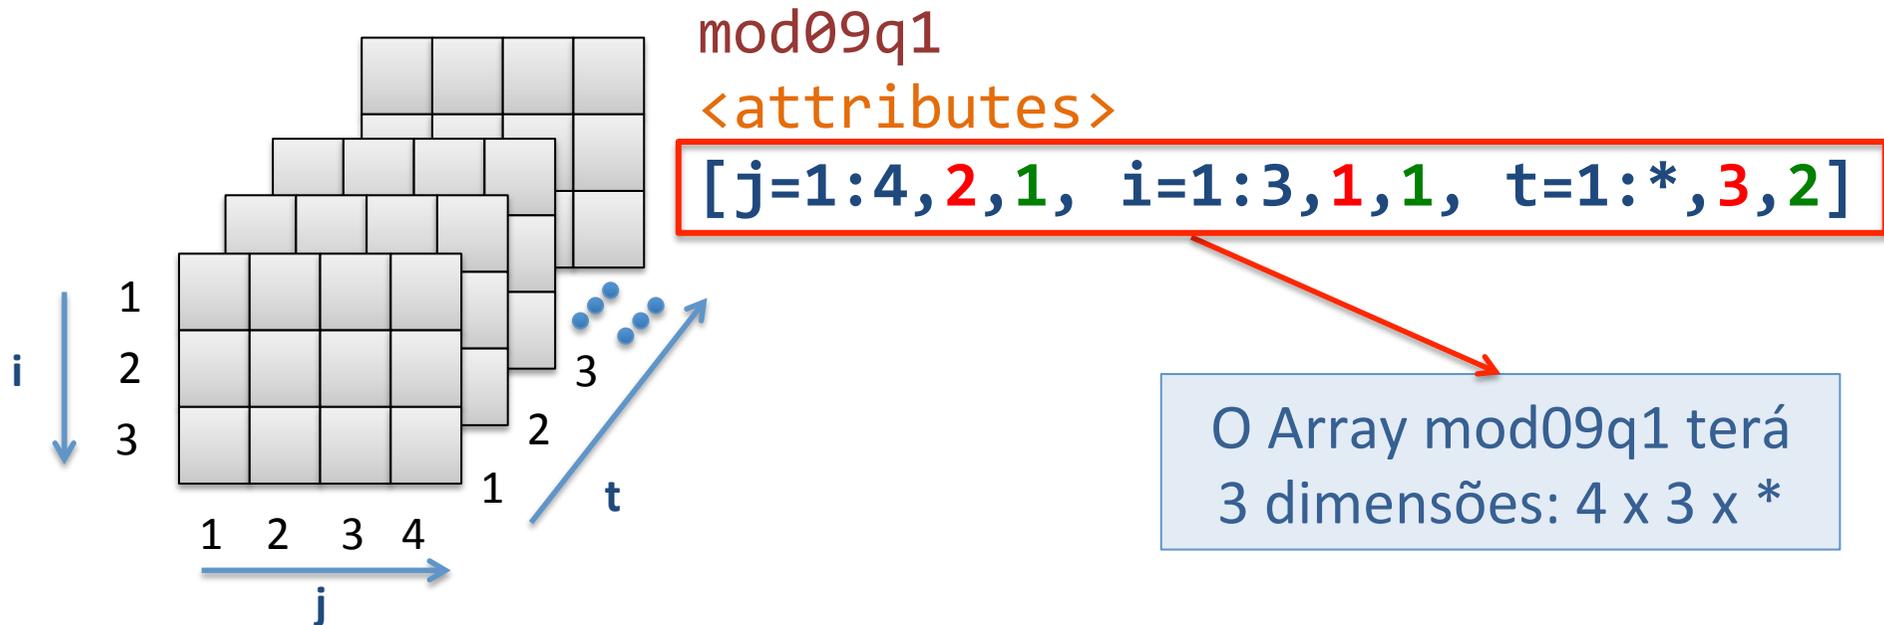
# array

name <attributes> [dimensions]



# Arrays: Dimensões

- Em geral utiliza-se valores inteiros de 64-bit.
- Dimensões com limites bem definidos (*bounded dimension*):
  - Quando sabemos a priori o número total de células em uma dada dimensão (ou a cardinalidade de uma dimensão).
- Dimensões com limites indefinidos (*unbounded dimension*):
  - Quando não sabemos a cardinalidade do array em tempo de criação.



