



Instituto Tecnológico de Aeronáutica
Engenharia Eletrônica e Computação

CLASSIFICAÇÃO DE AMOSTRAS DE IMAGENS GEO-REFERENCIADAS PARA CORREÇÃO GEOMÉTRICA DE IMAGENS DOS SATÉLITES CBERS

Emiliano F. Castejon

Orientadores

Carlos Henrique Quartucci Forster - ITA

Leila Maria Garcia Fonseca - INPE

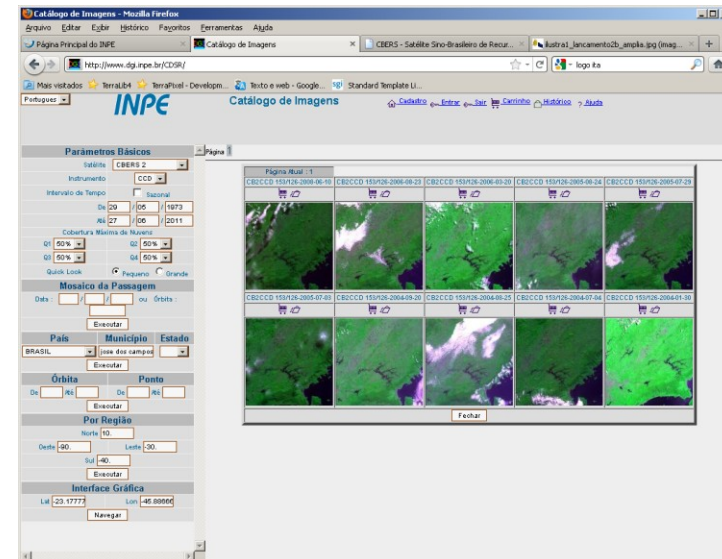
São José dos Campos – Julho de 2011

A série de satélites CBERS (*Brazil Earth Resources Satellite*)

- Resultado de cooperação entre Brasil e China.
- Política de dados livres (catálogo de imagens) <http://www.dgi.inpe.br/CDSR/>
- Câmeras a bordo: WFI, IRMSS, **CCD (20m x 20m)**, HRC



CBERS-2B

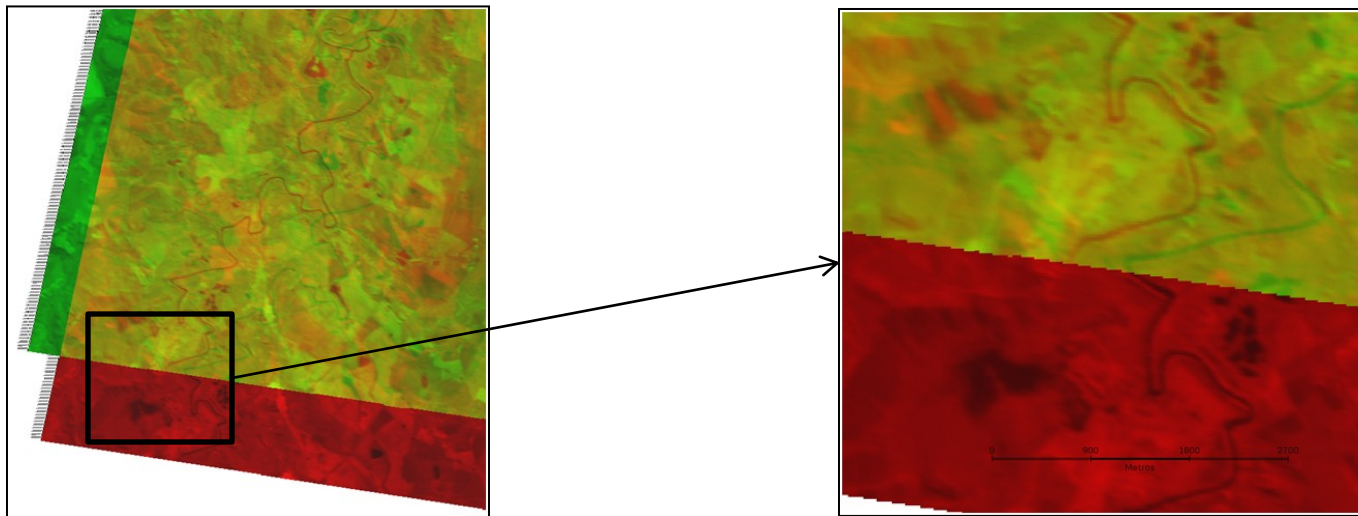


Imagens CBERS CCD – Níveis de correção geométrica

- **Nível 0 – Imagem em estado bruto (formato interno apenas para armazenamento, intercâmbio)**
- **Nível 1- Imagem com correção radiométrica, com calibração de detectores e redução de ruído**
- **Nível 2- Imagem com correção geométrica, geo-referenciada, **distorções geométricas ainda presentes** (erro de posicionamento do satélite)**
- **Nível 3 – Imagem georeferenciada, com posicionamento correto, refinado por pontos de controle.**

Imagens CBERS CCD distribuídas para usuários

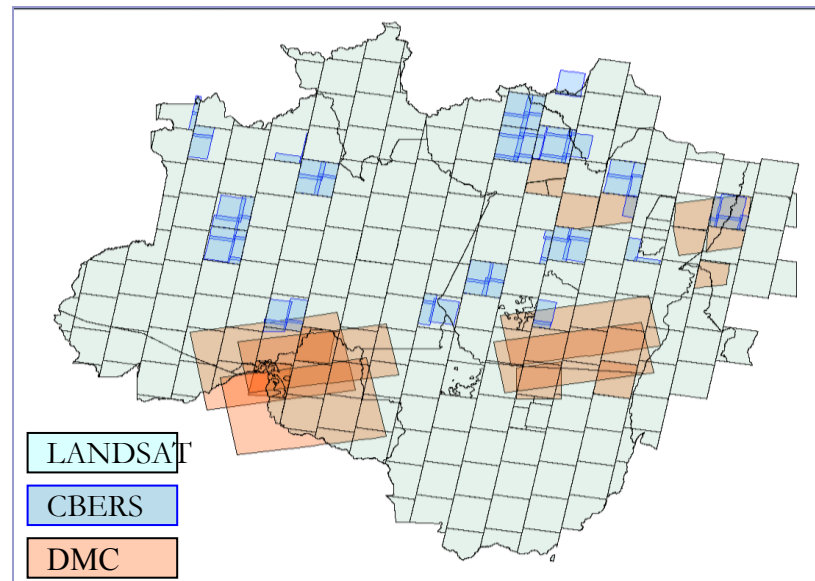
- Possuem **nível 2** de correção geométrica.
- Apresentam **distorções** (deslocamento, etc.)
- Fica a cargo do **usuário efetuar a correção**



Deslocamento (~2500m) de uma imagem CBERS2 CCD em relação à respectiva imagem corrigida

Correção das imagens CBERS/CCD

- **Dificuldades encontradas pelos usuários**
 - O **tempo** gasto na correção é alto.
 - **Nem sempre é factível**: diferentes sensores, variações de iluminação, variações temporais, ruído.




SisProdes – Detecção de áreas de desflorestamento dentro da Amazônia legal.

Mais de 400 imagens (CBERS+LANDSAT+DMC)

Correção das imagens CBERS/CCD

- Solução: **correção automática (nível 3)**
 - Baseada no método proposto pela **USGS** (United States Global Land Survey)
 - Feita na própria **estação terrena**
 - O usuário já receberia a imagem com o nível 3 de correção
 - Usa imagens corrigidas como referência (*kernel*s)


LANDSAT (corrigida)




Correção das imagens CBERS/CCD

- **Nível 3: Problema** - Nem todos os kernels tem boa qualidade


O ponto central define o centro do kernel gerado




Ruído na imagem




Oclusão/Nuvens




Oclusão/Nuvens





Culturas sazonais



Corpos d'água

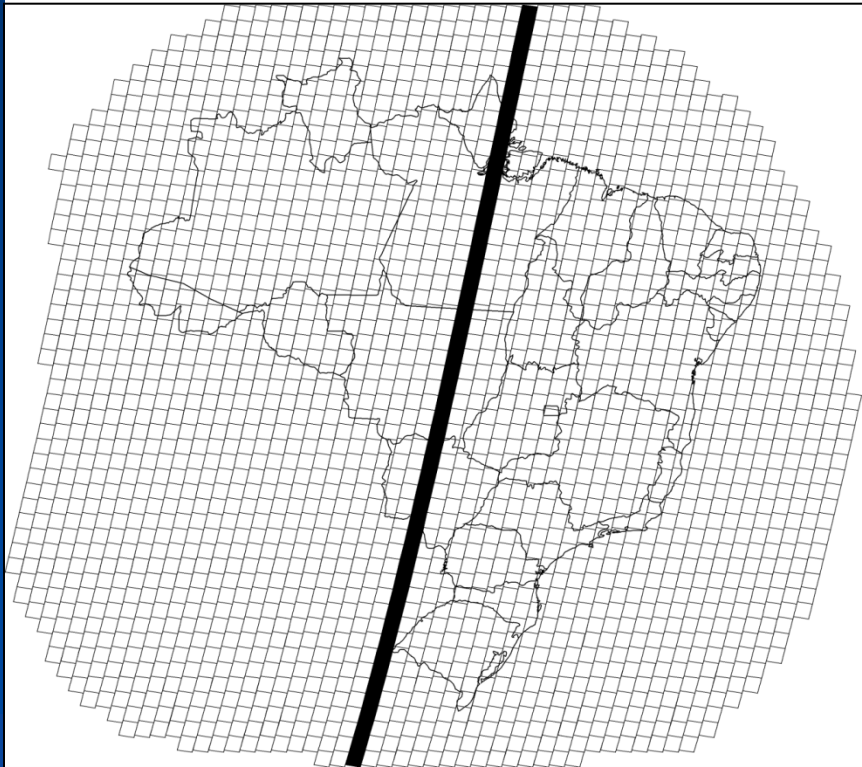


Relevo/variação de luminosidade



Correção das imagens CBERS/CCD

- **Dificuldades** na correção automática:
 - **Tempo** de execução alto
 - Todos os *kernels* são usados (incluindo *kernels ruins*)
 - Vários **casamentos** de *kernels* **falham**



CBERS/CCD:

