

PTR 5003

S.R.: OBIA, Modelagem Dinâmica e Perspectivas de Pesquisa

Profa. Mariana A. Giannotti

LGP – Laboratório de Geoprocessamento da EPUSP



Pré-processamentos

Correção Radiométrica

- Eliminação de ruídos
- Restauração
- Correção Atmosférica






Imagem de Satélite



Vetor padrão do pixel (1,1)

$$\begin{bmatrix} 45 \\ 50 \\ 56 \\ 32 \end{bmatrix}$$

Espaço de Atributos




Vegetação
Água
Área impermeável

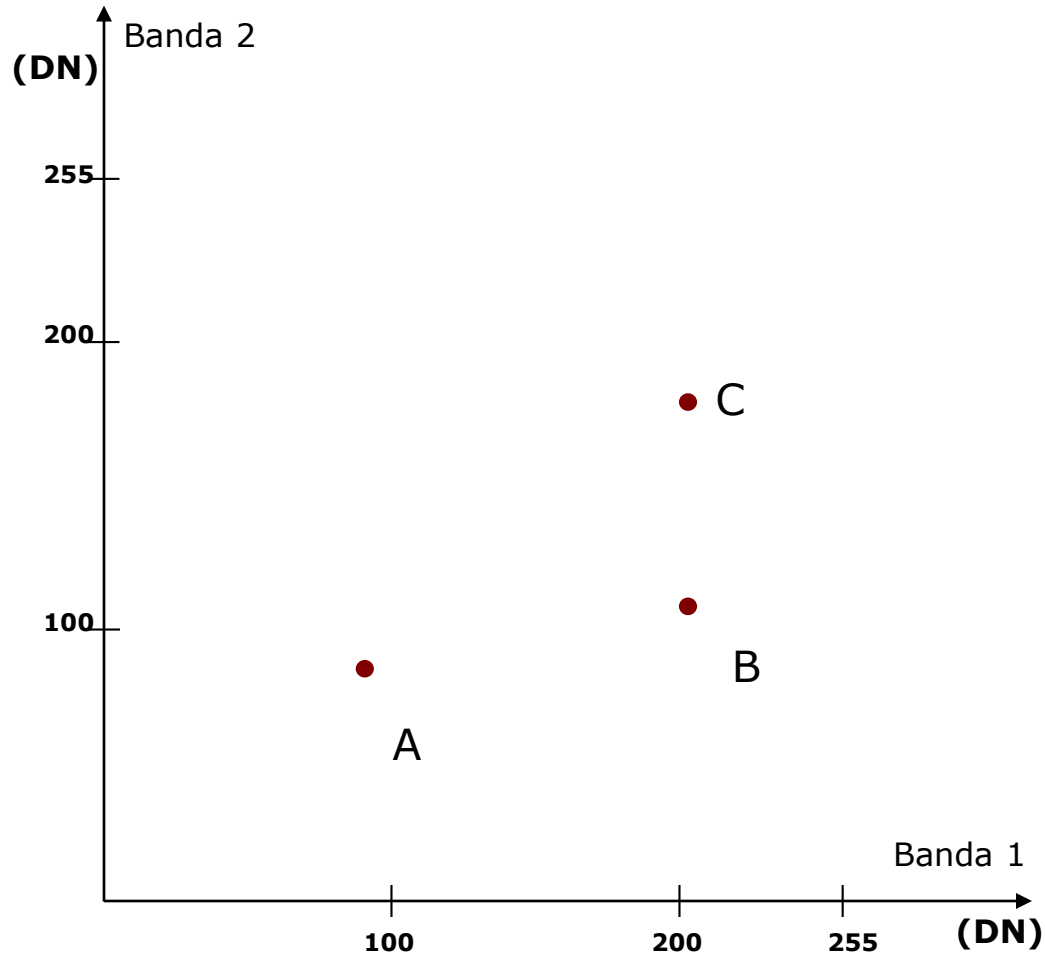
“O gráfico contendo as frequências de distribuição de intensidades de duas ou mais bandas de uma imagem multiespectral “

(Crósta 1989)

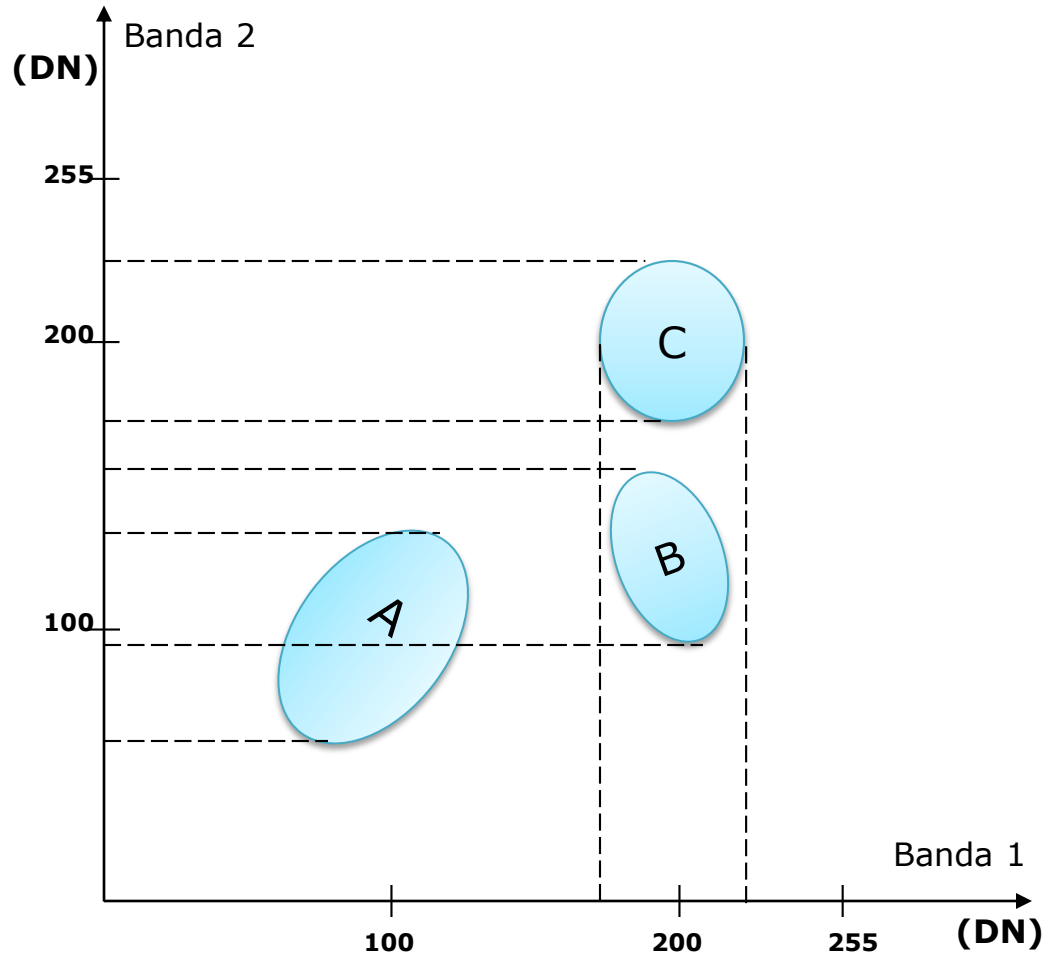
Seleção de atributos




Seleção de atributos



Seleção de atributos



Seleção de atributos



Operações Aritméticas

- ✓ Subtração
 - ✓ Adição
 - ✓ Multiplicação
 - ✓ Divisão (ou Razão)
-
- ✓ NDVI
(Normalized Difference Vegetation Index)

NDVI

O NDVI é obtido através do seguinte algoritmo:


$$\text{NDVI} = \frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED})}$$

onde:

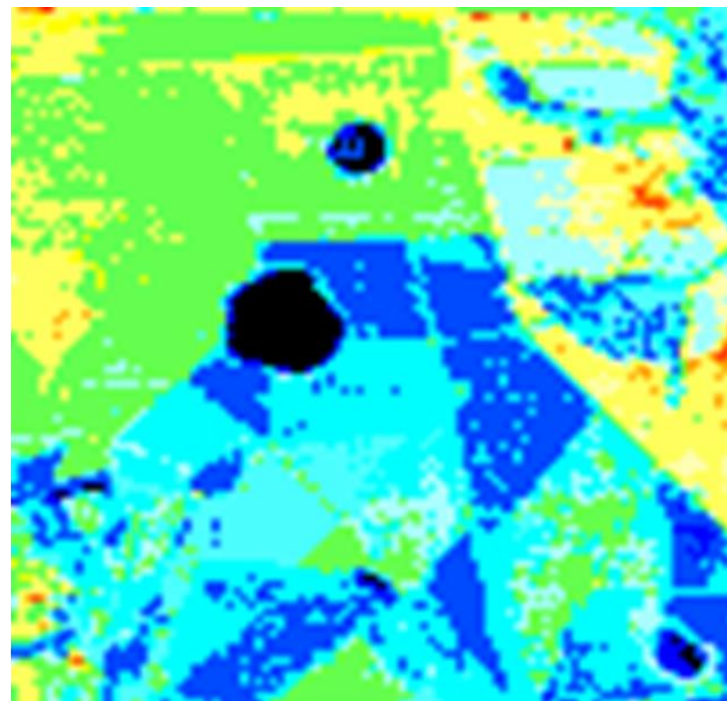

NIR = Região do Infravermelho Próximo

RED = Região do Vermelho

Classificação de Imagens



Geração de um
Mapa Temático



Associação de pixels aos temas (classes).

Obtenção de Mapas Temáticos

- Interpretação visual
 - Tonalidade, cor, textura, tamanho, forma, sombra, padrão, localização geográfica e data de aquisição da imagem (FLORENZANO, 2002)
- Classificação de imagens
 - Procedimentos computacionais para a análise de imagens

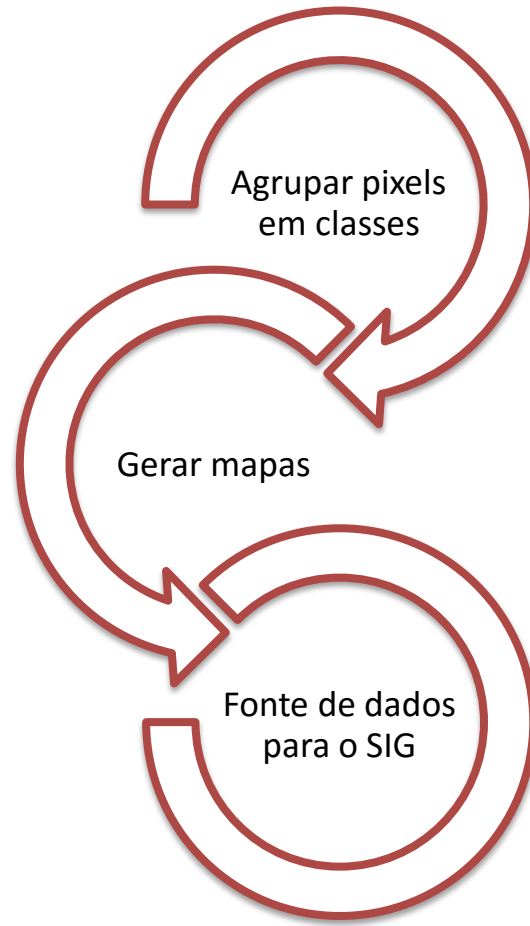
Classificação de Imagens Multiespectrais

- Imagens multiespectrais
- Componentes principais
- Espaço de atributos
- Classificação
- Segmentação

Classificação de Imagens Multiespectrais

- Objetivos da classificação:
 - definir classes de objetos semelhantes, segundo algum critério de
parecença ou homogeneidade
 - incluir novos elementos (alocar de maneira ótima) nas classes pré-
definidas, segundo alguma regra de decisão

Classificação de Imagens Multiespectrais



Classificação de Imagens Multiespectrais

- Quanto ao elemento de análise
 - Baseada em Pixel
 - Baseada em Regiões
 - Baseada em Objeto
 - Hard ou Fuzzy...
- Quanto a interação do usuário
 - Supervisionada
 - Não Supervisionada
- Quanto às regras de decisão
 - Paramétrico (estatístico)
 - Não paramétrico (geométrico)

Classificação de Imagens Multiespectrais

- Suposições/condições desta abordagem:
 - pixels de uma mesma classe são semelhantes
 - diferentes alvos tem diferentes comportamentos espectrais

Classificação de Imagens Multiespectrais

- Classificação não supervisionada
 - segmentação (ou não)
 - escolha do algoritmo de classificação
 - interpretação das classes geradas
 - avaliação da classificação e possível reprocessamento

Segmentação

- Segmentação: dividir a imagem em **regiões**.
- Regiões: conjunto de **pixels contíguos**, cujas características de atributos são semelhantes.
- Crescimento por regiões
- Detecção de bordas