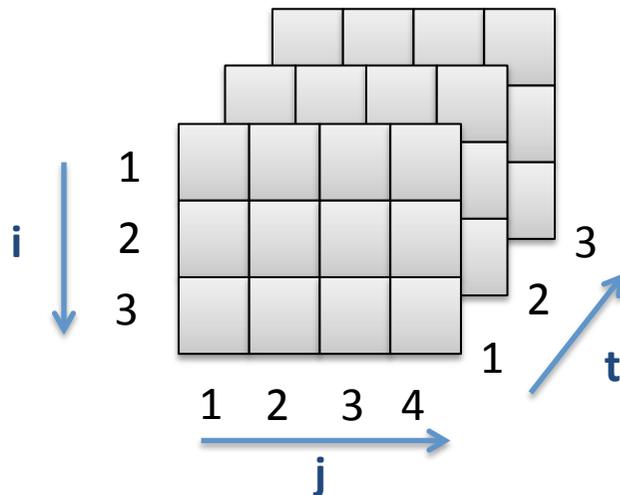
# Arrays: Atributos

- Cada Célula pode estar associada a múltiplos valores (ou atributos), cada um pertencente a um tipo de dados específico:
  - int8, uint8, int16, uint16, int32, uint32, int64, uint64, float, double, string, datetime, datetimetz...
- Cell =  $(d_1, d_2, \dots, d_n)$ .

mod09q1

**<red:int16, nir:int16, quality:uint16>**

[j=1:4, 2, 1, i=1:3, 1, 1, t=1:\*, 3, 2]



Cada célula do array mod09q1 terá 3 atributos

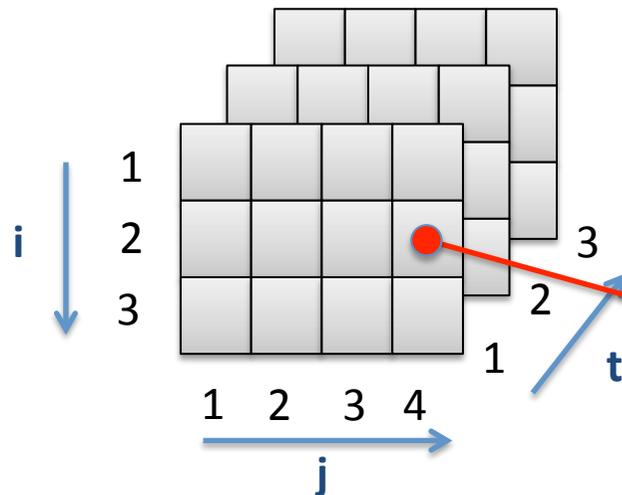
# Arrays: Atributos

- Cada Célula pode estar associada a múltiplos valores (ou atributos), cada um pertencente a um tipo de dados específico:
  - int8, uint8, int16, uint16, int32, uint32, int64, uint64, float, double, string, datetime, datetimetz...
- Cell =  $(d_1, d_2, \dots, d_n)$ .

mod09q1

**<red:int16, nir:int16, quality:uint16>**

[j=1:4, 2, 1, i=1:3, 1, 1, t=1:\*, 3, 2]



Cada célula do array mod09q1 terá 3 atributos

Ex: a célula(4, 2, 1) pode estar associada aos valores:  
red = 474; nir = 3109; quality = 4096

# Linguagens de Consulta

**Array Query Language (AQL)**  
**Array Functional Language (AFL)**

# Array Query Language: AQL

**SELECT** expression  
[**INTO** target\_array]  
**FROM** array\_expression | source\_array  
[**WHERE** expression]

individual attributes and dimensions,  
as well as constants and expressions

new or pre-existing

Array or any expression that returns  
an array (like sub-queries)

filter parameters on attribute values  
or dimension bounds

There are DML and DDL clauses

# Array Functional Language (AFL)

```
store(build(<num:double>[x=0:8,1,0, y=0:9,1,0],  
         random()),  
       random_numbers);
```

