

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Marcelo Henrique Freitas Avelar

**Metodologia para análise da deformação rígida
e elástica entre diferentes bandas de uma
imagem multiespectral**

Uberlândia, Brasil

2020

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Marcelo Henrique Freitas Avelar

**Metodologia para análise da deformação rígida e elástica
entre diferentes bandas de uma imagem multiespectral**

Trabalho de conclusão de curso apresentado
à Faculdade de Engenharia Mecânica da
Universidade Federal de Uberlândia, Minas
Gerais, como requisito exigido parcial à ob-
tenção do grau de Bacharel em Engenharia
Mecatrônica.

Orientador: Mauricio Cunha Escarpinati

Universidade Federal de Uberlândia – UFU

Faculdade de Engenharia Mecânica

Bacharelado em Engenharia Mecatrônica

Uberlândia, Brasil

2020

Dedico esse projeto de conclusão à minha mãe, cujo amor e perseverança me mostraram que o mais valioso trabalho é o projeto da vida e ao meu falecido avô Rafael, cujas memórias de um grande homem me inspirarão eternamente à competência, bondade e hombridade.

Agradecimentos

Agradeço à minha namorada que com paciência, amor e uma estupenda força me ajudou e ajuda a conduzir de forma sagaz esse valioso caminho, ao meu professor orientador, que pôde dedicar parte da sua rotina a me ajudar a construir esse episódio de vida, aos meus amigos queridos, em especial aos de longa data, que com inteligência e honradez me ajudaram a enxergar a vida de formas diferentes. Por fim, agradeço com toda gratidão e respeito à FEMEC e à Universidade Federal de Uberlândia, onde vivi pessoas, momentos e projetos que me tornaram melhor de forma incalculável.

“O segredo do sucesso é a constância do propósito.”

- Benjamin Disraeli

Resumo

Como parte da evolução humana, entre tantos outros processos, a tecnologia leva ao aprimoramento das técnicas agrícolas por meio de Veículos Aéreos Não Tripulados (VANT), com foco no melhor plantio e, conseqüentemente, na qualidade dos alimentos. Este trabalho propõe uma metodologia baseada em *funções de ângulo acumulativo* para analisar a deformação de imagens multiespectrais obtidas por VANT, classificando-as através da comparação de formas poligonais. Um dos principais desafios neste contexto é a classificação e alinhamento das deformações entre as diferentes bandas, uma vez que, ao combinar-se diferentes faixas do espectro, obtemos resultados melhores e diversificados. Usando a ferramenta Seleção de Ponto de Controle (cpselect), pontos comuns entre pares de bandas diferentes foram obtidos manualmente. Posteriormente, um algoritmo foi executado para obter o melhor polígono formado por estes pontos. Finalmente, utilizando os polígonos obtidos, o método das funções de ângulo acumulativo foi aplicado para comparação das formas poligonais e, em seguida, as dissimilaridades registradas. Os resultados preliminares mostraram que as bandas **azul** e **verde** obtiveram uma melhor correspondência de forma, enquanto a **vermelha** e **NIR** eram menos semelhantes (de acordo com os parâmetros adotados). O método proposto foi validado e também apresentou boas considerações por alguns outros autores. Foi possível verificar qual par de bandas melhor ou pior combina uma com a outra. Porém, o método não pode ser concluído para outra câmera multiespectral, uma vez que este método foi validado apenas para uma série de imagens registradas apenas por uma câmera. É necessário, portanto, futuros trabalhos com outros tipos diversificados de plantios para uma validação mais generalizada.

Palavras-chave: deformação, rígida, elástica, não-rígida, similaridade, bandas, multiespectral, processamento, digital, imagens, PDI sensoriamento remoto, geoprocessamento, dissimilaridade, tangente, cumulativo, registro, transformação, turningdist, matlab, cpselect, infravermelho, infravermelho próximo, banda, mosaico, combinação, pontos, forma, poligonal, polígono, distância, affine, turning function, euclidiano, VANT, satélite, RGB, borda do vermelho, tile, KAZE, SURF, MSER, sobreposição, câmera, algodão, fotografia, campo, vegetação, plantação.

Abstract

As part of human evolution, among many other processes, technology leads to improve farming techniques through Unmanned Aerial Vehicles (UAV), focusing on better plantations and, consequently, on foods' quality. This vehicles works on registering tillages' photographs by multispectral cameras. This paper proposes a methodology based on *turning functions*, to analyze the deformation of multispectral images obtained by UAV, classifying it through polygonal shapes comparison. One of the main challenges in this context is the classification and alignment of the deformations among the different bands, whereas combining many bands of multispectral images must provide better and diversified results. Using the Control Point Selection (*cpselect*) tool, common points between pairs of different bands were manually obtained. Then, an algorithm was executed to obtain the best polygon formed by this points. Finally, using those best polygons, the method of turning functions was applied for polygonal shapes comparison and then the dissimilarities were registered. Preliminar results has shown that both **blue** and **green** bands obtained better shape matching, whereas **red** and **NIR** were less similar (according to the adopted parameters). The purposed method was validated and performed good results too, as shown by some other authors. It was possible to verify which pair of bands worst or best matches one with another. However, the method couldn't be concluded for another multiespectral camera, once this method was validated just for a image's series registered just by one camera. Therefore, future works with different types of plantations are necessary for a more generalized validation.

Keywords: deformation, rigid, elastic, non-rigid, similarity, band, multiespectral, processing, digital, image, DIP, remote sensing, geoprocessing, dissimilarity, tangent, cumulative, registering, infra-red, transformation, turningdist, matlab, cpselect, Near Infra-Red, NIR, band, mosaic, matching, points, polygonal, shape, polygon, distance, affine, turning function, euclidian, UAV, satellite, RGB, red-edge, tile, KAZE, SURF, MSER, overlap, camera, cotton, photography, photo, field, vegetation, plantation.

Lista de ilustrações

Figura 1 – Representação cartesiana de uma imagem digital	15
Figura 2 – Segmentação de um tumor pulmonar utilizando técnicas de PDI. (a) Imagem original (b) Imagem com gradiente (c) Aplicação da técnica watershed à imagem original (d) Sobreposição entre a imagem com watershed e a imagem original (e) Imagem segmentada com técnica watershed a partir de marcadores.	17
Figura 3 – Identificação de características do campo utilizando NDVI	19
Figura 4 – Exemplo de fotografia de campo no espectro azul.	20
Figura 5 – Fotografia de campo no espectro verde.	21
Figura 6 – Exemplo de fotografia de campo no espectro vermelho.	21
Figura 7 – Círculo branco localizado em (646; 598) em uma imagem no espectro azul.	23
Figura 8 – Círculo branco localizado em (669; 615) em uma imagem no espectro verde.	23
Figura 9 – Outras classificações das transformações geométricas.	26
Figura 10 – Tela de execução da ferramenta <i>cpselect</i> . Os quadros inferiores mostram a fotografia completa e os superiores o zoom pelo quadro em azul.	27
Figura 11 – Pontos marcados manualmente (azul) e o ponto médio central (verde).	29
Figura 12 – Outras classificações das transformações geométricas.	29
Figura 13 – Ângulo calculado entre um dos segmentos de reta e o eixo das ordenadas.	30
Figura 14 – Polígono formado pelos pontos ordenados.	31
Figura 15 – (a) Polígono genérico A. (b) Polígono genérico B. (c) Representação gráfica de ambas <i>turning functions</i>	34
Figura 16 – (a) Polígonos transladados entre si. (b) Polígono rotacionado e de menor escala	35
Figura 17 – (a) Polígono verde cisalhado (metade superior deslocada). (b) Polígono verde com deformação no ponto superior.	35
Figura 18 – (a) Polígono verde com canto superior esquerdo deformado. (b) Polígono verde com ambos cantos superiores deformados	36
Figura 19 – (a) Polígono verde deformado elasticamente. (b) Polígono verde com deformação no ponto superior.	36
Figura 20 – Teste de transformação rígida para translação.	45
Figura 21 – Teste de transformação rígida para rotação.	46
Figura 22 – Teste de transformação rígida para rotação e escala.	46
Figura 23 – Teste de transformação não-rígida cisalhamento 25%.	47
Figura 24 – Teste de transformação não-rígida cisalhamento 50%.	47

Figura 25 – Teste de transformação não-rígida cisalhamento >90%.	48
Figura 26 – Teste de transformação não-rígida assimétrica 1	48
Figura 27 – Teste de transformação não-rígida assimétrica 2	49
Figura 28 – Teste de transformação não-rígida simétrica	49
Figura 29 – Teste de transformação não-rígida completa	50
Figura 30 – Teste de transformação não-rígida diagonal assimétrica	50
Figura 31 – Teste de transformação não-rígida diagonal simétrica	51
Figura 32 – Teste de transformação não-rígida diagonal completa	51
Figura 33 – Teste de transformação não-rígida vertical livre	52
Figura 34 – Teste de transformação não-rígida flambagem 1	52
Figura 35 – Teste de transformação não-rígida flambagem 2	53
Figura 36 – Teste de transformação não-rígida flambagem 3	53
Figura 37 – Teste de transformação não-rígida flambagem 4	54
Figura 38 – Teste de transformação não-rígida livre	54
Figura 39 – Teste de transformação não-rígida livre	55
Figura 40 – Teste de transformação não-rígida livre	55
Figura 41 – Teste de transformação não-rígida livre	56
Figura 42 – Teste de transformação não-rígida livre	56

Lista de abreviaturas e siglas

cpselect	Control Point Selection
EIA	Estudos de Impactos Ambientais
IR	Infra-Red
MATLAB	Matrix Laboratory - Software matemático
MicaSense	Câmera Multiespectral
NIR	Near Infra-Red
NVDI	Normalized Difference Vegetation Index
PDI	Processamento Digital de Imagens
RGB	Red, Green, Blue
RIMA	Relatórios de Impacto sobre Meio Ambiente
tile	Agrupamento de imagens que formam um mosaico
turningdist	Função de cálculo de distância
UAV	Unmanned Aerial Vehicle
VANT	Veículo Aéreo Não Tripulado

Lista de símbolos

δ	Delta minúsculo
\in	Pertence
\int	Integral
Λ	Lambda
Σ	Somatória
Θ	Letra grega teta maiúsculo
θ	Letra grega teta minúsculo

Sumário

1	INTRODUÇÃO	12
1.1	Objetivos	14
1.2	Organização do Trabalho	14
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	Imagem digital	15
2.2	Processamento Digital de Imagens	16
2.3	O PDI no sensoriamento de campo e aplicações	17
2.4	Espectros e dispositivos	19
2.5	Combinação entre bandas	22
2.5.1	Deslocamento entre bandas	22
3	DESENVOLVIMENTO	25
3.1	Base de dados	25
3.2	Classificação e problemas de distorção	26
3.3	<i>Control Point Selection</i>	27
3.4	Método dos polígonos	28
3.4.1	Escolha do melhor polígono	28
3.5	Diferenças entre polígonos	31
3.5.1	Medidas de dissimilaridade	31
3.5.2	Turning Function	32
3.5.3	Distância entre as formas	32
3.6	Validação do método	33
3.6.1	Valores manuais e computacionais	33
3.6.2	Outros exemplos	34
4	RESULTADOS	37
4.1	Resultados preliminares	37
4.2	Outro método proposto em artigo	38
5	CONCLUSÃO	40
	REFERÊNCIAS	41
	ANEXO A – CÓDIGO DA FUNÇÃO CPSELECT()	44
	ANEXO B – POLÍGONOS UTILIZADOS NA VALIDAÇÃO	45

1 Introdução

A história do processamento digital de imagens e sinais muito se aproxima à história da evolução humana. A busca pelo constante progresso e melhoria de vida traz à tona a necessidade de novas ferramentas e metodologias que, quando aplicadas de maneira correta, alinham a ciência à evolução.

Nesse contexto, o cenário da melhoria da qualidade de vida leva em conta a qualidade do ambiente, das plantações, dos terrenos e, entre outros, a produção de alimentos, cuja qualidade e quantidade dependem direta e indiretamente do bom plantio. Nesse sentido, a preocupação com plantações saudáveis e abundantes são de suma importância para garantir, no mínimo, uma melhora na produtividade (uma das variáveis intrínsecas na evolução humana) sem que haja prejuízos à vida e ao meio ambiente. É plausível, portanto, que se tenha uma clara necessidade da qualidade dos processos que iniciam o processo produtivo. Assim, o processamento digital de imagens (PDI) tem sido cada dia mais empregado nas lavouras e campos nesses mesmos processos a princípio, para mapeamento dos campos no intuito de monitoramento de estado do plantio, prevenção de pragas e desperdícios, etc.(ALMEIDA, 2017);(SACI, 2019);(BOASPRATICAS, 2019).

Para que haja uma eficiente e completa visão do ambiente, VANTs e satélites são utilizados para fotografar essas regiões, fazendo do sensoriamento remoto uma realidade que substitui cada vez mais o trabalho braçal de monitoramento a olho nu, além de economizar em maquinários pesados, como mostra uma reportagem em Oliveira (2017). Contudo, em sua grande parte, as lavouras possuem áreas de grande escala, com centenas ou até milhares de km^2 , dificultando o detalhamento de informações em fotografias únicas. Assim, uma das práticas que se utiliza são fotografias em partes menores da plantação. Posteriormente, ao se cobrir todo o campo de interesse, as imagens são compiladas para que formem uma única e grande fotografia do terreno. Tal fotografia é chamada de mosaico, que consiste em uma imagem composta por centenas de fotografias tiradas parte a parte da plantação(NAGENDRA; MANJULA; KURIAN, 2020);(ABRAHAM; SIMON, 2013).

