

# UAV-Multispectral Sensed Data Band Co-Registration Framework

Jocival Dantas Dias Junior

Universidade Federal de Uberlândia  
Faculdade de Computação  
Programa de Pós-Graduação em Ciência da Computação

17 de Fevereiro de 2020

- Introdução
- Problema
- Fundamentação Teórica
- Trabalhos Relacionados
- Metodologia
- Resultados
- Conclusão

# Introdução

# Introdução

## Importância da agricultura.

- O agronegócio representa 21,6% do PIB brasileiro, sendo a agricultura responsável por R\$ 383,97 bilhões de reais;
- No Brasil existe apenas 6,7% de área disponível para crescimento (56,6 milhões de hectares).
- Estudos indicam que até 2050 a população mundial poderá dobrar porém, só poderão ser utilizados mais 5% de terra para a agricultura;
- Nesse contexto de limitação de recursos, surge a Agricultura de Precisão (AP).

# Introdução

## Agricultura de precisão (AP).

- A AP baseia-se na utilização de menos inputs (energia, água, etc) produzindo alimentos com maior qualidade e em maior quantidade enquanto reduz os impactos ambientais.
- A AP utiliza de métodos como: sensoriamento remoto, automação, robótica, *big data*, inteligência artificial e internet das coisas para alcançar seus objetivos.
- Para várias de suas aplicações, a aquisição de imagens multiespectrais de baixa/média altitude faz-se necessária.
- Para adquirir essas imagens, os veículos aéreos não tripulados (VANT) são utilizados.


# Introdução

Veículos Aéreos não tripulados.



# Introdução

Sensores.



# Introdução


Veículos Aéreos não tripulados (VANT) e Imagens Multiespectrais.

- Para cobrir um área normalmente são necessárias centenas e em alguns casos milhares de imagens sobrepostas.
- Problemas durante o voo (velocidade do vento, direção do vento, etc) podem causar distorções entre as imagens.
- Os sensores multiespectrais apresentam uma distorção natural devido a posição física de cada sensor.
- Para serem úteis a AP, as imagens multiespectrais precisam ter suas bandas devidamente alinhadas.



# Introdução

## Distorção Natural.



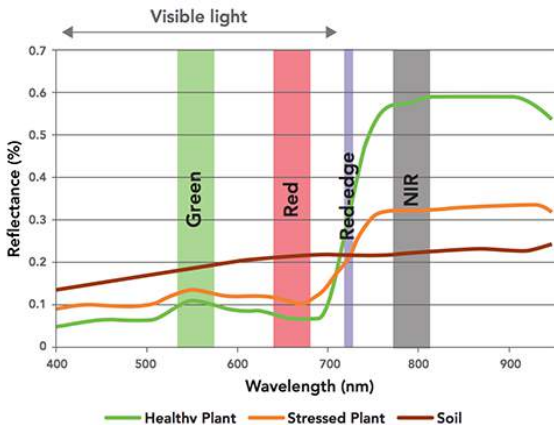
# Introdução

## Alinhamento de imagem multispectral.

- O alinhamento entre as bandas de uma imagem multispectral é uma tarefa complexa.
- A variação entre cada espectro leva a uma perda de características entre as bandas.
- Autores consideram que variáveis durante a aquisição aumentam a distorção entre as bandas.

# Introdução

Diferença na Reflectância.



# Problema

## Problema

Realizar o alinhamento entre as bandas de uma imagem obtida por um VANT.

## Hipóteses

- O desalinhamento natural é um atributo da câmera e portanto não é modificado durante o voo.
- A velocidade de deslocação do VANT não é o suficiente para causar distorções adicionais entre as bandas.

# Fundamentação Teórica

### Registro de imagens

Pode ser definido como a tarefa de alinhar duas ou mais imagens. Este processo exige a definição de uma imagem para ser utilizada como referência e a aplicação de transformações geométricas (e.g. translações, rotações e escala) nas outras imagens de forma a alinhá-las na referência.