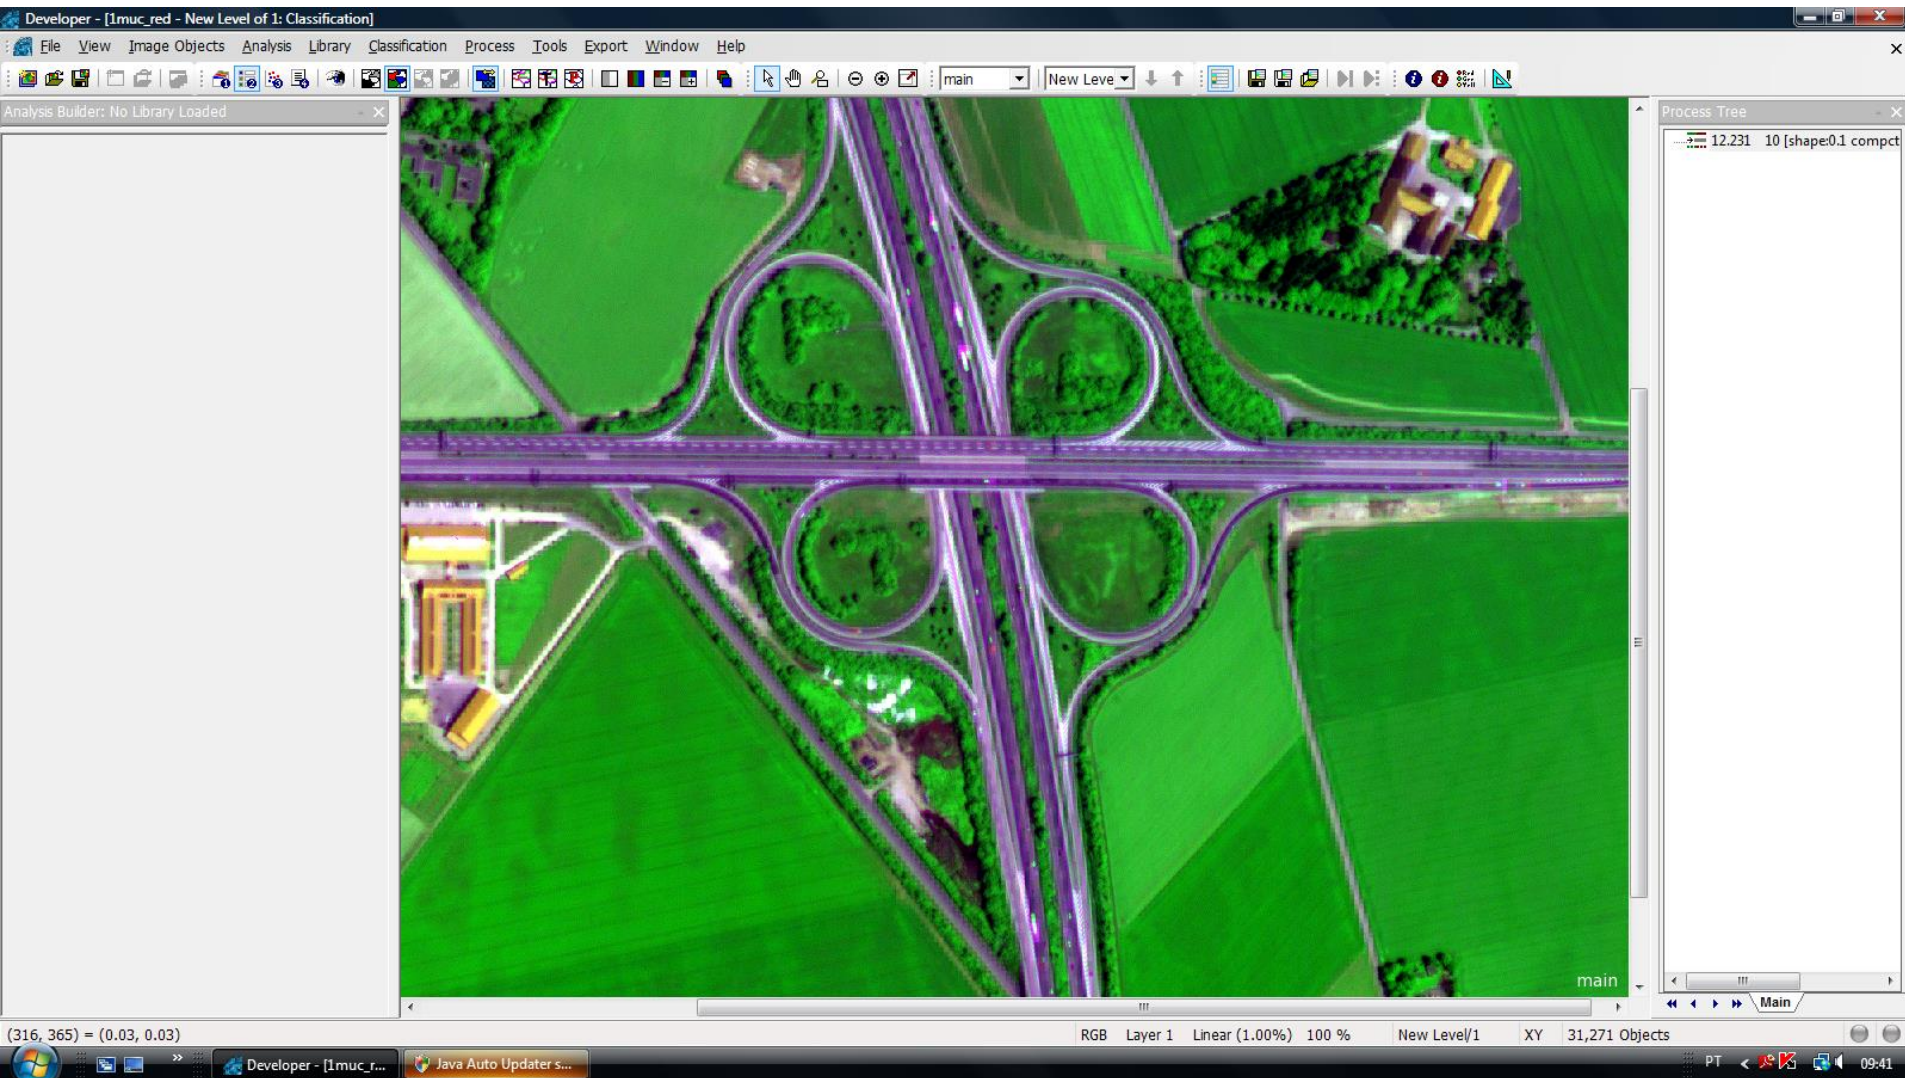
Segmentação


- Crescimento por regiões
- Detecção de bordas

Segmentação

- Limiar de área
- Limiar de similaridade

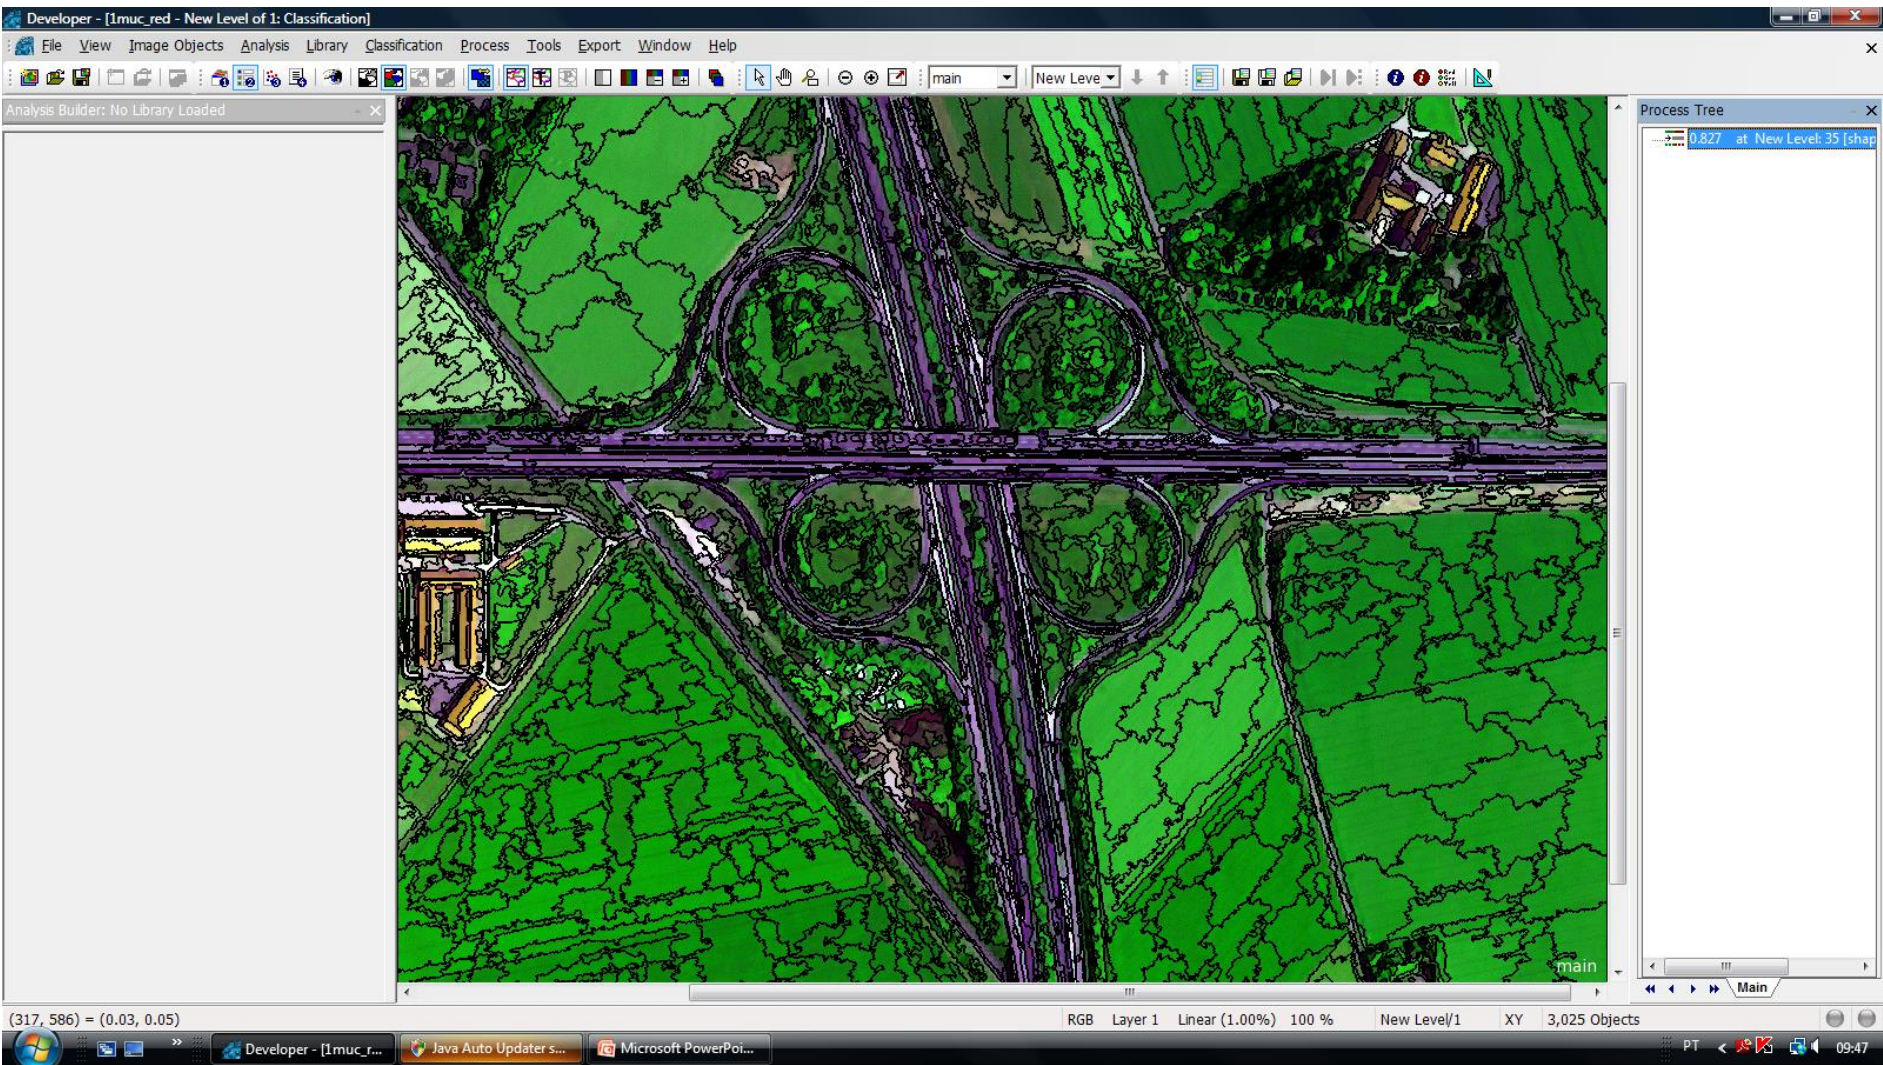
O parâmetro de escala influencia em qual objeto descreve melhor as fe





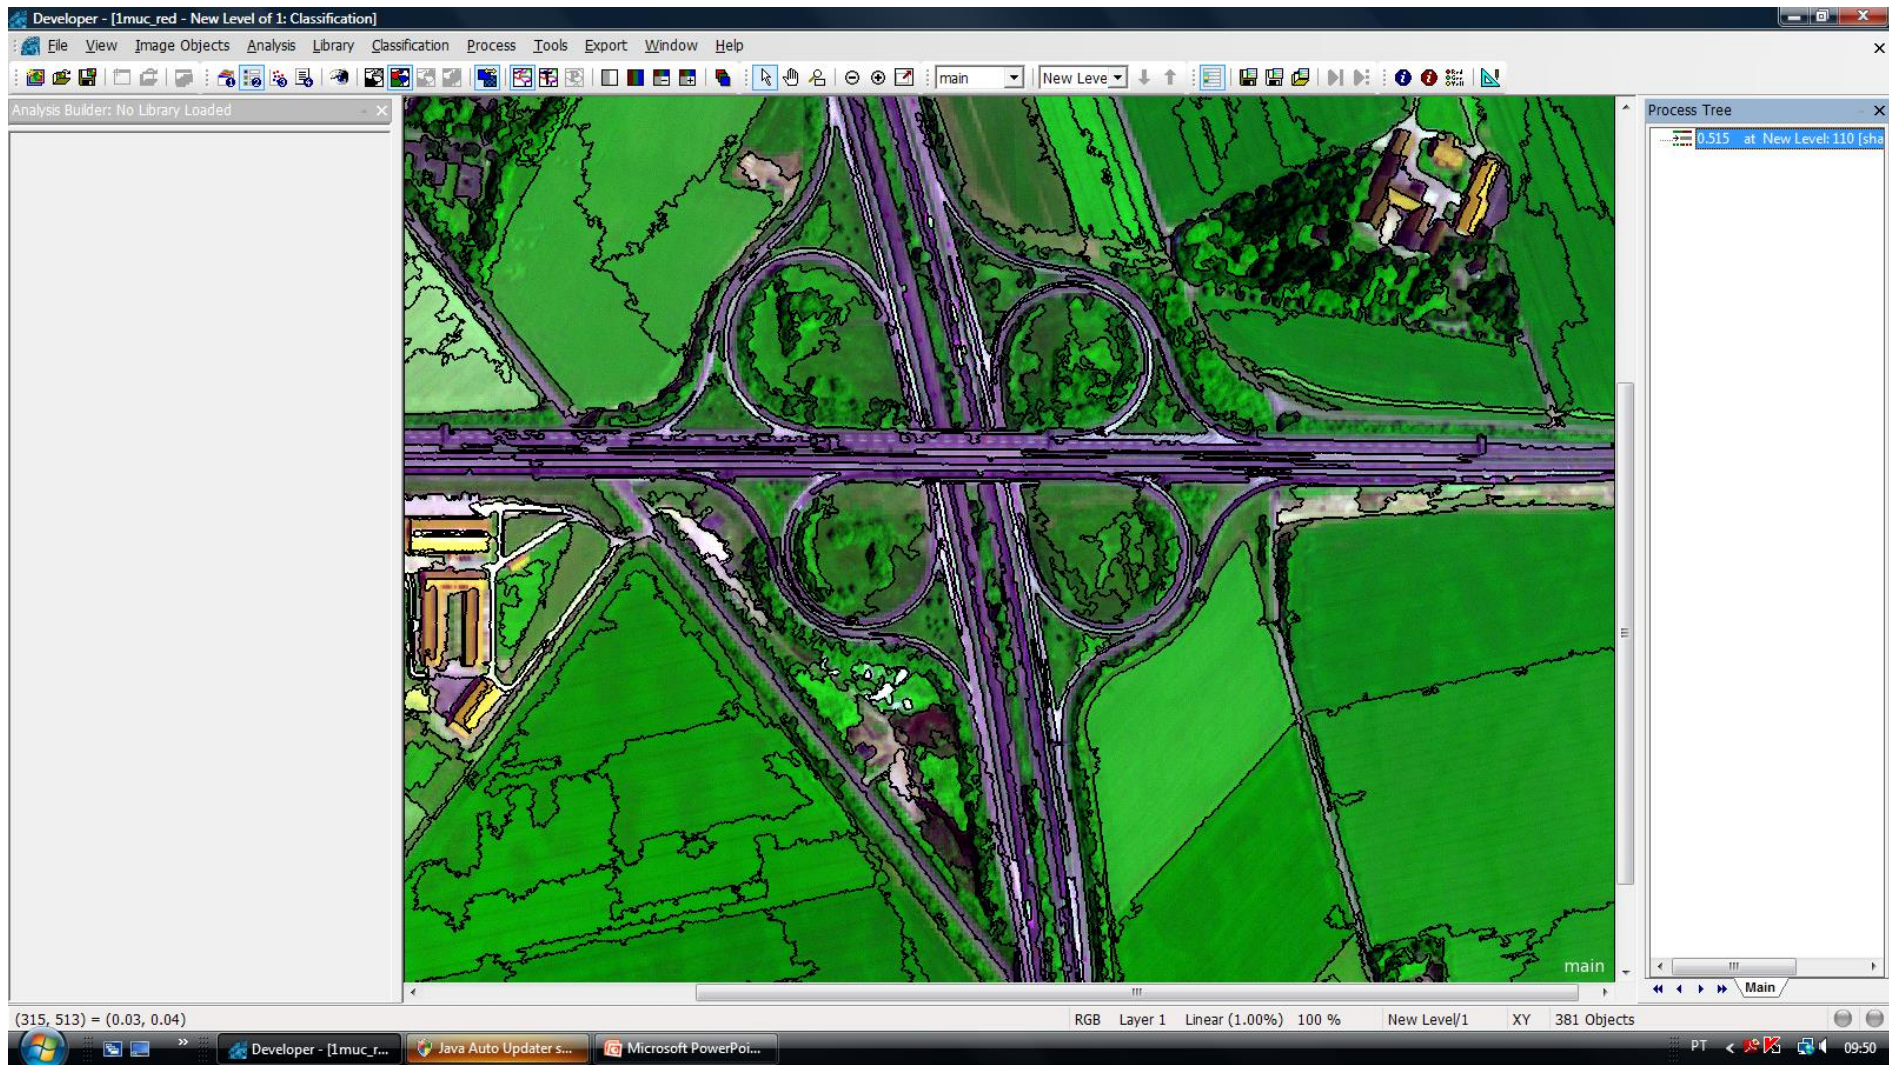
Parâmetro de escala: 10

Fonte: LGP / EPUSP



Parâmetro de escala: 35

Fonte: LGP / EPUSP



Parâmetro de escala: 110

Fonte: LGP / EPUSP

Classificação: Supervisionada

- Baseada no conhecimento prévio da área em análise.
- Amostras de treinamento.
- Classes definidas a priori: processo de classificação visa a enquadrar cada pixel a uma classe.