Após capturadas, as imagens são armazenadas e submetidas a técnicas de processamento digital de imagens. Quando processadas fornecem informações valiosas sobre o local como a qualidade e umidade do solo, presença de pragas, anomalias, riscos de incêndio, distinção entre espécies, etc., permitindo a prevenção de prejuízos, prováveis replantios, aumento da produção e outras ações (SAUSEN, 2007);(JAISWAL et al., 2002).

Nessa linha, um outro ponto marcante no sensoriamento remoto trata da identificação dessas características. Classificar a qualidade do solo e plantas, por exemplo, pode

exigir mais que um trabalho básico de processamento como realces, contrastes e redução de ruídos. Assim como exemplifica [Pietrzykowski et al. \(2007\)](#), as plantas absorvem diferentes cores de acordo com suas condições de qualidade, tempo e saúde. Dessa forma, é possível saber em quais espectros (ou quais combinações entre esses), pode-se detectar e classificar a saúde de uma plantação, identificar solos férteis, classificar espécies, etc., devido às diferentes absorções de cores pela clorofila. São muitos fatores que podem distinguir essas características, como mostrado por [Henrich V. \(2007\)](#). Portanto, há interesse nas fotografias tiradas em diferentes bandas de cores, uma vez que um leque de possibilidades de identificação qualitativa se abre.

Assim, o processamento de fotografias capturadas de certas regiões pode identificar áreas de risco, diferentes tipos de vegetação, características quanto à natureza de folhas e frutos, pastos e canaviais e outras especificidades de uma dada região de plantio que ajudam a melhorar a produtividade e a qualidade do produto. Do ponto de vista econômico, outrora despendidas horas ou até dias para monitoramento completo de plantações utilizando simples veículos automotores, as fotografias por *drones*, VANTs e satélites destas são feitas em poucas horas, minutos ou, em casos menores, em segundos. Posteriormente o registro, segmentação e demais processamentos das imagens identificam cenários que demandam atenção

Tendo em vista essa necessidade, esses veículos são equipados com câmeras multi-espectrais a fim de tirar fotografias de um mesmo local. No entanto, como as imagens são captadas em sequência, há uma distorção e/ou deslocamento entre duas imagens, devido à posição das lentes e as capturas serem feitas em tempos distintos. Dessa forma, o posterior interesse na combinação/sobreposição entre bandas acaba por ser comprometido, uma vez que, ainda que fotografadas em um mesmo local, as imagens possuem muitos pontos não coincidentes entre si. Portanto, são necessárias ferramentas para classificação dessas distorções e posterior correção.

1.1 Objetivos

Este trabalho tem como principal objetivo o desenvolvimento de uma metodologia de classificação das distorções entre as bandas multispectrais presentes em imagens de campos obtidas por drone. Primeiro mapeia-se os pontos em comum entre as imagens nos seus diferentes espectros. Depois aplica-se um algoritmo de obtenção do melhor polígono formado pelos pontos marcados. Por fim, executa-se um algoritmo de comparação entre os polígonos, classificando-os quanto à dissimilaridade, ou seja, o quão “distantes” são essas geometrias, analisadas em pares.

1.2 Organização do Trabalho

No capítulo 2 será apresentada a fundamentação teórica, onde conceitos gerais do processamento digital de imagens, exemplos de aplicação e especificidades do geoprocessamento são apresentados.

No capítulo 3 o método de trabalho e desenvolvimento serão apresentados, visando mostrar quais caminhos foram seguidos para chegar até o objetivo final.

No capítulo 4 resultados e discussões serão apresentados a partir das informações obtidas acerca da execução do método e futuras implicações.

No capítulo 5 há uma conclusão do trabalho, mostrando uma visão do autor do que se pode extrair dos resultados desse projeto.

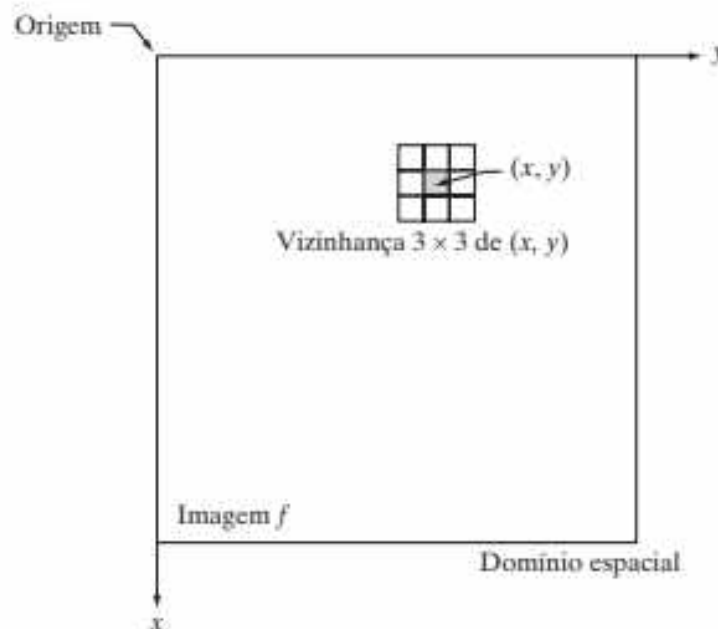
2 Fundamentação Teórica

Será apresentada neste capítulo a fundamentação teórica sobre os conceitos que envolvem este trabalho, sendo, basicamente, sobre o Processamento Digital de Imagens, desde as imagens digitais até e demais aplicações na área.

2.1 Imagem digital

Uma imagem computadorizada pode ser definida em termos matemáticos como uma função bidimensional $f(x, y)$, onde x e y são coordenadas espaciais e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto (Figura 1). Quando x , y e os valores de intensidade de f são quantidades finitas e discretas, chamamos de imagem digital (GONZALEZ; WOODS, 2009). Em geral, a imagem pura, recém adquirida pelo dispositivo de captura, necessita de transformações e realces que a torne mais adequada para que se possa extrair o conteúdo de informação desejada com maior eficiência (ESQUEF; ALBUQUERQUE; ALBUQUERQUE, 2003).

Figura 1 – Representação cartesiana de uma imagem digital



Fonte: Gonzalez e Woods (2009)

2.2 Processamento Digital de Imagens

O Processamento Digital de Imagens pode ser definido como um processo onde as entradas são imagens digitais e as saídas imagens com correções, manipulações e modificações diversas. [Câmara et al. \(1996\)](#) definem o processamento digital de imagens por um processo de entrada e saída, no qual ocorre a manipulação de uma imagem durante todo o processo. [Junior \(2013\)](#) cita como exemplo a alteração dos valores dos pixels de uma imagem, de forma a obter uma nova imagem, de melhor visualização (também chamado frequentemente de realce de imagens). [Gonzalez e Woods \(2009\)](#) se referem ao campo apenas como o processamento de imagens digitais por um computador digital. Estes comentam ainda que outros autores não definiriam limites claros entre o processamento de imagens e uma visão computacional e sugerem 3 processos básicos nessa “linha contínua” que liga essas áreas: nessa

- Pré-processamento

Os processos de nível 1 (ou baixo) consiste nos processamentos iniciais de uma imagem (ou pré-processamento), filtros serão aplicados para redução de ruídos, técnicas para realce de contraste, calibração radiométrica, correção de distorções geométricas, etc. Uma característica dessa etapa é que tanto a entrada quando saída são imagens;

- Segmentação e classificação

Esta etapa consiste na separação da imagem pré-processada, ou seja, na separação da imagem em regiões e objetos, classificação e descrição a fim de reduzi-los a uma forma adequada para o posterior processamento computacional. Neste nível, em geral, as entradas são imagens e as saídas atributos extraídos dessas imagens;

- Sentido e cognição


Esse nível consiste em “dar sentido” a um conjunto de objetos reconhecidos, como na análise de imagens e, como sendo o mais alto nível nessa classificação, realizar as funções cognitivas normalmente associadas à visão.

De maneira geral, é uma área bastante abrangente e que tem sido largamente empregada nos mais diversos setores. Consiste, basicamente, na aplicação de técnicas de processamento em uma imagem digital, anteriormente adquirida por um dispositivo de aquisição de imagens. [Lopes, Bruno e Namikawa \(1996\)](#) ainda definem a área como técnicas voltadas para a análise de dados multidimensionais, adquiridos por diversos tipos de sensores, ou seja, é a manipulação de uma imagem por computador de modo onde a entrada e a saída do processo são imagens.

2.3 O PDI no sensoriamento de campo e aplicações

Atualmente é empregada nas mais diversas áreas, desde a engenharia, como no processamento de imagens de pesquisas aeroespaciais, meteorologia, termografia, robôs em áreas de catástrofes e sensoriamento de plantios até na medicina, na identificação de células cancerígenas (Figura 2).

Figura 2 – Segmentação de um tumor pulmonar utilizando técnicas de PDI. (a) Imagem original (b) Imagem com gradiente (c) Aplicação da técnica watershed à imagem original (d) Sobreposição entre a imagem com watershed e a imagem original (e) Imagem segmentada com técnica watershed a partir de marcadores.



Fonte: [Patil e Jain \(2014\)](#)

Em suma, o campo permite a visualização de problemas muitas vezes invisíveis ou imperceptíveis a olho nu e até mesmo através de lentes fotográficas.

Dentre as demais aplicações, as áreas da agronomia e ciências da terra são exemplos de onde o PDI tem sido utilizado com devida consideração e será o foco deste trabalho. Entre outros exemplos de aplicação nesse campo, podemos citar:

- mapeamento da qualidade de água nos oceanos ([PHINN et al., 2005](#));
- monitoramento de pragas;
- segmentação de vegetações e tipos de vegetações;

- mapeamento de zonas de risco de fogo (JAISWAL et al., 2002);
- nível de salinidade das águas e zonas passíveis de incêndio.

SAUSEN (2007) cita outras atividades relacionadas a este campo de aplicação:

- desenvolver mapas e obter informações sobre áreas minerais, bacias de drenagem, agricultura, florestas;
- monitorar desastres ambientais tais como enchentes, poluição de rios e reservatórios, erosão, deslizamentos de terras, secas;
- monitorar desmatamentos;
- estimativa da taxa de desflorestamento da Amazônia Legal;
- estudos de Impactos Ambientais (EIA) e Relatórios de Impacto sobre Meio Ambiente (RIMA);
- levantamento de áreas favoráveis para exploração de mananciais hídricos subterrâneos;
- monitoramento de mananciais e corpos hídricos superficiais;
- estimativa de área plantada em propriedades rurais para fins de fiscalização do crédito agrícola;
- identificação de áreas de preservação permanente e avaliação do uso do solo.

Na Figura 3 é apresentada uma diferenciação entre os índices RGB e NDVI, que permite a análise da taxa de fotossíntese das plantas. Normalmente são imagens em tons de verde, amarelo e vermelho, onde: tons de verde são plantas em processo de fotossíntese (saudáveis), tons de amarelo indicam algum problema (indicadores de estresses) e tons de vermelho são áreas com plantas mortas ou sem vegetação (HORUS, 2020).

Figura 3 – Identificação de características do campo utilizando NDVI



Fonte: [Baiwang \(2018\)](#)

2.4 Espectros e dispositivos

Há situações em que a identificação de determinadas características nas plantações não seria possível através de câmeras comuns (ainda que sejam aplicados realces e contrastes simples). Assim como apresentado em alguns exemplos na seção anterior, algumas dessas características são identificadas apenas em outras bandas do espectro, devido as diferentes morfologias celulares das plantas, refletindo, portanto, cores distintas de acordo com o estado e situação da planta. Dessa forma, fotografias em diferentes comprimentos de onda são importantes para análises diversas, extraindo informações específicas e completas.

[Zaidan \(2011\)](#) exemplifica algumas faixas onde é possível identificar características de acordo com o ambiente fotografado por satélite:


- Banda azul (0,4 a 0,52 μm): apresenta grande penetração em corpos de água e sensibilidade a plumas de fumaça ou atividades industriais;
- Banda verde (0,5 a 0,6 μm): grande sensibilidade à presença de sedimentos em suspensão na água, boa para mapeamento de vegetação e áreas onde ocorrem atividades antrópicas.
- Banda vermelha (0,63 a 0,69 μm): apresenta bom contraste entre áreas cobertas com vegetação e solo exposto, bem como discrimina diversos tipos de vegetação. Adequada para mapeamentos de uso do solo, agricultura e estudos de qualidade d'água.
- Banda infravermelho próximo (0,76 a 0,90 μm): apresenta bom contraste entre solo e corpos d'água, permitindo o mapeamento de rios de grande porte, lagos, lagoas,

reservatórios e áreas úmidas. Serve também para mapear a vegetação que foi queimada. Banda muito sensível à absorção da radiação eletromagnética pelos óxidos de ferro e titânio, muito comuns nos solos tropicais muito intemperizados.

- Banda infravermelho médio (1,55 a 1,75 μm): permite observar o teor de umidade nas plantas e detectar possíveis estresses na vegetação causados por falta de água. Utilizada também para obter informações sobre a umidade do solo.


Para capturas nesses diferentes espectros, câmeras especiais instaladas nos equipamentos aéreos, como câmeras RGB (Red, Green, Blue), NIR (Near Infra-Red) e multiespectral são utilizadas largamente por serem dispositivos especialmente capacitados para este tipo de fotografia. Nas Figuras 4, 5 e 6 podem ser visualizados exemplos de uma mesma região de um campo, fotografada em diferentes espectros:

Figura 4 – Exemplo de fotografia de campo no espectro azul.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

Figura 5 – Fotografia de campo no espectro verde.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

Figura 6 – Exemplo de fotografia de campo no espectro vermelho.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

2.5 Combinação entre bandas

Os espectros permitem, como mostrado nos subcapítulos anteriores, que as fotografias sejam tiradas em diferentes bandas, o que possibilita a identificação de várias informações sobre o estado dos objetos em foco, mostrando dados distintos, outrora não explícitos nas fotografias de bandas unitárias (isto é, fotografias em apenas uma cor). [Zaidan \(2011\)](#) também mostra vários exemplos onde a combinação entre bandas se torna mais eficiente, especialmente na distinção entre características do solo, da vegetação e da água.