3 passagens diárias
Média de 20 cenas por passagem
5 bandas por cena

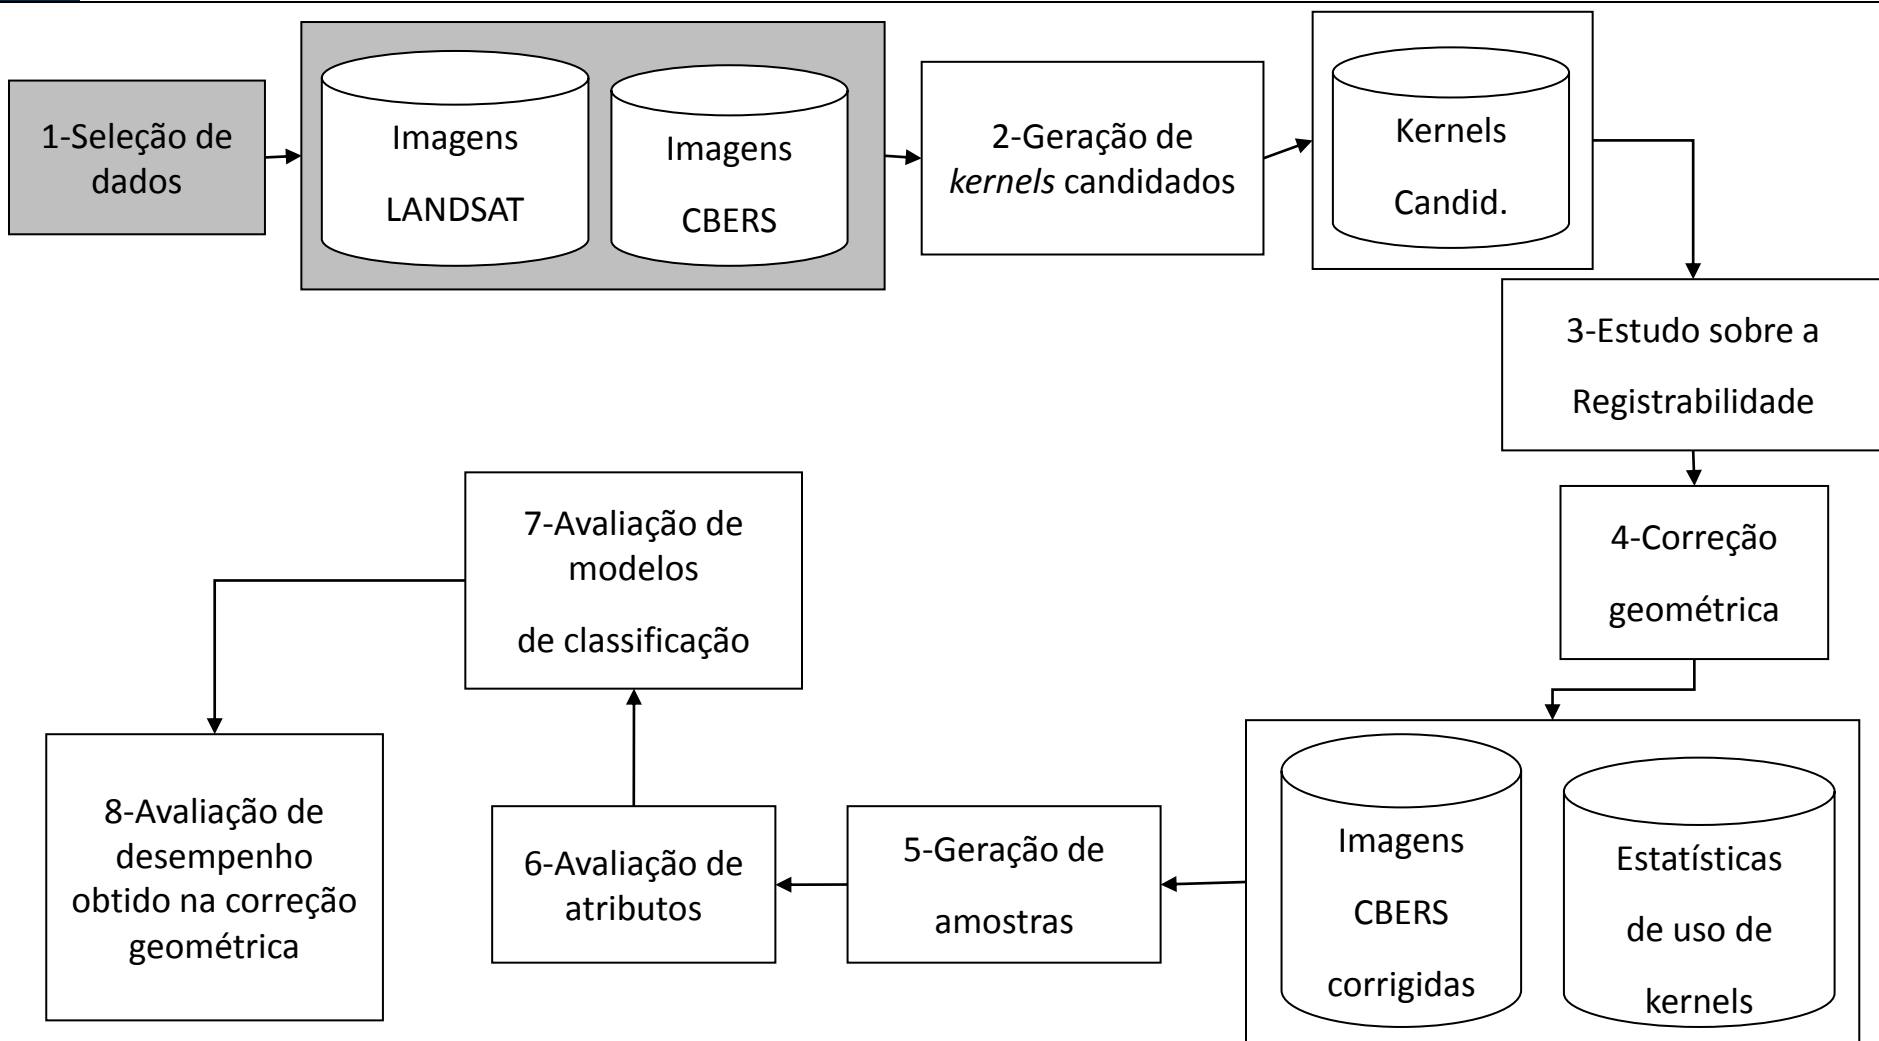
$3 * 20 * 5 = 300$ imagens CCD diárias

Tempo de processamento L2>L3 por cena:
~30 minutos (~3000 kernels por cena,
software multiprogramado (threads),
hardware Xeon de 8 núcleos, 2Ghz

Objetivos


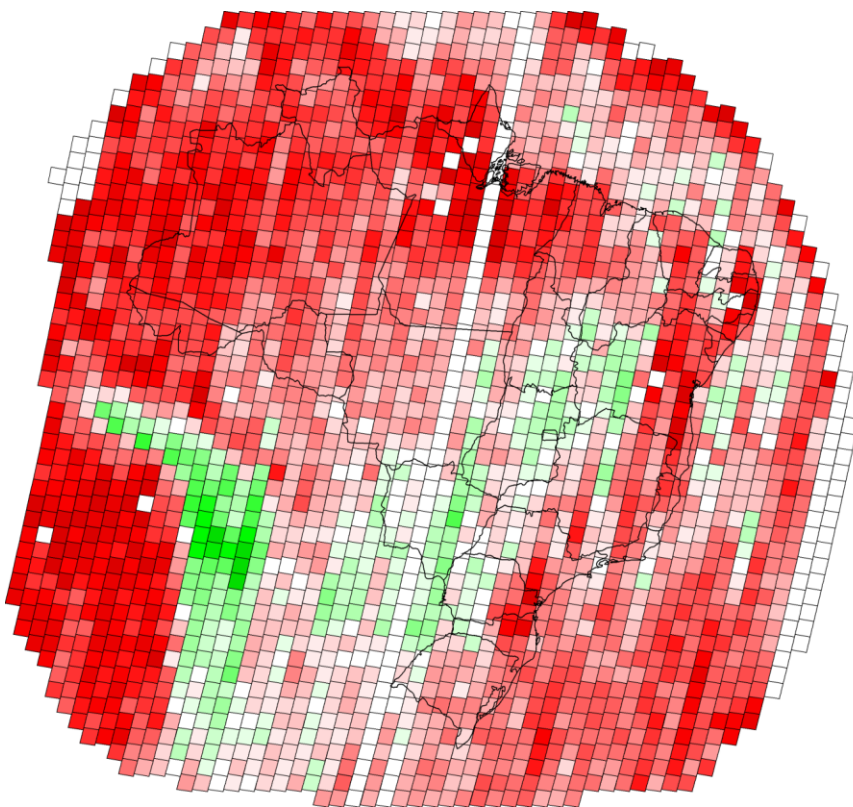
- Obter maior **qualidade** das imagens geradas (corrigidas)
- Obter melhor **desempenho** (menor tempo de execução)
- Metodologia
 - **Aperfeiçoar** do processo de correção geométrica
 - Incluir um **processo para classificar *kernels*** segundo o grau de contribuição no processo de correção geométrica.
 - **Validar** a método aperfeiçoado usando imagens CBERS/CCD.

Metodologia – Seleção de imagens



Metodologia – Seleção de imagens CBERS


- Busca no catálogo CBERS
 - Regiões com maior **disponibilidade** de cenas
 - Seleção manual das **melhores regiões** (cobertura de nuvens, várias **datas**)




Metodologia – Seleção de imagens CBERS

- Regiões da grade CBERS selecionadas:


22 imagens-Paratinga(153/114)




22 imagens-Bom Jesus da Lapa(153/115)



23 imagens-Iguatemí(162/126)




18 imagens-Iguatemí(162/126)



Metodologia – Avaliação das imagens CBERS


- Análise dos deslocamentos
 - Auxiliar a definição dos parâmetros de correção



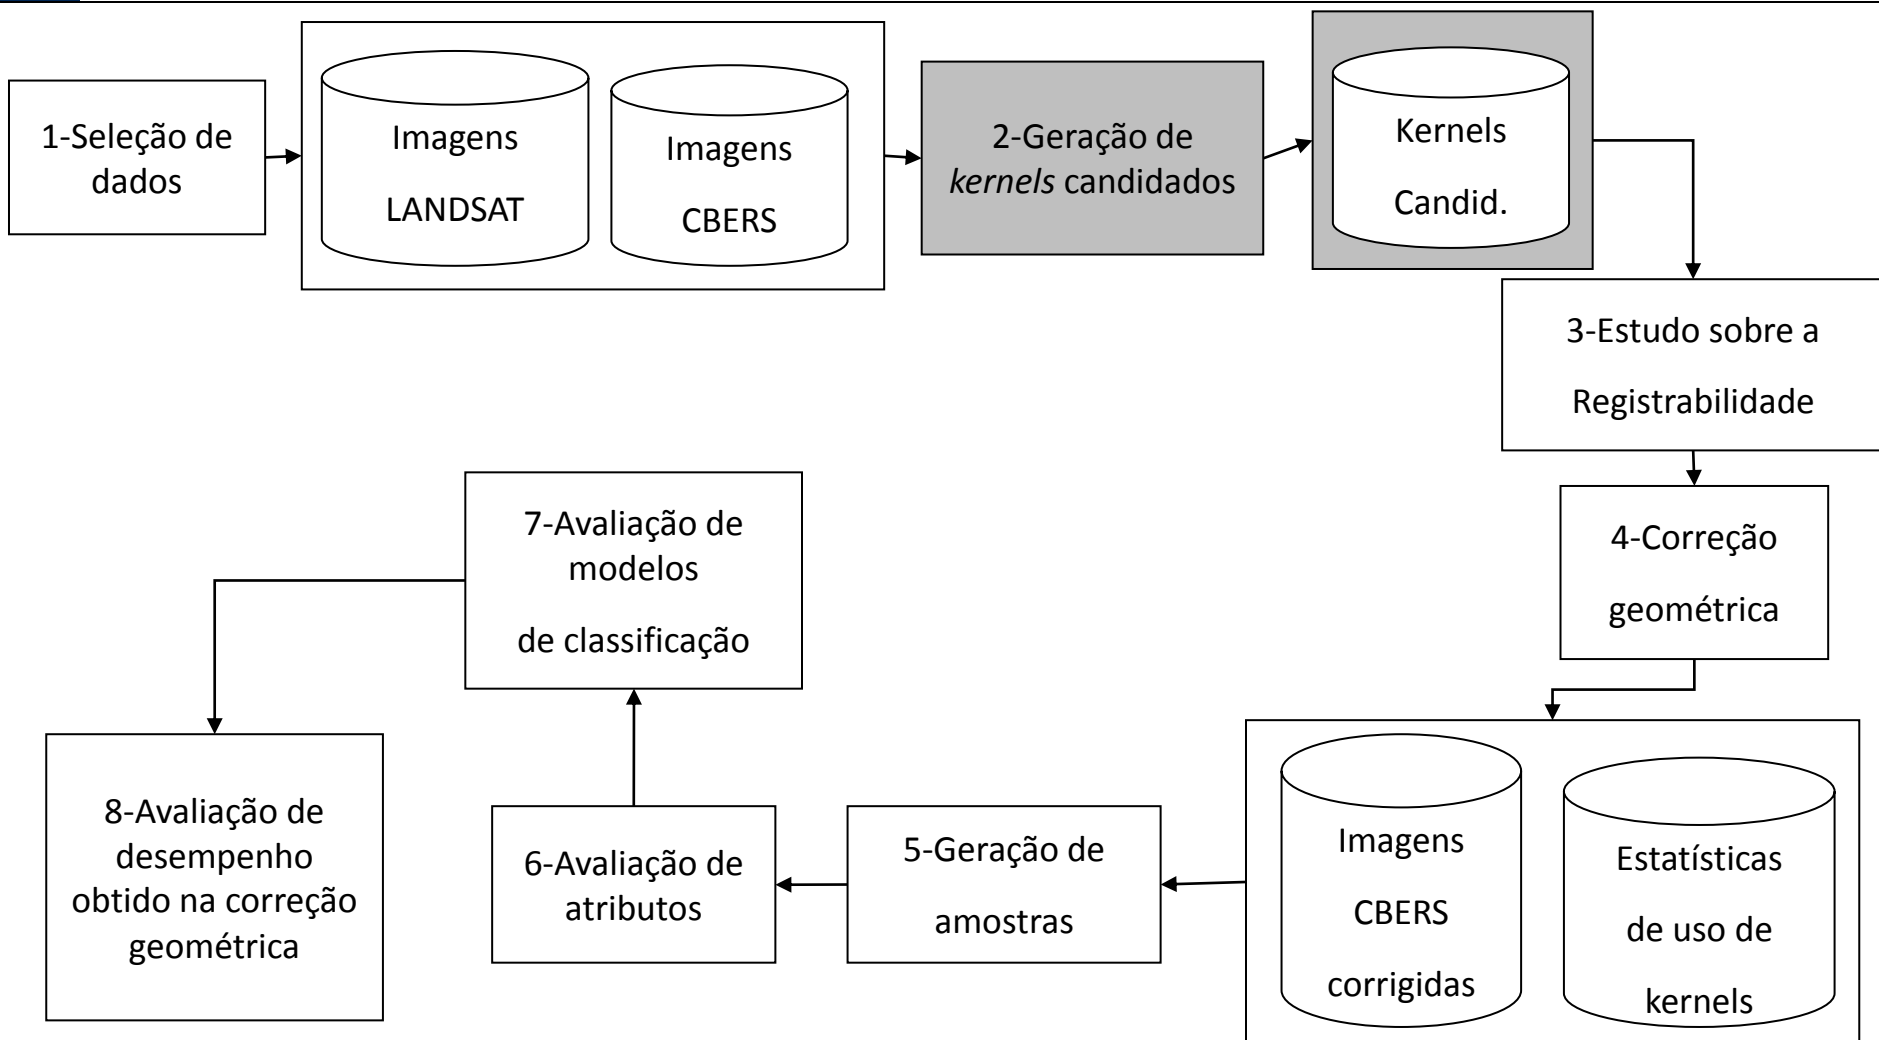
Metodologia – Seleção de imagens

LANDSAT(referência)

- Busca das respectivas imagens LANDSAT (USGS) ortoretificadas (nível 4)