Classificação: Supervisionada

- Baseada no conhecimento prévio da área em análise.
 - “Verdade” de campo
 - Fotografia aérea
 - Imagem de melhor resolução

Classificação: Supervisionada

- Amostras de treinamento
 - conjunto de pixels representativos
 - parâmetros estatísticos das classes
 - padrão de comportamento espectral

Classificação: Supervisionada

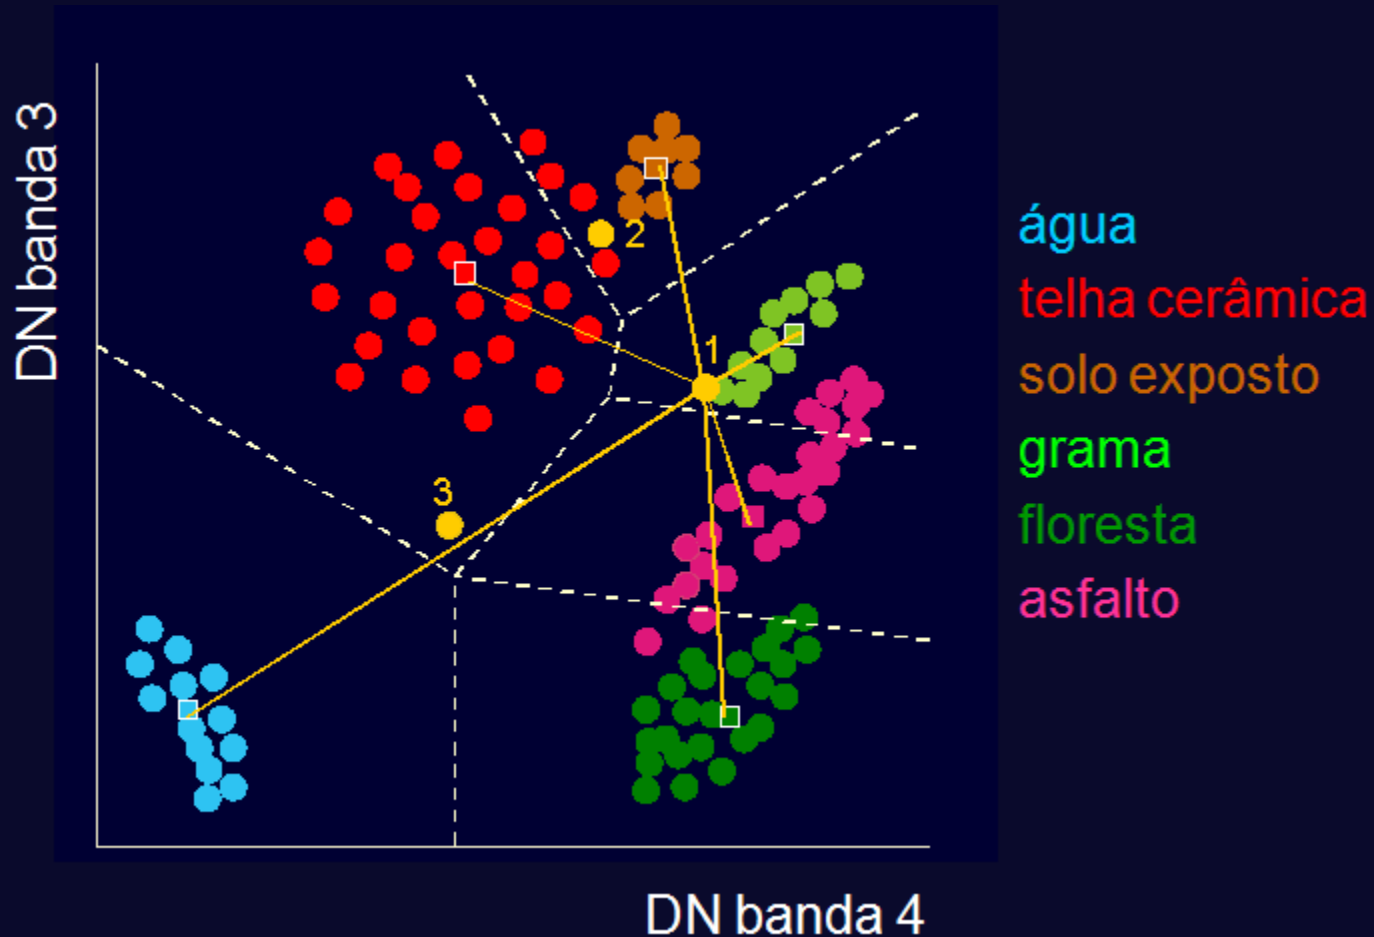
- Coletar amostras para cada classe
- “Treinar” o algoritmo
- Maior exatidão e representatividade das amostras, melhores resultados

Classificação: Supervisionada

- Classes definidas a priori: processo de classificação visa a alocar cada pixel a uma classe (exceto quando é usada lógica fuzzy).
 - diferentes métodos para “alocar” pixel a uma classe:
 - Paralelepípedo
 - Mínima distância
 - Vizinho mais próximo
 - Máxima verossimilhança (Maxver)
 - ...

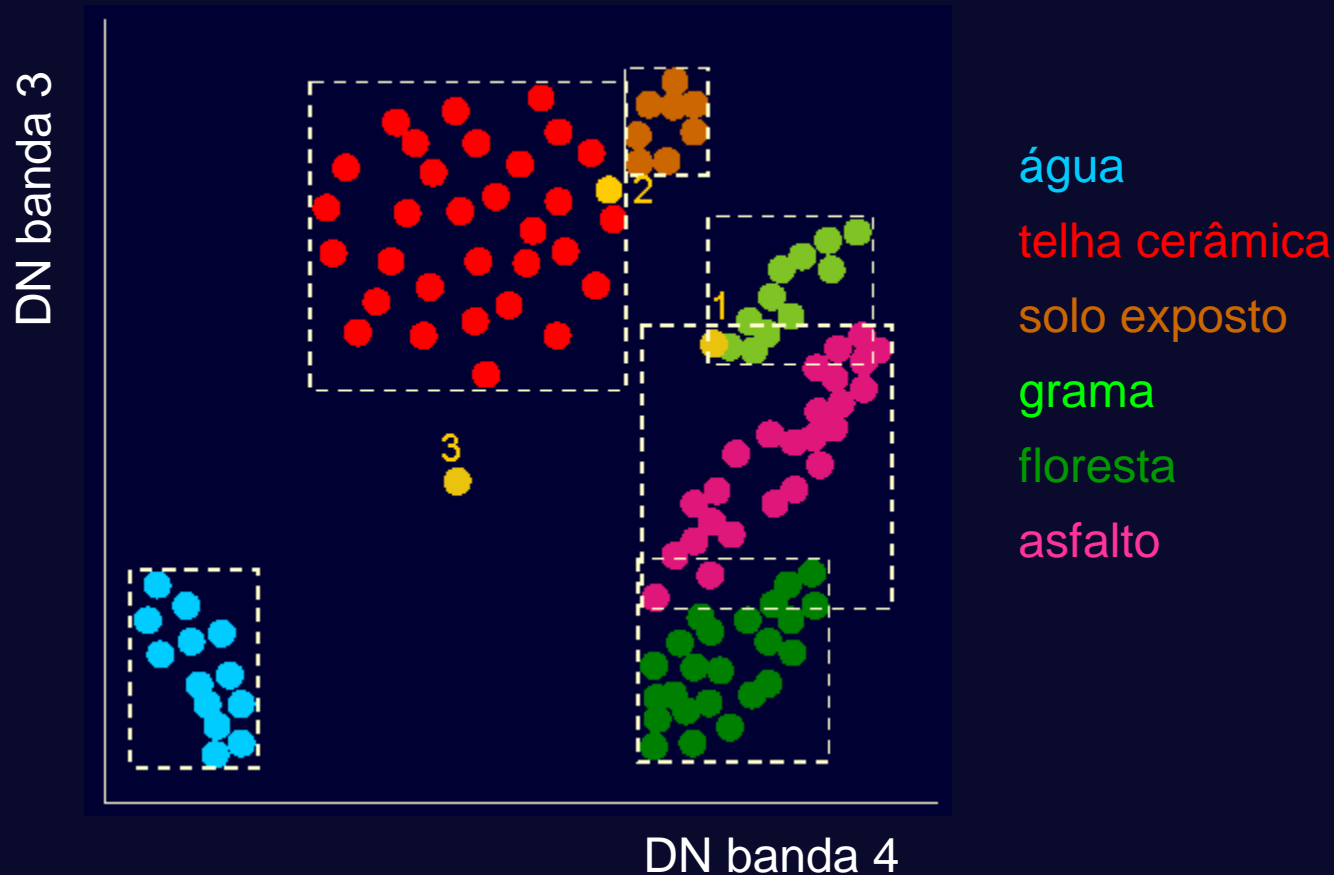
Classificação: Supervisionada

Mínima Distância




Classificação: Supervisionada

Paralelepípedo


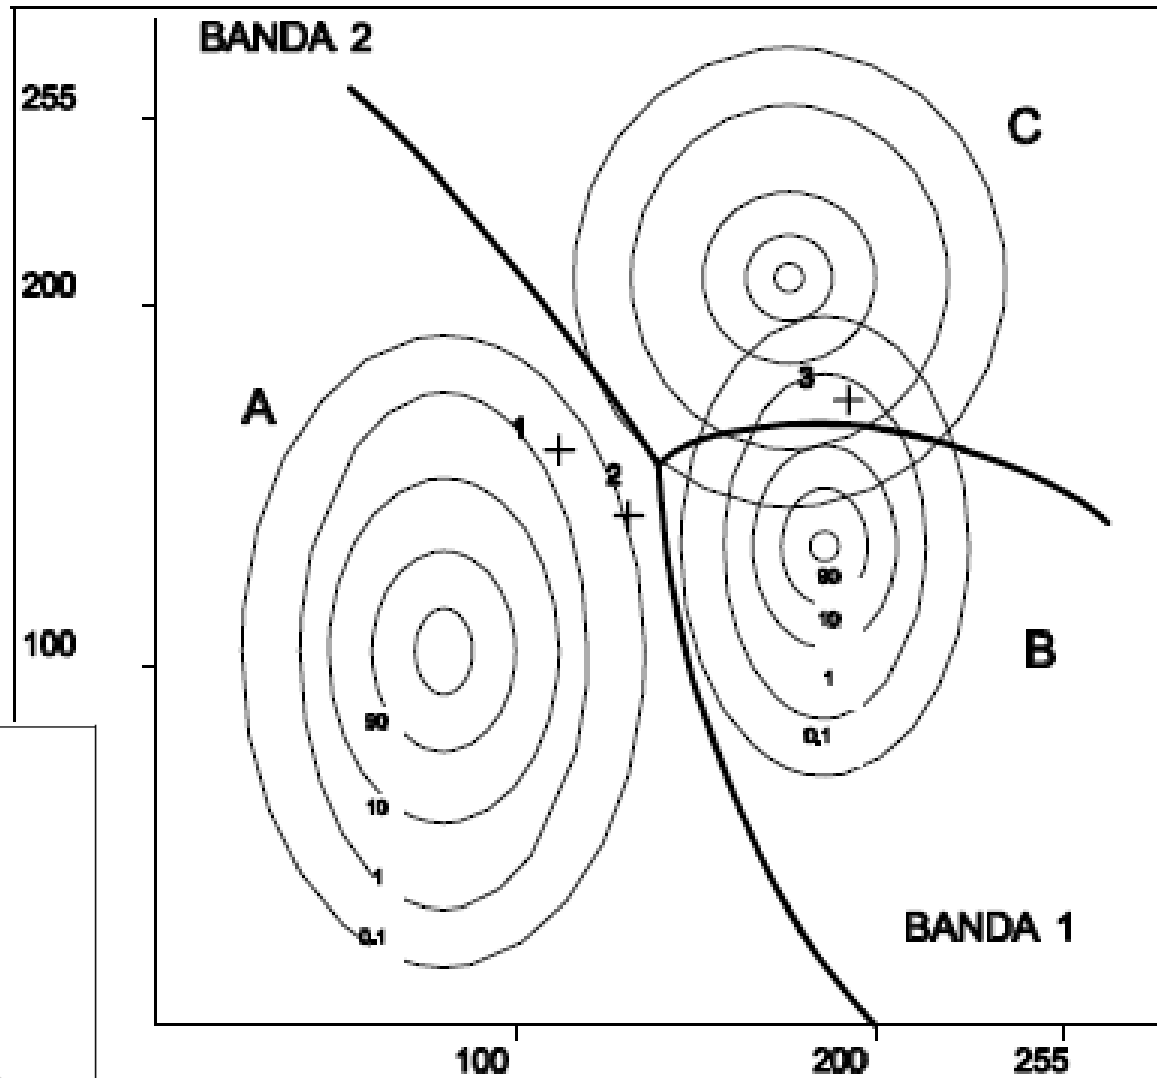


Classificação: Supervisionada

Máxima Verossimilhança



Classificação: Máxima Verossimilhança








Fonte: Crósta, 1993


Classificação Supervisionada



Imagem CBERS, São Paulo, 2008

Classificação Maxver

-  Vegetação densa
-  Vegetação rasteira
-  Água
-  Área urbana
-  Asfalto, amianto



Classificação: Avaliação

- Matriz de erro ou confusão:
 - Verdade de campo x classificação;
 - Índices de desempenho geral e por classe:
 - Erro de omissão;
 - Erro de comissão;
 - Coeficiente Kappa.

Classificação: Matriz de erros

		Classificada						Total
		C1	C2	C3	C4	C5	C6	
Referência	C1	897	308	75	65	17	33	1395
	C2	65	347	141	105	0	26	684
	C3	0	7	110	131	3	71	322
	C4	0	0	18	117	32	49	216
	C5	2	0	101	127	294	127	651
	C6	0	0	3	12	0	325	340
	Total	964	662	448	557	346	631	3608

	Acurácia %	Omissão %	Comissão %
C1	64.3	35.7	6.9
C2	50.7	49.2	47.5
C3	34.1	65.8	75.4
C4	54.1	45.8	78.9
C5	45.8	54.8	15
C6	95.5	4.4	48.4

Acurácia total da classificação
 (Total de acertos / Total) * 100%
 (2090/3608) * 100% = 57,9%

Erro de omissão (C1) = (498/1395) * 100% = 35,7%

Erro de comissão (C1) = (67/964) * 100% = 6.9%

Qual é o erro que eu admito?

GEOBIA - Definição

- Desenvolvimento de métodos automatizados para particionar as imagens de sensoriamento remoto em **objetos geográficos com semântica** avaliando suas características **espectrais, espaciais e temporais**.
- Identificação de objetos que têm uma existência concreta no mundo real e que expressam características de **cor, forma, textura, padrão e contexto** na imagem analisada.

GEOBIA - Premissas

- **Simulação do conhecimento do intérprete** de forma a **automatizar**, completamente ou em parte, o processo de análise e imagens e extração de informações.



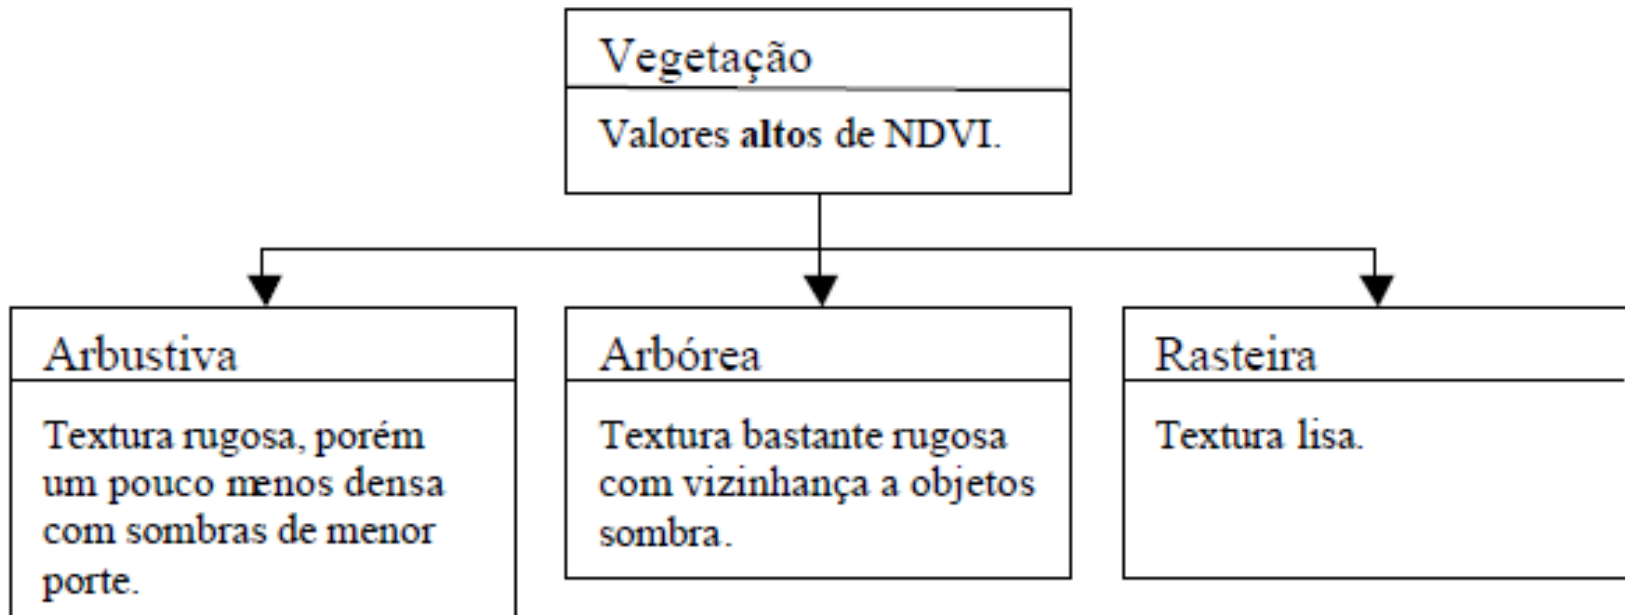
GEOBIA - Premissas

- Um problema é representado por uma coleção de **objetos** que interagem entre si (Rumbaugh et al., 1994).
- A **informação** semântica necessária **para a interpretação** da imagem **não está** presente **no pixel**, e sim **em objetos de imagem e nas relações** entre eles.

GEOBIA – Premissas

- Os objetos com **características** em **comum** são agrupados em **CLASSES**.
- As características são organizadas em forma de **REDE HIERÁRQUICA**, onde as classes de um nível inferior (**subclasses**) **herdam** as características da classe do nível superior (**superclasse**).