A exatidão de mapeamento entre a imagem classificada e a fotointerpretação foi considerada de regular a fraca, sendo **os melhores resultados obtidos por combinação de bandas** ([MACHADO et al., 2003](#)).

2.5.1 Deslocamento entre bandas

Tais combinações podem ser realizadas através da sobreposição das imagens. Para que se obtenha o máximo de correspondência possível, essas necessitam de um mínimo de correlação, isto é, pontos em comum em ambas fotografias devem ser coincidentes, ainda que com certo desvio. As Figuras 7 e 8 mostram fotografias tiradas em canais azul e verde, respectivamente, de uma mesma localidade. Porém, ao se observar detalhadamente, é possível reparar que, apesar das mesmas dimensões do quadro e distância da câmera, pontos do ambiente não correspondem às mesmas coordenadas $p(x,y)$ de uma imagem para outra.


Para ilustrar o problema, em ambas imagens é possível identificar um círculo branco localizado em um terreno isolado, correspondente a algum tipo de reservatório, indicado pelo quadrado azul (Figura 7). Na mesma fotografia as coordenadas desse objeto está em, aproximadamente, $p(646,598)$ (de acordo com o mapeamento gerado da função *cpselect* utilizada no MATLAB). Na Figura 8, com mesmo enquadramento, sendo a fotografia tirada após a fotografia da Figura 7, esse objeto tem nova localidade, em $p(669,615)$, aproximadamente. Ou seja, a distorção presente na fotografia da Figura 10 foi causada por um deslocamento de ± 23 e 17 pixels em cada um dos eixos principais da imagem.

Figura 7 – Círculo branco localizado em (646; 598) em uma imagem no espectro azul.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

Figura 8 – Círculo branco localizado em (669; 615) em uma imagem no espectro verde.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

Assim, o trabalho de junção e correlação entre imagens se torna mais difícil, uma vez que uma simples sobreposição resultaria na formação de objetos e cenários duplicados ou sobrepostos de forma desalinhada em uma mesma imagem. Portanto, é necessário que se classifique os deslocamentos e os níveis de deslocamento presentes entre essas imagens para facilitar o trabalho de aplicação dos algoritmos de correção, a fim de se obter fotografias mais correlatas possível em termos de coordenadas, para que posteriores análises e trabalhos de registro de imagens sejam facilitados e melhor desempenhados.

3 Metodologia

Para este trabalho, o seguinte fluxo para obtenção dos resultados foi realizado:

1. Uma base de 785 imagens foi arranjada em grupos de 5 fotografias (*tiles*), sendo as 5 de uma mesma localidade, porém em diferentes espectros;
2. Das 5 imagens de cada, tomou-se a imagem no espectro *verde* como fixa;
3. Entre cada par de imagens (verde-azul, verde-vermelho, verde-rededge e verde-NIR) foram identificados os pontos em comum do local fotografado, utilizando a função *cpselect* no MATLAB;
4. Uma vez selecionados os pontos em comum na imagem, o *cpselect* e de posse de suas coordenadas, aplica-se um algoritmo para identificar o melhor polígono formado pelos pontos marcados (em cada imagem);
5. Obtidos os melhores polígonos para cada imagem, compara-se cada par de polígonos (entre as 5 imagens mapeadas) aplicando um algoritmo de distância entre as formas geométricas, com a função *turningdist*;
6. Registra-se cada distância obtida para posterior análises e conclusões.

3.1 Base de dados

As imagens utilizadas no trabalho pertencem ao acervo da SenSix Inovações em Drone Ltda. A base é composta por 1 mosaico com 157 tiles, onde em cada tile contém 5 imagens, totalizando 785 imagens de uma plantação de algodão.

Cada *tile* é composto por 5 imagens em 5 espectros distintos: Azul (475nm central, 20nm de largura de banda), Verde (560nm central, 20nm de largura de banda), vermelho (668nm central, 10nm de largura de banda), borda do vermelho (rededge) (717nm central, 10nm de largura de banda), Infravermelho próximo (near-IR ou NIR) (840nm central, 40nm de largura de banda).

As imagens foram obtidas utilizando uma câmera MicaSense Red-Edge em um VANT Micro UAV SX2 (Sensix Inovações em Drone Ltda, Uberlândia, MG, Brasil) em uma altitude média de 100 metros, a, aproximadamente, 70 km/h.

3.2 Classificação e problemas de distorção

Devido ao fato das fotografias nos diferentes espectros de cores serem tiradas pelo VANT de forma sequencial (ainda que de forma quase instantaneamente), à distância entre veículo e o solo ($\sim 100\text{ m}$), qualquer mínima perturbação ocorrida no veículo pode ampliar e distorcer as imagens, fazendo com que um espectro e outro estejam ligeiramente distorcidos entre si, quando deveriam representar uma mesma imagem.

Assim, algumas imagens podem estar distorcidas de várias maneiras, desde formas mais simples como rotações, translações ou mudanças de escala, até mais complexas como conjuntos de pixels modificados, fazendo com que algumas regiões estejam estiradas, contraídas, etc. A essas distorções chamamos de **transformações elásticas** ou **não-rígidas**, enquanto às distorções que se restringem a apenas rotação, translação e escala, de **transformações rígidas**.

Fisher et al. (1996) ainda classificam as transformações como de **similaridade** (*similarity*), **euclidianas** (*euclidian*), **afim** (*affine*) e **projetivas** (*projective*), como mostra a Figura. 9

Figura 9 – Outras classificações das transformações geométricas.

Transformation	Before	After
Projective		
Affine		
Similarity		
Euclidean		

Fonte: Fisher et al. (1996).

Para simplificar o desenvolvimento neste trabalho, optou-se por utilizar apenas

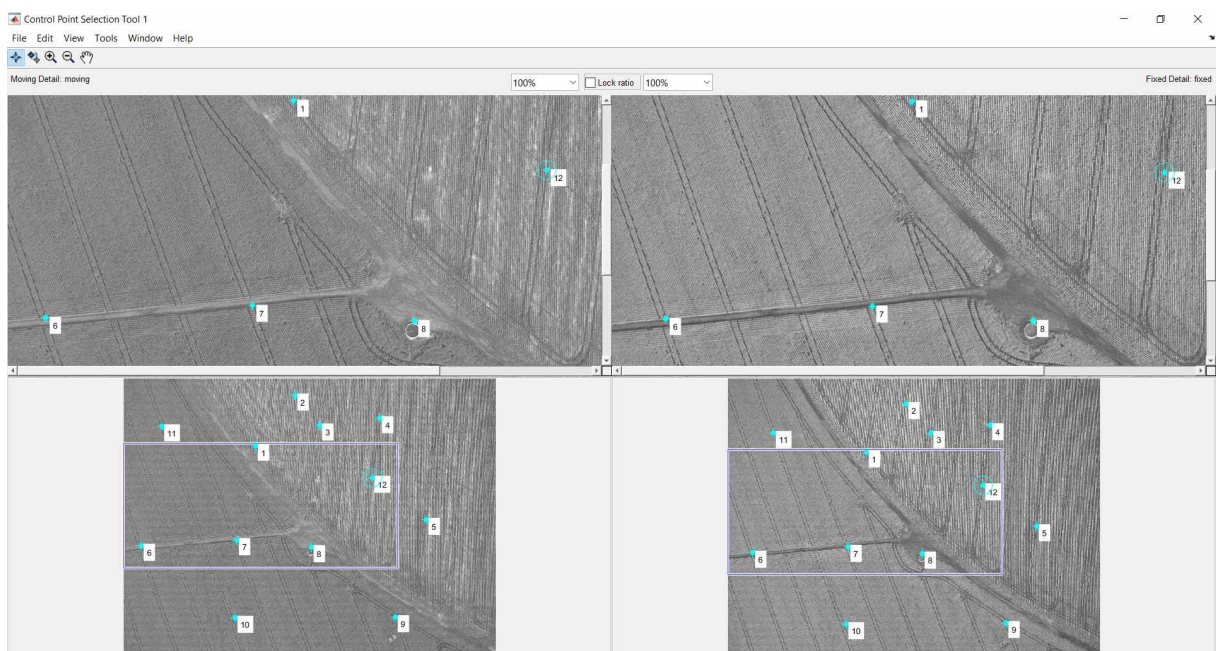
duas classificações, classificando as transformações de *similaridade* e *euclidianas* como **rígidas** e as *afim* e *projetivas* como **não-rígidas**, também com base na literatura (Marias et al. (2004); Crum, Hartkens e Hill (2004)).

Para as transformações não-rígidas (ou elásticas) a aplicação dos algoritmos se torna um pouco mais complexa, uma vez que há certa dificuldade de se medir o nível de distorção entre as imagens para então se aplicar algoritmos de correção. Uma alternativa para facilitar a aplicação desses algoritmos seria aplicar técnicas para medição e pré-classificação das distorções nas bandas, analisando o quão distorcidos estão os pontos entre si, com a metodologia aqui apresentada.

3.3 Control Point Selection

O *Control Point Selection* (*cpselect*) é uma ferramenta que permite selecionar pontos de controle em duas imagens relacionadas (MATHWORKS, 2006). Do conjunto, uma imagem é escolhida para ser a imagem de referência, ou **fixa**, isto é, a imagem à qual todas as outras imagens (**móveis**) serão comparadas, registrando-se as coordenadas. Para este trabalho, de um conjunto de 5 imagens nos 5 diferentes espectros mencionados, a fotografia em **verde** foi a escolhida para ser a imagem de referência, ou seja, fixa. A Figura 10 mostra um exemplo de marcação feita em duas fotografias de um mesmo local. A imagem da direita é fixa. Assim, a cada execução do *cpselect*, a imagem da esquerda é trocada, comparando cada espectro com a fotografia em verde.

Figura 10 – Tela de execução da ferramenta *cpselect*. Os quadros inferiores mostram a fotografia completa e os superiores o zoom pelo quadro em azul.



Fonte: Do autor (2020).

Com o intuito de se aumentar a precisão das medidas, neste trabalho, em cada imagem, foram marcados 12 pontos com a ferramenta, com uma aproximação de zoom de 400%.

3.4 Método dos polígonos

Após a identificação e marcação dos pontos comuns entre duas imagens, é possível identificar uma vasta gama de polígonos que podem ser formados ligando-se esses pontos (observar Figura 10). No intuito de facilitar a análise das distorções, o método consiste na marcação de um polígono em comum entre ambas imagens, uma vez que o processamento direto na fotografia de pontos em comum e análises de dissimilaridade seriam complicados do tanto do ponto de vista de performance computacional quanto humano. Identificando nas imagens polígonos e registrando apenas seus pontos e arestas, os novos processamentos implicam apenas na análise de formas geométricas, com pontos e distâncias no plano cartesiano. Assim, para posteriores cálculos, podemos conservar as informações numéricas e "descartar", por ora, as informações visuais da imagem.

3.4.1 Escolha do melhor polígono


Ainda que o método dos polígonos seja uma boa escolha, claramente existem exigências e cuidados ao se considerar sua aplicação. Os 12 pontos na imagem permitem a formação de inúmeras formas e polígonos ao serem marcados de forma aleatória. Portanto, alguns requisitos devem ser levados em conta para que um bom polígono seja considerado para as análises.

Dadas propriedades das funções de distância, *turning functions* (ARKIN et al., 1991) e para se evitar pontos de descontinuidade e cruzamentos internos de arestas nas formas, deve-se garantir que os pontos sejam unidos de forma que as linhas que formarão as arestas do polígono não se cruzem e os ângulos sejam formados gradativamente e de forma progressiva, como explicado nas Figuras 11, 12, 13 e 14 (evitando a formação de geometrias que não correspondem a polígonos).

Para que sejam produzidos os melhores polígonos, o algoritmo criado no MATLAB consiste nas seguintes etapas:


1. Dado o conjunto de pontos dispostos no espaço, representados pela cor azul na Figura 11, encontra-se o ponto central médio entre os 12 pontos (ponto verde);
2. Calcula-se e são traçados segmentos de reta ligando todos os pontos periféricos ao ponto central médio, representados pela cor branca na Figura 12;

Figura 11 – Pontos marcados manualmente (azul) e o ponto médio central (verde).



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).


Figura 12 – Outras classificações das transformações geométricas.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

3. São calculados todos os 12 ângulos entre os segmentos e o eixo X (Figura 13);


Figura 13 – Ângulo calculado entre um dos segmentos de reta e o eixo das ordenadas.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

4. Armazena-se os ângulos em ordem crescente;
5. Utilizando a ordem calculada no item 5, ordena-se os pontos periféricos.
6. Utilizando a ordem obtida, une-se os pontos para formação do polígono final (Figura 14)

Figura 14 – Polígono formado pelos pontos ordenados.



Fonte: Adaptada de Sensix Inovações em Drone Ltda (2020).

Dessa forma, obtém-se o melhor polígono representante dos pontos marcados através da *cpselect*, sendo o mesmo algoritmo aplicado posteriormente para as fotografias deste mesmo local, em nos outros 4 espectros. A ordem dos pontos periféricos registrados é importante, uma vez que será tomada como referência de cálculo das distâncias para todos os outros pontos registrados nas outras imagens do mesmo grupo. Ou seja, em para que haja uma comparação fiel entre os diferentes espectros, a mesma ordem de ligação dos pontos deve ser mantida.