# Particionamento de Dados

Chunks

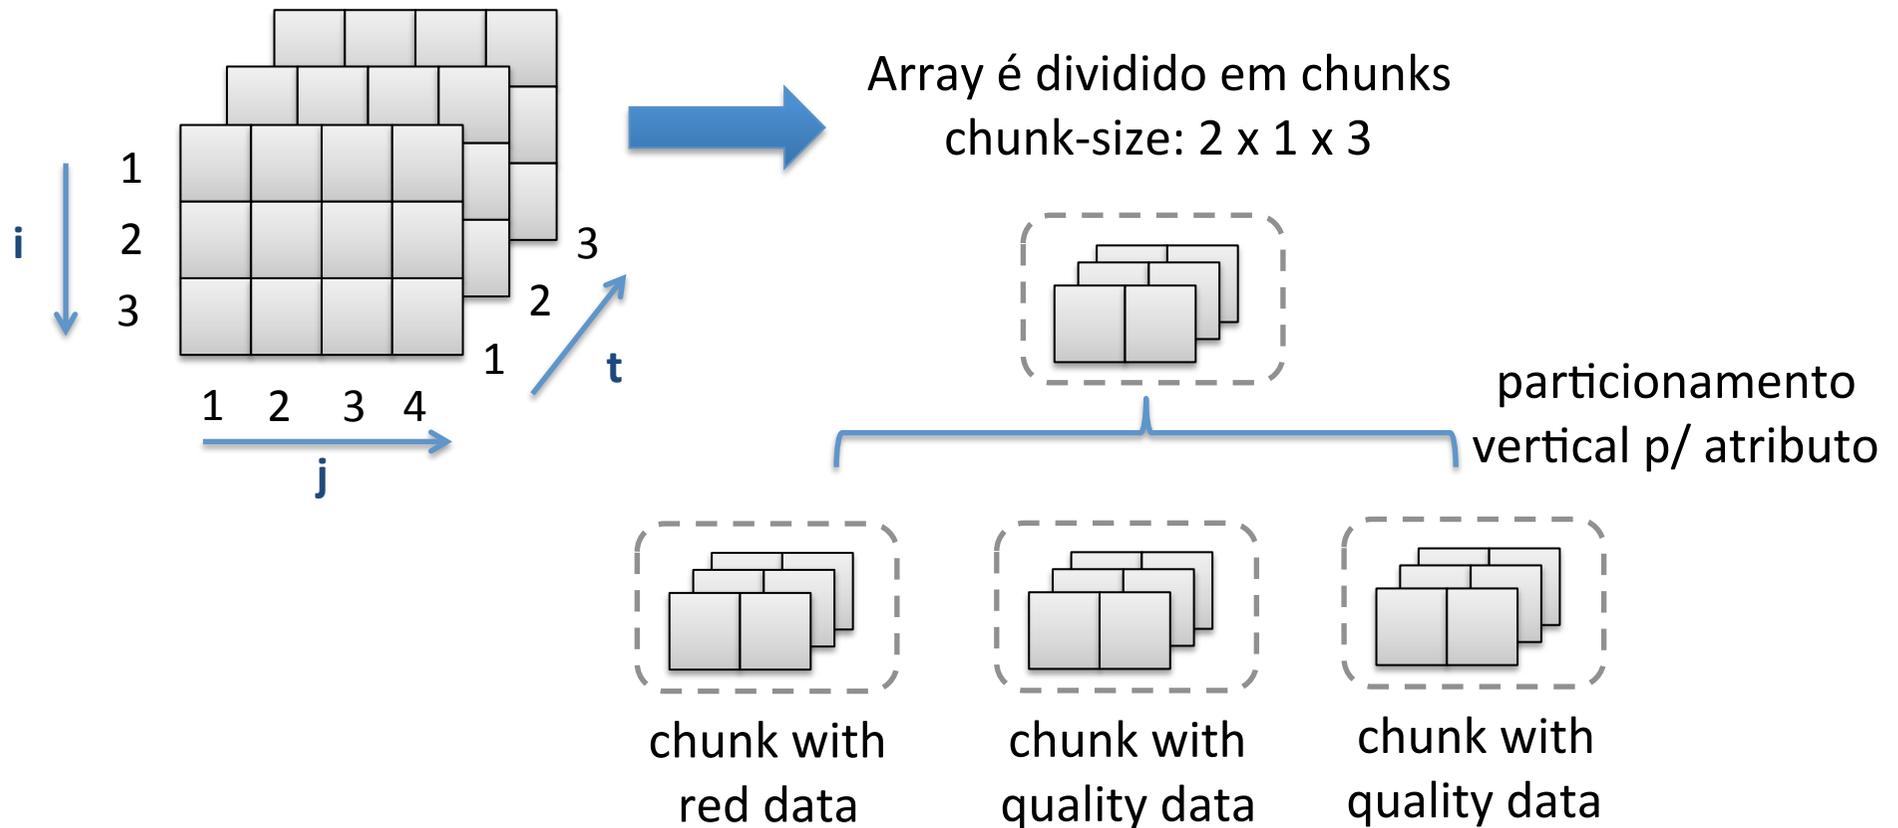
Vertical Partitioning

# Arrays: Particionamento

mod09q1

<red:int16, nir:int16, quality:uint16>

[j=1:4, 2, 1, i=1:3, 1, 1, t=1:\*, 3, 2]