Metodologia - Geração de kernels candidatos



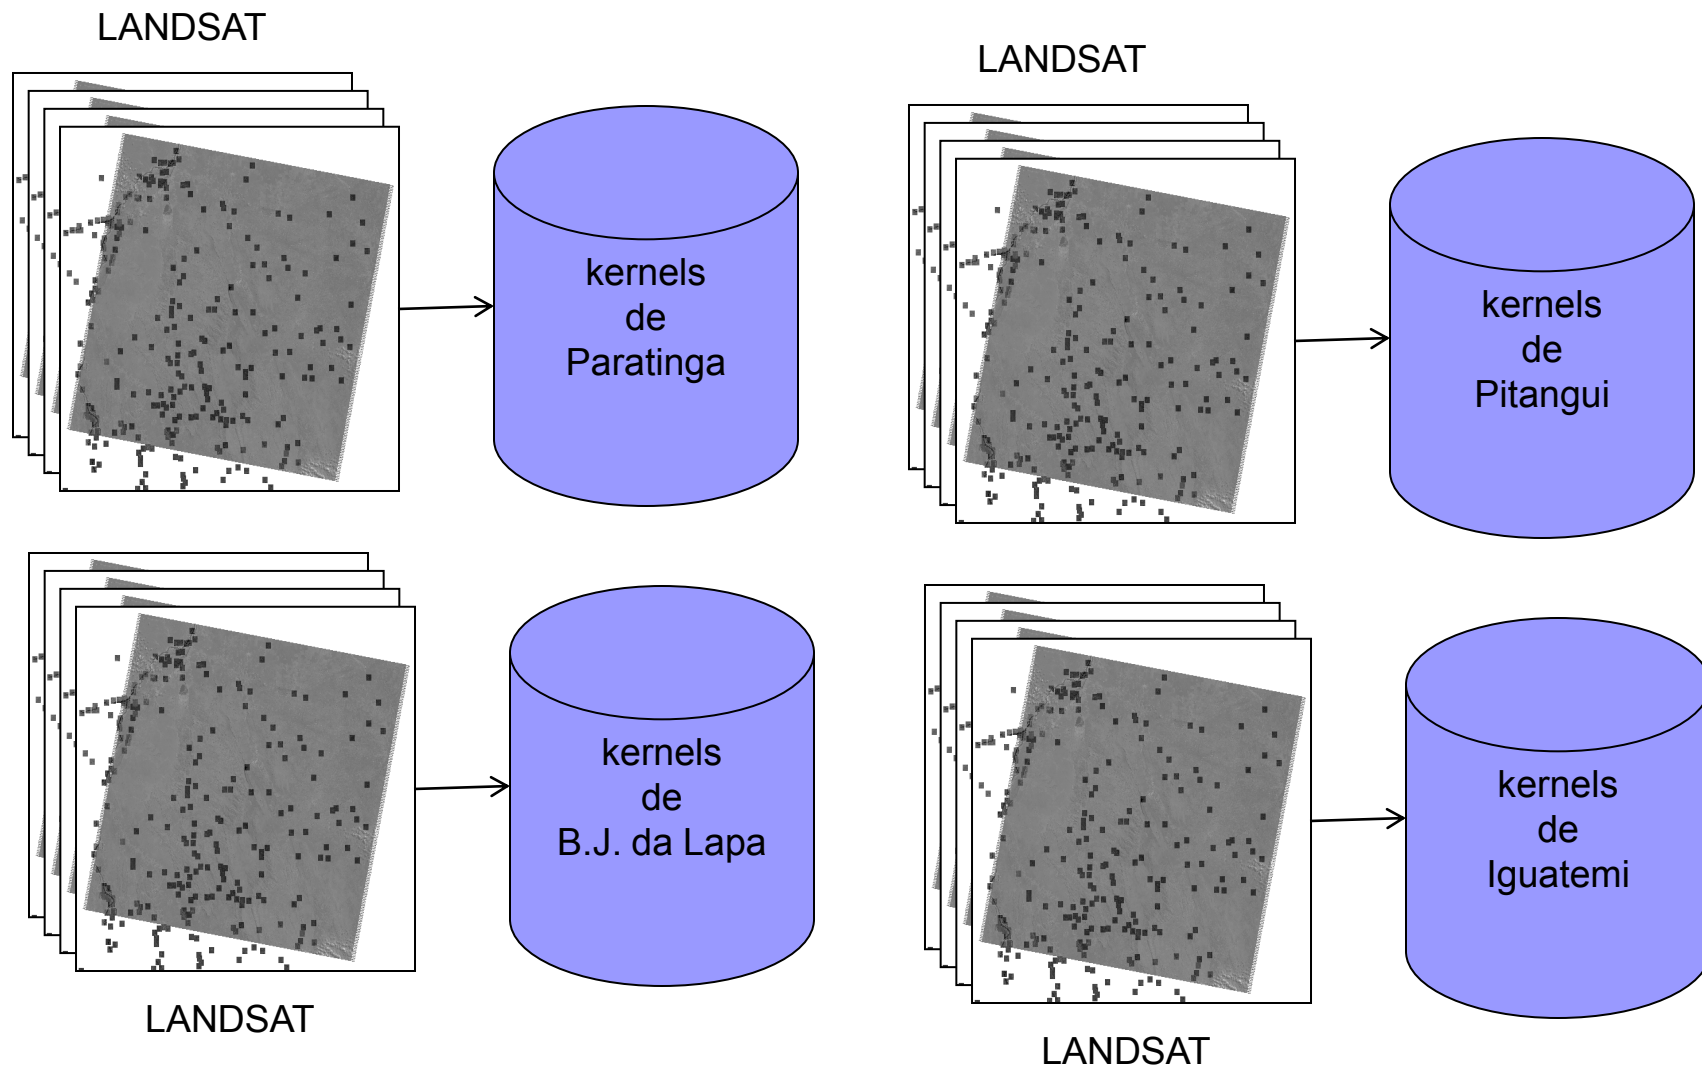
Metodologia - Geração de kernels candidatos

- Geração de *kernels*: Operador de **Moravec** define as posições onde serão recortados os *kernels* (*segundo o método proposto pela USGS*)

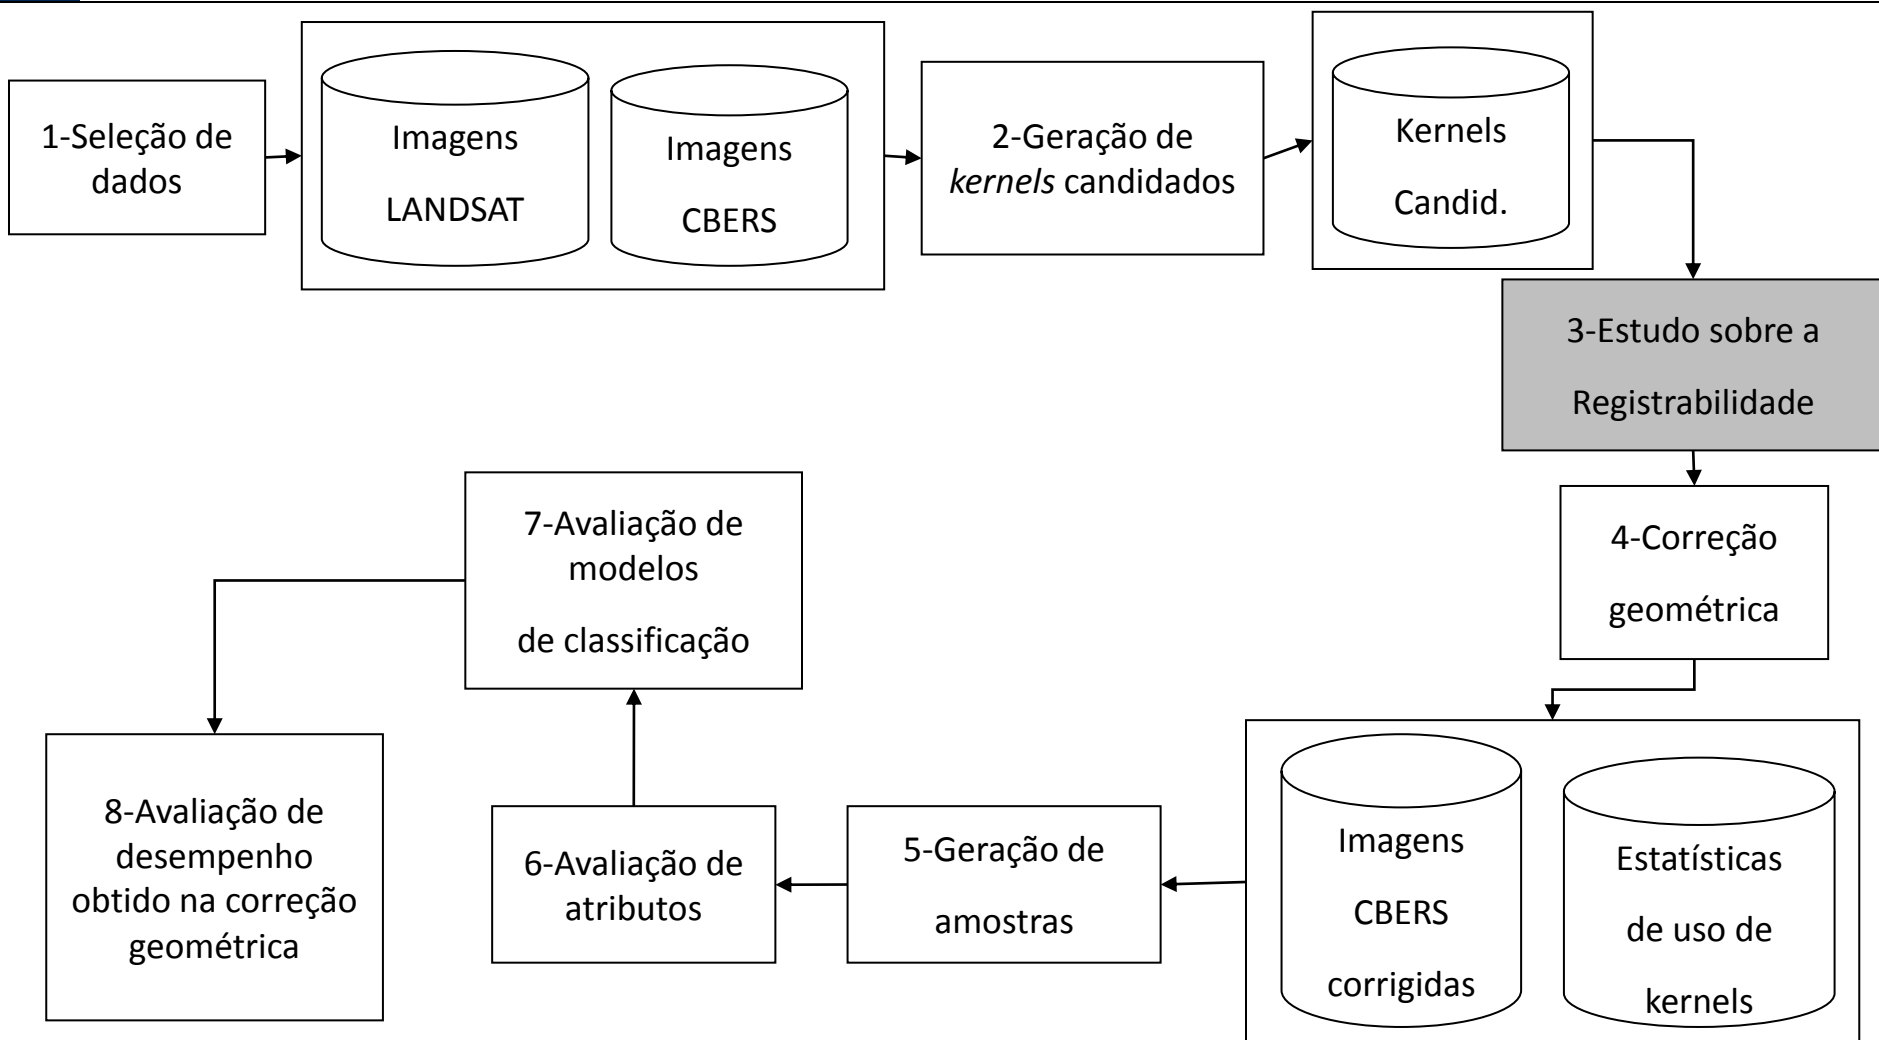
LANDSAT (corrigida)