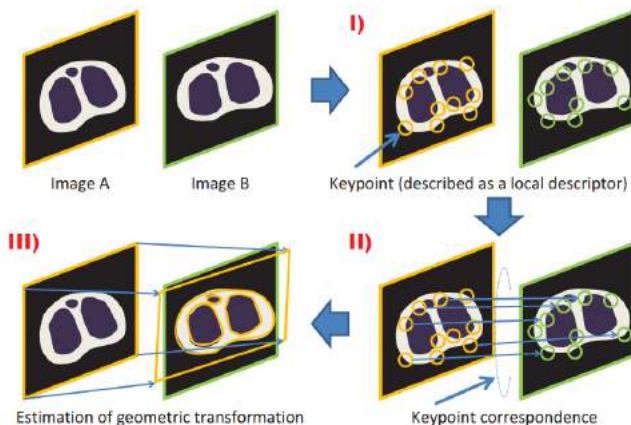
### Etapas para o registro de imagens

- **Feature extraction**, que identifica as *features* relevantes nas duas imagens como bordas, cantos e regiões;
- **Feature matching**, que estabelece a correspondência entre as *features* nas duas imagens;
- **Construção da função de transformação (mapeamento)**, que determina os parâmetros de transformação das funções de mapeamento usando a correspondência entre as features;
- **Transformação da imagem**, que transforma geometricamente a imagem de acordo com a função de mapeamento estabelecida.



# Fundamentação Teórica

Etapas para o Registro de imagens.



### Feature extraction

- *Feature* pode ser definido como um padrão que ocorre em um local da imagem e difere-se dos vizinhos mais próximos.
- Geralmente, esse padrão está associado a uma mudança repentina em uma ou mais propriedades de uma imagem (por exemplo, textura, cor ou intensidade).
- Os algoritmos para registro de imagens baseados em *features* encontram *keypoints* (pontos de interesse ou pontos de atributo) analisando a magnitude e a direção das mudanças de intensidade nos pixels vizinhos a feature da imagem para detectar regiões, cantos ou bordas.

### *Feature matching*

- Após a extração dos atributos faz-se necessário criar uma correspondência entre os atributos obtidos em cada uma das imagens.
- Métodos exaustivos (e.g. força bruta) e aproximados (e.g. *nearest neighbor search* (NNS)) podem ser aplicados para obter as correspondências.

### Construção da função de mapeamento (transformação)

- Matematicamente uma função de mapeamento, ou *warping*, pode ser definida como sendo uma função 2D que mapeia as coordenadas x-y de uma imagem A para as coordenadas x-y de uma imagem B.
- Pode ser Linear ou Não-linear

# Fundamentação Teórica

Construção da função de mapeamento (transformação).





Figure: Exemplo de transformações lineares e não lineares.

### Transformação da imagem

Por fim, o último passo para realizar o processo de registro é a transformação da imagem de acordo com uma função de transformação  $F$ .



**Figure:** Exemplo de transformação de uma imagem (a) para a imagem alvo (b). O resultado da sobreposição após a transformação é mostrado na imagem (c).

### Keypoints para o Registro de Imagens

Os algoritmos recentes para registro de imagens tem focado em aumentar a quantidade de *keypoints* obtidos em diferentes cenas, sensores e situações. Os principais algoritmos são:

- Scale Invariant Feature Transform (SIFT);
- Speeded-Up Robust Features (SURF);
- Binary Robust Invariant Scalable Keypoints (BRISK);
- MinEigen Features (MEF);
- Kaze Features (KAZE);
- Oriented FAST and rotated BRIEF (ORB);
- Maximally Stable Extremal Regions (MSER);
- Features from Accelerated Segment Test (FAST).

### *Back Projection Error* (BPE)

- Avalia o quão bem a localização dos *keypoints* da imagem alvo se alinham com os *keypoints* da imagem registrada.
- O cálculo é realizado por meio da distância entre os *keypoints* da imagem registrada e os da imagem alvo.
- Quanto menor o BPE, melhor o alinhamento.

$$BPE(I, J) = \sum_{x_i, x_j} d^2(X_i, F \times X_j) \quad (1)$$

onde  $I$  e  $J$  representam as imagens alvo e registrada, respectivamente,  $d^2$  representa a métrica de distância e  $F$  a matriz de transformação.