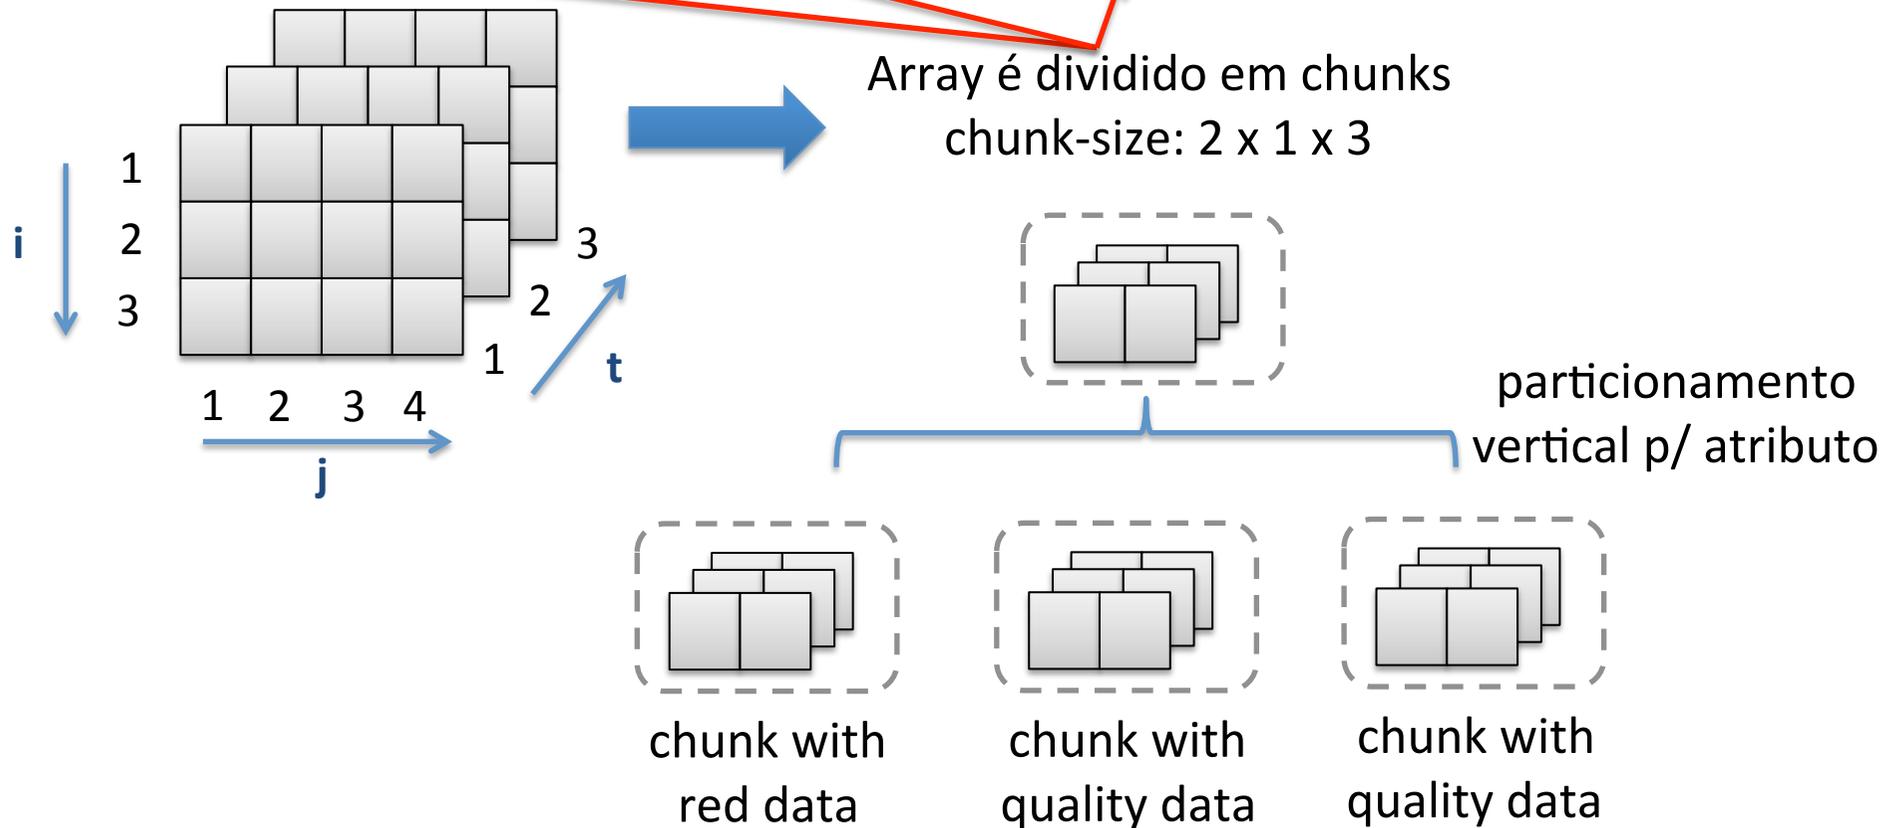


# Arrays: Particionamento

mod09q1

<red:int16, nir:int16, quality:uint16>

[j=1:4, 2, 1, i=1:3, 1, 1, t=1:\*, 3, 2]



# Arrays: Particionamento

- Não existe uma B<sup>+</sup>-tree ou R-tree:
  - As dimensões formam a base da indexação dos dados
- O dado é “quebrado” em *chunks* e mapeados através de uma função *hash* para cada instância do cluster.
- Uma questão importante trata-se de como especificar o número de células ao longo de cada dimensão que será usado para estabelecer o tamanho do *chunk*.