Metodologia – Geração de kernels candidatos

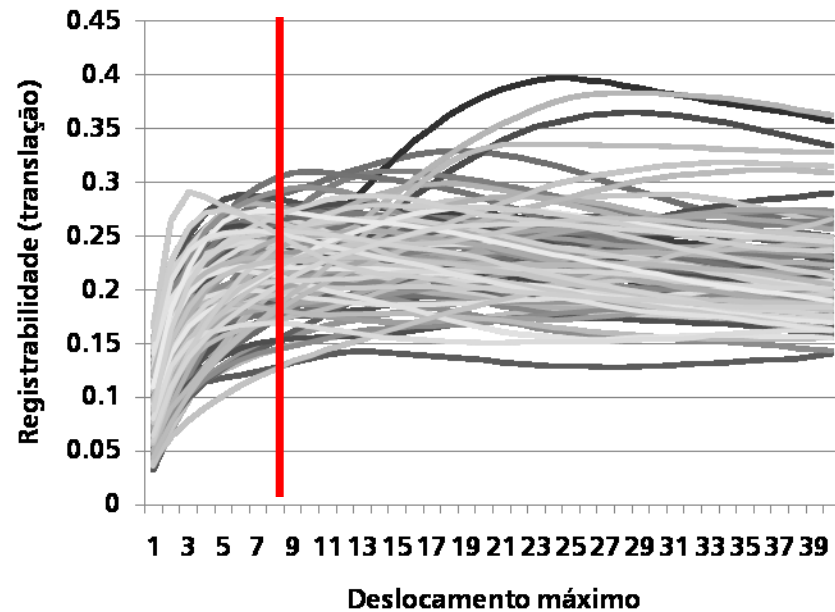
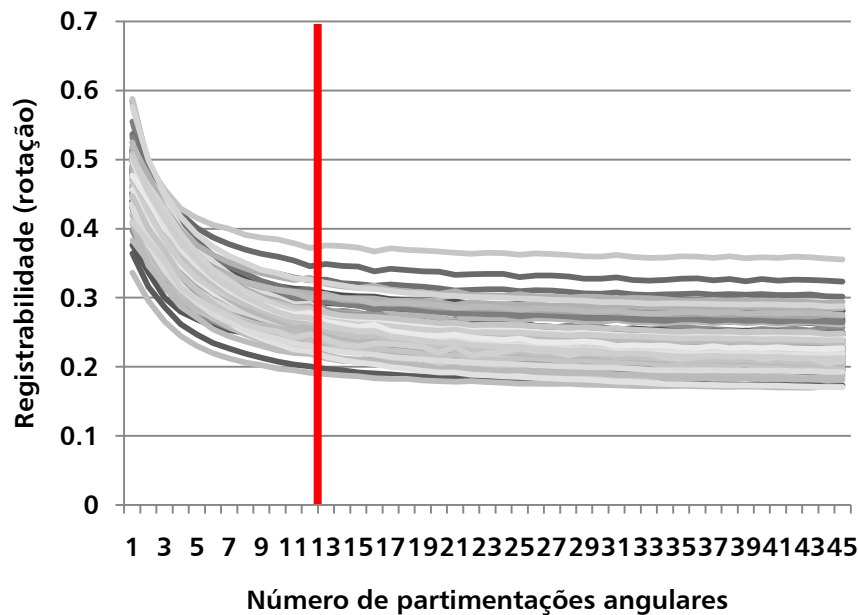


Metodologia – Estudo sobre registrabilidade

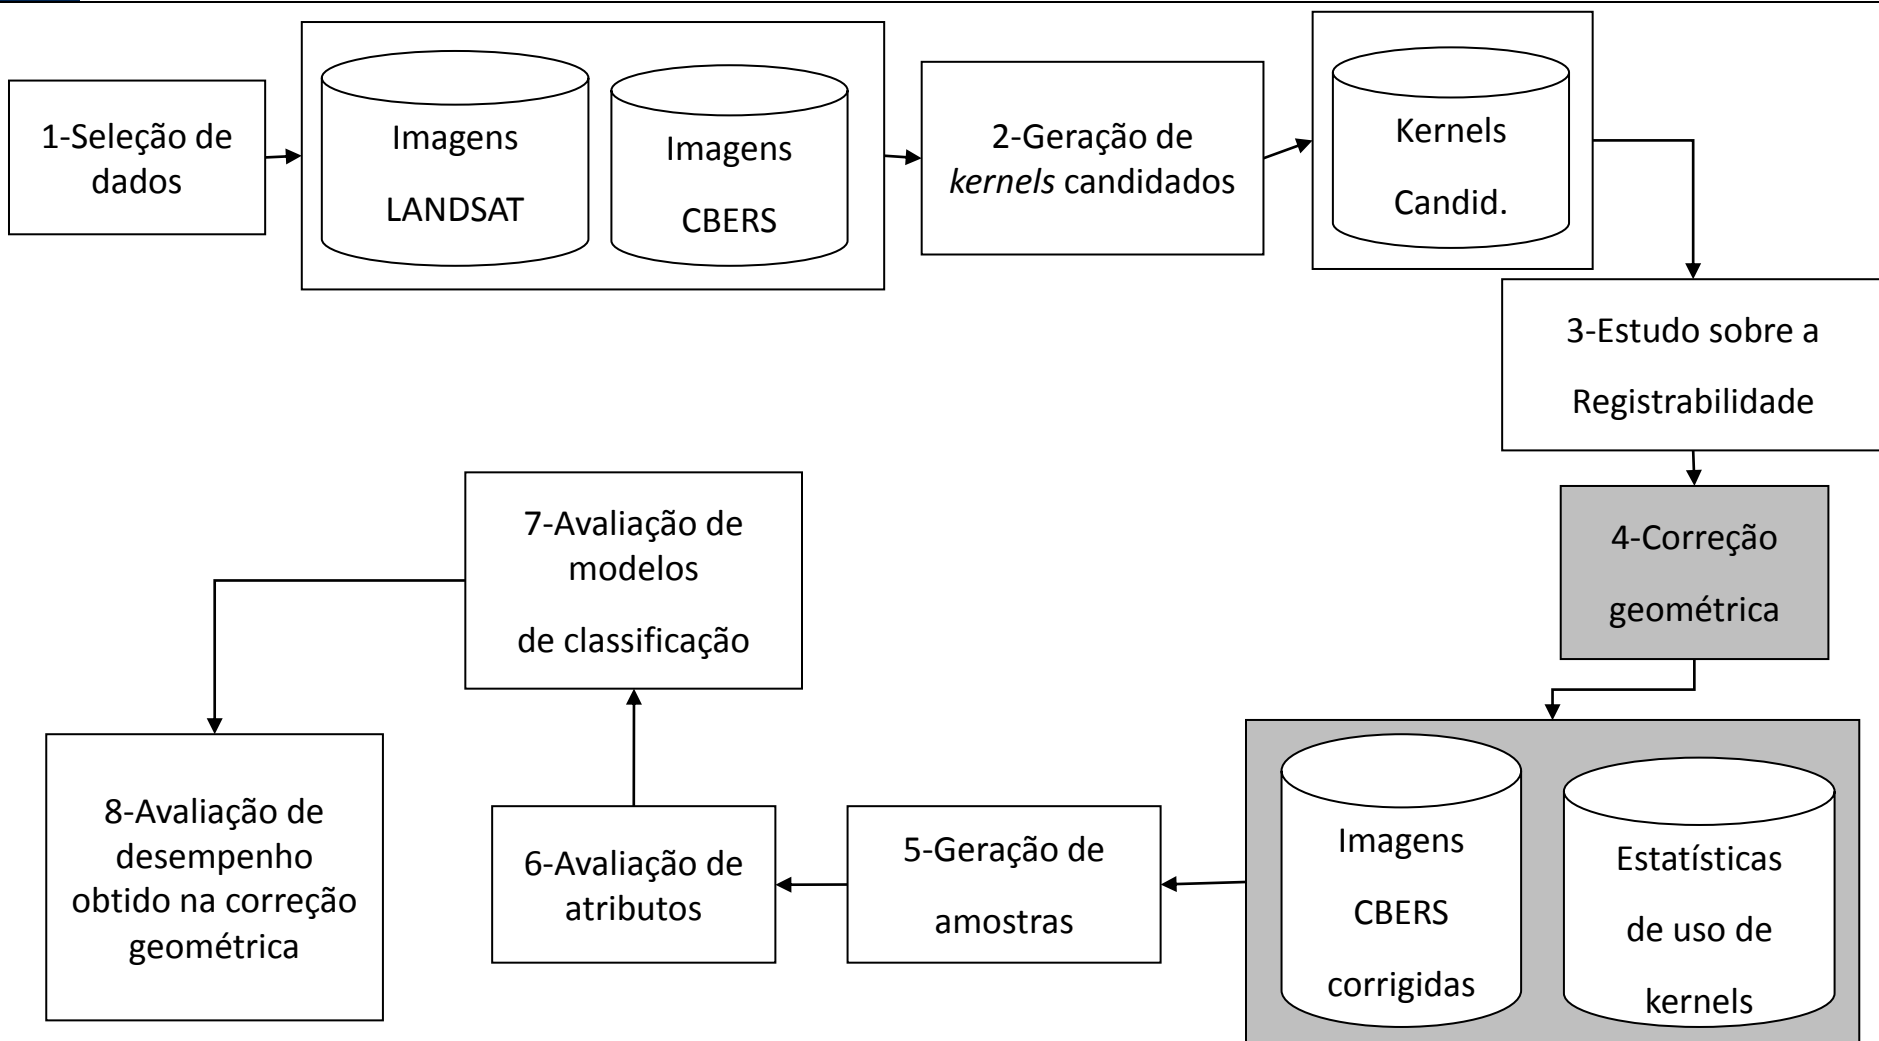


Metodologia – Estudo sobre o atributo de registrabilidade

- Atributo de **registrabilidade**: expressa a probabilidade de se obter um bom casamento/registro de uma imagem.
- É **dependente** do tipo de **transformação geométrica**.
- É necessário definir os parâmetros de transformação para o cálculo da registrabilidade.
- Transformações usadas: rotação e translação.




Metodologia – Correção geométrica




Metodologia – Correção geométrica

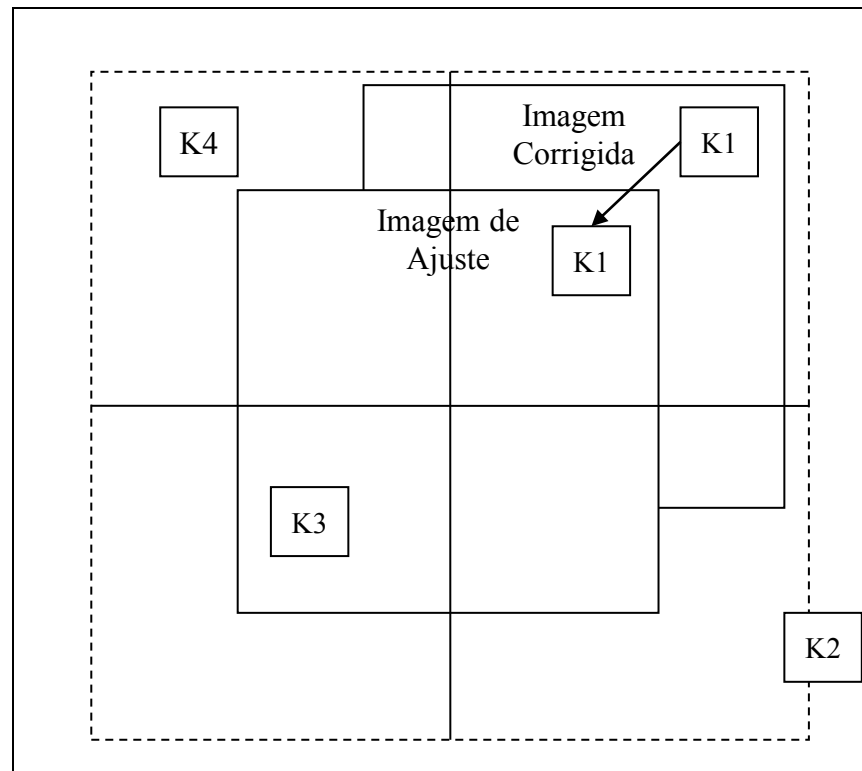
- Objetivos
 - Reproduzir e aperfeiçoar o método de correção geométrica
 - Gerar estatísticas de uso de *kernels*




Metodologia – Correção geométrica



- Etapa 1 – Localização de *kernels* geograficamente compatíveis pelo conhecimento do erro aproximado das imagens.



Metodologia – Correção geométrica



- Etapa 2 – Localização da melhor posição de cada kernel na imagem de ajuste (imagem a ser corrigida)
- Geração de pontos de controle candidatos
- Métrica de similaridade: **Coeficiente de correlação**


Artigo referência:

Castejon, E. F., Forster, C.H.Q., Fonseca, L.M.G. Marcari Junior, E. “Avaliação de métodos de casamento de imagens para mosaico de imagens orbitais”. XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 6805-6812.