### Trabalhos Relacionados

Vários são os trabalhos que se propuseram a realizar o alinhamento entre bandas em imagens multi/hiperespectrais. São exemplos:

- Alignment of UAV-hyperspectral bands using keypoint descriptors in a spectrally complex environment;
- Data-driven Multispectral Image Registration;
- A Normalized SURF for Multispectral Image Matching and Band Co-Registration;
- Automated Coregistration of Multisensor Orthophotos Generated from Unmanned Aerial Vehicle Platforms;
- Automated Co-Registration of Multi-Temporal Series of Multi-Spectral UAV Images for Crop Monitoring;
- A Rigid Image Registration Based on the Nonsampled Contourlet Transform and Genetic Algorithms;

# Fundamentação Teórica

Alignment of UAV-hyperspectral bands using keypoint descriptors in a spectrally complex environment

## Alignment of UAV-hyperspectral bands using keypoint descriptors in a spectrally complex environment

Neste trabalho foram avaliadas diversas técnicas que utilizam de descritores de características locais para realizar o registro hiperespectral de imagens em ambientes espectralmente complexos, mais especificamente em pântanos e zonas úmidas.

- Vários métodos avaliados (HSF, MEF, SIFT, SURF, BRISK e FAST);
- Proposta de duas ordens de alinhamento (Espectral e Temporal);
- Ordem espectral obteve um resultado superior em conjunto com a técnica SURF.

### Data-driven Multispectral Image Registration

Propõe a criação de um *framework* automático para a realização do registro de imagens multiespectrais. Porém, diferentemente de outros trabalhos relacionados, este *framework* permitirá alvos intermediários para registro. O *framework* tem como premissas básicas a necessidade de uma quantidade mínima de correspondência entre os pontos de controle entre dois canais para garantir um baixo erro de alinhamento e que quanto maior a quantidade de pontos de controle correspondente entre os canais melhor será o registro.

- Vários métodos avaliados (SIFT, SURF, BRISK e ORB);
- Possibilitou o alinhamento intermediário;
- Framework consiste na criação de um esquema para alinhar as bandas;
- Obteve os melhores resultados com o SIFT.

# Metodologia

### Datasets

- Em nossos experimentos, usamos dois datasets para avaliar o desempenho da proposta: Soybean e Cotton dataset;
- Imagens com tamanho de  $1280 \times 960$  pixels e uma média de 80% sobreposição entre imagens;
- Cada dataset foi obtido em único voo sem qualquer tipo de pré-processamento;
- VANT: Micro UAV SX2 a uma altura média de 100 metros e a uma velocidade média de 20 m/s;
- Sensor: MicaSense Red-Edge M (ground sample distance (GSD) de 6,8 cm/pixel a 100 metros de altura);


### Datasets

Os espectros presentes nas imagens são:

- Azul (centro 475 nm, largura de banda 20 nm);
- Verde (centro 560 nm, largura de banda 20 nm);
- Vermelho (centro 668 nm, largura de banda 10 nm);
- RedEdge (rededge) (centro de 717 nm, largura de banda de 10 nm);
- Near-IR (nir) (centro de 840 nm, largura de banda de 40 nm).

### Soybean dataset


- O primeiro dataset foi obtido de uma plantação de soja localizada na seguinte coordenada decimal:  
( $-17.877308292165985$ ,  $-51.08216452139867$ ).
- Contém 1080 imagens (216 cenas e 5 canais).



**Figure:** Exemplo de uma cena de imagem contendo todos os canais (respectivamente, azul, verde, vermelho, nir e reledge) do soybean dataset.

### Cotton dataset

- O segundo dataset foi obtido de uma plantação de algodão na seguinte coordenada decimal:  $(-17.820275501545474, -50.32411830846922)$ .
- Contém 830 imagens (166 cenas e 5 canais).



**Figure:** Exemplo de uma cena de imagem contendo todos os canais (respectivamente, azul, verde, vermelho, nir e rededge) do cotton dataset.



- O *framework* proposto visa alinhar as bandas de imagens multiespectrais obtidas por VANTs usando métodos baseados em features (feature-based).
- Diferentemente das várias abordagens de alinhamento banda-a-banda, nosso método busca o melhor conjunto de transformações entre todas as imagens do conjunto de dados para alinhar posteriormente todas as cenas usando o mesmo conjunto de transformações.
- Nossa abordagem recebe um dataset de imagens multiespectrais e, como saída, retorna a ordem na qual as bandas devem ser alinhadas e qual transformação deve ser usada em cada alinhamento.
- Chance de falha drasticamente reduzida.