Em suma, o melhor polígono deve ser formado por uma geometria em que suas arestas não se cruzem, seus vértices sejam registrados e armazenados de forma ordenada, em função dos ângulos (medido de forma crescente e anti-horária) entre suas respectivas arestas e o eixo X.

3.5 Diferenças entre polígonos

3.5.1 Medidas de dissimilaridade

A **similaridade** entre formas refere-se à medida de proximidade entre formas, ou seja, o quão parecidas entre si. De forma inversa as medidas de **dissimilaridade** são métricas para quantificar o quão diferentes (ou distantes) dois objetos, figuras ou

formas são. Neste campo, uma das métricas mais utilizadas é a Distância Euclidiana. Este método calcula a distância entre dois pontos quaisquer em um plano, dadas suas coordenadas cartesianas. No exemplo de um polígono, visando comparar ponto a ponto de dois vetores p e q quaisquer, é representada matematicamente pela fórmula:

$$d(p,q) = d(q,p) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (3.1)$$

Com base nessa métrica, a comparação entre dois objetos (que no caso deste trabalho, serão polígonos de 12 vértices) será feita a fim de se obter o quão distante estão as distorções das imagens entre seus espectros. Neste trabalho os polígonos serão discriminados por funções chamadas de *turning functions*.

3.5.2 Turning Function

Uma *Turning Function* (funções tangente ou ainda funções de ângulo cumulativa) é uma ferramenta simples usada para caracterização discreta de uma forma. O método é invariante à escala e consiste em normalizar o comprimento total das formas para 1. Isso é feito dividindo o comprimento de cada aresta pelo comprimento total da forma (perímetro no caso de uma forma fechada). Na prática, uma *turning function* Θ mede e registra os ângulos que cada aresta S do polígono analisado faz com o eixo das abscissas X (referenciado no início de cada ponto em questão) em função do comprimento normalizado da aresta. A função de cada polígono pode ser registrada na forma gráfica, somando ou subtraindo os ângulos conforme orientação, somando quando em sentido anti-horário e subtraindo quando horário. (ARKIN et al., 1991).

3.5.3 Distância entre as formas

Arkin et al. (1991) propõem, como aperfeiçoamento de propostas anteriores, uma métrica para se obter, numericamente, a diferença entre formas, baseada na comparação entre funções tangentes de cada forma. A métrica é invariante à escala, translação e rotação, sendo ideal para a aplicabilidade em questão, ou seja, fotografias sequenciais em lavouras, onde as ruídos sobre as fotografias tiradas pelos VANTs são, em sua maioria, distorcidas elasticamente, como explicado na seção 3.2.

A métrica consiste em uma das variações da função de espaço (L^p) (ROYDEN, 1968) generalizada, tomando-se o perímetro normalizado $s : [0,1]$:

$$\delta_p(A,B) = \|\Theta_A - \Theta_B\|_p = \left(\int_0^1 |\Theta_A(s) - \Theta_B(s)|^p ds \right)^{1/p} \quad (3.2)$$

onde os autores consideram, por questões de aplicabilidade, a função para $p = 2$ (L^2), ou seja,

$$\delta_2(A,B) = \|\Theta_A - \Theta_B\|_2 = \sqrt{\int_0^1 |\Theta_A(s) - \Theta_B(s)|^2 ds} \quad (3.3)$$

Para uma distância mínima entre A e B , é encontrado, na Eq.(3.3), o valor mínimo θ para uma distância mínima t percorrida no perímetro do polígono. Assim, para um deslocamento em $\Theta(s+t)$ e θ temos:

$$\delta_2(A,B) = \sqrt{\min_{\theta \in \mathbb{R}, t \in [0,1]} \int_0^1 |\Theta_A(s+t) - \Theta_B(s) + \theta|^2 ds} \quad (3.4)$$

O termo $\int_0^1 |\Theta_A(s+t) - \Theta_B(s) + \theta|^2 ds$ pode ser trivialmente calculado (manual ou computacionalmente) por uma distância fixada ds multiplicada pelo quadrado da diferença entre as duas *turning functions* Θ_a e Θ_B . Em outras palavras pode-se, de certa forma, relacionar a distância calculada na métrica à soma das áreas entre os gráficos de ambas funções tangentes, como mostra a Figura 15. Após a raiz quadrada do número obtido na integral, obtém-se o valor numérico de δ , a distância entre ambos polígonos pelo método em questão.

3.6 Validação do método

3.6.1 Valores manuais e computacionais

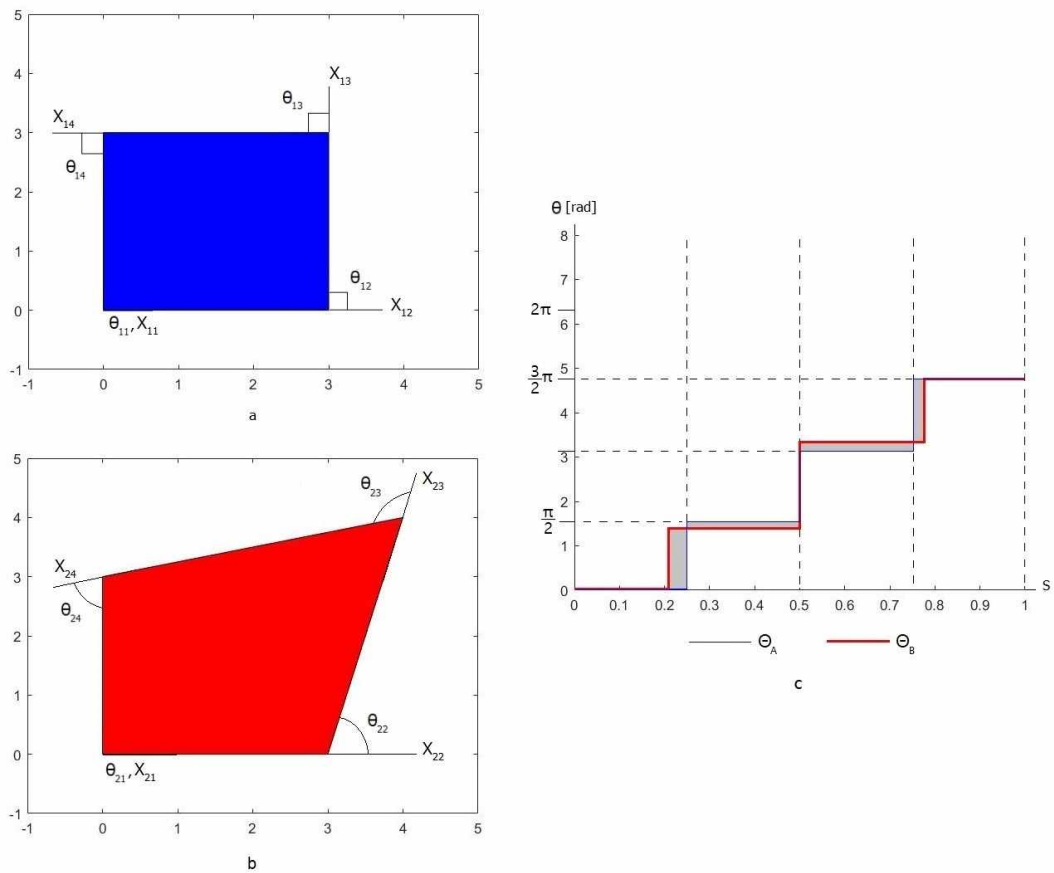
Muitas vezes a complexidade do método implica diretamente no tempo computacional

Para os exemplos apresentados na Figura 15 foram calculadas as distância entre as formas manual e computacionalmente (MATLAB), através da Eq. (3.4), para fins de comparação.

Para o **procedimento manual**, cada segmento do perímetro ds representado pela base de cada área sombreada na Figura 15(c), foi multiplicado por cada quadrado da diferença entre as funções tangente, $(\Theta_A(s+t) - \Theta_B(s) + \theta)^2$. Após a somatória e extração da raiz, obteve-se $\delta = D(A,B) = 0,4105$.

Portanto, para fins comparativos, ambos procedimentos convergem, com um erro menor que 0,05%.

Figura 15 – (a) Polígono genérico A. (b) Polígono genérico B. (c) Representação gráfica de ambas *turning functions*.

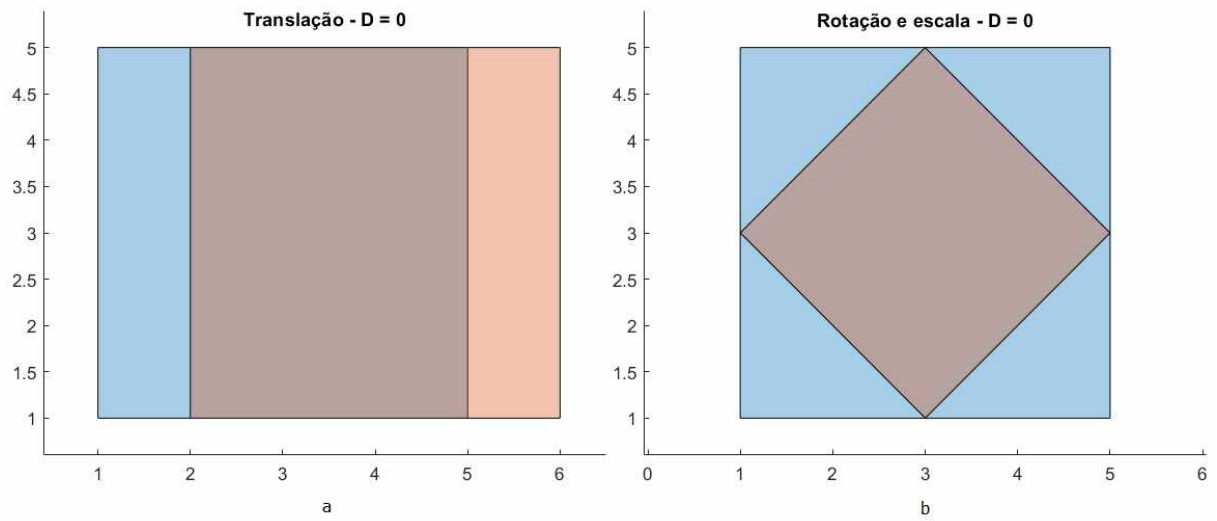


Fonte: Do autor (2020).

3.6.2 Outros exemplos

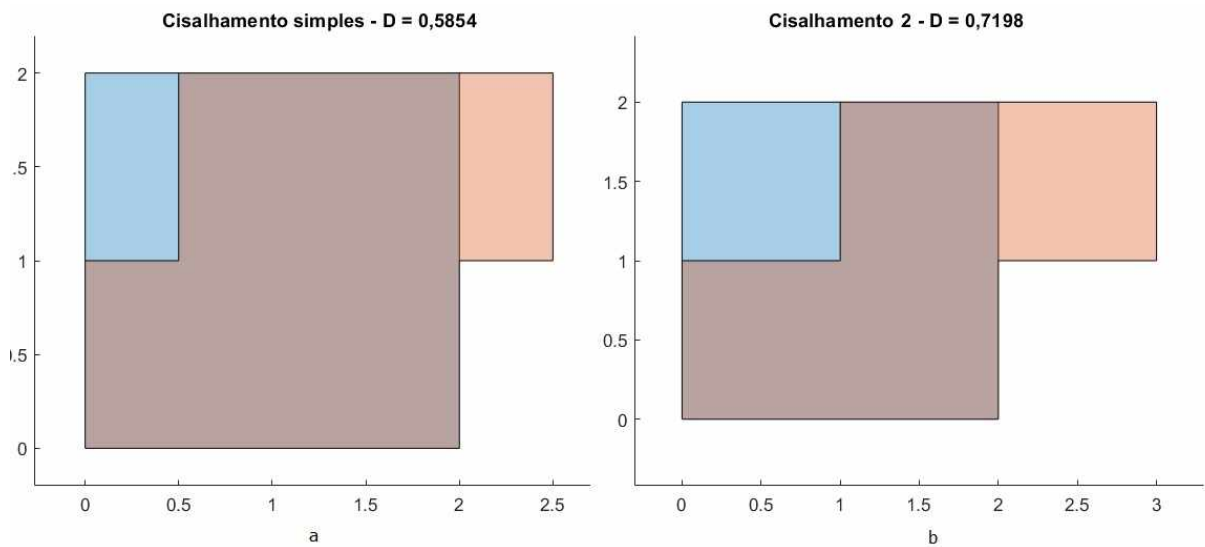
Para validar o método, além de valores numéricos, incluindo a testagem e comprovação quanto às invariâncias à escala, translação e rotação, mais 21 pares de exemplos de diferentes polígonos foram reproduzidos e suas distâncias calculadas computacionalmente através da função *turningdist()*. Devido à extensa lista de imagens, as mesmas e os resultados constam no Anexo B. As Figuras 16, 17 e 18 são alguns dos exemplos dos testes. Neles, o polígono azul é mantido em sua forma original, enquanto que o outro polígono é variado. Todavia, pôde-se concluir e validar a eficácia do método, uma vez que os testes para pares de formas distorcidas rigidamente, a distância $D(,)$ calculada permaneceu nula, ou seja, continuam com similaridade total, ou ainda, dissimilaridade igual a 0.