GEOBIA – Premissas



GEOBIA – Etapas

Segmentação

```
graph TD; A[Segmentação] --> B[Rede Hierárquica]; B --> C[Regras de Classificação]; C --> D[Imagem Classificada];
```

Rede Hierárquica


Regras de Classificação

Imagem Classificada

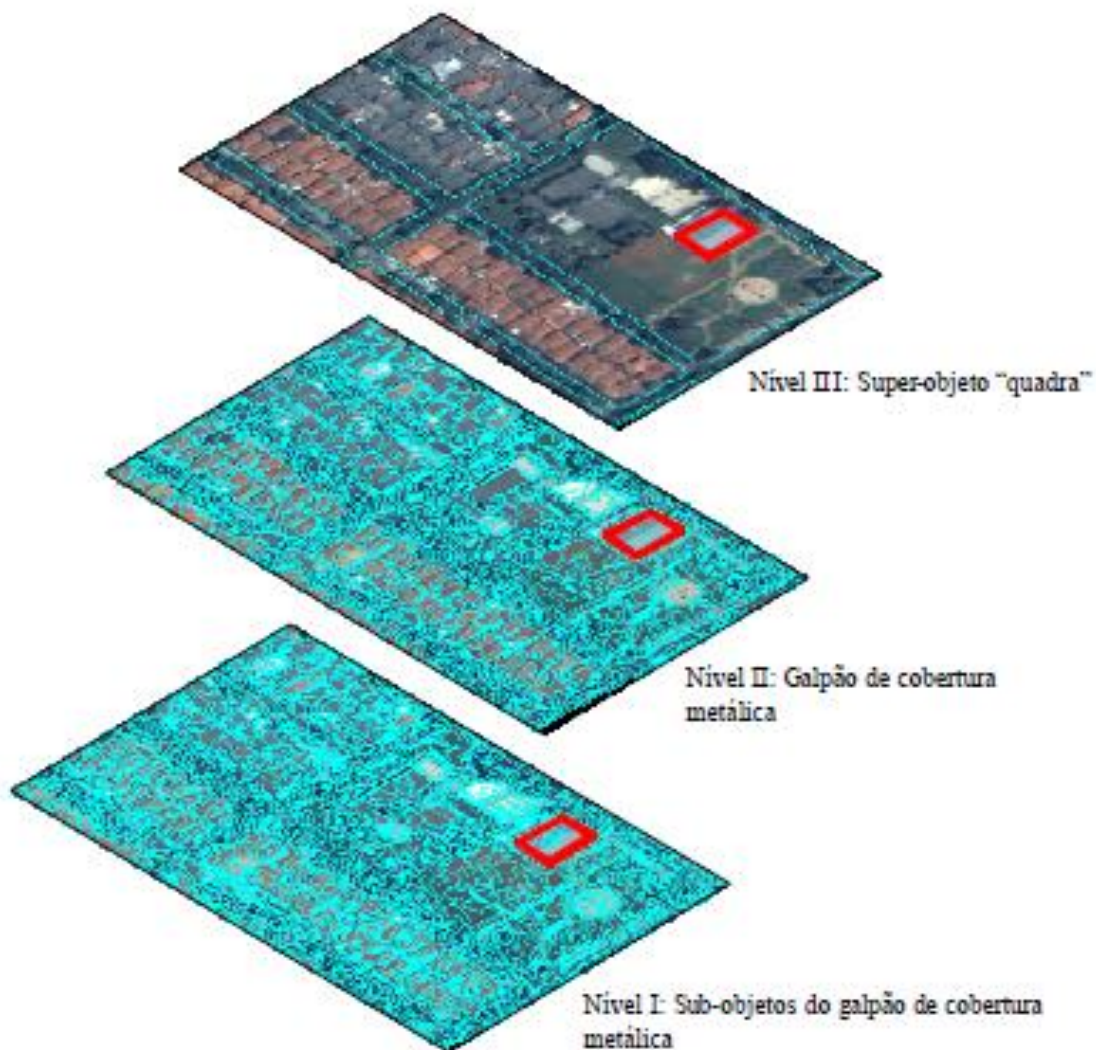
GEOBIA – Segmentação Multiresolução

- Segmentação:
 - Divisão de uma imagem em regiões que melhor representam os objetos de interesse numa cena.
- Segmentação Multiresolução:
 - Geração dos objetos da imagem em diferentes escalas de detalhamento.

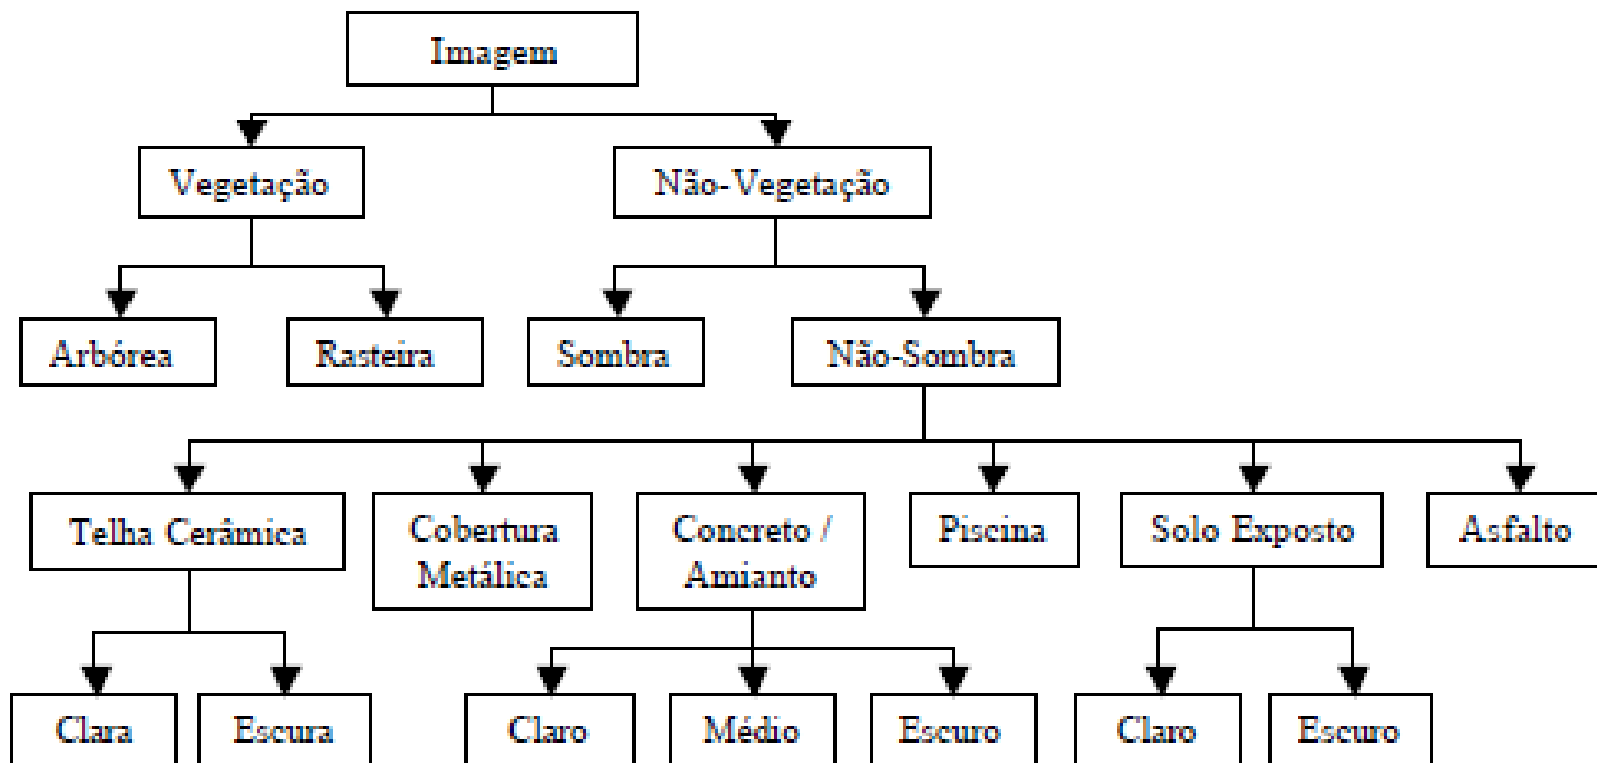
GEOBIA – Segmentação Multiresolução



GEOBIA – Segmentação Multiresolução



GEOBIA – Rede Hierárquica



GEOBIA – Regras de classificação

espectrais (como intensidade média dos *pixels*, razão entre bandas, etc.)

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Média da
banda verm.



Média da
banda verde




Média da
banda azul




geométricos (forma retangular, simetria, compacidade, tamanho, largura, etc.)


$$compactness = \frac{4 * \pi * Area}{Perimeter^2}$$






Comprimento/
Largura




Area



topológicos (contexto em relação a objetos vizinhos, de outros níveis, na cena, etc.)



Num. de sub-
objetos



Contraste com
pixels vizinhos



GEOBIA – Regras de classificação





Gráfico de dispersão das classes áreas naturais (verde) e tecido urbano (rosa). Os pontos correspondem aos objetos classificados, enquanto as bolinhas correspondem às amostras selecionadas

Espaço de Atributos



Vegetação
Água
Área impermeável

“O gráfico contendo as frequências de distribuição de intensidades de duas ou mais bandas de uma imagem multiespectral “

(Crósta 1989)

GEOBIA – Regras de classificação


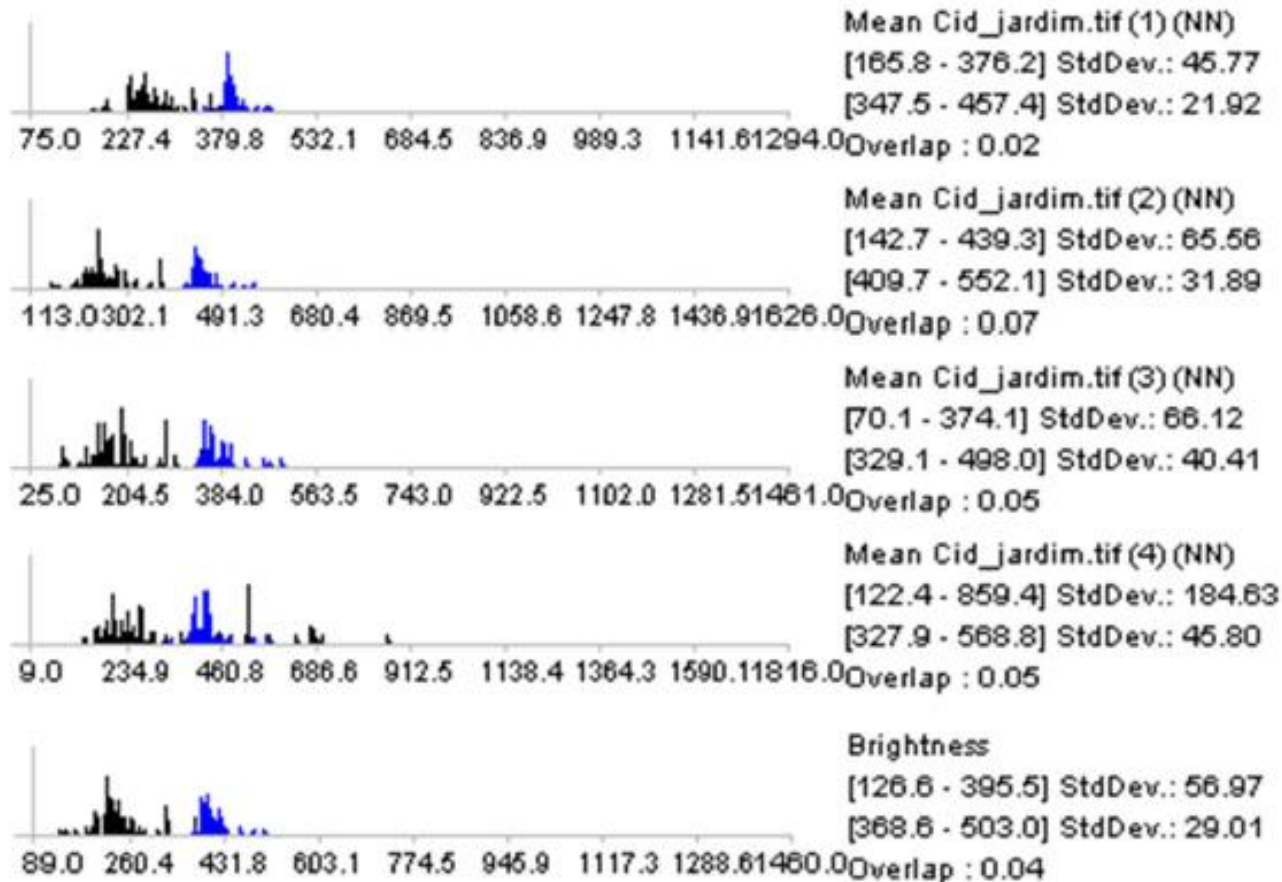



Gráfico de dispersão das classes áreas naturais (verde) e tecido urbano (rosa). Os pontos correspondem aos objetos classificados, enquanto as bolinhas correspondem às amostras selecionadas

GEOBIA – Regras de classificação



Histogramas de média dos objetos da banda 1, 2, 3 e 4 e Brilho para as classes Sombra (em preto) e Concreto/ Amianto Escuro (em Azul).

GEOBIA – Classificação



edific. não cerâmica	máscara	não residenc. impermeável	vias não pavimentadas	água
edific. cerâmica	sombra	não residencial indefinido	via pavimento indefinido	campo de futebol
vegetação		não residencial permeável	via pavimentada	ônibus

GEOBIA – Software

- Comercial
 - E-Cognition
 - ENVI – EX
 - IMAGINE Objective (ERDAS)
- OpenSource
 - Interimage (PUC-RJ)

Aplicação: desastres



Crescimento Urbano

EUA



Europa (UK)



Brasil

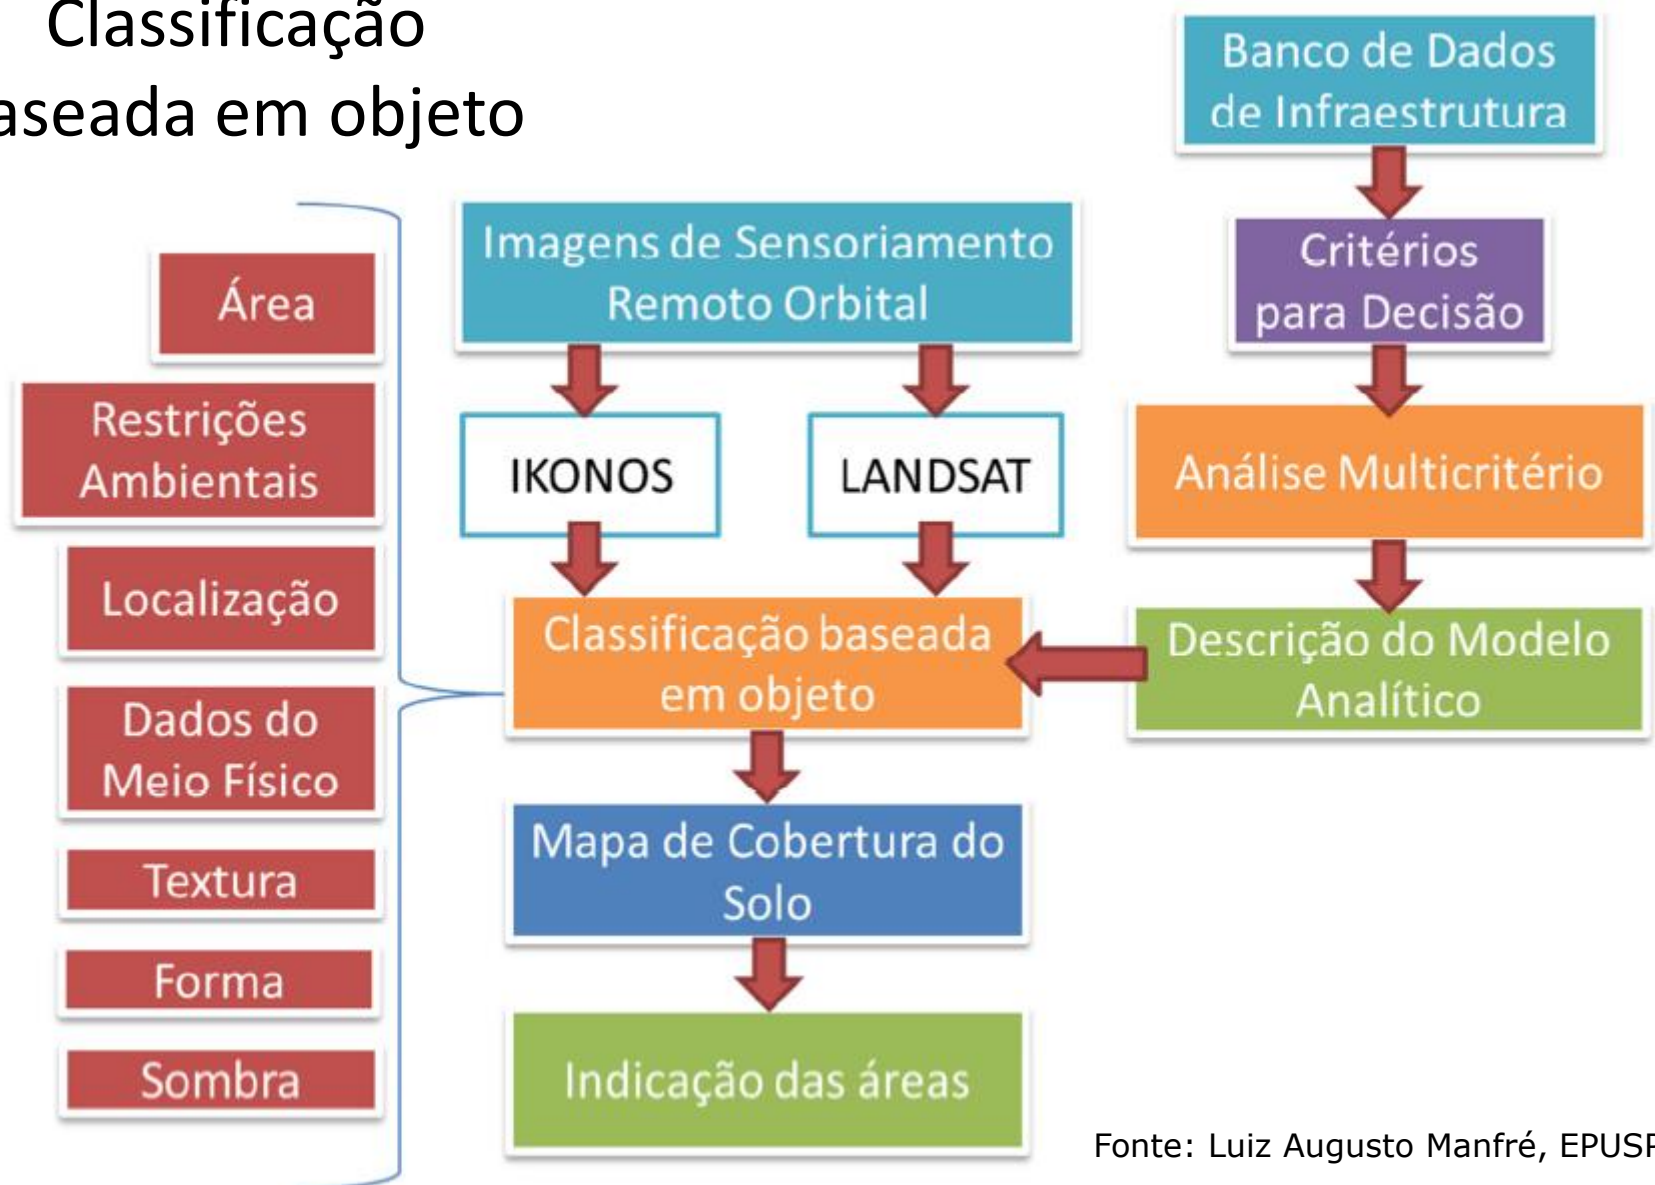


Aplicação: desastres



Aplicação: desastres (RMSP)