- Entrada: Métodos para detecção de pontos de controle e um dataset multispectral;
- Saída: Esquema (Ordem) para o registro das imagens e as transformações entre cada banda;
- O *framework* proposto possui as seguintes etapas:
  - Extração de *keypoints* e construção do grafo;
  - Construção do esquema;
  - Construção de transformações e alinhamento do dataset.

### Extração de keypoints e construção do grafo.

- Para cada cena multiespectral, combinamos as bandas tomadas duas a duas.
- Para cada combinação, o número de *keypoints*, após a eliminação de *outliers*, é extraído por cada método fornecido como entrada no *framework*.
- O número de *keypoints*, o identificador de imagem, o método de extração de recursos que gerou esses *keypoints* e a combinação de bandas são armazenados em uma tupla.
- Dado o conjunto de tuplas extraídas anteriormente, para cada combinação de bandas, é obtida a tupla que retorna o maior número de *keypoints*.

### Output

Ao final desta etapa, um grafo ponderado não direcionado completo  $G$  é construído, com as bandas como nós e as tuplas máximas como arestas. Cada aresta é rotulada com a imagem, técnica que gerou essa aresta e o número de pontos-chave. Os pesos das arestas são representados pelo número de *keypoints* obtidos.

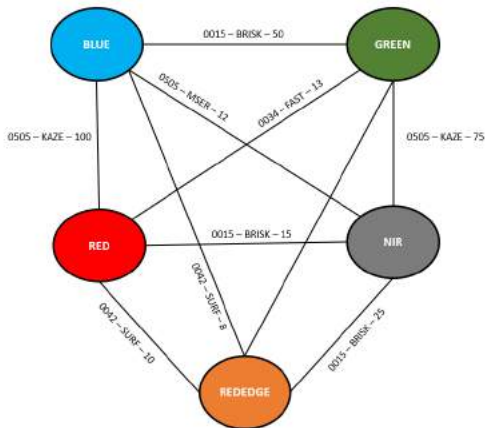


Figure: Grafo não ponderado completo,  $G$ . As arestas são rotuladas, respectivamente, com ID da imagem, método e número de keypoints.

### Construção do esquema.

- Partindo do grafo  $G$ , aplicamos o algoritmo Kruskal para construir uma Árvore Geradora Máxima (MST).
- Para encontrar o canal para o alinhamento, os pesos entre os nós são substituídos por 1 e o *all-pairs-shortest-path* de Floyd-Warshall é usado. O nó com a menor soma de distâncias entre si e todos os outros nós é selecionado como o canal de destino para o esquema de registro.
- Ao final, cada aresta não direcionada  $(a, b)$  é convertida em um aresta direcionada  $(a, b)$  se  $b$  estiver mais próximo da raiz, caso contrário,  $(b, a)$ .

### Output

No final deste processo, temos um grafo  $G'$  direcionado que representa a melhor ordem para executar o processo de alinhamento.




Figure: Esquema final para o registro.

### Construção de transformações e alinhamento do dataset

- Para cada uma das arestas presentes em  $G'$ , a função de transformação é extraída para alinhar um nó ao outro.
- Observe que, ao extrair todas as transformações, podemos executar o processo de alinhamento entre as faixas da maneira ideal, ou seja, com a melhor transformação que pode ser estimada no conjunto de dados.
- Com as transformações obtidas, todas as cenas presentes no conjunto de dados são alinhadas usando esse mesmo conjunto de transformações.



### Métodos para detecção e extração de keypoints avaliados

- Binary Robust Invariant Scalable Keypoints (BRISK);
- Features from Accelerated Segment Test (FAST);
- Maximally Stable Extremal Regions (MSER);
- Harris Features (HARRIS);
- Speeded-Up Robust Features (SURF);
- Kaze Features (KAZE).

### Métodos de comparação

- Alignment of UAV-hyperspectral bands using keypoint descriptors in a spectrally complex environment (BANERJEE; RAVAL; CULLEN, 2018);
- Data-driven Multispectral Image Registration (YASIR, 2018).

### Métricas de avaliação

- Back Projection Error (BPE).