Figura 16 – (a) Polígonos transladados entre si. (b) Polígono rotacionado e de menor escala



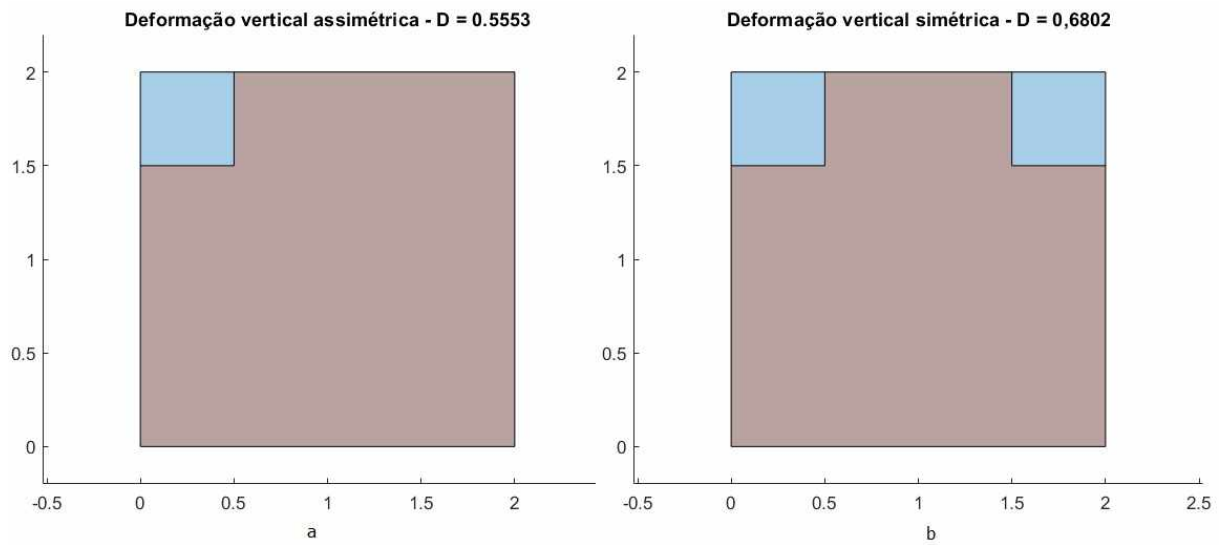
Fonte: Do autor (2020).

Figura 17 – (a) Polígono verde cisalhado (metade superior deslocada). (b) Polígono verde com deformação no ponto superior.



Fonte: Do autor (2020).

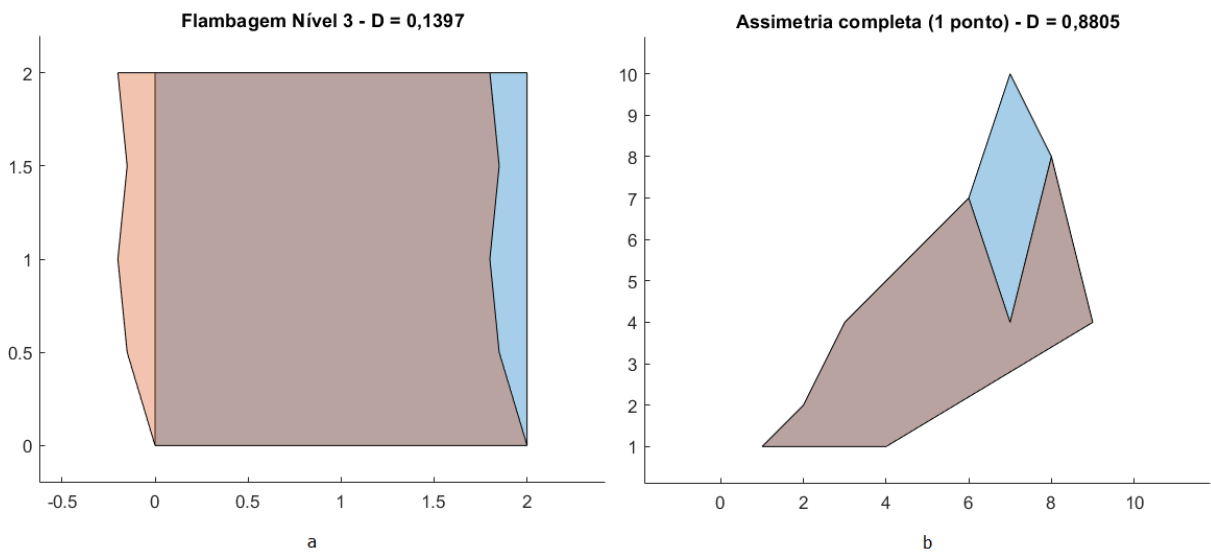
Figura 18 – (a) Polígono verde com canto superior esquerdo deformado. (b) Polígono verde com ambos cantos superiores deformados



Fonte: Do autor (2020).

A Figura 19 mostra um exemplo claro da forma como a comparação entre funções tangente funciona, através da *turningdist()* no MATLAB. Ainda que deformado, o polígono da Figura 19-a ainda corresponde à uma forma semelhante ao polígono azul. Matematicamente, pela Eq. 3.4, os ângulos suavemente no decorrer do perímetro do polígono alterado, fazendo com que $D(.)$ seja menor. Em contrapartida, o polígono verde da Figura 19-b sofreu uma deformação drástica, implicando em uma dissimilaridade alta, próxima de 1.

Figura 19 – (a) Polígono verde deformado elasticamente. (b) Polígono verde com deformação no ponto superior.



Fonte: Do autor (2020).

4 Resultados e Discussão

4.1 Resultados preliminares

Durante o processo de aplicação do método às imagens obtidas *in locu* (das lavouras - vide capítulo 3.1) alguns tiles foram descartados devido às condições das imagens ou até mesmo do terreno. Em alguns casos, por exemplo, não foi possível identificar pontos expressivos na(s) fotografias(s), no momento da marcação pelo *cpselect*, devido à falta aos pontos de interesse perderem nitidez em alguns espectros, comprometendo todo o restante do tile. Ao final, todo o processo foi realizado para 157 tiles, cada tile contendo 5 imagens em diferentes espectros (785 imagens).

Para o cálculo da diferença (distância) entre as diferentes bandas, 10 comparativos foram feitos, combinando-se todas as 5 bandas de cada tile. Cada banda recebeu uma letra: A - Azul, B - Verde, C - Vermelho, D - NIR e E - rededge. Os resultados obtidos foram compilados em uma só tabela. Para remoção de inconsistências e outliers, os valores foram verificados manualmente e também aplicados percentis de 2% e 98% para cada par de bandas analisado. Após o procedimento, novas médias, desvios e medianas foram calculados, a fim de se realizar uma comparação geral entre as bandas (Tabela 1).

Tabela 1 – Médias das distâncias por pares de bandas

Par	Média (\bar{X})	Desvio (σ)	Mediana (\tilde{X})
D(A,B)	0,1059	0,0553	0,0935
D(A,C)	0,1566	0,0629	0,1500
D(A,D)	0,1250	0,0607	0,1118
D(A,E)	0,1301	0,0701	0,1106
D(B,C)	0,1576	0,0740	0,1424
D(B,D)	0,1274	0,0679	0,1120
D(B,E)	0,1306	0,0684	0,1156
D(C,D)	0,1577	0,0614	0,1484
D(C,E)	0,1692	0,0725	0,1521
D(D,E)	0,1337	0,0732	0,1099

A Tabela 1 mostra que, em média, os espectros que mais se aproximaram, isto é, mais similares nos termos da metodologia aplicada e para os dados da plantação de algodão analisada, foram Azul (A) e Verde (B), com uma dissimilaridade média de **0,1059**

e os mais distantes os espectros Vermelho (C) e NIR (D), com dissimilaridade média de **0,1692**, com uma diferença de 36

Contudo, não se pode afirmar se a metodologia é válida para outros tipos de plantações, uma vez que as análises não foram feitas para apenas um tipo, de algodão. Outro ponto importante a se considerar é que as fotografias foram tiradas de uma única câmera multiespectral e em um veículo de asas fixas, portanto, os mesmos resultados podem não ser válidos para veículos de asas rotativas (como, por exemplo, drones) ou para outros tipos de câmeras multiespectrais no mercado.

4.2 Outro método proposto em artigo

Com os mesmos materiais produzidos por este trabalho, em [Junior et al. \(2020\)](#) foi proposta uma nova abordagem, baseada no proposto por [Yasir et al. \(2018\)](#), com mesmo propósito do alinhamento de bandas de imagens multiespectrais. A nova abordagem proposta recebe a base de dados (subcapítulo 3.1) como entrada e, como saída, retorna um esquema de quais bandas devem ser alinhados (em ordem) e qual método de alinhamento deve ser aplicado. Uma das vantagens do novo método proposto pelos autores é de se aplicar o alinhamento a um conjunto de imagens, ao invés de ser aplicado um a cada imagem, como fazem os outros métodos comparados. Isso porque, ao se analisar o grupo de imagens, o método sempre vai buscar o melhor alinhamento. Posteriormente comparada com dois outros *frameworks* já existentes na literatura, a abordagem proposta também demonstrou melhor precisão em relação aos outros dois *frameworks*. Um dos *frameworks* analisados foi testado para outros 6 diferentes métodos, como mostra a Tabela 2.

Tabela 2 – Precisão obtida pelos métodos testados no alinhamento da base de plantação de algodão

Método	Falhas	Precisão
(JUNIOR et al., 2020) Abordagem proposta	0	100:00%
Yasir et al. (2018)	1	99:85%
Banerjee, Raval e Cullen (2018) KAZE	165	75,15%
Banerjee, Raval e Cullen (2018) SURF	200	69,88%
Banerjee, Raval e Cullen (2018) MSER	240	63,86%
Banerjee, Raval e Cullen (2018) HSF	382	42,47%
Banerjee, Raval e Cullen (2018) FAST	390	41,27%
Banerjee, Raval e Cullen (2018) BRISK	431	35,09%

Para avaliação da performance entre os *frameworks*, foi utilizada a métrica *Back*

Projection Error (BPE) (RAN et al., 2016), que leva em conta os dados obtidos manualmente através do *cpselect*, distância euclidiana (Eq. 3.1) e demais manipulações algébricas. A métrica avalia o quão alinhados estão os pontos da imagem de referência (subcapítulo 3.3) com os pontos das demais imagens registradas. **Quanto menor o BPE, melhor a performance do registro.** Os resultados das comparações com os outros *frameworks*, para plantação de algodão, estão registrados na Tabela 3

Tabela 3 – Performance de registro na plantação de algodão

Método	BPE
(JUNIOR et al., 2020) Abordagem proposta	0,71
Yasir et al. (2018)	1,54
Banerjee, Raval e Cullen (2018) KAZE	31,19
Banerjee, Raval e Cullen (2018) SURF	84,97
Banerjee, Raval e Cullen (2018) MSER	132,60

Apesar deste *framework* ter bom desempenho, podemos citar 3 pontos que o limitam. O principal é que, para ser executado, os dados devem ter sido obtidos por uma mesma câmera e, de preferência, em um mesmo vôo (isso se deve ao fato de que o principal intuito dessa abordagem é fazer o alinhamento de imagens obtidas por uma mesma câmera). Outro ponto relevante é que, devido ao alto custo de aquisição das fotografias pelas câmeras multiespectrais, não foram testadas outras, impossibilitando verificar se o método é robusto para outras câmeras multiespectrais. Um outro ponto importante a ser considerado é que a abordagem proposta foi executada com dados obtidos por aeronaves de asa fixa, não sendo possível afirmar sobre sua aplicação a imagens obtidas por aeronaves com asas rotativas (ex. Drones).

5 Considerações finais

A metodologia apresentada se mostrou eficiente às validações executadas, uma vez que, além de simples de ser calculada e de fácil entendimento, há um custo de processamento computacional de complexidade $O(m.n.(m+n))$ para implementações simples e $O(m.n.\log(m.n))$ para as mais arrojadas, além de ser um método de boa confiabilidade para as formas analisadas e de ampla aplicação, como consideram [Cakmakov e Celakoska \(2004\)](#). Ao comparar o método com 6 outros métodos, avaliando suas performances em relação à similaridade com a percepção humana ao se comparar formas em 2D, [Scassellati, Alexopoulos e Flickner \(1994\)](#) concluem que o método em questão, baseado em turning functions, obteve a melhor performance com melhores resultados.

Ainda não se há um consenso sobre um parâmetro apropriado para distinção e classificação dos valores obtidos puramente por este método como, por exemplo, níveis bons de semelhança para valores de $0,1 \leq D \leq 0,2$, regulares $0,2 < D \leq 0,5$, etc., sendo também inconclusiva para aplicações em outros tipos de plantação. No entanto, como uma metodologia validada, trabalhos futuros mais aprofundados e outras validações para sua utilização prática, com bancos de imagens diferentes e maiores (visto que parte das imagens da plantação de algodão continham muitos ruídos, sendo muitas delas excluídas, perdendo de forma considerável a quantidade de dados para serem analisados), outros critérios classificatórios das distâncias definidos e comparação com outros métodos.