# Replicação

Overlap de Células

Replicação de Chunks entre as Instâncias do *Cluster*

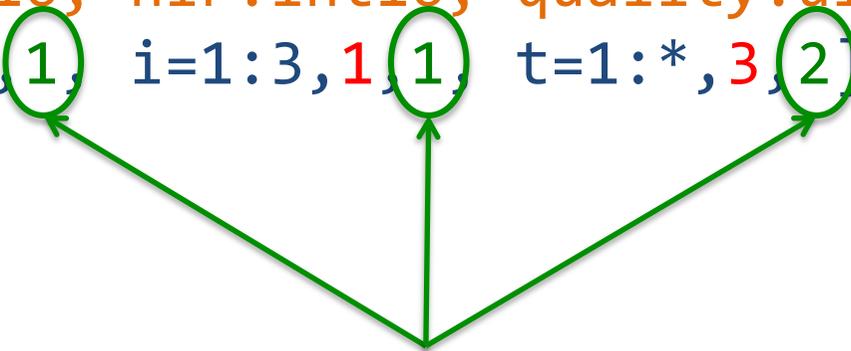
# Arrays: Replicação Células de Borda

- É possível definir um fator chamado de *overlap* para as células de borda de um *chunk*:
  - Trata-se de uma boa estratégia para acelerar consultas envolvendo vizinhança (*neighborhood*).

mod09q1

<red:int16, nir:int16, quality:uint16>

[j=1:4, 2, 1, i=1:3, 1, 1, t=1:\*, 3, 2]