# Experimentos e Resultados

# Experimentos e Resultados

## Desalinhamento Natural

**Table:** Média do desalinhamento, em pixels, entre os sensores presentes no soybean dataset.

	<b>Azul</b>	<b>Verde</b>	<b>Vermelho</b>	<b>Nir</b>	<b>Rededge</b>
<b>Azul</b>	-	5.18	15.75	15.07	12.14
<b>Verde</b>	5.18	-	15.09	12.33	4.02
<b>Vermelho</b>	15.75	15.09	-	<b>29.25</b>	14.79
<b>Nir</b>	15.07	12.33	<b>29.25</b>	-	16.17
<b>Rededge</b>	12.14	4.02	14.79	16.17	-

# Experimentos e Resultados

## Desalinhamento Natural

**Table:** Média do desalinhamento, em pixels, entre os sensores presentes no cotton dataset.

	<b>Azul</b>	<b>Verde</b>	<b>Vermelho</b>	<b>Nir</b>	<b>Rededge</b>
<b>Azul</b>	-	28.30	12.11	33.28	8.48
<b>Verde</b>	28.30	-	21.44	24.01	35.66
<b>Vermelho</b>	12.11	21.44	-	14.94	21.30
<b>Nir</b>	33.28	24.01	14.94	-	<b>39.37</b>
<b>Rededge</b>	8.48	35.66	21.30	<b>39.37</b>	-

# Experimentos e Resultados

## Desalinhamento Natural

- Para uma câmera multiespectral comum, o tempo máximo de exposição recomendado é de 2,5ms e a velocidade recomendada de um VANT, para o processo de aquisição, varia entre 5 e 25m/s.
- Analisando o pior caso, temos que o tempo entre a primeira e a última aquisição é de 10ms, que a 25m/s, gerará um deslocamento de 25cm.
- Para a câmera utilizada neste trabalho, a 100 metros de altura, seria um deslocamento de 3,67 pixels.
- No entanto, o cenário acima é irreal, pois, para a grande maioria das câmeras multiespectrais usadas, o processo de aquisição é sincronizado entre todos os sensores.

# Experimentos e Resultados

## Esquemas para o registro

- Todos os métodos avaliados neste trabalho propõem a criação de um esquema (ordem) para o alinhamento do dataset.
- (BANERJEE; RAVAL; CULLEN, 2018) apresenta um esquema espectralmente ordenado.
- (YASIR, 2018) realiza uma busca em cada dataset para a montagem do melhor esquema para alinhamento.
- Nossa abordagem é baseada na proposta por (YASIR, 2018) e também realiza uma busca em cada dataset para a montagem do melhor esquema para alinhamento.
- Porém, diferentemente de (YASIR, 2018), nossa abordagem busca a melhor ordem e o melhor conjunto de transformações. Aplicando um único conjunto de transformações em todo o dataset

# Experimentos e Resultados

## Soybean dataset



# Experimentos e Resultados

Soybean dataset - Esquema gerado

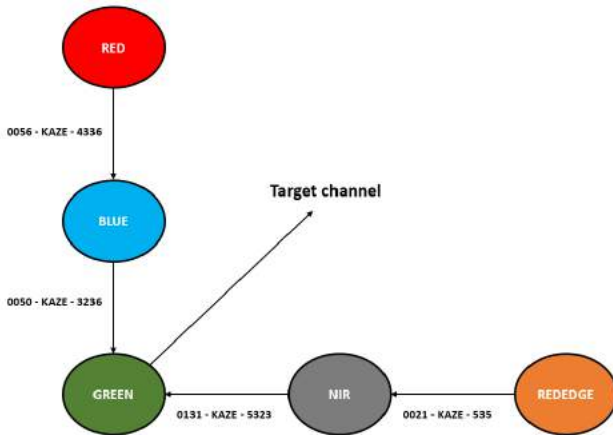


Figure: Esquema gerado por nossa abordagem para o Soybean dataset. A legenda para cada aresta consiste em: ID da imagem - Método - Número de keypoints.