Coeficiente de correlação


$$C(i, j) = \frac{\sum_{l=0}^{k-1} \sum_{m=0}^{L-1} (W_z(l, m) - \mu_w)(S_{i,j}(l, m) - \mu_s)}{\sqrt{\sum_{l=0}^{k-1} \sum_{m=0}^{L-1} (W_z(l, m) - \mu_w)^2 \sum_{l=0}^{k-1} \sum_{m=0}^{L-1} (S_{i,j}(l, m) - \mu_s)^2}}$$

Metodologia – Correção geométrica

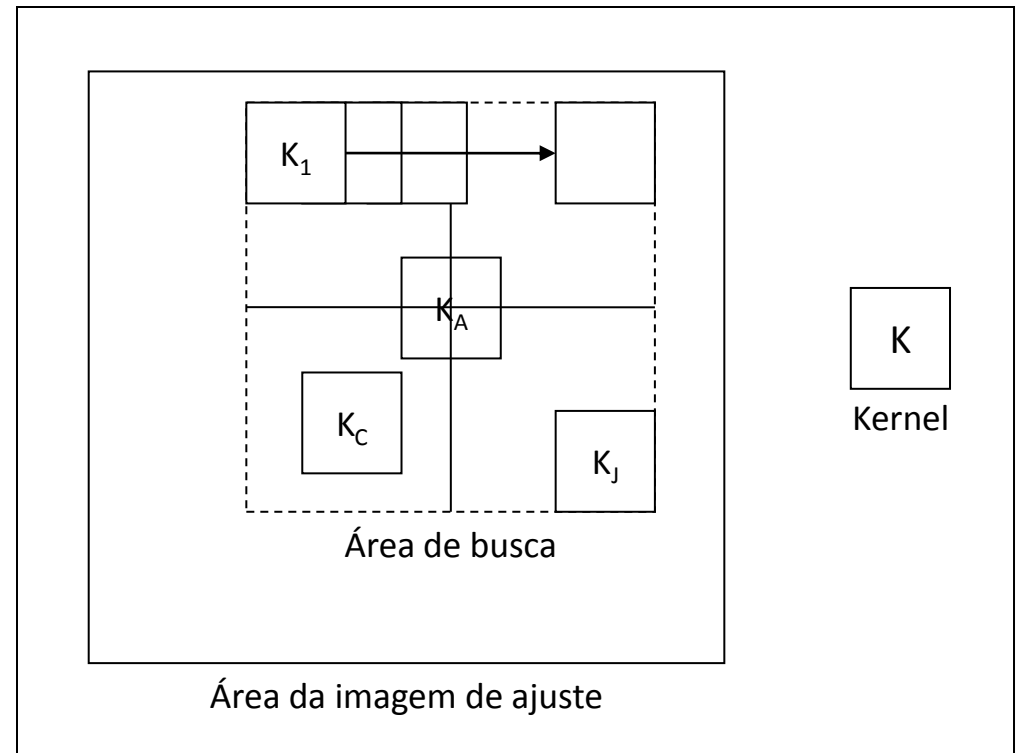



- Etapa 2 – Localização da melhor posição de cada kernel na imagem de ajuste (imagem a ser corrigida)


Kernels



Áreas de Busca



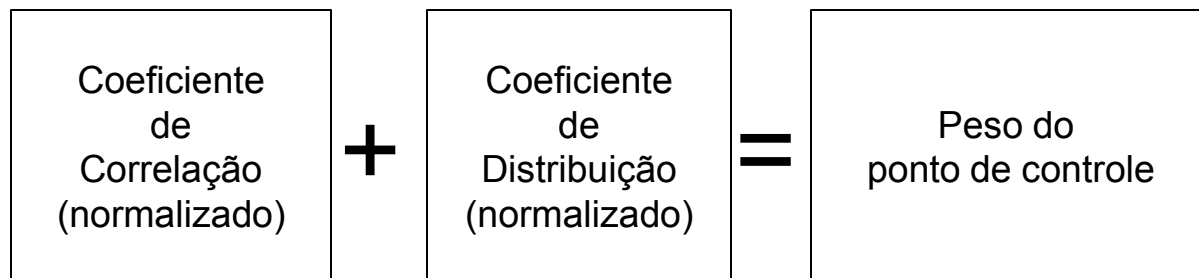

Metodologia – Correção geométrica




- Etapa 3 – Cálculo dos parâmetros da transformação geométrica
 - Uso de uma variação do método RANSAC

Artigo referência:

Castejon, E. F., Forster, C.H.Q., Fonseca, L.M.G. Korting, T.S. “Orbital image correction for multiple models of geometric transformations”. XV Simpósio Brasileiro de Sensoriamento Remoto, Curitiba, Brasil, 30 Abril 2011, INPE, p. 7448.

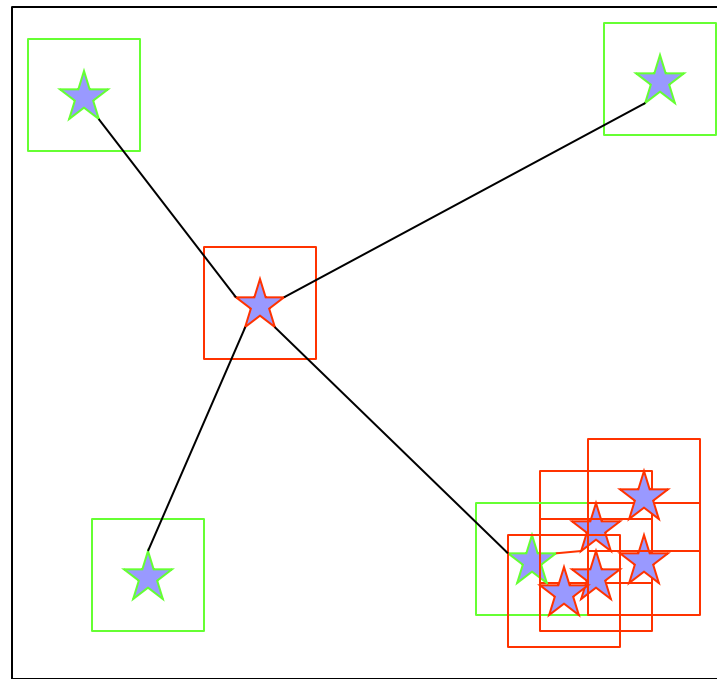


Metodologia – Correção geométrica




- Etapa 3 – Cálculo dos parâmetros da transformação geométrica
 - "Coeficiente de distribuição": Evitar que aglomerações de pontos prejudiquem ou inviabilizem o cálculo dos parâmetros da transformação geométrica