Referências

- ABRAHAM, R.; SIMON, P. Review on mosaicing techniques in image processing. In: IEEE. *2013 Third International Conference on Advanced Computing and Communication Technologies (ACCT)*. [S.l.], 2013. p. 63–68. Citado na página 12.
- ALMEIDA, G. *Como funciona a agricultura de precisão e quais são as vantagens?* Mega Sistemas Corporativos, 2017. Acesso em 27 de Dez. de 2020. Disponível em: <<https://www.mega.com.br/blog/como-funciona-a-agricultura-de-precisao-e-quais-sao-as-vantagens-6849/>>. Citado na página 12.
- ARKIN, E. M. et al. *An efficiently computable metric for comparing polygonal shapes*. [S.l.], 1991. 1 p. Citado 2 vezes nas páginas 28 e 32.
- BAIWANG, S. D. P4 multispectral – dados precisos de vegetação – dji. Dajiang Baiwang, 2018. Acesso em 30 de Nov. de 2019. Disponível em: <<https://www.dji.com/br/p4-multispectral>>. Citado na página 19.
- BANERJEE, B. P.; RAVAL, S. A.; CULLEN, P. J. Alignment of uav-hyperspectral bands using keypoint descriptors in a spectrally complex environment. *Remote Sensing Letters*, Taylor & Francis, v. 9, n. 6, p. 524–533, 2018. Citado 2 vezes nas páginas 38 e 39.
- BOASPRATICAS. *Agricultura de precisão é tecnologia aliada à produção agrícola*. Boas Práticas Agronômicas, 2019. Acesso em 27 de Dez. de 2020. Disponível em: <<https://boaspraticasagronomicas.com.br/noticias/agricultura-de-precisao/>>. Citado na página 12.
- CAKMAKOV, D.; CELAKOSKA, E. Estimation of curve similarity using turning functions. *International Journal of Applied Mathematics*, ACADEMIC PUBLICATIONS, v. 15, p. 403–416, 2004. Citado na página 40.
- CÂMARA, G. et al. Spring: Integrating remote sensing and gis by object-oriented data modelling. *Computers & graphics*, New York, v. 20, n. 3, p. 395–403, 1996. Citado na página 16.
- CRUM, W. R.; HARTKENS, T.; HILL, D. Non-rigid image registration: theory and practice. *The British journal of radiology*, British Institute of Radiology, v. 77, n. suppl_2, p. S140–S153, 2004. Citado na página 27.
- ESQUEF, I. A.; ALBUQUERQUE, M. P. d.; ALBUQUERQUE, M. P. d. Processamento digital de imagens. *Rio de Janeiro*, v. 12, 2003. Citado na página 15.
- FISHER, R. et al. *Hypermedia image processing reference*. England: John Wiley & Sons Ltd, p. 118–130, 1996. Citado na página 26.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento digital de imagens*. [S.l.]: Pearson Educación, 2009. Citado 2 vezes nas páginas 15 e 16.
- HENRICH V., K. G. G. C. S. C. A database for remote sensing index. 2007. Disponível em: <<https://www.indexdatabase.de/db/i.php>>. Citado na página 13.

- HORUS. *Mapeamento com Drones: tipos de câmeras utilizadas*. HORUS Aeronaves, 2020. Acesso em 04 de Ago. de 2020. Disponível em: <<https://horusaeronaves.com/mapeamento-com-drones-tipos-cameras-rgb-multiespectral/>>. Citado na página 18.
- JAISWAL, R. K. et al. Forest fire risk zone mapping from satellite imagery and gis. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 4, n. 1, p. 1–10, 2002. Citado 2 vezes nas páginas 12 e 18.
- JUNIOR, D. D. et al. Uav-multispectral sensed data band co-registration framework. In: . [S.l.: s.n.], 2020. p. 223–228. Citado 2 vezes nas páginas 38 e 39.
- JUNIOR, M. P. P. *Realce de imagens parte 1: operações pontuais*. Instituto de Ciências Matemáticas e de Computação USP, 2013. Acesso em 04 de Jan. de 2020. Disponível em: <http://wiki.icmc.usp.br/images/5/5e/DIP_02_Realce_p1.pdf>. Citado na página 16.
- LOPES, E. S. S.; BRUNO, R. L. d. S.; NAMIKAWA, L. M. *Teoria : Processamento de Imagens*. IMPE, 1996. Acesso em 26 de Nov. de 2019. Disponível em: <<http://www.dpi.inpe.br/spring/teoria/realce/realce.htm>>. Citado na página 16.
- MACHADO, M. L. et al. Caracterização de agroecossistemas cafeeiros da zona da mata de minas gerais utilizando o sistema de processamento de informações georreferenciadas (spring). In: IN: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 3., 2003, PORTO SEGURO . . . *Embrapa Café-Resumo em anais de congresso (ALICE)*. [S.l.], 2003. Citado na página 22.
- MARIAS, K. et al. Non-rigid image transformation for assessing changes in fluorescence imaging data of molecular activity in time-dependent geometries. In: IEEE. *2004 2nd IEEE International Symposium on Biomedical Imaging: Nano to Macro (IEEE Cat No. 04EX821)*. [S.l.], 2004. p. 484–487. Citado na página 27.
- MATHWORKS. *cpselect*. MathWorks, 2006. Acesso em 05 de Nov. de 2019. Disponível em: <<https://www.mathworks.com/help/images/ref/cpselect.html>>. Citado na página 27.
- NAGENDRA, M.; MANJULA, Y.; KURIAN, M. A review on various image mosaic techniques. *INTERNATIONAL JOURNAL OF ENGINEERING RESEARCH TECHNOLOGY (IJERT)*, NCETESFT - - 2020 Conference Proceedings, v. 8, n. 14, p. 168–174, 2020. Citado na página 12.
- OLIVEIRA, A. Usados na pulverização, drones geram economia de 80% ao produtor rural. *Globo Comunicação*, 2017. Acesso em 01 de Dez. de 2019. Disponível em: <<https://g1.globo.com/sp/ribeirao-preto-franca/agrishow/2017/noticia/usados-na-pulverizacao-drones-geram-economia-de-80-ao-produtor-rural.ghtml>>. Citado na página 12.
- PATIL, B. G.; JAIN, S. N. Cancer cells detection using digital image processing methods. *International Journal of Latest Trends in Engineering and Technology (IJLTET)*, v. 3, n. 4, p. 45–49, 2014. Citado na página 17.
- PHINN, S. et al. Mapping water quality and substrate cover in optically complex coastal and reef waters: an integrated approach. *Marine Pollution Bulletin*, Elsevier, v. 51, n. 1-4, p. 459–469, 2005. Citado na página 17.

- PIETRZYKOWSKI, E. et al. Predicting mycosphaerella leaf disease severity in a eucalyptus globulus plantation using digital multi-spectral imagery. *Southern Hemisphere Forestry Journal*, Taylor & Francis, v. 69, n. 3, p. 175–182, 2007. Citado na página 13.
- RAN, L. et al. Multiple local autofocus back-projection algorithm for space-variant phase-error correction in synthetic aperture radar. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 13, n. 9, p. 1241–1245, 2016. Citado na página 39.
- ROYDEN, H. L. *Real analysis*. [S.l.]: Krishna Prakashan Media, 1968. Citado na página 32.
- SACI. *A importância da agricultura de precisão nas lavouras*. Soluções, Amostragem e Coleta de Infor. LTDA, Saci, 2019. Acesso em 27 de Dez. de 2020. Disponível em: <<https://www.sacisolucoes.com.br/blog/a-importancia-da-agricultura-de-precisao-nas-lavouras/>>. Citado na página 12.
- SAUSEN, T. M. Sensoriamento remoto e suas aplicações para recursos naturais. *Apostila de sensoriamento remoto INPE*. Disponível em:< <http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>> Acessado em 18 de Jan. de 2020, v. 29, n. 05, 2007. Citado 2 vezes nas páginas 12 e 18.
- SCASSELLATI, B. M.; ALEXOPOULOS, S.; FLICKNER, M. D. Retrieving images by 2d shape: a comparison of computation methods with human perceptual judgments. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Storage and Retrieval for image and Video Databases II*. [S.l.], 1994. v. 2185, p. 2–14. Citado na página 40.
- YASIR, R. et al. Data-driven multispectral image registration. In: IEEE. *2018 15th Conference on Computer and Robot Vision (CRV)*. [S.l.], 2018. p. 230–237. Citado 2 vezes nas páginas 38 e 39.
- ZAIDAN, R. T. *Sensoriamento Remoto: Características das Imagens Orbitais*. Laboratório de Geoprocessamento Aplicado, UFJF, 2011. Acesso em 04 de Jan. de 2020. Disponível em: <<https://www.ufjf.br/lga/files/2011/03/10-Características-da-Imagens.pdf>>. Citado 2 vezes nas páginas 19 e 22.

ANEXO A – Código da função cpselect()

```

diretorio_entrada = 'X:\(endereco_imagens_entrada)\';
diretorio_saida = 'X:\(endereco_tabela_saida)\';
fixed_image = '(nome_imagem_fixa)';
extension = '.tif';

export_filename = [fixed_image, '.xlsx'];
fixed = imread([diretorio_entrada, fixed_image, extension]);

pt_fixed = [100 100; 200 100; 300 100; 400 100; 500 100;
600 100; 700 100; 800 100; 900 100; 1000 100; 1100 100; 1200 100];

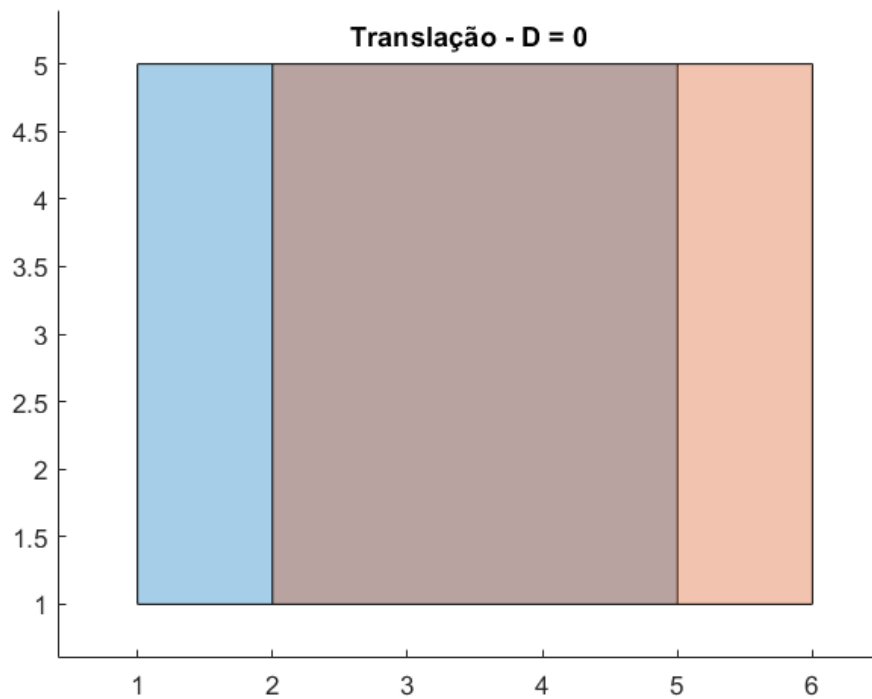
pt_moving = [100 100; 200 100; 300 100; 400 100; 500 100;
600 100; 700 100; 800 100; 900 100; 1000 100; 1100 100; 1200 100];

for i = 1:5
    if( i == 2 )
        continue;
    end
    moving_image = fixed_image;
    moving_image(size(fixed_image, 2)) = int2str(i);
    moving = imread([ diretorio_entrada , moving_image ,
extension ]);
    [pt_moving, pt_fixed] = cpselect(moving, fixed ,
pt_moving, pt_fixed , 'wait' , true);
    imagem_fixa = repmat(fixed_image , 12, 1);
    imagem_variavel = repmat(moving_image , 12, 1);
    T = table(imagem_fixa , pt_fixed , imagem_variavel , pt_moving ;
writetable(T,[ diretorio_saida , export_filename] ,
'WriteRowNames' , true , 'Sheet' , i)
end

```

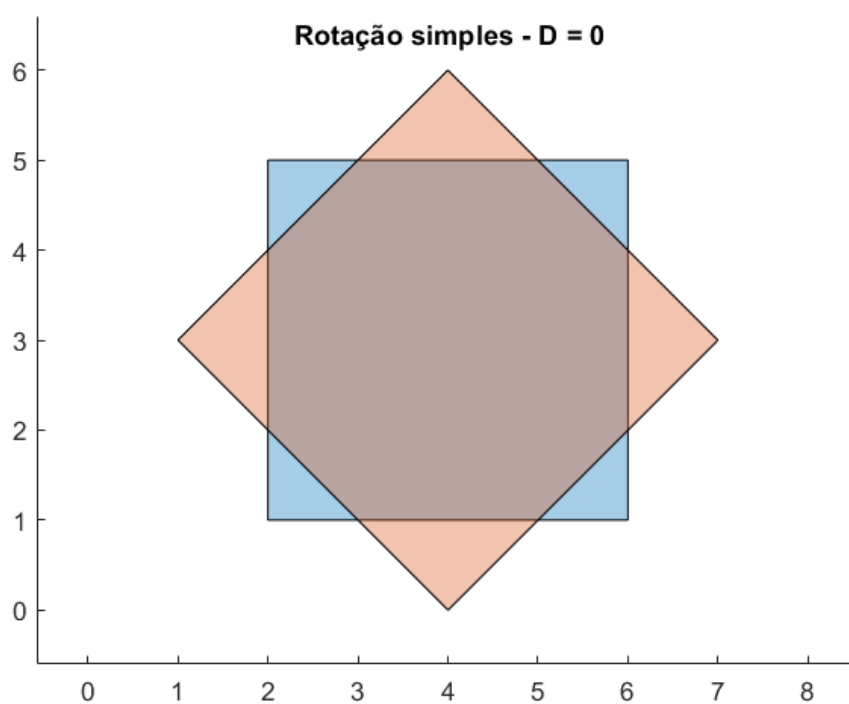
ANEXO B – Polígonos utilizados na validação

Figura 20 – Teste de transformação rígida para translação.