Classificação baseada em objeto



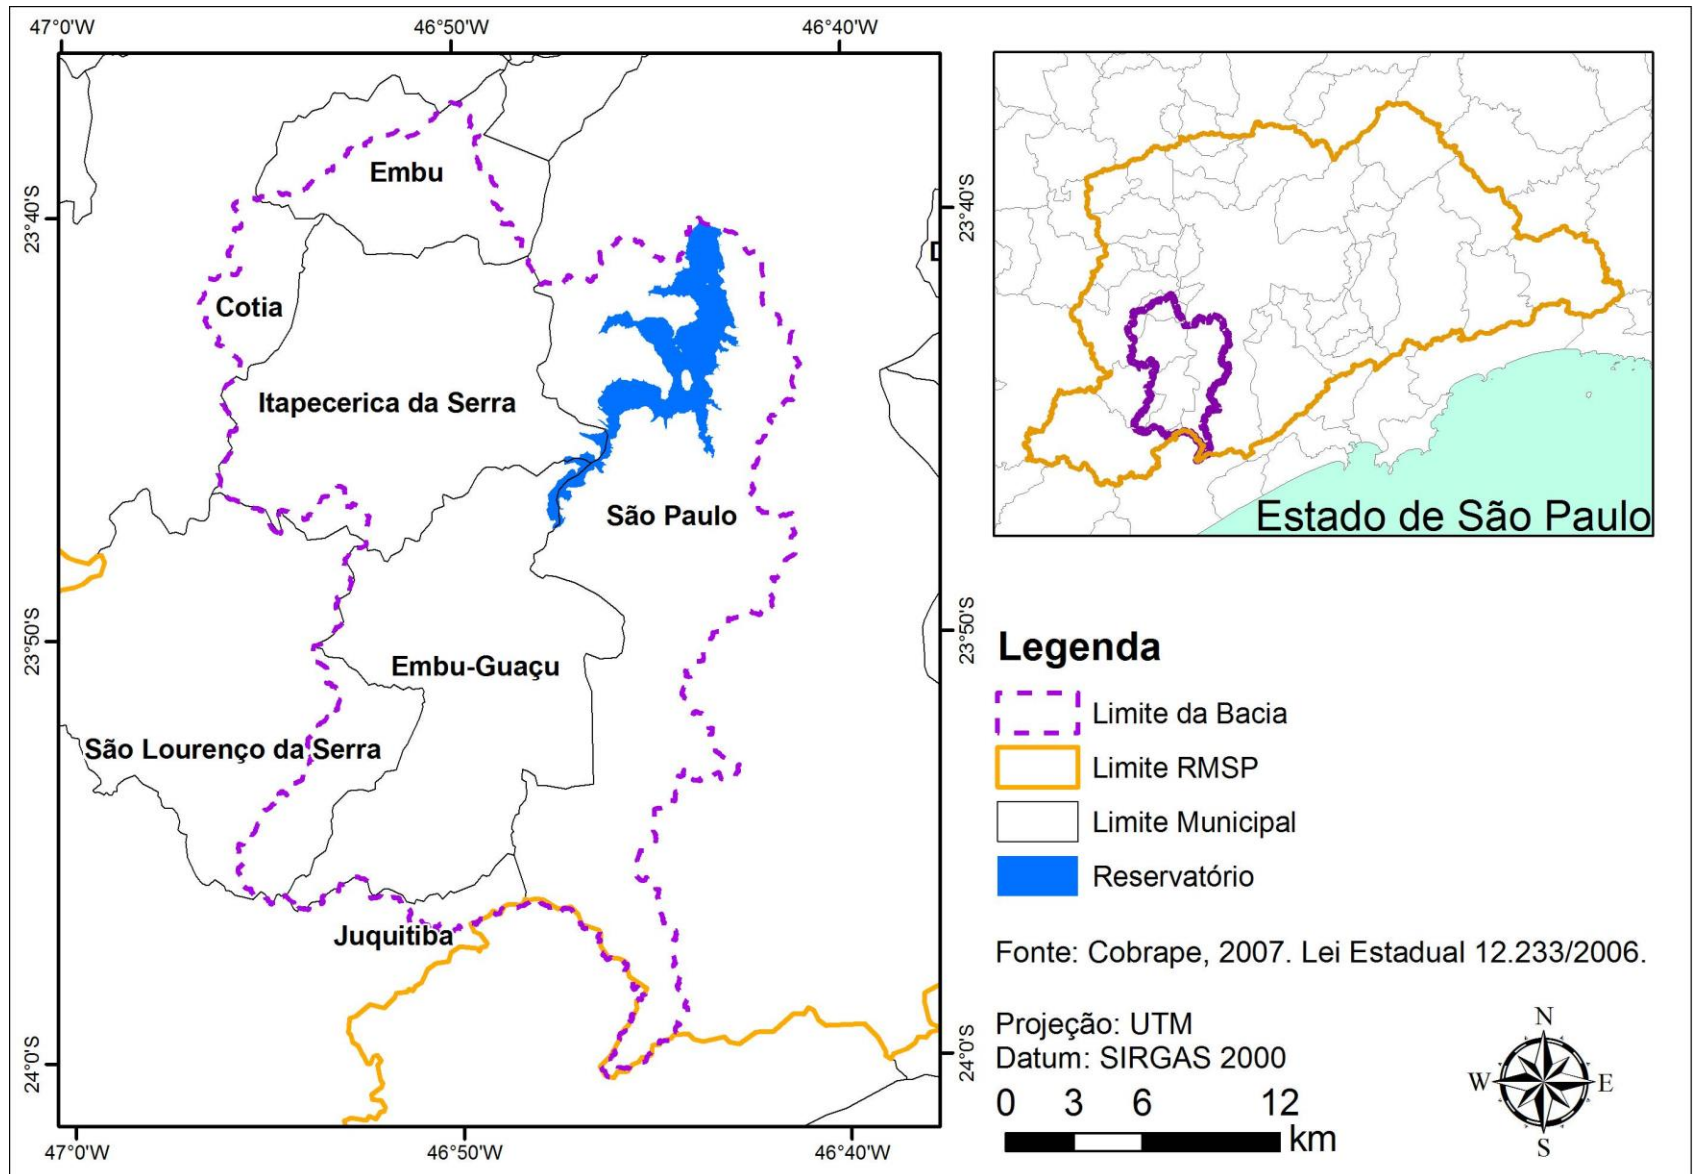
Aplicação: Guarapiranga

- Identificar os diferentes padrões de ocupação do espaço urbano do entorno do reservatório do Guarapiranga – RMSP a partir de dados de cobertura da terra e dados socioeconômicos do Censo do IBGE



- Inferências a respeito da caracterização socioeconômica da população.

Aplicação: Guarapiranga



Aplicação: Guarapiranga



Aplicação: Guarapiranga



Aplicação: Guarapiranga




Aplicação: Guarapiranga

Segmentação

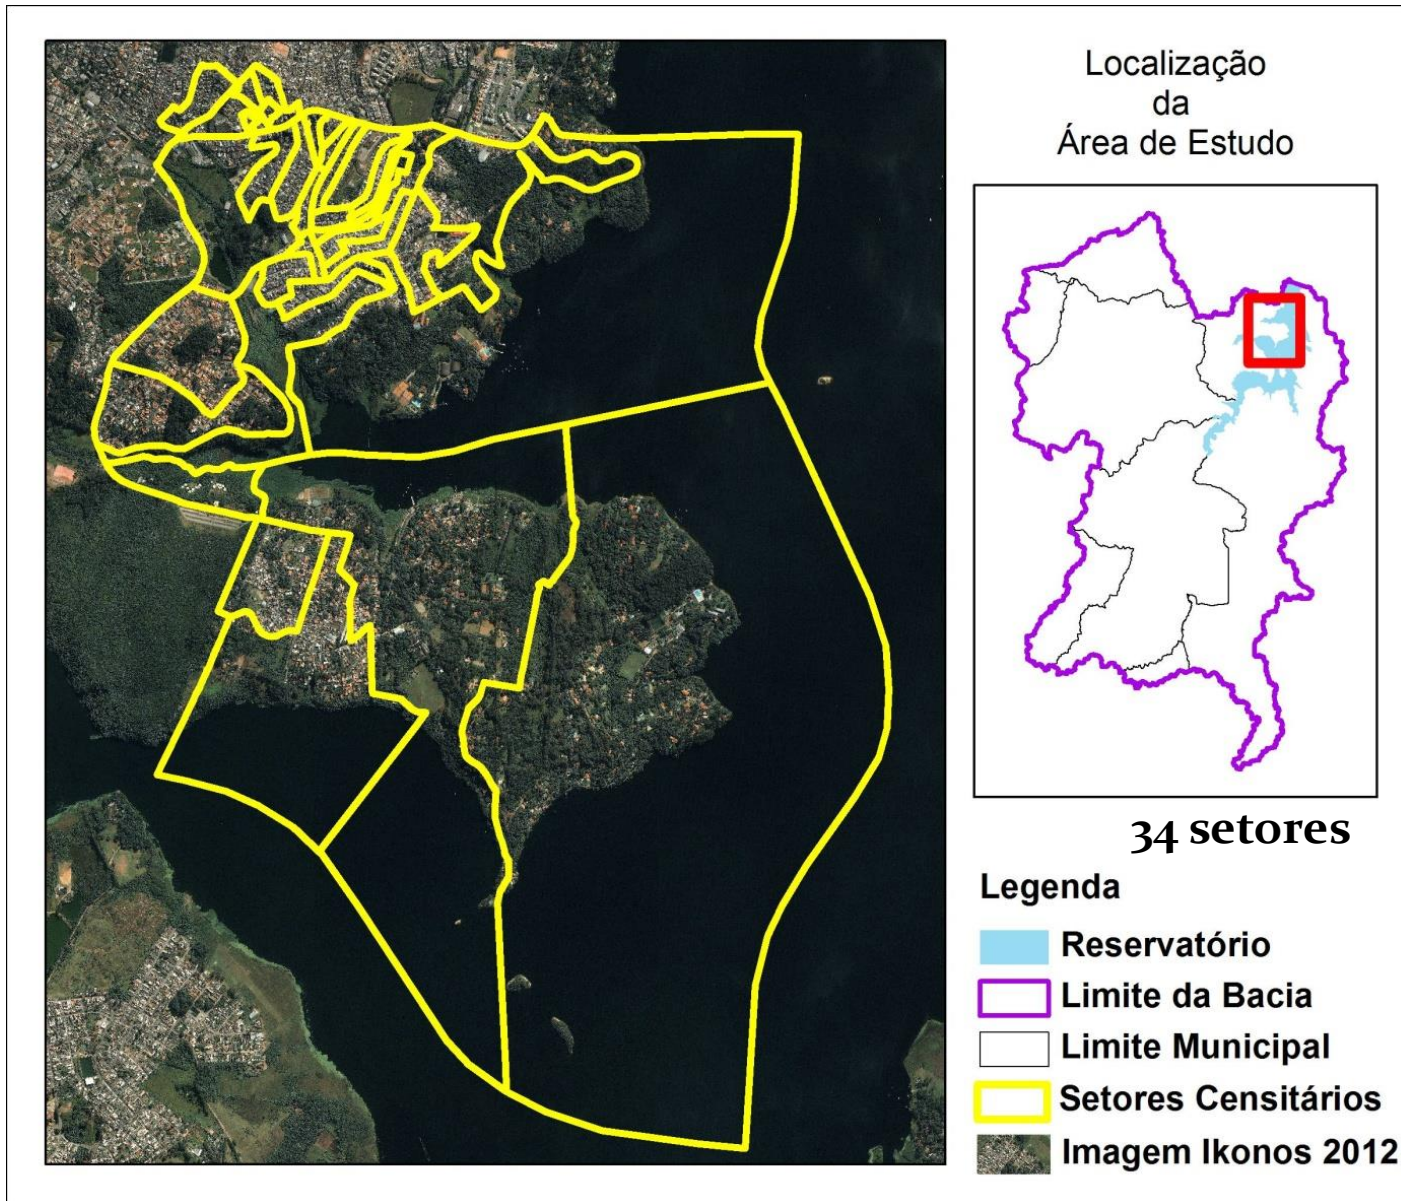


Aplicação: Guarapiranga



MINBAND_2	MAXBAND_2	AVGBAND_2	STDBAND_2	MINBAND_3	MAXBAND_3
198,000000	248,000000	218,823529	16,890216	95,000000	189,000000
186,000000	186,000000	186,000000	0,000000	124,000000	124,000000
249,000000	301,000000	274,000000	18,568791	189,000000	228,000000
282,000000	423,000000	346,083333	45,131038	241,000000	381,000000
276,000000	373,000000	320,400000	46,328177	225,000000	327,000000
441,000000	600,000000	524,000000	71,028163	371,000000	566,000000
419,000000	594,000000	499,666667	54,890801	395,000000	567,000000
207,000000	375,000000	291,395349	35,223869	133,000000	334,000000
435,000000	643,000000	537,800000	82,768956	399,000000	619,000000
268,000000	389,000000	330,769231	30,738558	181,000000	318,000000
174,000000	191,000000	182,500000	12,020815	122,000000	140,000000
171,000000	335,000000	208,431034	32,278999	83,000000	270,000000
356,000000	384,000000	370,833333	9,703951	275,000000	304,000000
169,000000	370,000000	242,000000	53,920817	100,000000	285,000000

Aplicação: Guarapiranga



Aplicação: Guarapiranga


- Porcentagem da classe de cobertura por setor



Setor	Telhado Escuro	Telhado Claro	Sombra	Vegetação	Telhado Cerâmica	Asfalto
1	31802	8201	14040	9190	10300	14119

Aplicação: Megacidades

- Abordagem **multitemporal** de dados de sensoriamento remoto para monitoramento sistemático da dinâmica espaço-temporal das **megacidades** do mundo.



Aplicação: Megacidades

- **Objetivo:**

Definir as **áreas urbanizadas** das megacidades e detectar as **mudanças ao longo do tempo** (replicar e comparar).

Estudos com séries multitemporais – monitoramento sistemático.

- **Dados:**

Imagens do satélite Landsat de 1975, 1990 e 2000, com resolução espacial de 80 metros (sensor MSS), 30 metros (sensor TM), e 15 metros (sensor ETM), no pancromático, totalizando 114 cenas;

Imagens do RADAR Terra SAR-X de 2010, com 3 metros de resolução espacial, totalizando 98 cenas.