# Experimentos e Resultados

## Soybean dataset - Acurácia

**Table:** A precisão obtida pelos *frameworks* no alinhamento do soybean dataset (total de 864 alinhamentos).

<b>Método</b>	<b>Falhas</b>	<b>Acurácia</b>
Nossa abordagem	0	100.00%
(YASIR, 2018)	183	78.82%
(BANERJEE; RAVAL; CULLEN, 2018) KAZE	352	59.26%
(BANERJEE; RAVAL; CULLEN, 2018) HARRIS	673	22.11%
(BANERJEE; RAVAL; CULLEN, 2018) SURF	677	21.64%
(BANERJEE; RAVAL; CULLEN, 2018) MSER	802	7.18%
(BANERJEE; RAVAL; CULLEN, 2018) BRISK	830	3.94%
(BANERJEE; RAVAL; CULLEN, 2018) FAST	842	2.55%

# Experimentos e Resultados


## Soybean dataset - Avaliação de desempenho

**Table:** Avaliação do desempenho no processo de alinhamento no Soybean dataset.

<b>Método</b>	<b>BPE (pixels)</b>
Nossa abordagem	0.14
(YASIR, 2018)	1.33
(BANERJEE; RAVAL; CULLEN, 2018) KAZE	40.50

# Experimentos e Resultados

Soybean dataset - Pior alinhamento RGB



**Figure:** Pior alinhamento alcançado por nossa abordagem no Soybean dataset.  
(a) RGB original; (b) RGB alinhada.

# Experimentos e Resultados

Soybean dataset - Pior alinhamento reledge-verde-nir



**Figure:** Pior alinhamento alcançado por nossa abordagem no Soybean dataset. (a) RGB (com o canal vermelho (R) substituído pelo reledge e o canal azul (B) substituído pelo nir); (b) RGB alinhada (com o canal vermelho (R) substituído pelo reledge e o canal azul (B) substituído pelo nir).

# Experimentos e Resultados

## Cotton dataset

# Experimentos e Resultados

## Cotton dataset - Esquema gerado

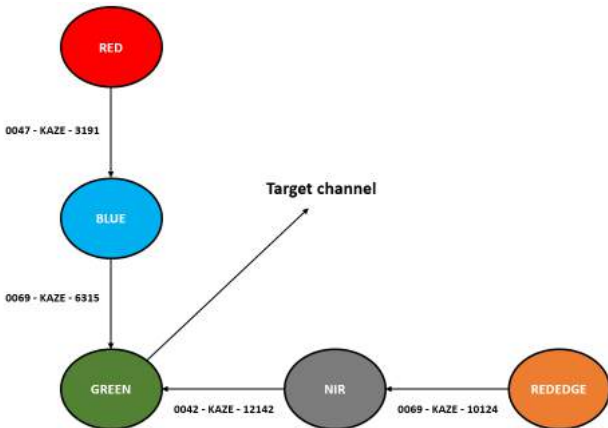


Figure: Esquema gerado por nossa abordagem para o Cotton dataset. A legenda para cada aresta consiste em: ID da imagem - Método - Número de keypoints.

# Experimentos e Resultados

## Cotton dataset - Acurácia

**Table:** A precisão obtida pelos *frameworks* no alinhamento do Cotton dataset (total de 664 alinhamentos).

<b>Método</b>	<b>Falhas</b>	<b>Acurácia</b>
Nossa Abordagem	0	100.00%
(YASIR, 2018)	1	99.85%
(BANERJEE; RAVAL; CULLEN, 2018) KAZE	165	75.15%
(BANERJEE; RAVAL; CULLEN, 2018) SURF	200	69.88%
(BANERJEE; RAVAL; CULLEN, 2018) MSER	240	63.86%
(BANERJEE; RAVAL; CULLEN, 2018) HARRIS	382	42.47%
(BANERJEE; RAVAL; CULLEN, 2018) FAST	390	41.27%
(BANERJEE; RAVAL; CULLEN, 2018) BRISK	431	35.09%



# Experimentos e Resultados


Cotton dataset - Avaliação de desempenho

**Table:** Avaliação do desempenho no processo de alinhamento no Cotton dataset.

<b>Método</b>	<b>BPE (pixels)</b>
Nossa abordagem	0.71
(YASIR, 2018)	1.54
(BANERJEE; RAVAL; CULLEN, 2018) KAZE	31.19
(BANERJEE; RAVAL; CULLEN, 2018) SURF	84.97
(BANERJEE; RAVAL; CULLEN, 2018) MSER	132.60

# Experimentos e Resultados


Cotton dataset - Pior alinhamento RGB



**Figure:** Pior alinhamento alcançado por nossa abordagem no Cotton dataset. (a) RGB original; (b) RGB alinhada.

# Experimentos e Resultados

Cotton dataset - Pior alinhamento rededge-verde-nir



**Figure:** Pior alinhamento alcançado por nossa abordagem no Cotton dataset. (a) RGB (com o canal vermelho (R) substituído pelo rededge e o canal azul (B) substituído pelo nir); (b) RGB alinhada (com o canal vermelho (R) substituído pelo rededge e o canal azul (B) substituído pelo nir).