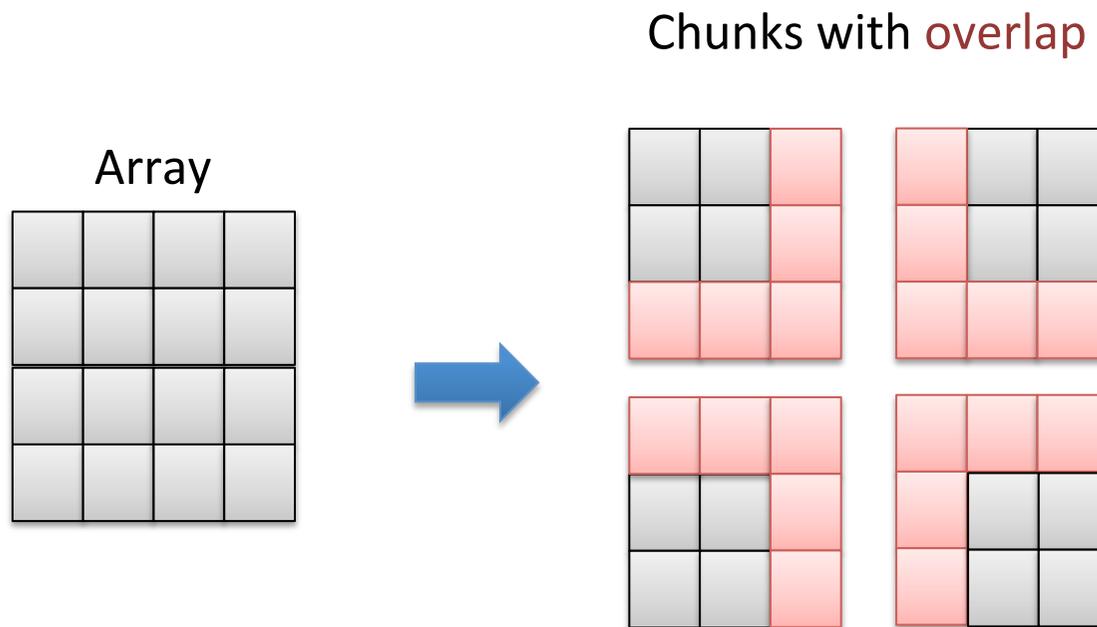
Cada *chunk* conterá uma célula de borda nas dimensões  $j$  e  $i$

Na dimensão  $t$  serão duas células de borda

Essas células são utilizadas apenas pelo SciDB durante as consultas

# Arrays: Replicação Células de Borda

- Ilustração da replicação das células de borda:



# Arrays: Replicação de Chunks entre as Instâncias

Tolerância a falhas

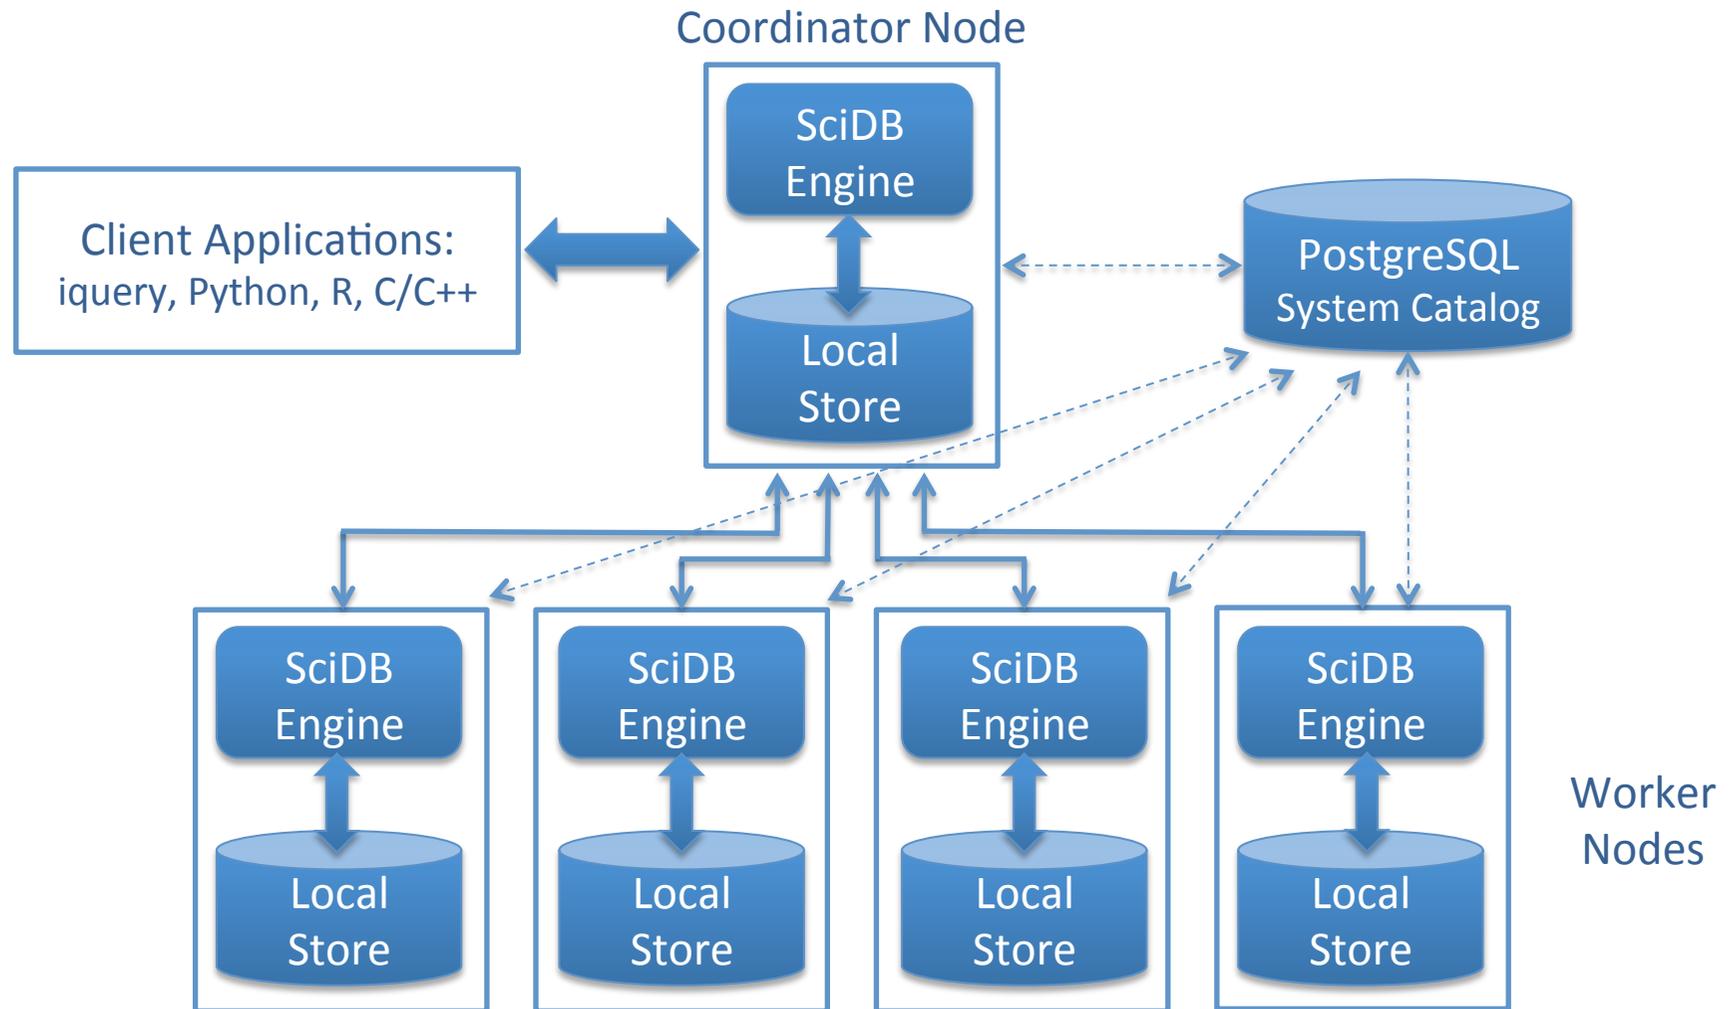
# Outras Características/Funcionalidades

- Can use RLE for data compression.
- Cache for frequently used chunks.
- Versioning:
  - The storage model is based on the idea of a “no overwrite”.
  - Update queries write a new full chunk or a delta chunk.
- Storage segments:
  - Reserved contiguous space on disk for a collection of chunks belonging to the same array.
- Provision for temporary storage during query execution.
- Single statement (ACID) transactions:
  - Array-level locking.
- Robust handling of empty cells, including NULL and code for missing data