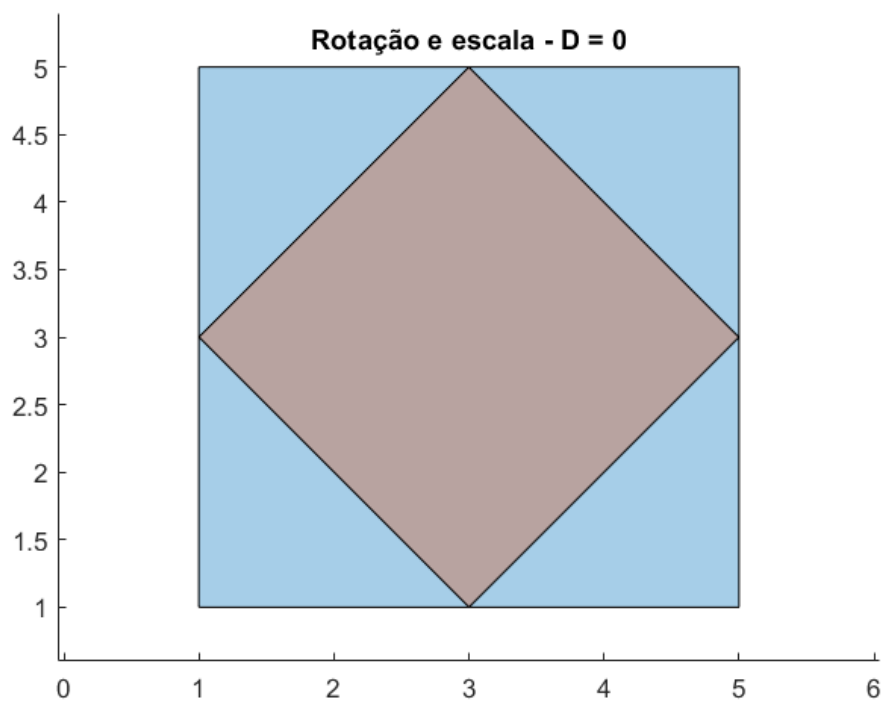
Fonte: Do autor (2020).

Figura 21 – Teste de transformação rígida para rotação.



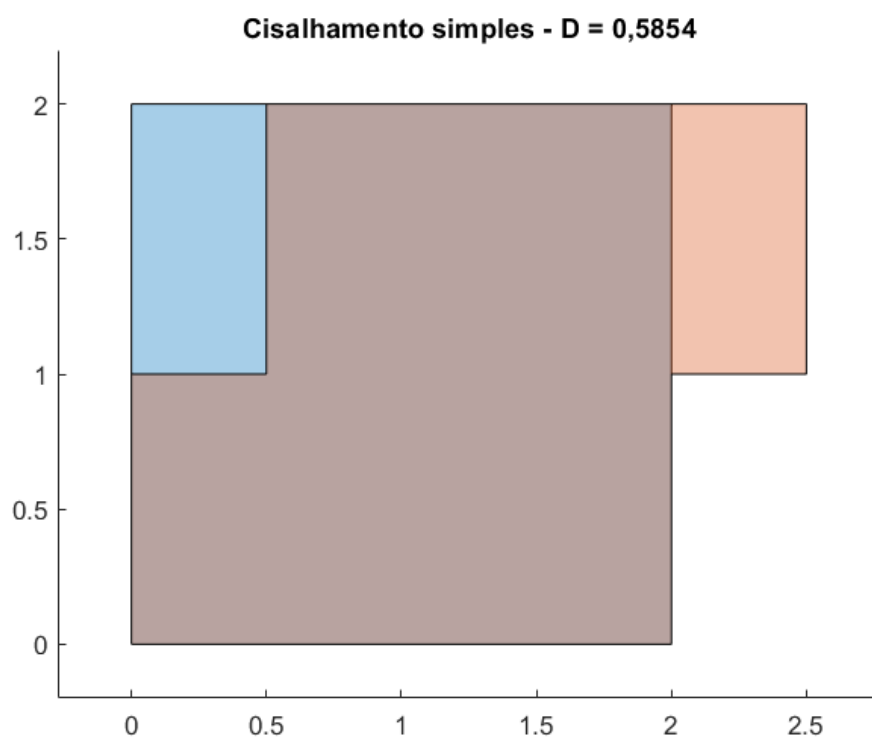
Fonte: Do autor (2020).

Figura 22 – Teste de transformação rígida para rotação e escala.



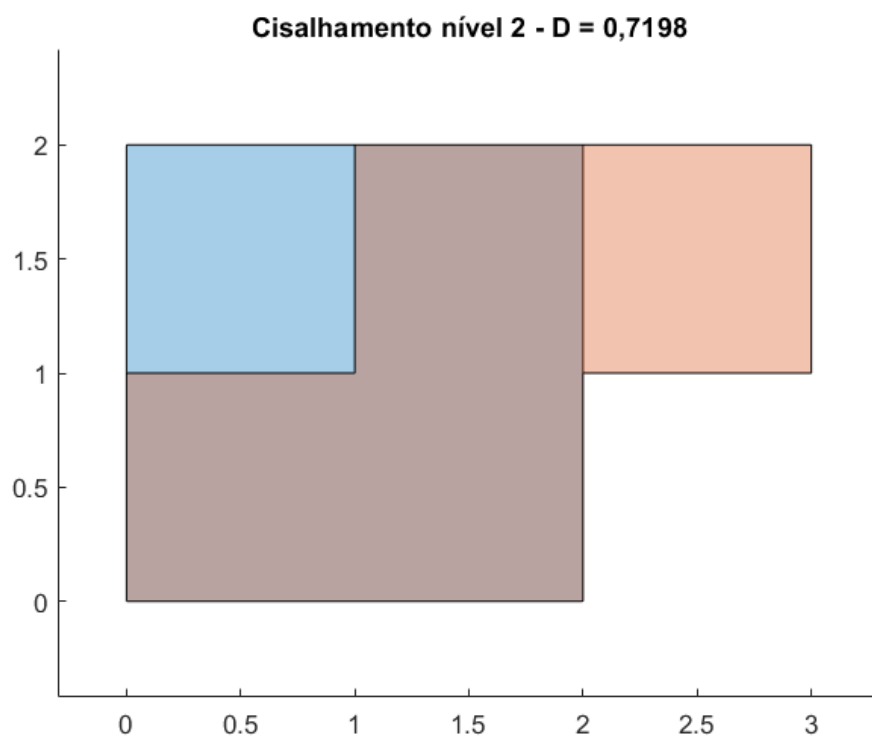
Fonte: Do autor (2020).

Figura 23 – Teste de transformação não-rígida cisalhamento 25%.




Fonte: Do autor (2020).

Figura 24 – Teste de transformação não-rígida cisalhamento 50%.



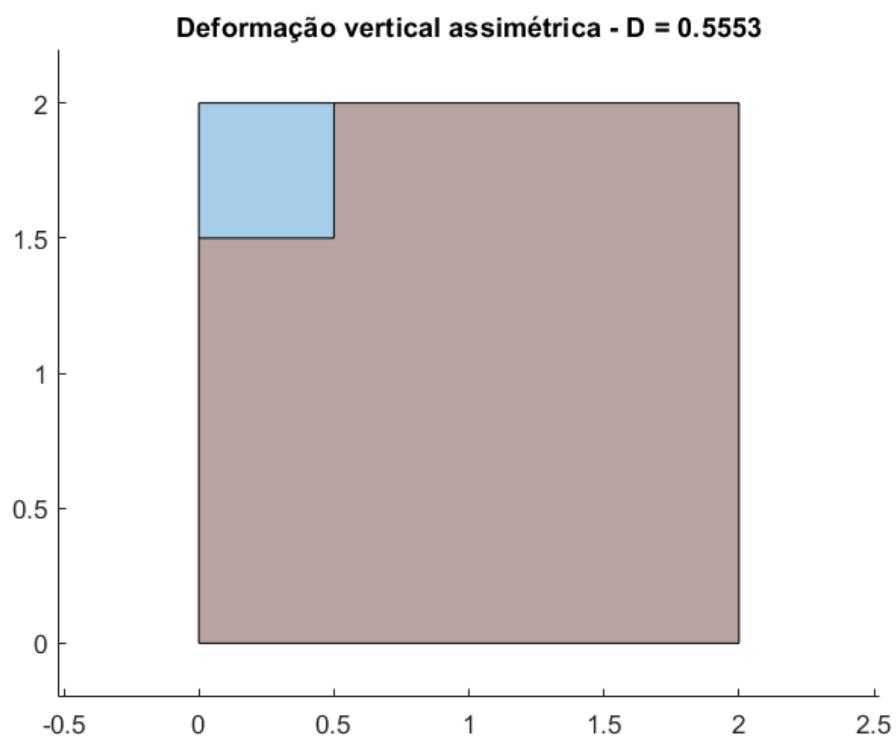
Fonte: Do autor (2020).

Figura 25 – Teste de transformação não-rígida cisalhamento >90%.



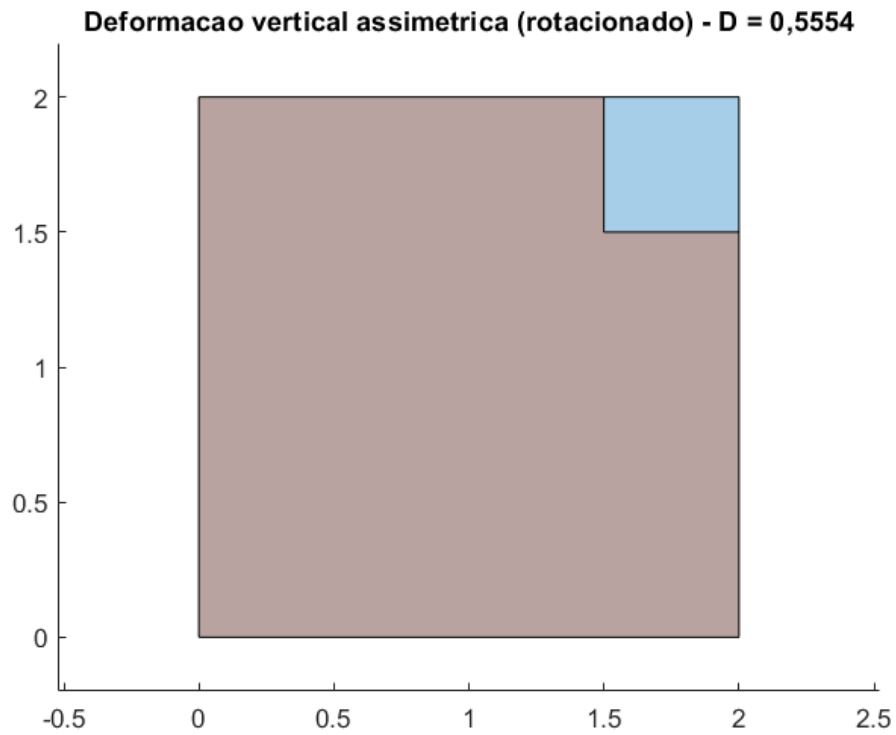
Fonte: Do autor (2020).

Figura 26 – Teste de transformação não-rígida assimétrica 1



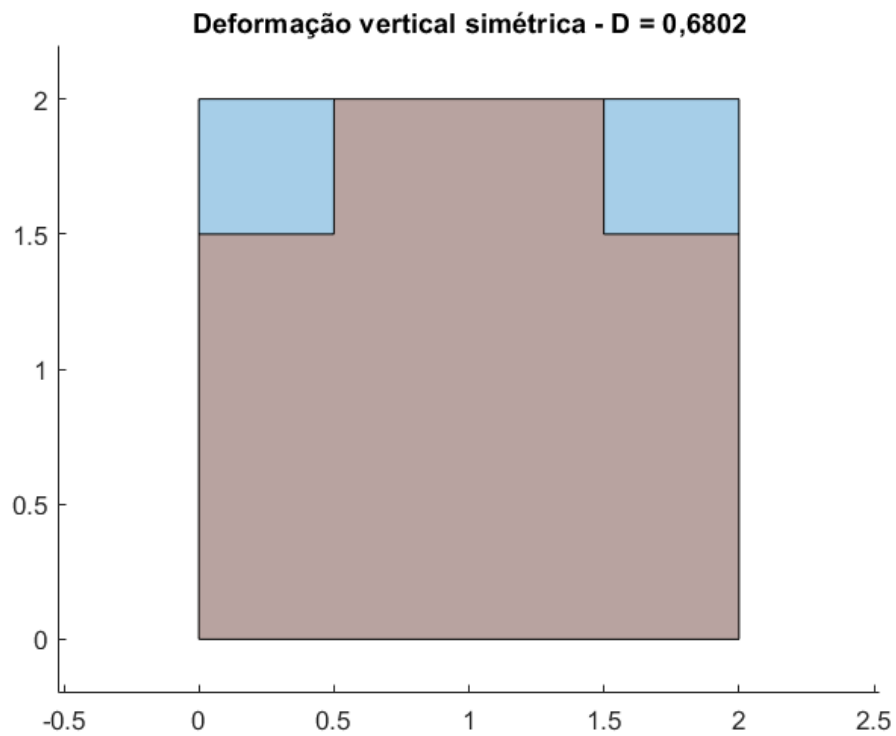
Fonte: Do autor (2020).

Figura 27 – Teste de transformação não-rígida assimétrica 2




Fonte: Do autor (2020).