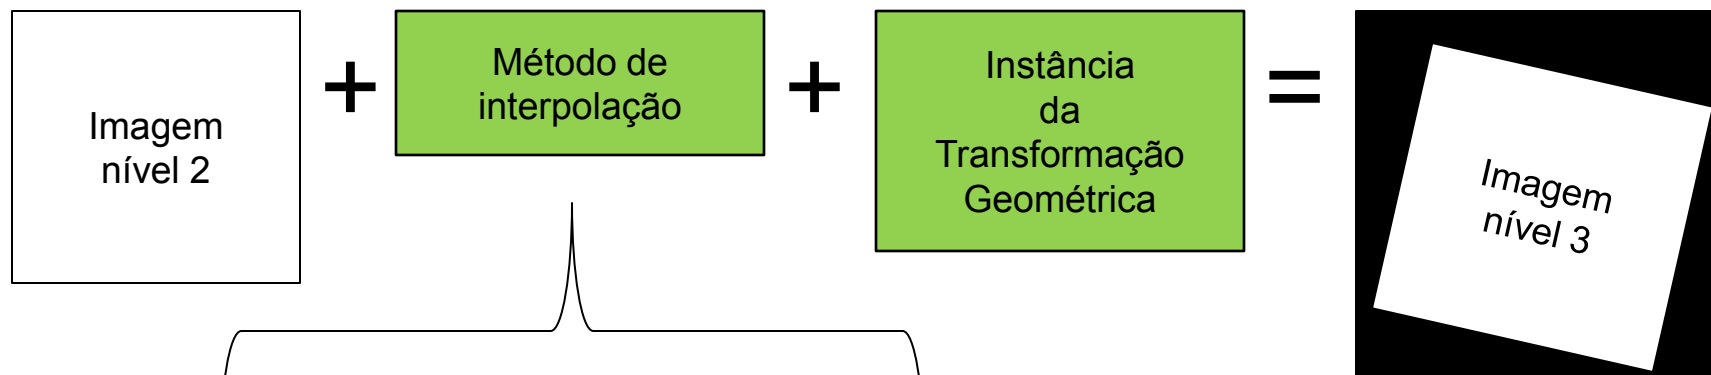
Área da imagem de ajuste



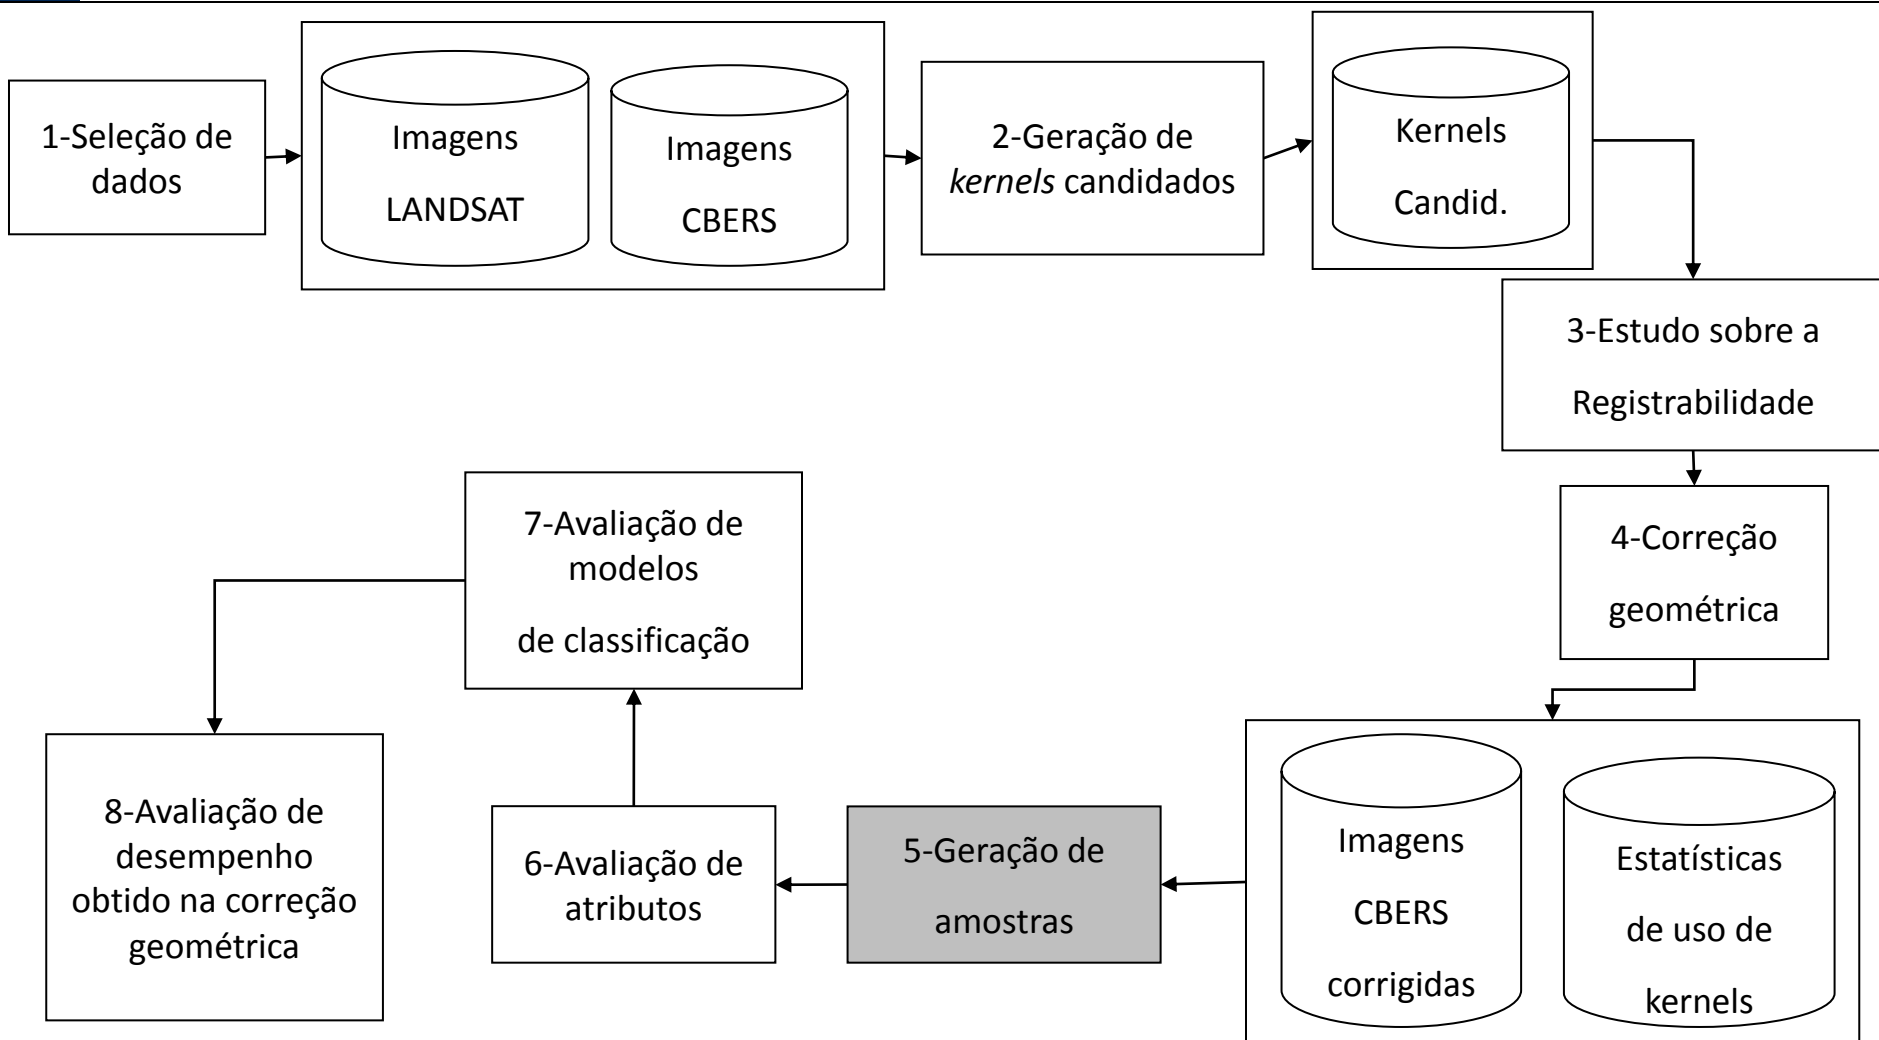
Metodologia – Correção geométrica



■ Etapa 4 – Geração das imagens corrigidas



Metodologia – Geração de amostras



Metodologia – Geração de amostras

■ Objetivo

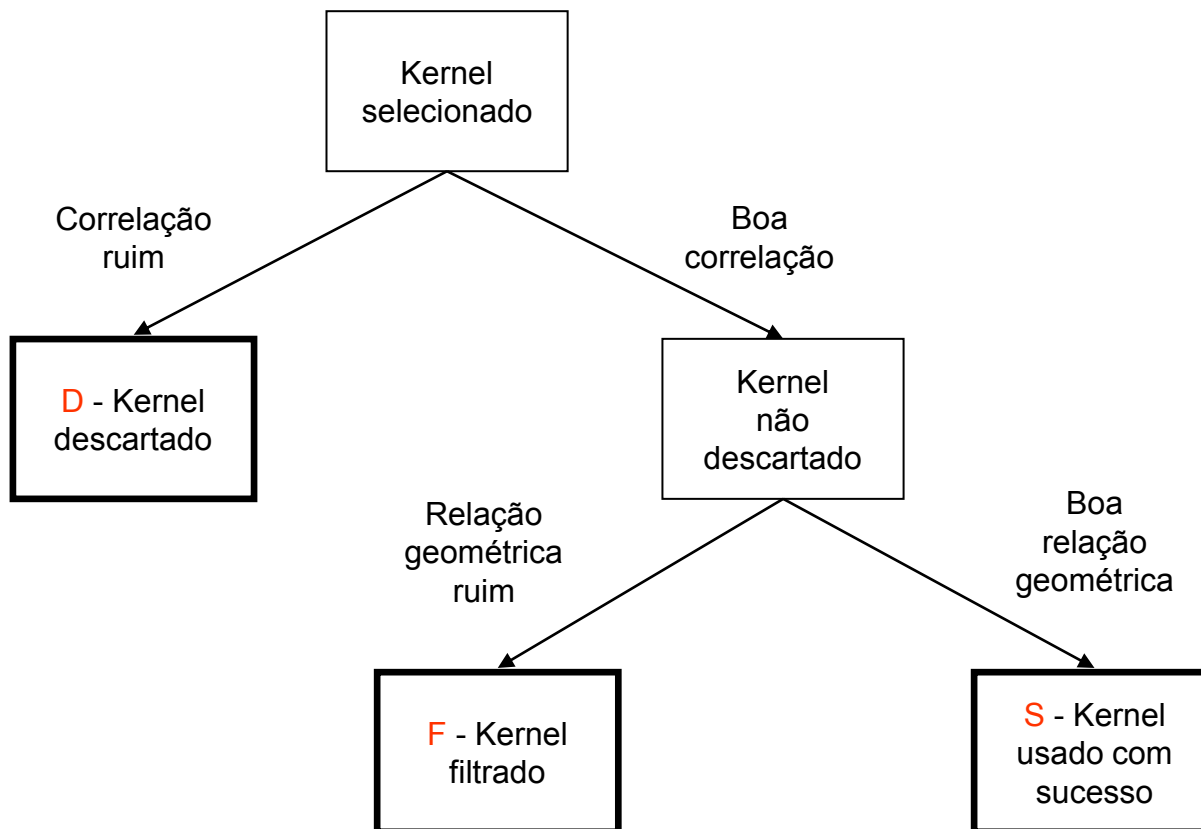
- Definição de um método para selecionar *kernels* que contribuem de forma positiva no processo de correção geométrica.

Forma: Uso de **classificadores supervisionados**

Problema: Como definir se um *kernel* é bom ou ruim ?


Metodologia – Geração de amostras

- Como definir se um kernel é bom ou ruim: **Índice de qualidade do kernel**
 - Todas as 80 imagens são processadas



dos kernels


Todas as 80 imagens



$$Q = \frac{S}{D + F + S}$$

Metodologia – Geração de amostras


- Definindo o rótulo da classe: **Conjuntos de amostras**
 - Avaliar o comportamento do método para diferentes níveis de qualidade
 - O mesmo número de amostras por classe (classe “bom kernel”, classe “kernel ruim”)



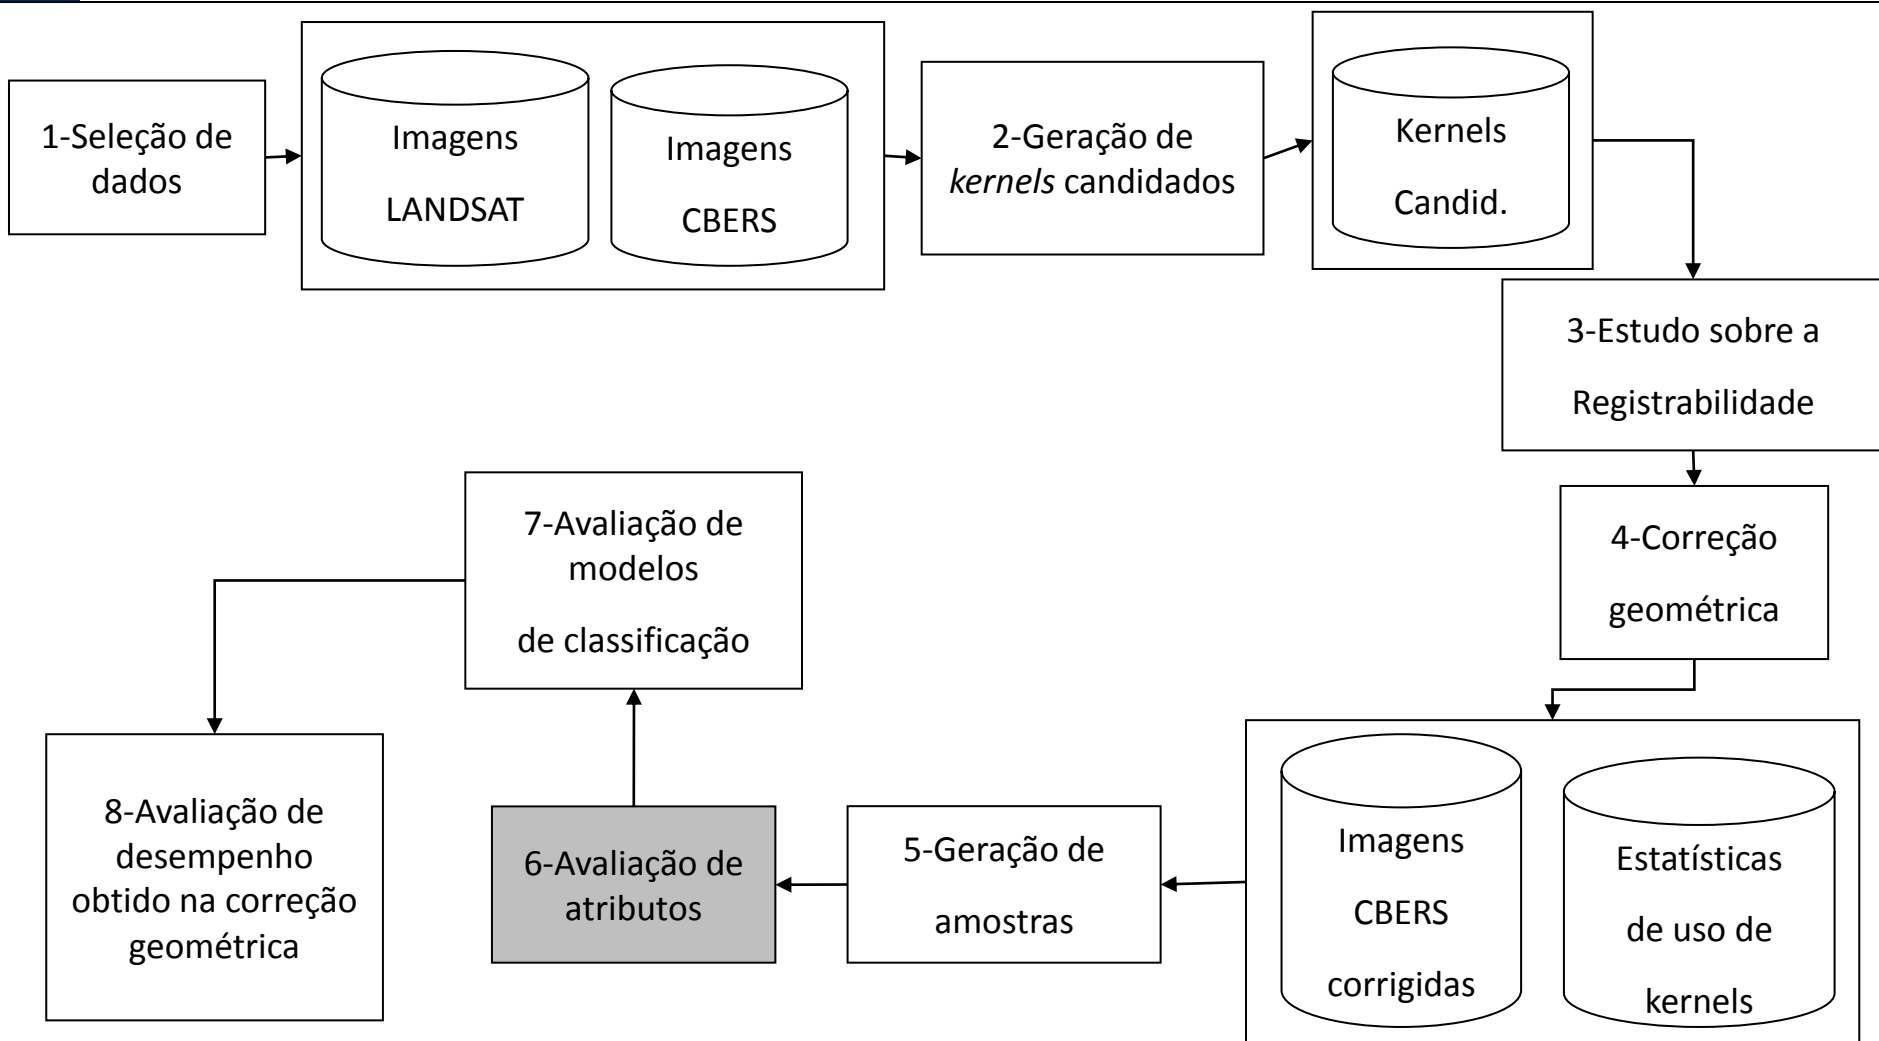
Metodologia – Geração de amostras

■ Conjuntos de amostras

- Gerados 9 conjuntos de amostras segundo diferentes limiares de qualidade:




Metodologia – Avaliação de atributos



Metodologia – Avaliação de atributos


- Para cada amostra são calculados vários **atributos** usando o kernel: estatísticos, texturais (Haralick), registrabilidade.
- **Selecionar** e usar os melhores atributos:
 - Boa capacidade de **discriminação** das classes
 - Reduzir a **complexidade computacional**
 - Melhorar a **taxa de acertos** do classificador
- Método usado baseado no trabalho de Wei Deng e L. Yu que usa a **razão de Fisher (compacidade e separabilidade de classes)**



Metodologia – Avaliação de atributos

- A análise é feita para cada um dos 9 grupos de amostras


Exemplo: Conjunto de amostras gerado com [limiar de qualidade 0.1](#)