Aplicação: Megacidades

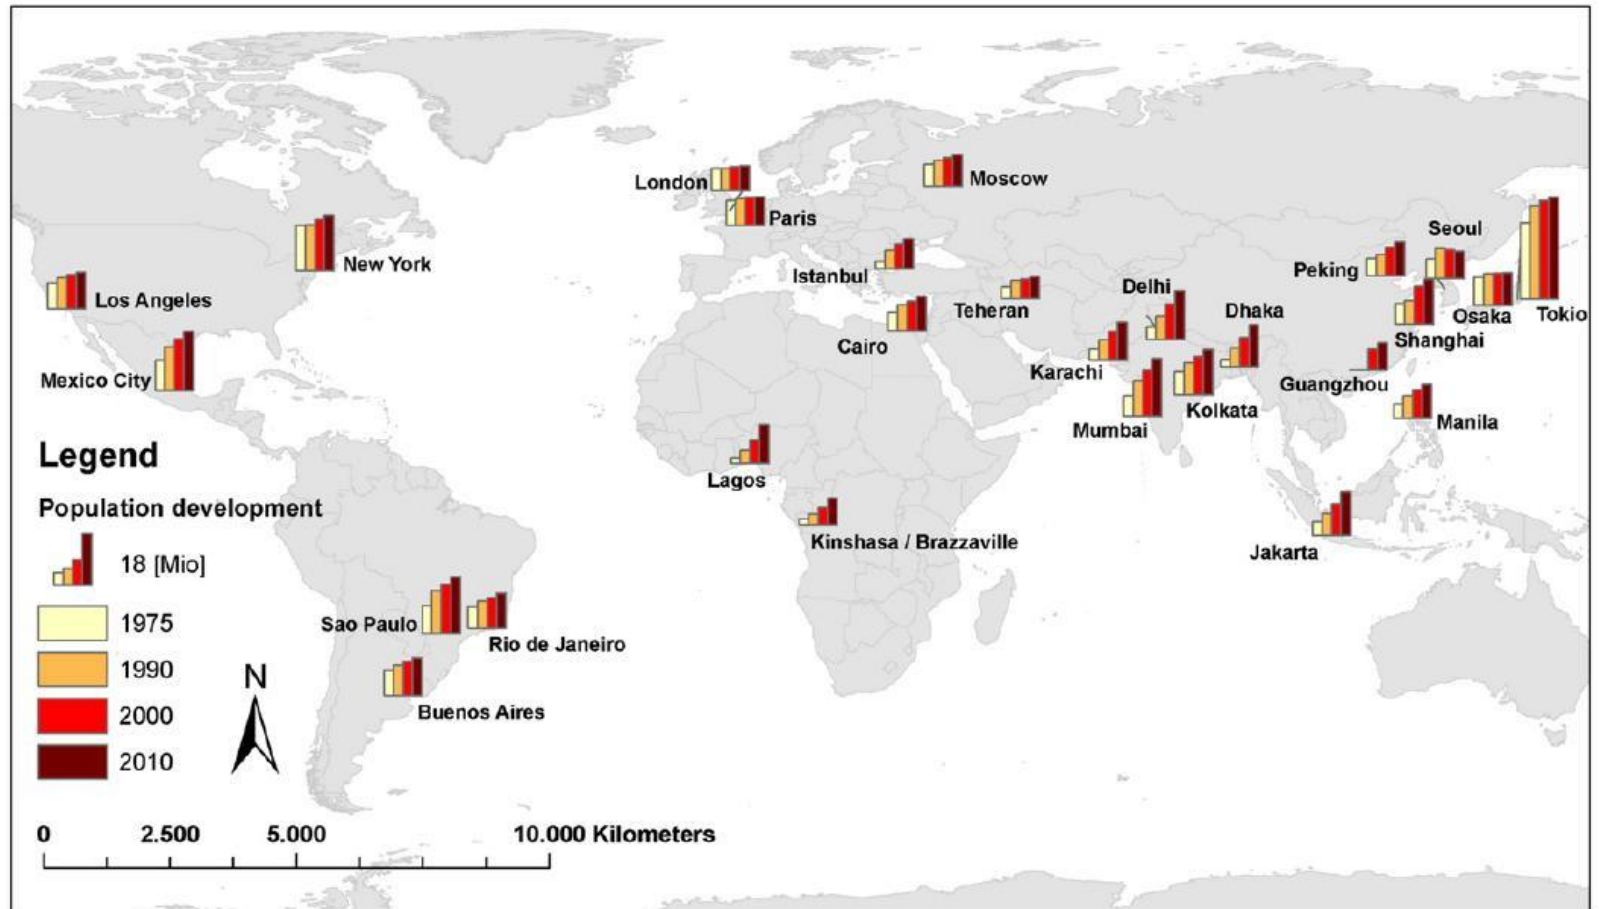


Fig. 1. Spatial distribution of the current mega cities of the world and their population development since 1975.
Data source: UN (2007).

27 megacidades do mundo

Aplicação: Megacidades

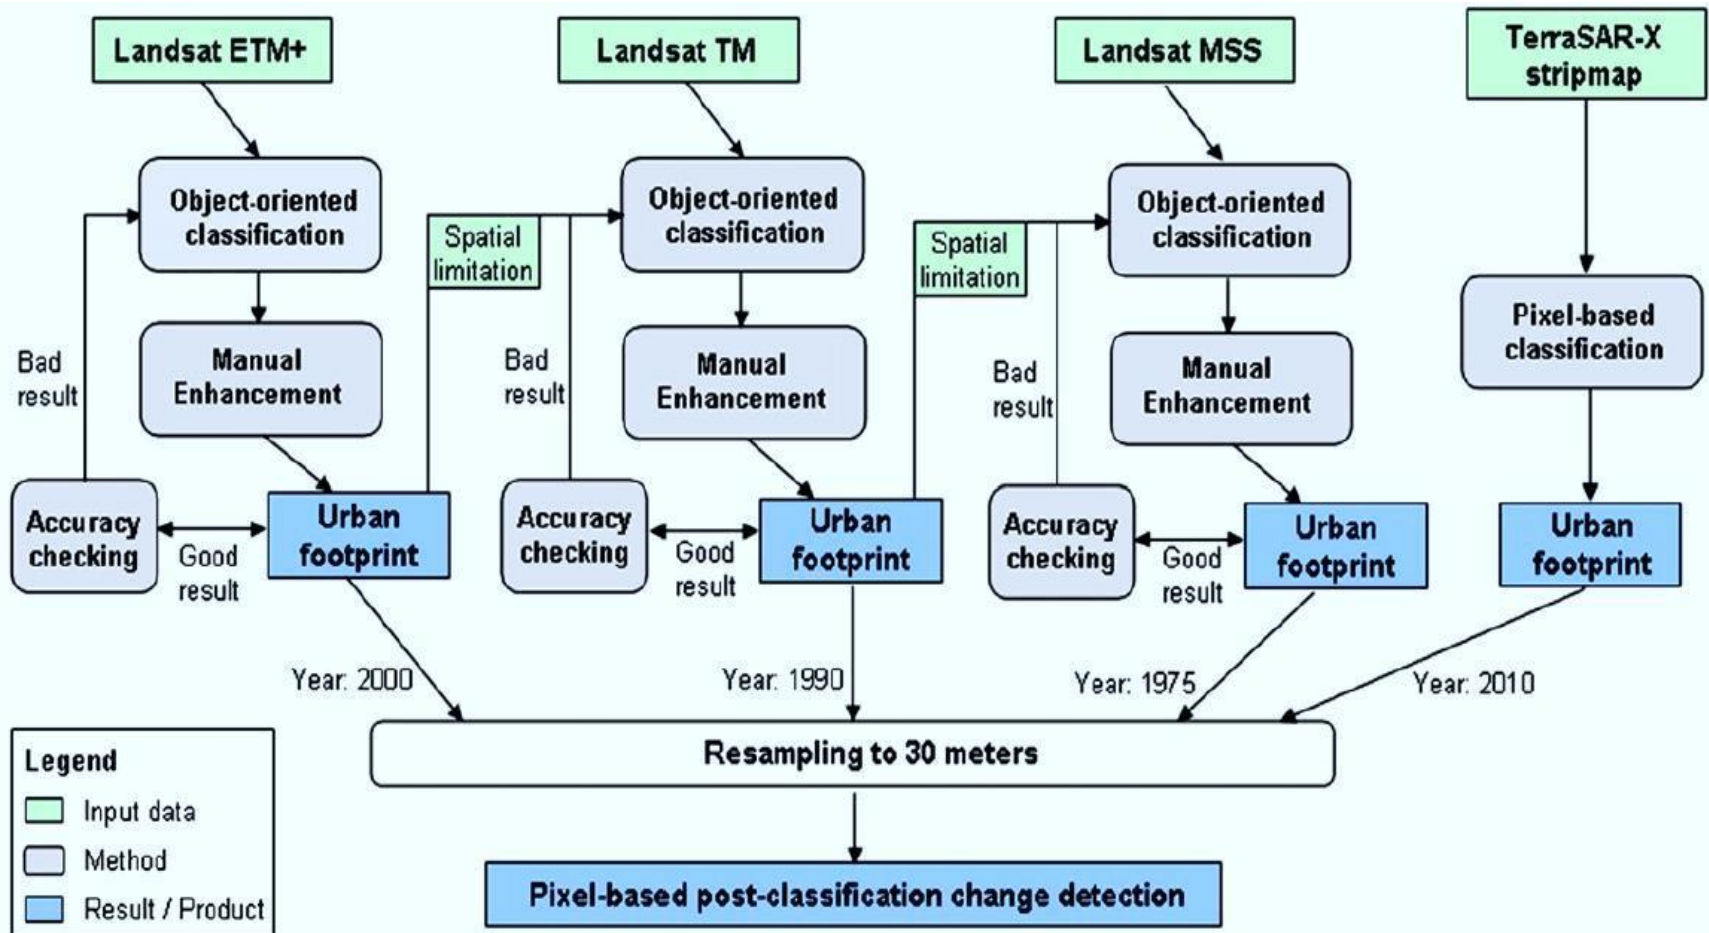


Fig. 2. Processing chain from the multi-sensoral satellite data to the multi-temporal change detection product.

Aplicação: Megacidades

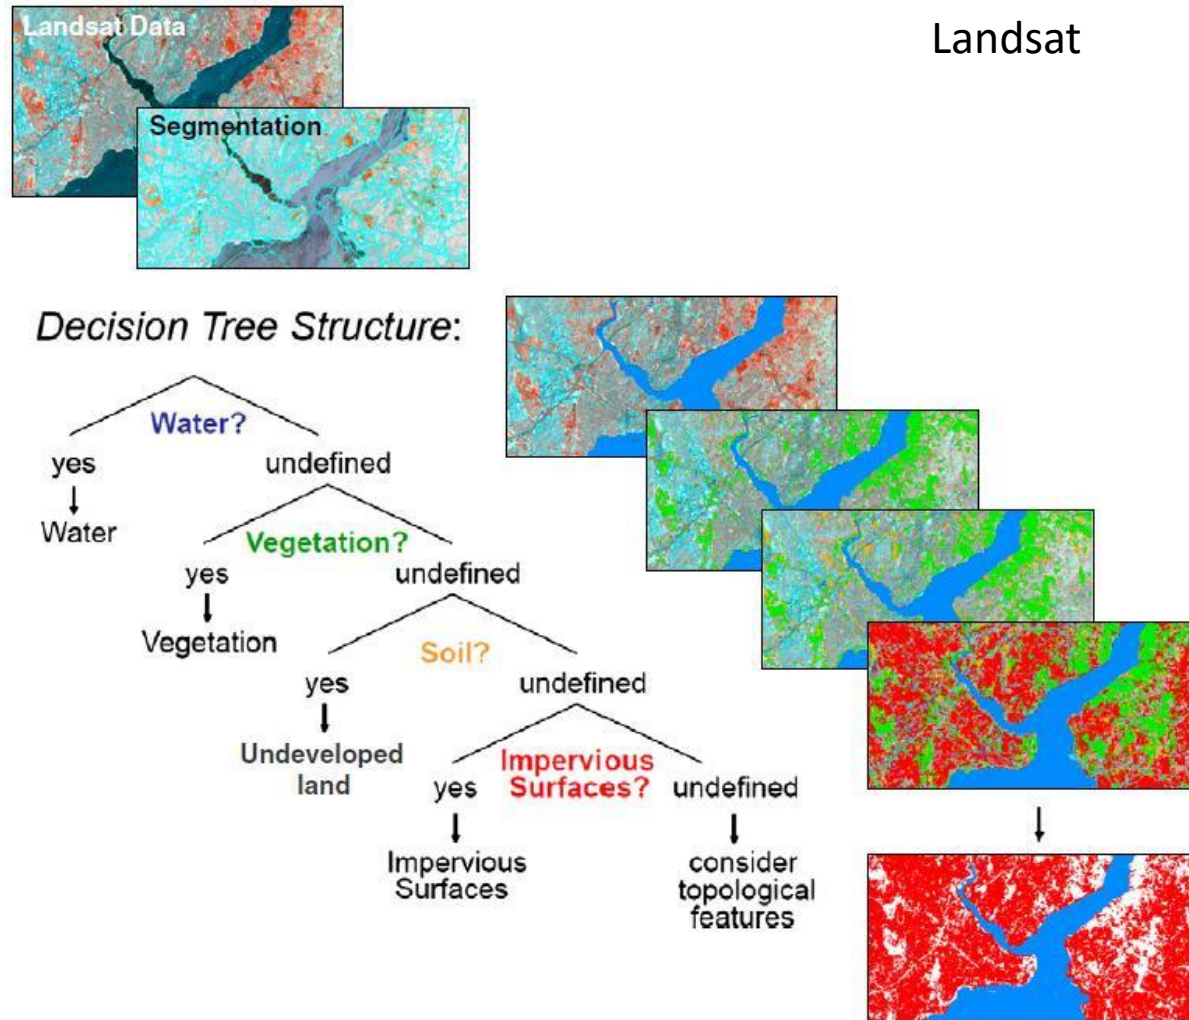



Fig. 3. Schematic overview of the step-wise hierarchical structure of the classification algorithm for Landsat data.

Aplicação: Megacidades



Terra SAR-X

Fig. 4. a) Intensity TerraSAR-X imagery. b) Ikonos imagery for visual comparison. c) 'Speckle divergence' derived from the TSX-intensity imagery – bright values indicate highly structured areas dark values indicate low texture. d) Detected 'urban seeds'. e) Urban footprint d) displayed as combination of the detected urban seeds and the generalization procedure. f) Urban footprint result transparently displayed over the original intensity imagery.

Aplicação: Megacidades




Fig. 6. Change detection for megacity London, England.

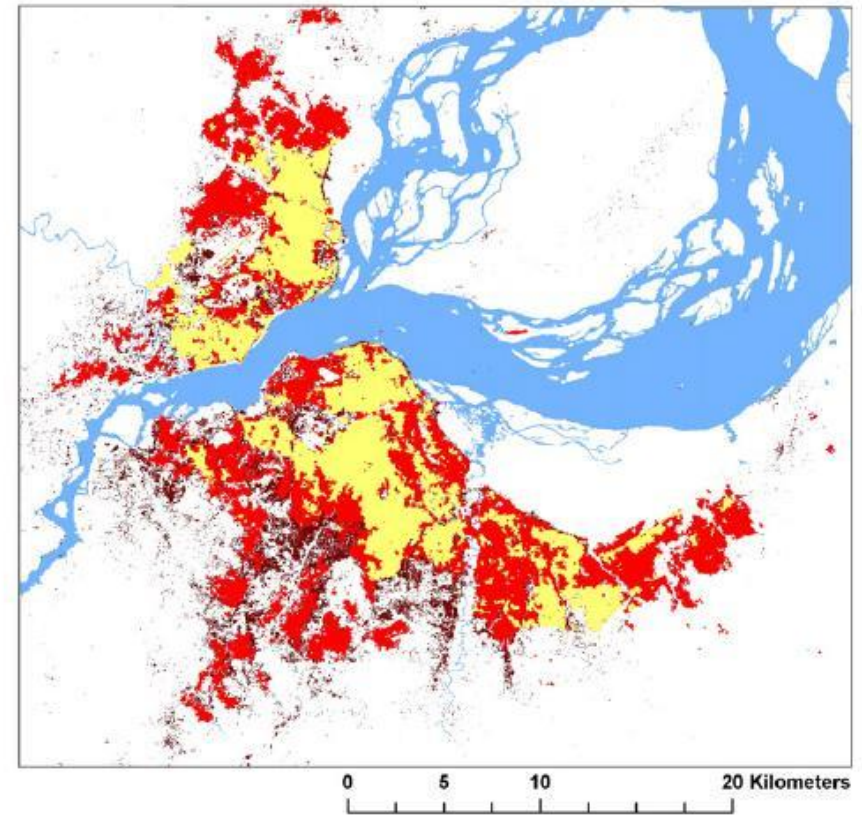


Fig. 8. Change detection for megacity Kinshasa-Brazzaville, Congo.

Aplicação: Megacidades




Fig. 11. Change detection for megacity New York City Metropolitan Area, USA.


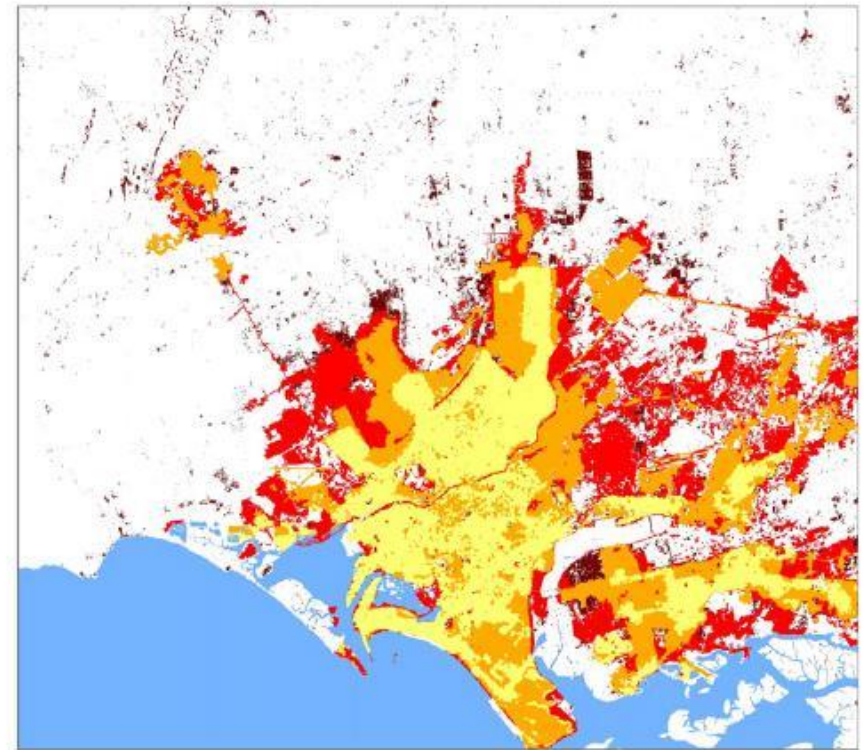


Fig. 13. Change detection for megacity Karachi, Pakistan.