Figura 28 – Teste de transformação não-rígida simétrica



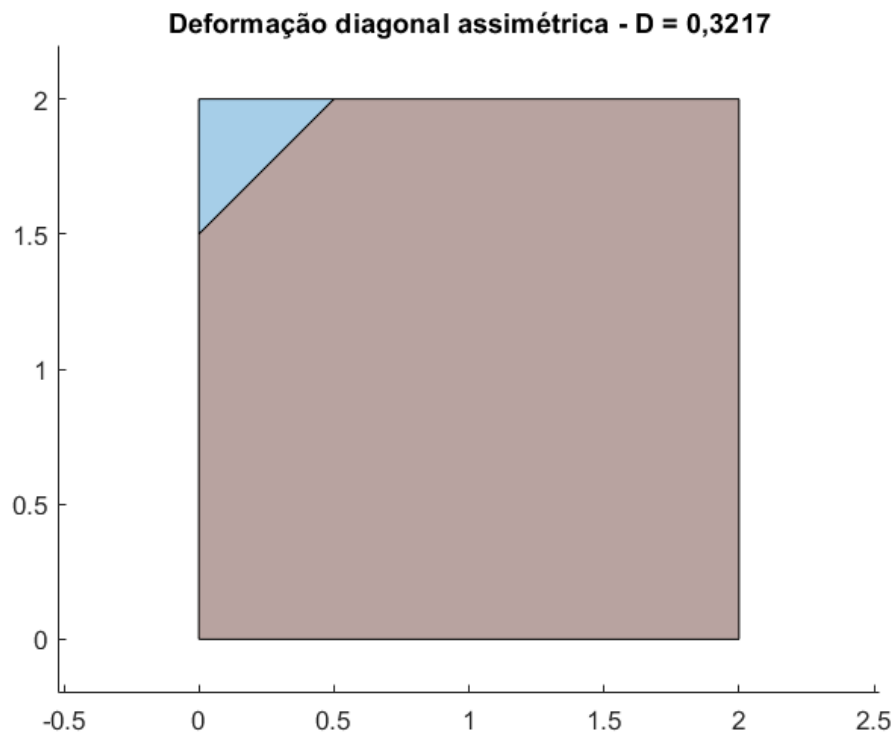
Fonte: Do autor (2020).

Figura 29 – Teste de transformação não-rígida completa



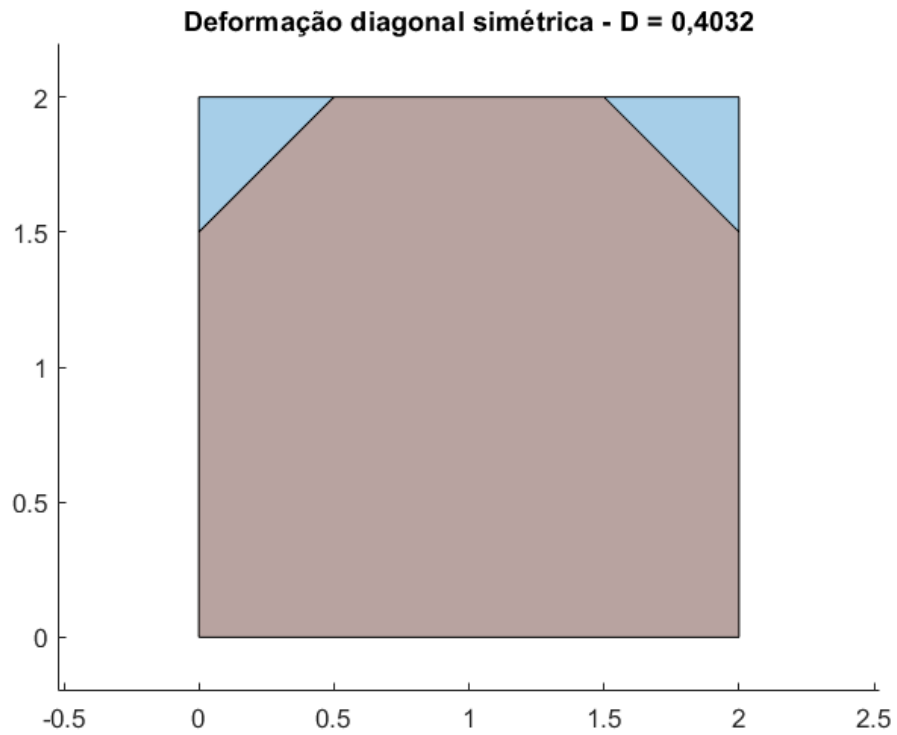
Fonte: Do autor (2020).

Figura 30 – Teste de transformação não-rígida diagonal assimétrica




Fonte: Do autor (2020).

Figura 31 – Teste de transformação não-rígida diagonal simétrica




Fonte: Do autor (2020).

Figura 32 – Teste de transformação não-rígida diagonal completa



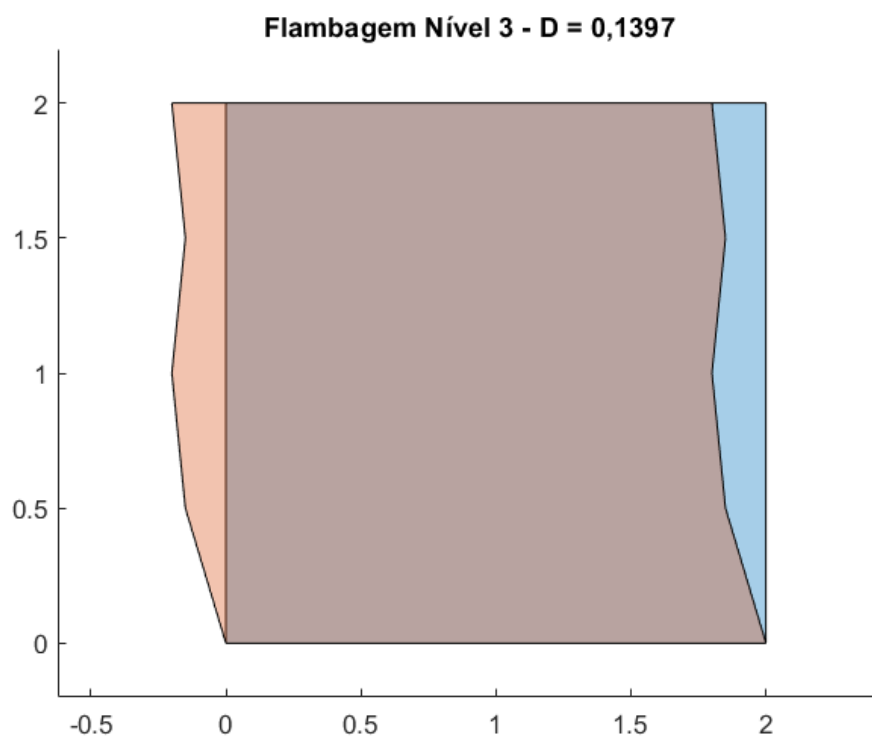
Fonte: Do autor (2020).

Figura 33 – Teste de transformação não-rígida vertical livre



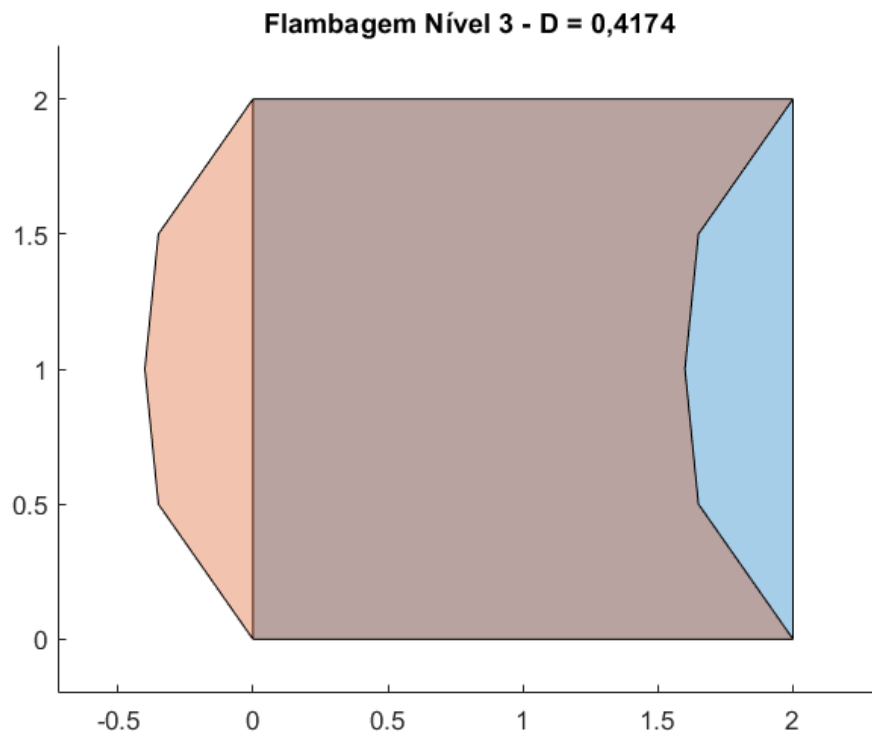
Fonte: Do autor (2020).

Figura 34 – Teste de transformação não-rígida flambagem 1




Fonte: Do autor (2020).

Figura 35 – Teste de transformação não-rígida flambagem 2




Fonte: Do autor (2020).

Figura 36 – Teste de transformação não-rígida flambagem 3




Fonte: Do autor (2020).

Figura 37 – Teste de transformação não-rígida flambagem 4




Fonte: Do autor (2020).

Figura 38 – Teste de transformação não-rígida livre



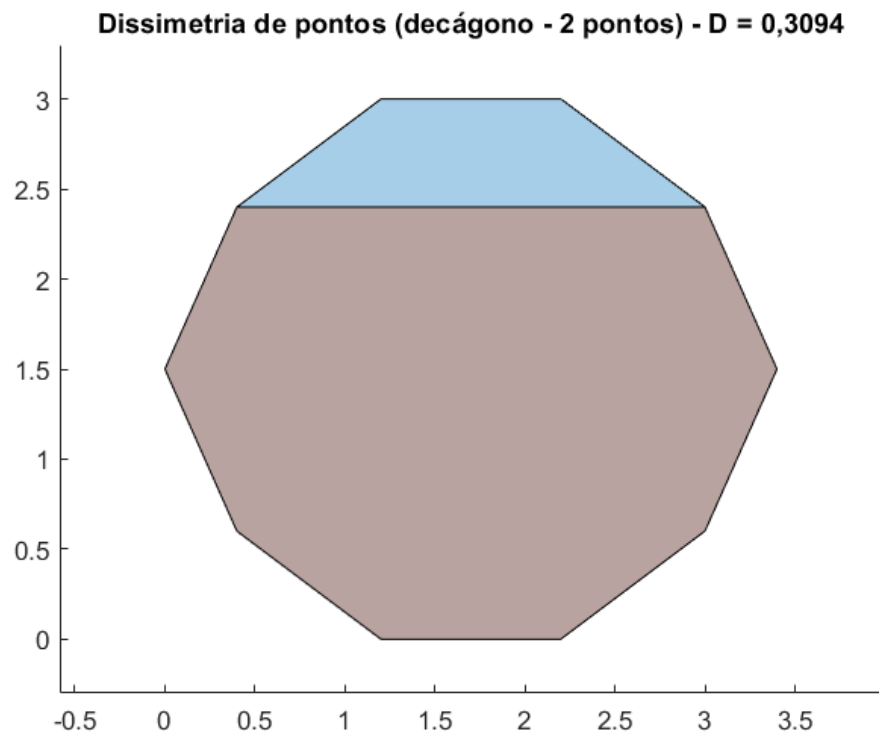
Fonte: Do autor (2020).

Figura 39 – Teste de transformação não-rígida livre




Fonte: Do autor (2020).

Figura 40 – Teste de transformação não-rígida livre



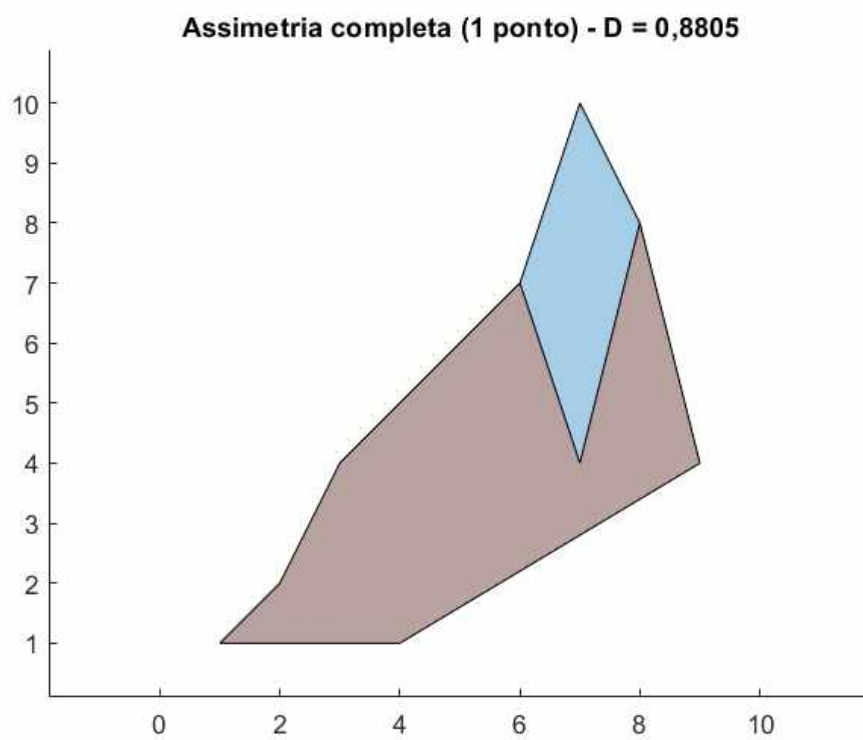
Fonte: Do autor (2020).

Figura 41 – Teste de transformação não-rígida livre



Fonte: Do autor (2020).

Figura 42 – Teste de transformação não-rígida livre



Fonte: Do autor (2020).