Metodologia – Avaliação de atributos

- Cada grupo de amostras tem seu próprio conjunto de melhores atributos

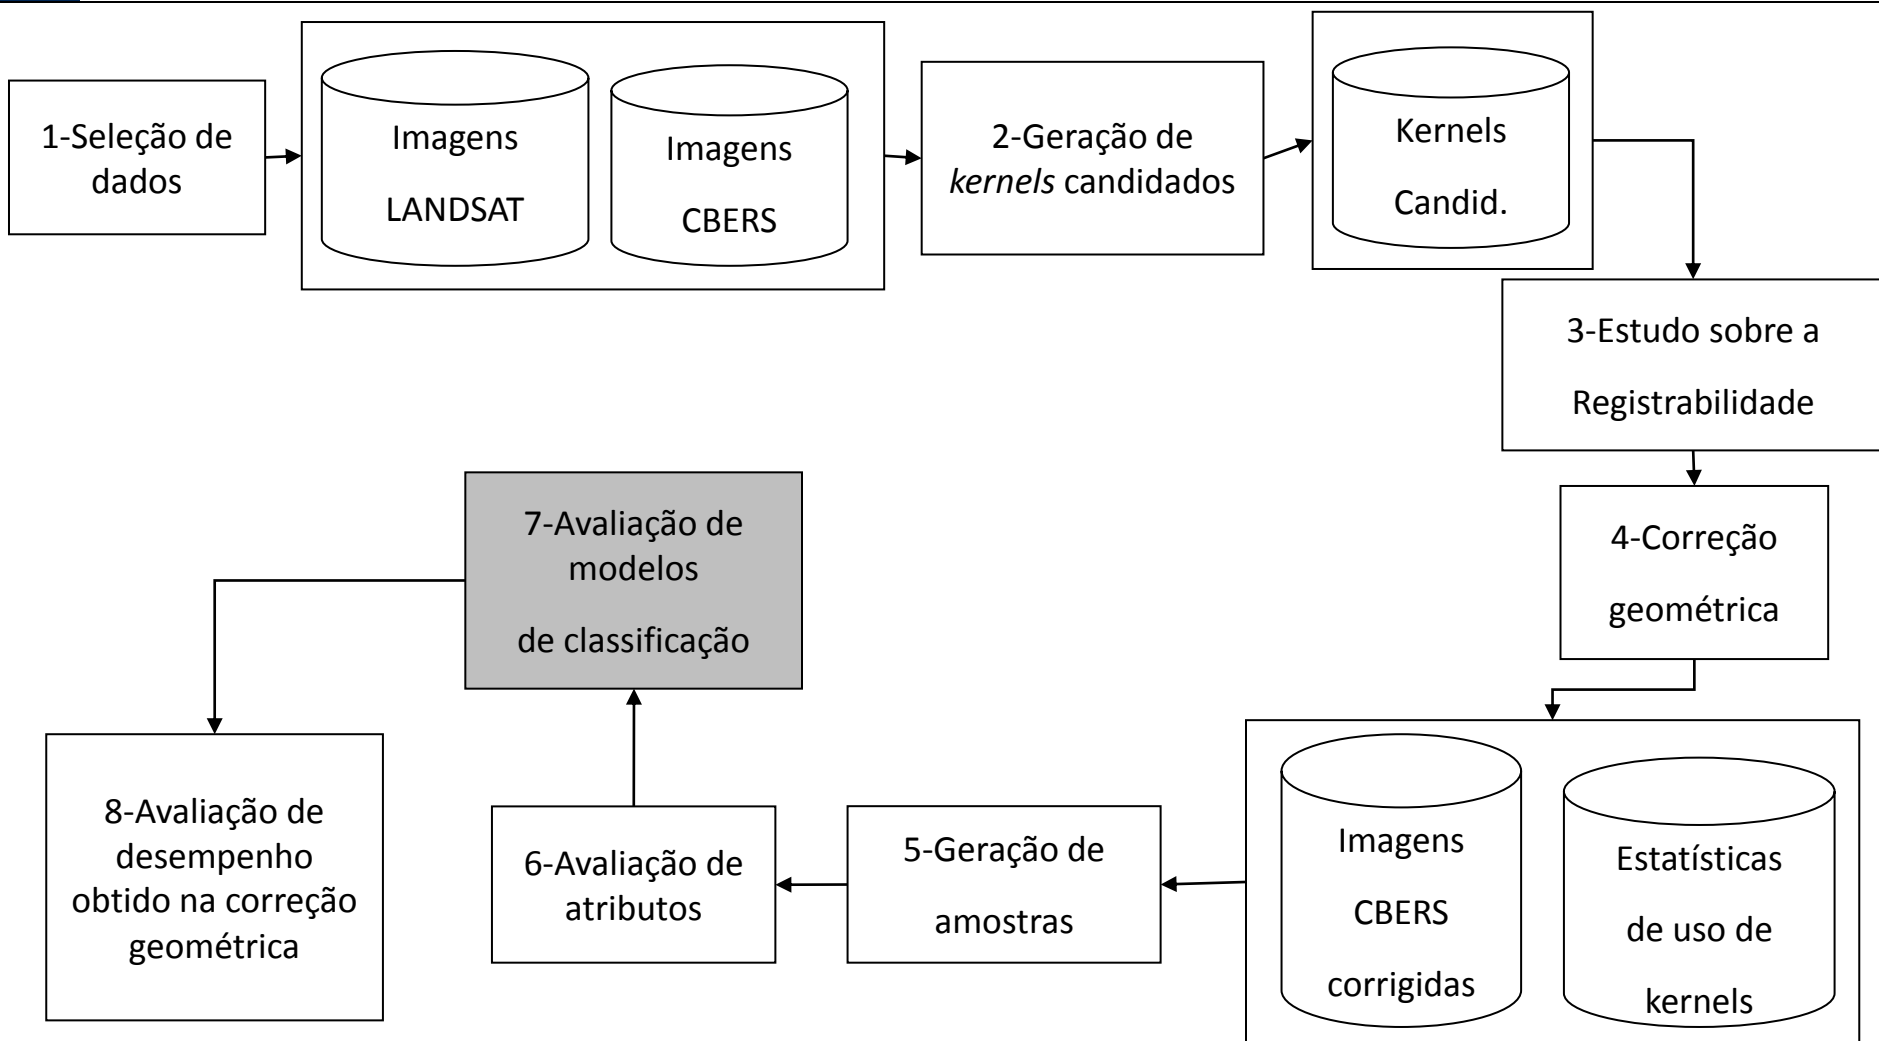
Conjunto de amostras gerado com limiar de qualidade 0.1



Conjunto de amostras gerado com limiar de qualidade 0.9



Metodologia – Avaliação de modelos de classificação

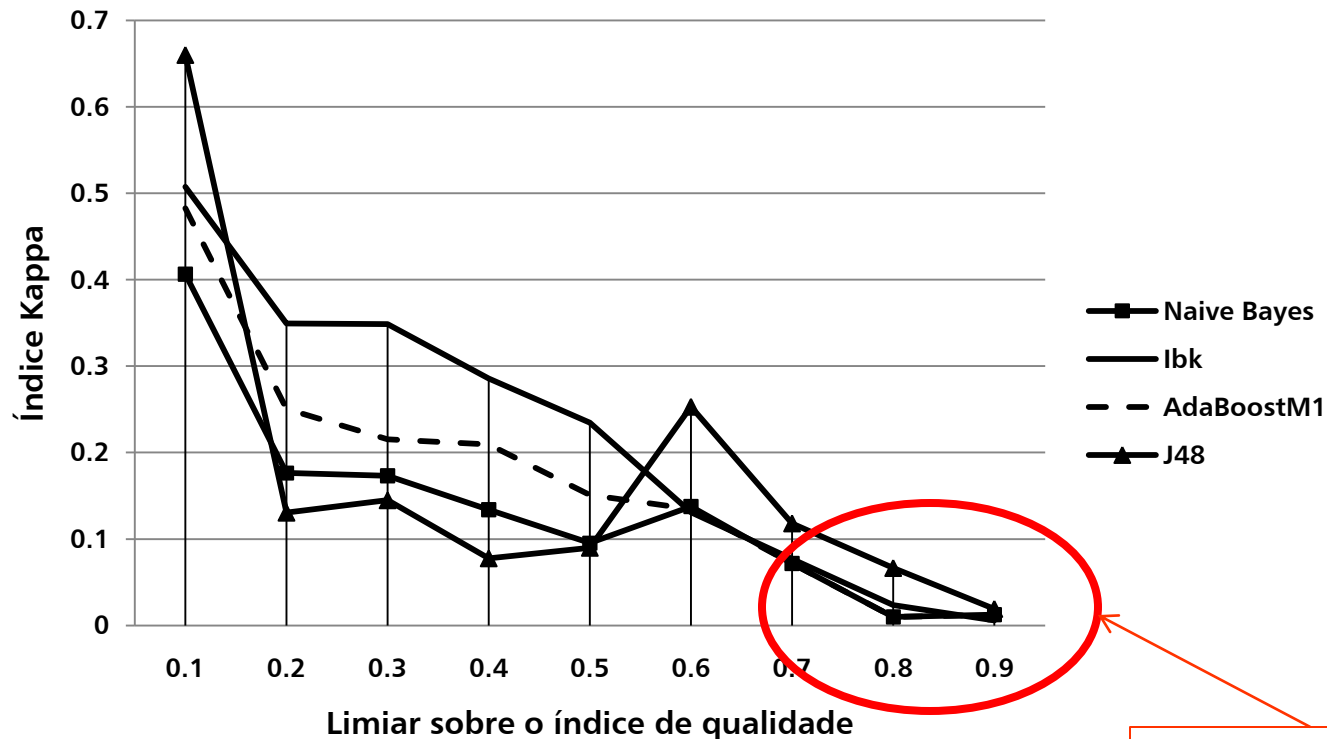


Metodologia – Avaliação de modelos de classificação

- Uso de **classificadores supervisionados** para selecionar *kernels* que contribuem de forma positiva no processo de correção geométrica.
- Avaliação de comportamento de quatro modelos diferentes de classificadores conhecidos:
 - **IBk**: Extensão do modelo de classificação por vizinho mais próximo
 - **Naive Bayes**: Modelo probabilístico baseado no teorema de Bayes.
 - **J48**: Baseado no algoritmo C4.5 que usa árvores de decisão
 - **AdaBoostM1**: Meta-classificador que efetua combinação de instâncias de classificadores fracos – *Boosting* - (**Naive Bayes**).

Metodologia – Avaliação de modelos de classificação


- A análise é feita para cada um dos 9 grupos de amostras
- Métrica usada: Índice **Kappa** [0,1] (maiores valores indicam maior taxa de acerto)