Aplicação: Megacidades

- O processo de urbanização é mais intenso nos países em desenvolvimento.
- A abrangência das áreas urbanizadas nos países em desenvolvimento é maior.




Fig. 17. Relative spatial growth of mega cities in percent with 1975 as baseline.

Aplicação: Megacidades

Table 2
Accuracy assessment of the various urban footprint products.

City	Landsat MSS		Landsat TM		Landsat ETM+		TerraSAR-X	
	Overall accuracy	Kappa coefficient	Overall accuracy	Kappa coefficient	Overall accuracy	Kappa coefficient	Overall accuracy	Kappa coefficient
Mexico City	88.0%	0.75	93.0%	0.88	92.0%	0.84	88.4%	0.72
Delhi	82.0%	0.69	87.0%	0.81	91.0%	0.85	84.2%	0.77
Jakarta	74.0%	0.67	81.0%	0.76	92.0%	0.81	88.2%	0.81
London	79.0%	0.71	82.0%	0.77	90.0%	0.82	87.6%	0.80
Istanbul	93.7%	0.82	92.4%	0.79	90.8%	0.82	92.8%	0.84

Aplicação: Megacidades

- O SR possibilita:
 - Delinear, identificar, medir, definir, localizar e quantificar áreas urbanizadas e o crescimento urbano espacial ao longo do tempo;
 - Encontrar padrões espaço-temporais.

Aplicação: Megacidades



- Apenas a **expansão urbana 2D** é mapeada, não havendo dados suficientes (com imagens de média resolução espacial) para **mapeamento da expansão urbana 3D (verticalização)**.

3D: Lidar

Varredura de feixe luminoso


Pulsos de luz laser (1040 a 1060nm) são direcionados ao terreno por um espelho.

Medição do **tempo** que o pulso leva do transmissor ao alvo e volta ao receptor.



3D: Lidar


Hannover, Alemanha



Fonte: Rodrigo Nóbrega, UFMG

3D: Lidar

Modelo Digital de Superfície, de Terreno e Edificações+Vegetação



3D: Lidar

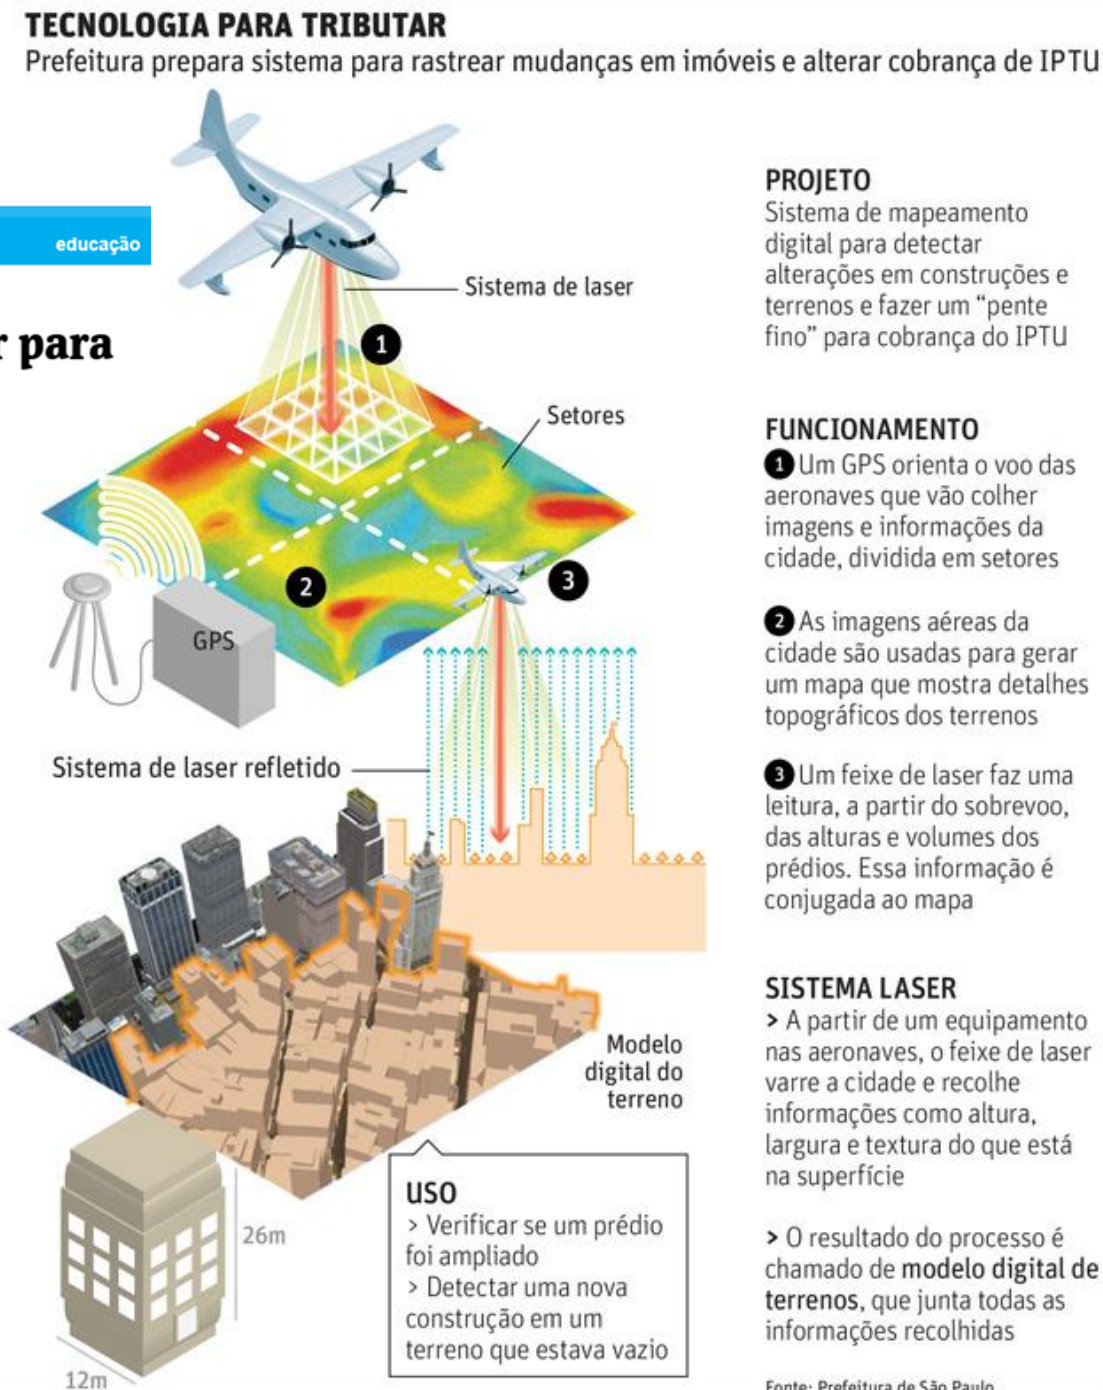
cotidiano

educação

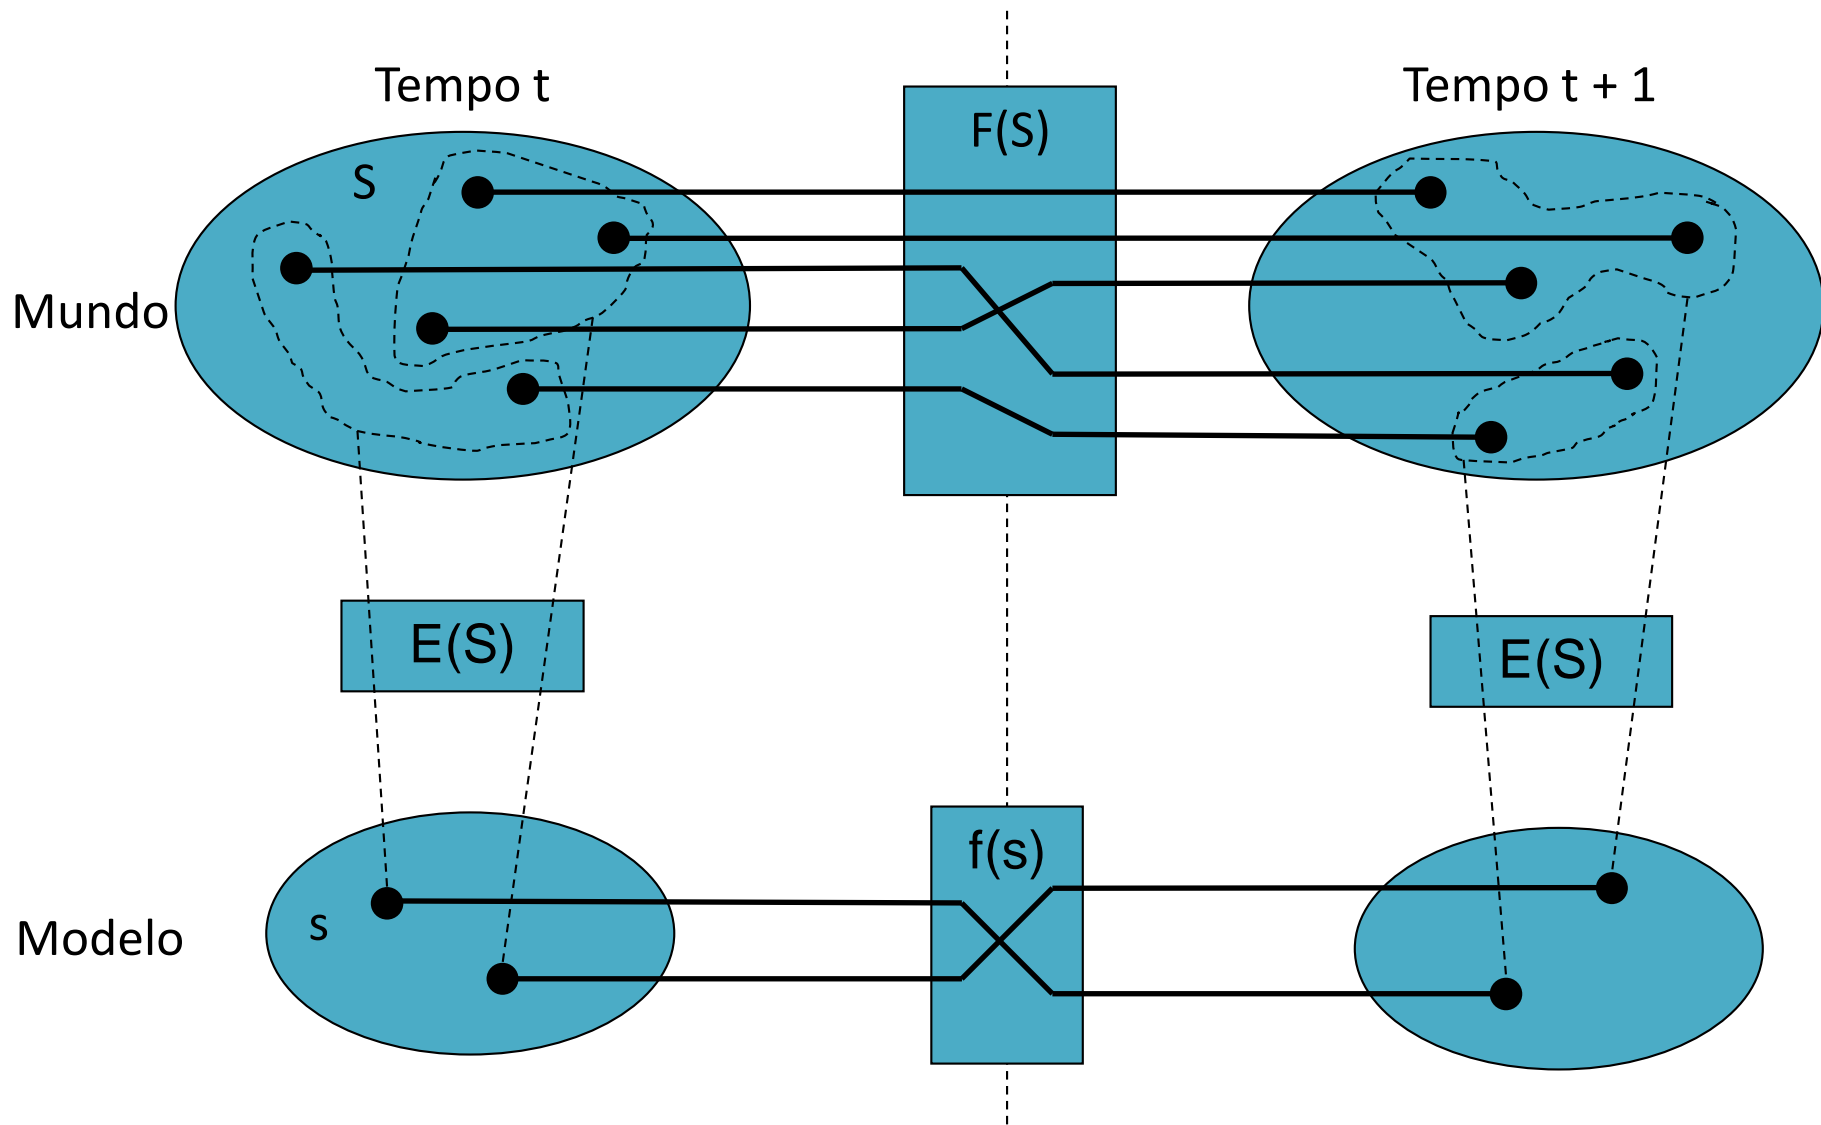
Prefeitura de SP vai utilizar laser para flagrar 'puxadinhos'

JOSÉ ERNESTO CREDENDIO
DE SÃO PAULO

22/09/2013 @ 03h00



Modelos Dinâmicos




Modelos Dinâmicos

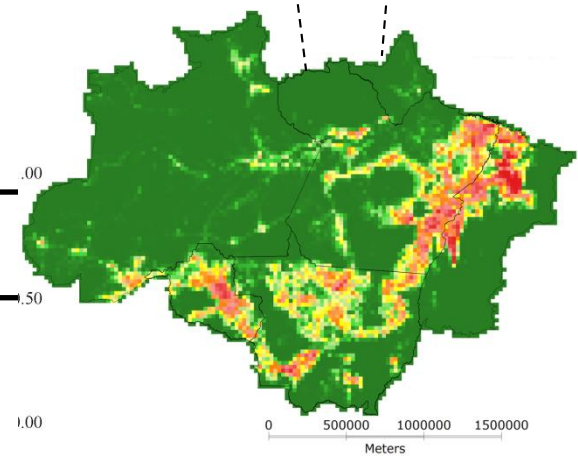


1997

2007


Mundo



Modelo




Modelos Espaciais Dinâmicos



“Um modelo dinâmico espacial é uma representação computacional de processos do mundo real em que um local na superfície da terra muda em resposta à variações dinâmicas internas e externas ” (Peter Burrough)

Autômatos Celulares


- Grade de células
- Vizinhança
- Conjunto finito de estados discretos
- Conjunto finito de regras de transição
- Estado inicial
- Tempo discreto




Tempo é discreto e o estado de cada célula em um tempo t é função do estado de seus vizinhos no tempo $t-1$.

Vizinhança

- A vizinhança representa a relação de proximidade de uma célula.