# Experimentos e Resultados

## Tempo de Execução dos frameworks

**Table:** Tempo médio de execução obtido pelos *frameworks* nos datasets.

<b>Dataset</b>	<b>Framework</b>	<b>Tempo (s)</b>
Soybean	(BANERJEE; RAVAL; CULLEN, 2018) KAZE	1235
	Nossa Abordagem	8808
	(YASIR, 2018)	10162
Cotton	(BANERJEE; RAVAL; CULLEN, 2018) KAZE	2145
	Nossa Abordagem	16339
	(YASIR, 2018)	18550

# Experimentos e Resultados

## Superioridade do método KAZE

- KAZE, ao contrário de métodos como SIFT e SURF, detecta e descreve atributos em um espaço de escala não linear;
- O processo de *blurring* é localmente adaptável na imagem, o que reduz o ruído enquanto mantém os limites naturais dos objetos;
- É importante notar que imagens de plantações obtidas por VANTs geralmente apresentam poucos detalhes úteis para o processo de alinhamento.
- A maioria desses detalhes são bordas, ou seja, transições do solo para a planta e vice-versa, devido à diferença na reflexão do solo para uma planta;
- A proposta do KAZE, de criar um espaço de escala não linear, torna as bordas das transições de reflexão mais detectáveis e distinguíveis, obtendo assim um resultado superior entre outras técnicas.

- Nossa abordagem pressupõe que a velocidade do VANT, quando comparada à velocidade de aquisição de imagens entre sensores, não é suficiente para causar distorções além das naturais causada pela distância entre os sensores.
- Por esse motivo, nossa abordagem pesquisa em todo o dataset, o melhor grupo de imagens para alinhar cada banda e, em seguida, cria um esquema de alinhamento, isto é, a ordem na qual as bandas serão alinhadas.
- Nossa abordagem foi, em média, 335% superior ao segundo melhor *framework*, obtendo para o Soybean dataset um alinhamento com um BPE próximo a zero (0,14 pixels) e para o Cotton dataset o BPE de 0,71 pixels.

- Na maioria das vezes, para algumas imagens, não é possível encontrar *keypoints* suficientes para estimar uma função de transformação, o que torna impossível alinhar a imagem.
- Nossa abordagem utiliza uma transformação global e, por essa razão, consegue realizar todos os alinhamentos.
- Os resultados obtidos foram relevantes e mostram que o *framework* apresentado neste trabalho pode ser usado para alinhar as bandas de imagens multiespectrais obtidas por VANTs.

# Conclusão

## Principais Contribuições

- A principal contribuição deste trabalho é o *framework* proposto para o processo de alinhamento banda-a-banda em imagens obtidas por VANTs. Este método apresenta uma nova abordagem para o alinhamento banda-a-banda e obteve um resultado superior aos demais *frameworks* avaliados.
- A segunda contribuição é a criação de dois datasets de imagens multiespectrais obtidos por VANTs devidamente alinhados por um especialista para medir o desempenho dos métodos para o processo de alinhamento banda-a-banda.



# Conclusão

## Principais Contribuições

- A principal contribuição deste trabalho é o *framework* proposto para o processo de alinhamento banda-a-banda em imagens obtidas por VANTs. Este método apresenta uma nova abordagem para o alinhamento banda-a-banda e obteve um resultado superior aos demais *frameworks* avaliados.
- A segunda contribuição é a criação de dois datasets de imagens multiespectrais obtidos por VANTs devidamente alinhados por um especialista para medir o desempenho dos métodos para o processo de alinhamento banda-a-banda.

- Avaliação de datasets obtidos por diferentes câmeras multiespectrais;
- Avaliação de datasets obtidos por VANTs multi-rotoreis;
- Avaliação métodos para a serem incluídos no framework como pré-processamento (por exemplo, suavização e realce).

Agradeço a atenção.