Baixo desempenho
Poucas amostras

Metodologia – Avaliação de modelos de classificação

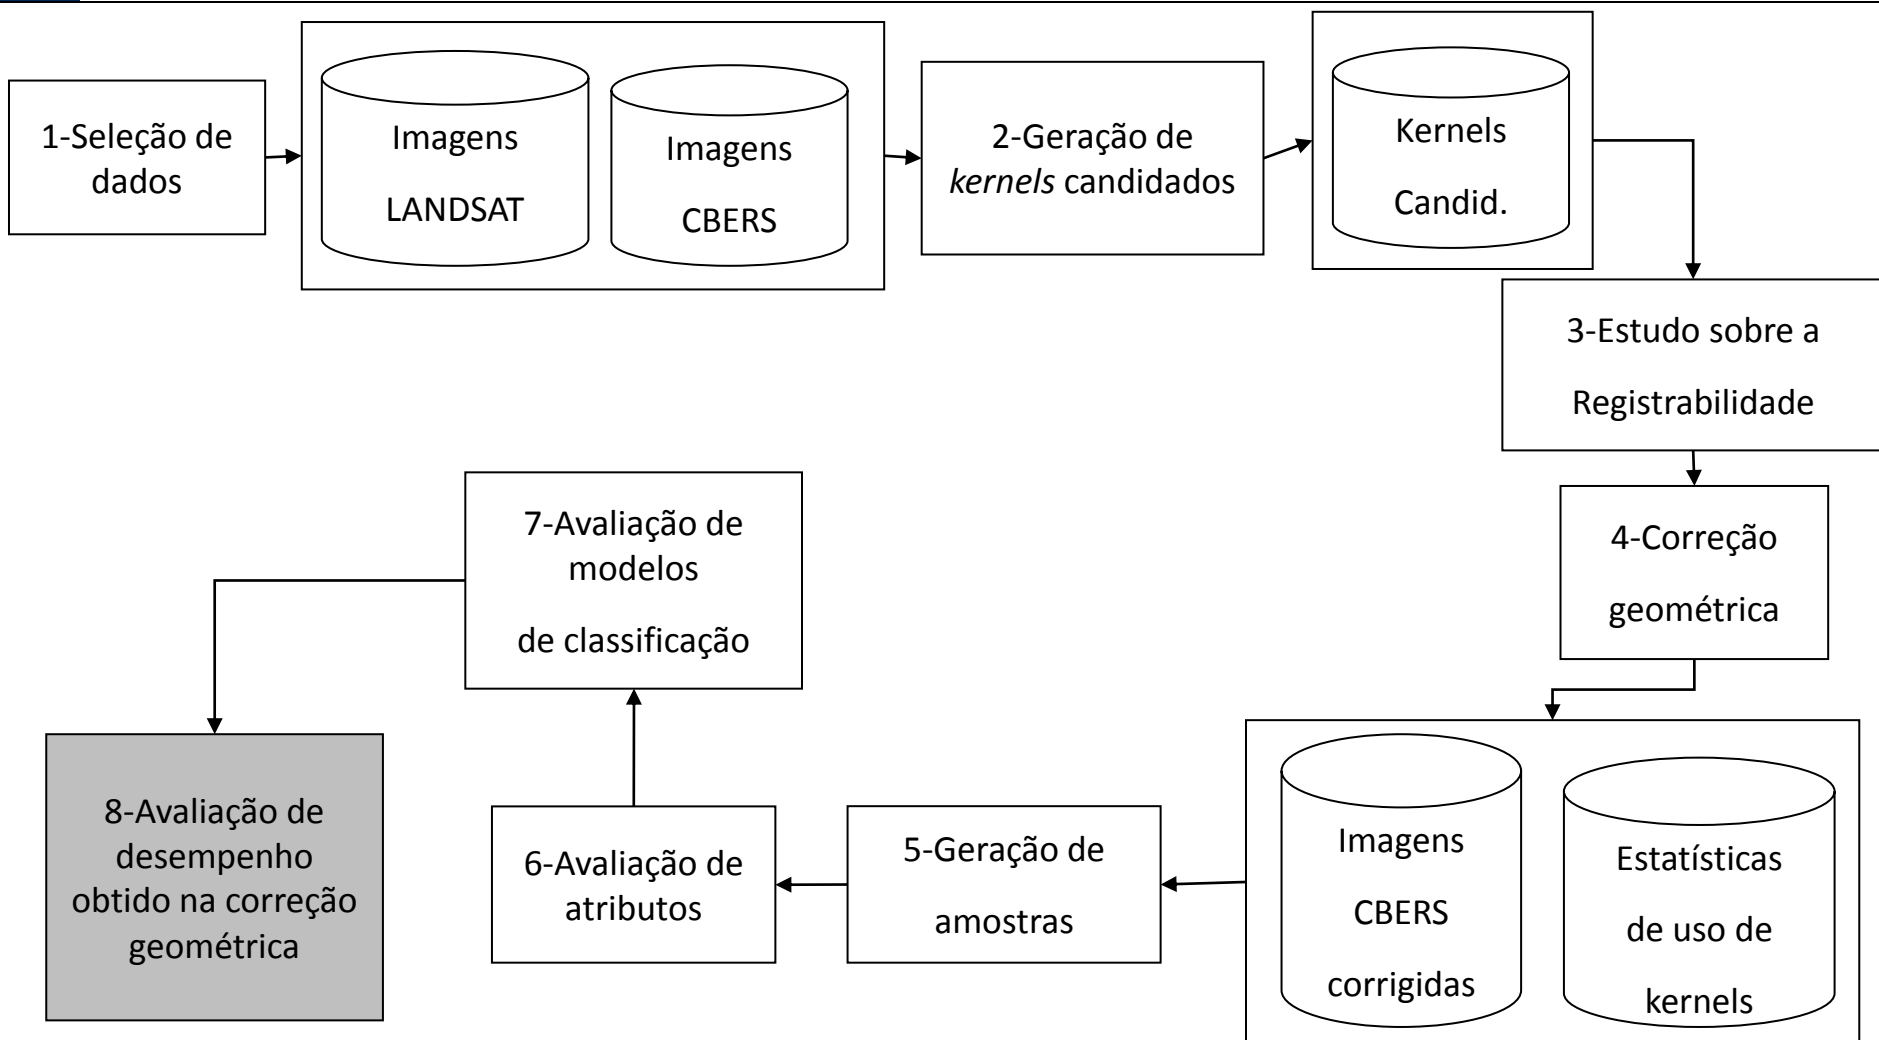
■ Melhores classificadores



Ibk com melhores resultados para casos intermediários

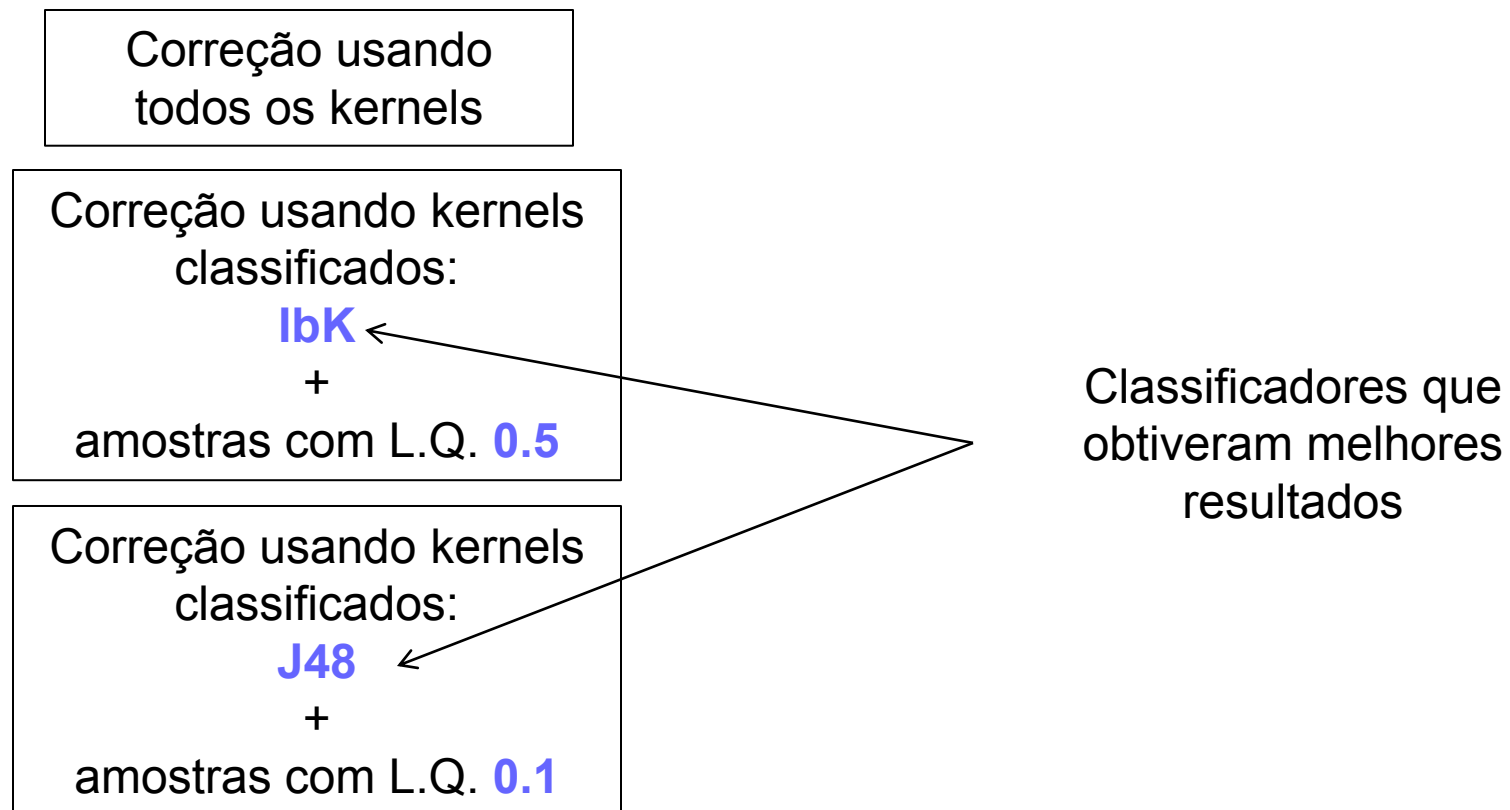
J48 com melhores resultados para casos críticos: poucas amostras ou limiar de qualidade baixo

Metodologia – Avaliação de desempenho na correção geométrica



Metodologia – Avaliação de desempenho na correção geométrica

- Comparativo dos resultados obtidos na correção geométrica de todas as imagens CBERS selecionadas
- São usados os mesmos parâmetros de correção




Metodologia – Avaliação de desempenho na correção geométrica

■ Comparativo da taxa de kernels úteis


- **Aumento** da taxa de kernels úteis na maioria dos experimentos

$$T = \frac{\text{Kernels usados com sucesso}}{\text{Kernels descartados + kernels correlacionados}}$$



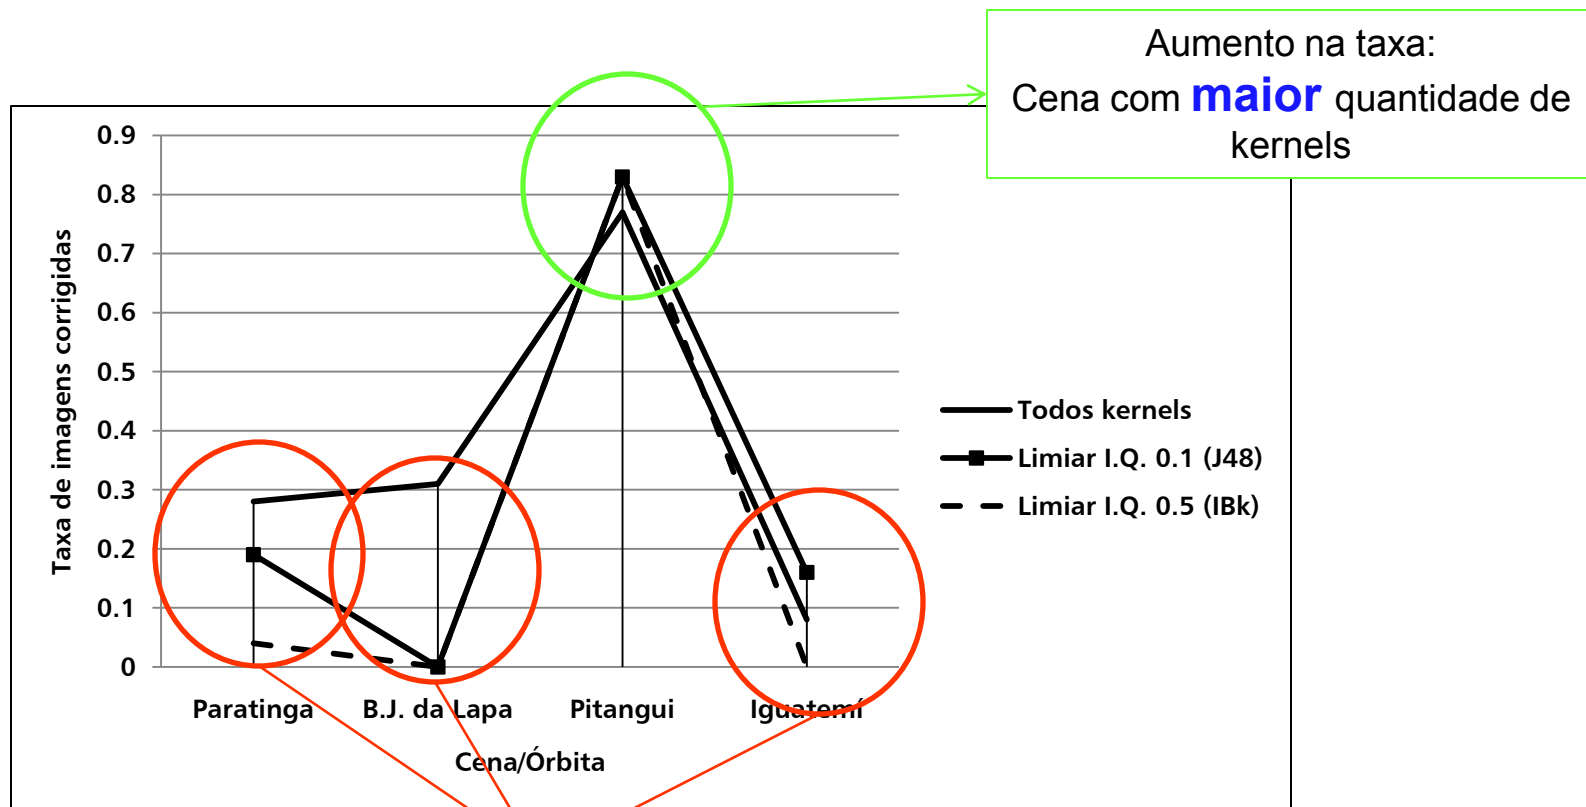
Metodologia – Avaliação de desempenho na correção geométrica

- **Comparativo do tempo de execução**
 - **Diminuição** do tempo de execução em todos os experimentos



Metodologia – Avaliação de desempenho na correção geométrica

■ Comparativo da taxa de imagens corrigidas



Diminuição da taxa:
Cenas com **menor** quantidade de kernels

Conclusões

- A **correção** de geometria das imagens CBERS/CCD distribuídas gratuitamente **ainda é um processo necessário**.
- Fica a cargo do **usuário** efetuar a correção manual ou assistida.
- O **custo** para efetuar a correção é alto:
 - Grande **quantidade de imagens**.
 - Nem sempre os métodos assistidos são **robustos** o suficiente.

Conclusões

- Foi demonstrado que é possível efetuar a **correção geométrica automática** de imagens CBERS/CCD nível 2
 - Pelo uso de *kernels* de imagens **LANDSAT** como referência
 - Pela compatibilidade das bandas
 - Pelo tipo de distorções nas imagens CBERS/CCD nível 2
- É possível localizar a correta posição dos *kernels* na imagem de ajuste usando coeficiente de **correlação** + **RANSAC** modificado apresentado.

Conclusões

*Nem todos os **kernels** usados contribuem positivamente no processo de correção por não possuírem boa **qualidade**.*

***Kernels ruins** aumentam o **tempo** de processamento e podem piorar ou **inviabilizar** a correção.*

- Foi proposto um **método automático de seleção de *kernels*** que permite **aperfeiçoar** o processo de correção geométrica:
 - Ganho de **desempenho** (menor tempo de execução)
 - Maior **qualidade** (menor erro de posicionamento)

Conclusões

- Demonstrado que é possível usar **classificadores** supervisionados para determinar quais os melhores *kernels* para a correção geométrica
 - Uso de **amostras** de treinamento geradas a partir da análise do uso dos *kernels* no processo de correção
 - Uso de **atributos** numéricos gerados a partir da informação radiométrica dos próprios *kernels*
 - Mostrada uma forma de **selecionar** os melhores **atributos**
 - A seleção dos atributos está relacionada com o índice de qualidade desejado dos *kernels*

Conclusões

- Melhor ganho de desempenho (2 vezes maior) obtido com *kernels* classificados com **J48** para os casos extremos:
 - Baixo limiar sobre o índice de qualidade.
 - Baixo número de amostras.
- O classificador **lbK** obteve melhor resultado para os casos intermediários.

Conclusões

- O número de kernels usados no processo de correção pode influenciar na taxa de imagens corrigidas:

Erro do classificador: Bons *kernels* podem ser **incorretamente classificados** como *kernels* ruins e a correção pode ficar comprometida.

- **Trabalho futuro:** Avaliar métodos de classificação mais robustos para aumentar a taxa de acertos.

Obrigado