# Integração com Diversos Ambiente

- REST API:
  - Shim
- Linguagens de Programação:
  - C++ e Python
  - Novidade: Julia
- Ambientes estatísticos:
  - R
- Álgebra linear:
  - [ScaLAPACK](#) — Scalable Linear Algebra PACKage

# Arquitetura



Source: Adapted from PARADIGM4

# Referências

# Livros

- John R. Jensen. ***Remote Sensing of the Environment***.
- ELMASRI, R.; NAVATHE, S. B. ***Fundamentals of database systems***. Addison Wesley, 2006. 1139p.
- DATE, C. J. ***An introduction to database systems***. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1991.

# Artigos

- STONEBRAKER, M.; BROWN, P.; POLIAKOV, A.; RAMAN, S. ***The architecture of SciDB***. In Proceedings of the 23rd international conference on Scientific and statistical database management (SSDBM'11), Judith Bayard Cushing, James French, and Shawn Bowers (Eds.). Springer-Verlag, Berlin, Heidelberg, 2011, 1-16.
- TAFT, R.; VARTAK, M.; SATISH, N. R.; SUNDARAM, N.; MADDEN, S.; STONEBRAKER, M. ***Genbase: a complex analytics genomics benchmark***. Computer Science and Artificial Intelligence Laboratory Technical Report, MIT-CSAIL-TR-2013-028, November 19, 2013.

# Artigos

- E. F. Codd. 1970. ***A relational model of data for large shared data banks***. *Communications of the ACM*, v. 13, n. 6, June 1970, pp. 377-387.
- Chen, P. ***The Entity-Relationship Model-Toward a Unified View of Data***. *ACM Transactions on Database Systems*, vl. 1, n. 1. March 1976, pp. 9-36.
- GRAY, J. ***Evolution of Data Management***. *IEEE Computer* 29(10): 38-46, 1996.
- Vijlbrief, T., and P. van Oosterom. ***The GEO++ System: An Extensible GIS***. *Proc. 5th Intl. Symposium on Spatial Data Handling*, Charleston, South Carolina, 1992, 40-50.

# Especificações e Padrões

- OGC. ***OpenGIS Implementation Specification for Geographic information - Simple feature access - Part 1: Common architecture***. Available at: <http://www.opengeospatial.org>. Access: October, 2012.
- OGC. ***OpenGIS Implementation Specification for Geographic information - Simple feature access - Part 2: SQL option***. Available at: <http://www.opengeospatial.org>. Access: October, 2012.
- ISO. ***SQL Multimedia and Application Packages – Part 3: Spatial***.

# Slides

- NAUGHTON, J. F. ***DBMS Research: First 50 Years, Next 50 Years***. Kynote speaker' slides at ICDE 2010. Disponível em: <http://pages.cs.wisc.edu/~naughton/naughtonicde.pptx>. Acesso: Abril de 2013.

# Videos

- [THAKAR, A](#) (Johns Hopkins University). **Billions of Stars on Off-the-shelf Software / The SDSS SkyServer and Beyond: Why "The Not-So-Little-Engine that Could" is Still Chugging Along.** 7<sup>th</sup> Extremely Large Databases Conference, September 9-12, 2013, Stanford University, California, USA. [Video](#), [Slides](#), Access: 04<sup>th</sup> April, 2014.

# Cursos

- FONSECA, L. M. G.; KÖRTING, T. S. **PDI: Fundamentos**. Notas de Aula SER 437 - Processamento Digital de Imagens de Sensores Remotos. Disponível em: <http://www.dpi.inpe.br/cursos/ser437>. Acesso: 02 de Maio de 2014.

# Manuais

- SciDB Reference Manual: Community and Enterprise Editions  
Document Version 14.12.2013. Copyright © 2010–2015  
Paradigm4, Inc.

# Entrevistas

- ***On the SciDB array database***. Interview with Mike Stonebraker and Paul Brown. Disponível em: <http://www.odbms.org/blog/2014/04/interview-mike-stonebraker-paul-brown/>. Acesso: Novembro, 2015. Blog Roberto V. Zicari.