Von Neumann



Moore

Vizinhança e Regras


Vizinhança



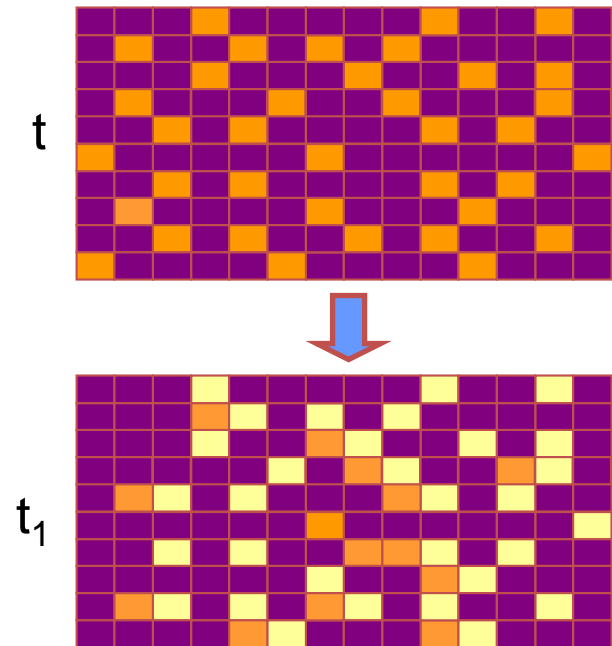
Estados



Regras

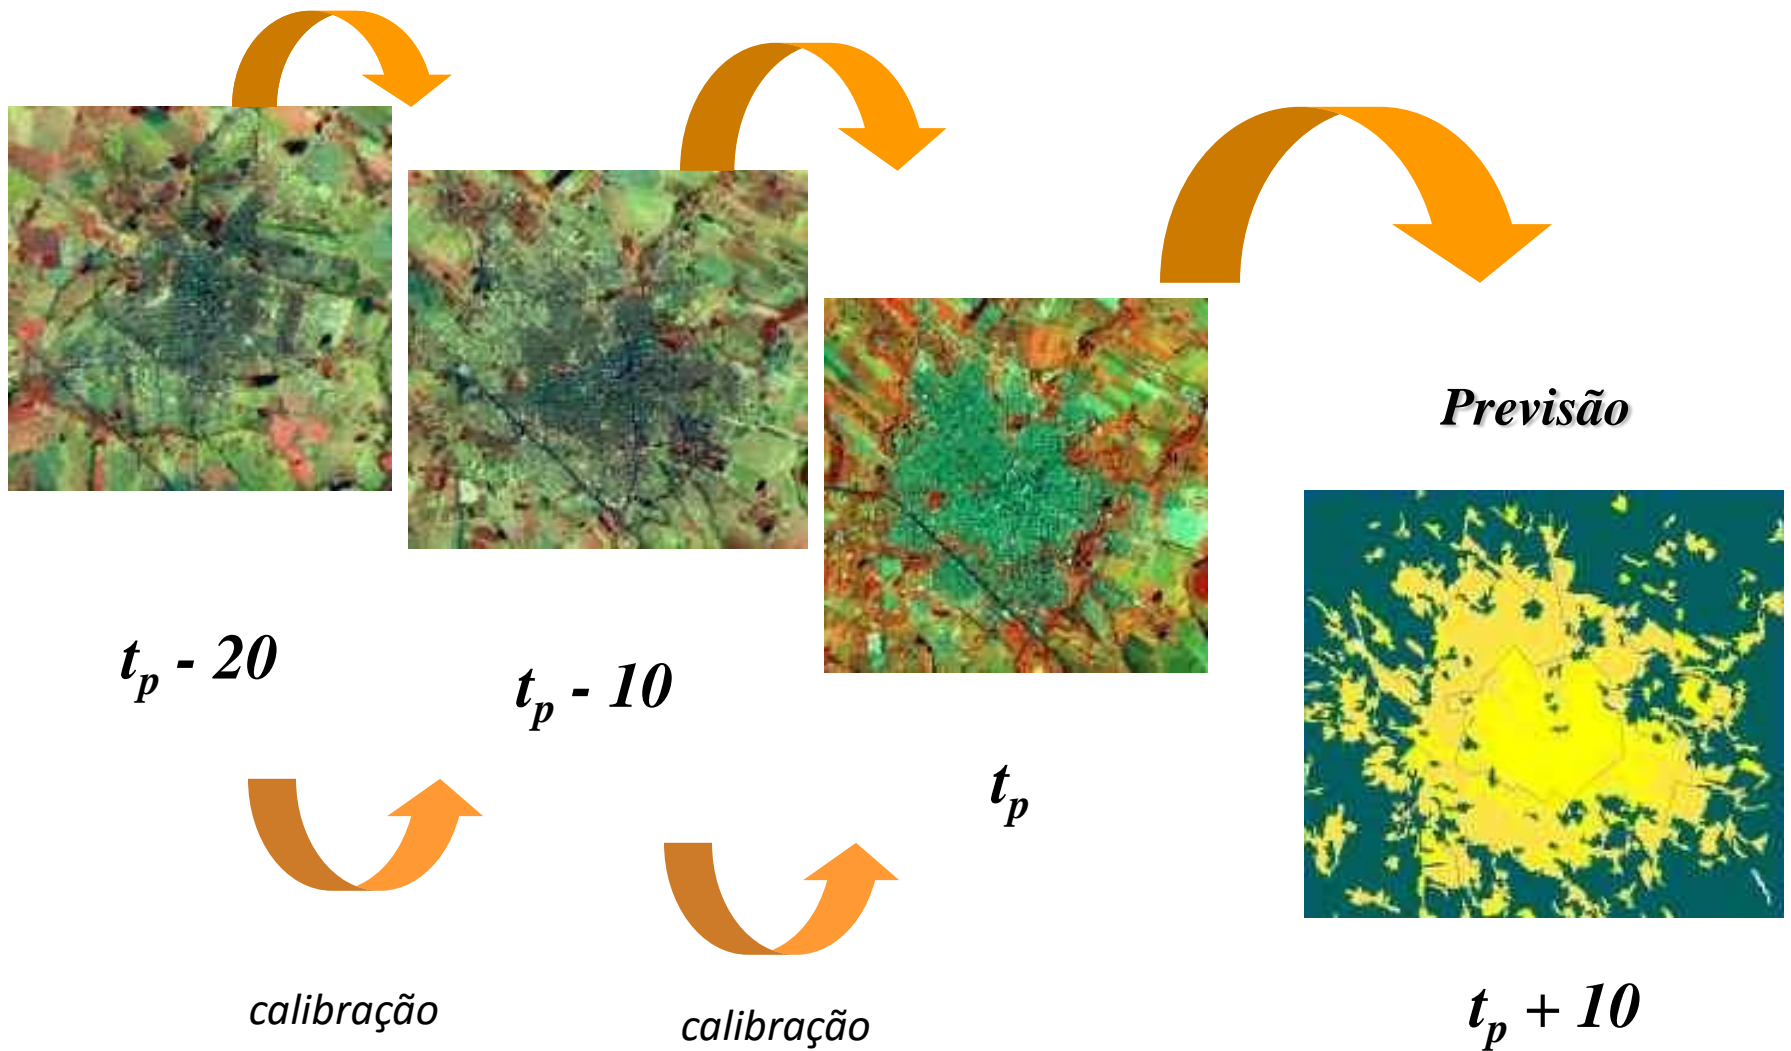


Espaço e tempo



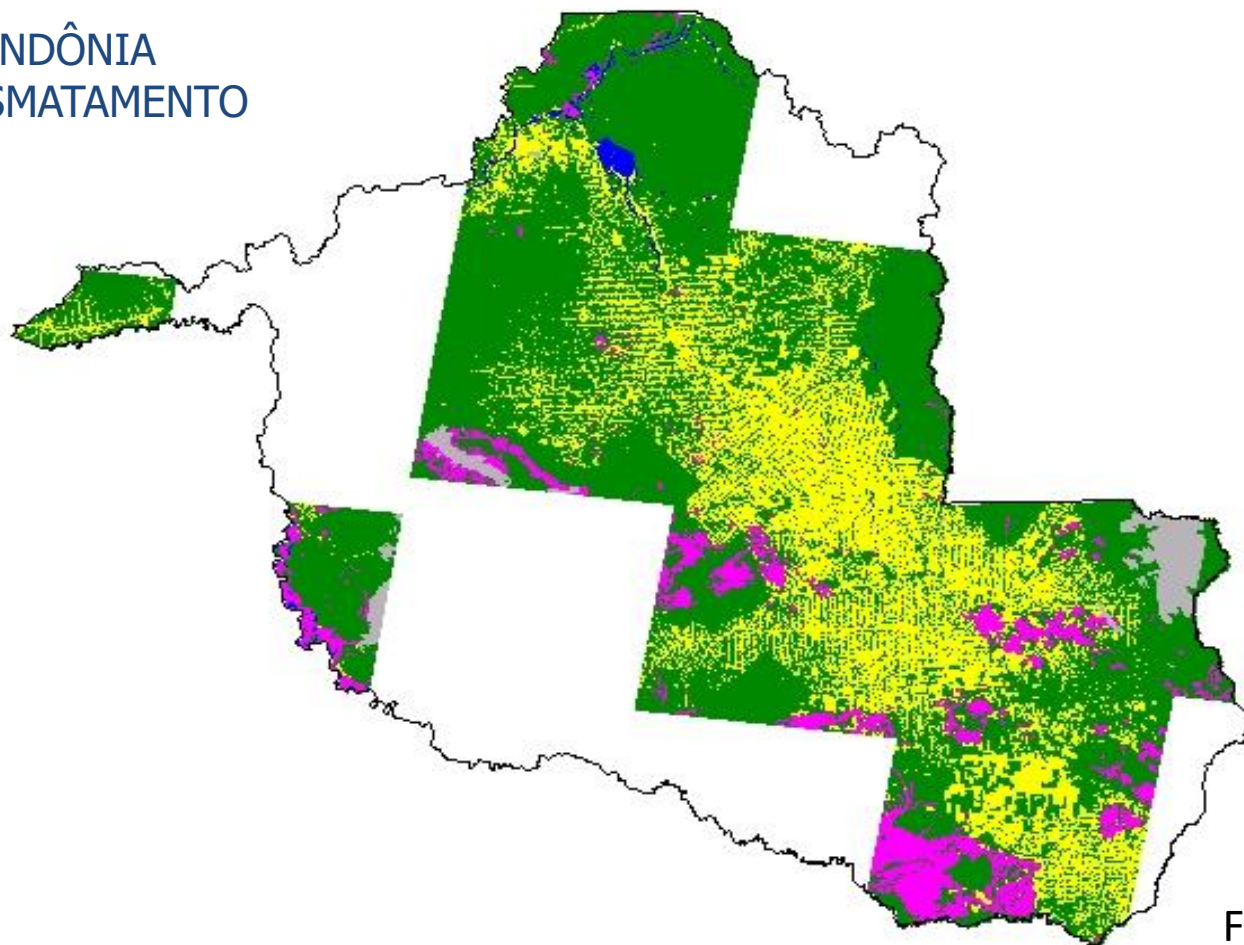
Cada célula é autônoma e muda seu estado de acordo com seu estado corrente e o estado de seus vizinhos.

Modelos Espaciais Dinâmicos




Nós Mapeamos o Passado

RONDÔNIA
DESMATAMENTO




Fonte: DPI / INPE

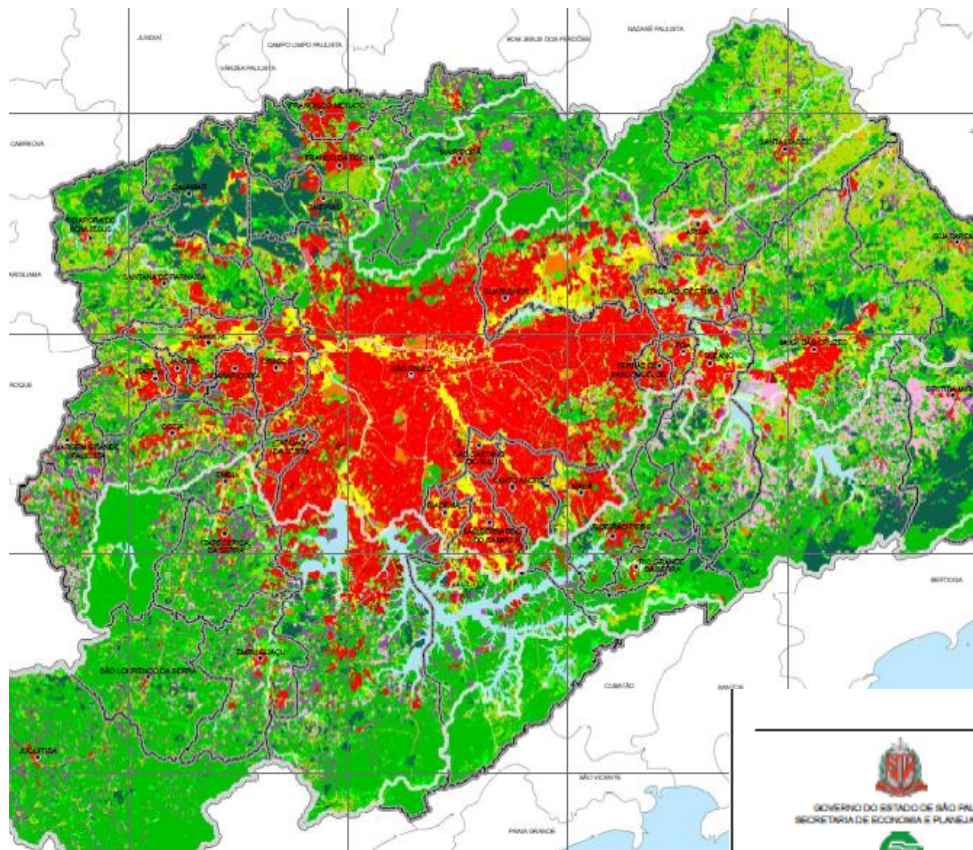
Como Prever o Futuro?



Amazônia em 2020?



O Território



CONVENÇÕES CARTOGRÁFICAS

-  Mata
-  Capoeira
-  Campo
-  Vegetação de Várzea
-  Reflorestamento
-  Hortifrutigranjeiro
-  Chácara
-  Área Urbanizada
-  Favela
-  Equipamento Urbano
-  Indústria
-  Loteamento Desocupado
-  Aterro Sanitário
-  Lixão
-  Mineração
-  Movimento de Terra / Solo Exposto
-  Reservatório de Retenção
-  Espelho D'água
-  Rodovia
-  Outro Uso
-  Sede de Município
-  Limite de Área de Proteção aos Mananciais
-  Limite Municipal (interno à RMSP)
-  Limite Municipal (externo à RMSP)
-  Limite RMSP


GOVERNO DO ESTADO DE SÃO PAULO
SECRETARIA DE ECONOMIA E PLANEJAMENTO


EPFLAB
Empresa Paulista de Planejamento Metropolitano S.A.


Fundo Estadual de Recursos Hídricos

USO E OCUPAÇÃO
DO SOLO DA RMSP

Escala 1:335.000

Revisão: Maio de 2008

Dados livres e GRANDES volumes (Big Data)

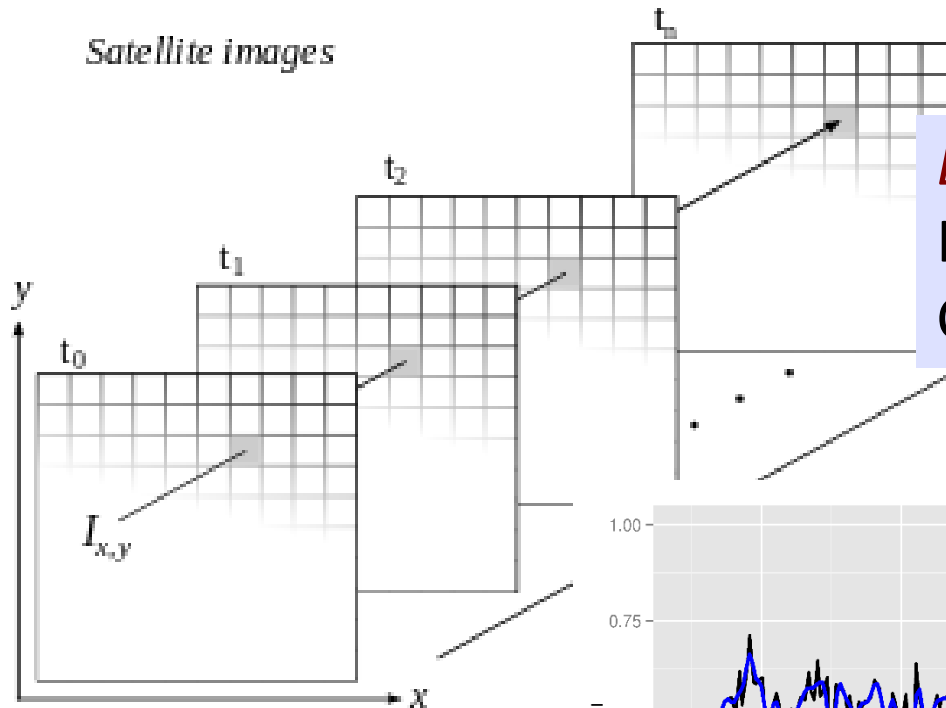
graphics: NASA




Sentinels + CBERS + LANDSAT + ...: > 10Tb/dia

Espaço primeiro, tempo depois ou *tempo primeiro e espaço depois?*

Satellite images




Espaço primeiro: classificar
Imagens separadamente
Comparar resultados no tempo



Tempo primeiro: classificar as series
temporais separadamente .
Juntar os resultados para ter os
mapas

Mineração de series temporais




Encontrar sequências em series temporais

Complexidade computacional alta
Padrões são idealizados, dados são “noisy”

Fonte: slide Gilberto Câmara / INPE

Esling & Agon (2012)


Big data: novas visões e conceitos



Como usar da melhor forma as informações do “big data”?

Multidimensional

Index 0	1	2	3	4	
0	65.340	12.483	138.189	902.960	633.877
1	5.246	424.642	650.380	821.254	866.122
2	89.678	236.781	601.691	329.274	913.534
3	103.902	4.567	733.611	263.010	85.550
4	2.778	658.305	128.788	978.155	620.702
5	45.024	55.058	705.586	89.672	384.605
6	780	47.538	523.784	556.801	617.107
7	32.667	350.890	834.753	638.108	85.188
8	56.083	145.582	775.040	548.322	756.587
9	41.123	543.542	537.738	513.048	418.482



$$g = f (\langle x, y, z \rangle [a_1, \dots, a_n])$$

Sugestão de Bibliografia

MORAES NOVO, Evlyn L.M. Sensoriamento Remoto: Princípios e Aplicações. 3ª Edição. São Paulo: Blucher, 2008.

CRÓSTA, A. P. Processamento digital de imagens de sensoriamento remoto. Edição revisada. Campinas. IG/UNICAMP, 1993.

JENSEN, John R. Sensoriamento Remoto do Ambiente – Uma Perspectiva em Recursos Terrestres. 2ª Edição. São José dos Campos: Parêntese, 2009.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Remote sensing and image interpretation. 5. ed. New York: John Wiley & Sons, 2004. 763 p.

Obrigada!!!

mariana.giannotti@usp.br