



# Revista Brasileira de Geografia Física

Homepage: [www.ufpe.br/rbgfe](http://www.ufpe.br/rbgfe)



## Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica

Bárbara Hass Miguel <sup>1</sup>, Edson Eyji Sano <sup>2</sup>

<sup>1</sup>Doutoranda em Geociências Aplicadas e Geodinâmica, Instituto de Geociências - Universidade de Brasília, Campus Darcy Ribeiro - 70910-900 – Brasília -DF, Brasil, babs.hass@gmail.com (autora correspondente)

<sup>2</sup>Chefe do Centro de Sensoriamento Remoto, Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis – IBAMA, SCEN Trecho 2, L4 Norte - 70818-900 - Brasília - DF, Brasil, edson.sano@ibama.gov.br.

Artigo recebido em 05/02/2019 e aceito em 24/05/2019

### RESUMO

O objetivo do presente trabalho foi avaliar o potencial das imagens de radar do satélite Sentinel 1A (banda C) para discriminar classes representativas de uso e cobertura da terra do Distrito Federal, Brasil. As imagens de coerência interferométrica utilizadas nesse estudo foram obtidas a partir de pares de imagens *Single Look Complex* (SLC) de junho e julho de 2018. Foi gerada uma composição colorida RGB a partir de imagens de coerência, intensidade de retroespalhamento e razão de retroespalhamento. Essa imagem foi classificada pelos métodos supervisionados *Support Vector Machine* (SVM) e *Random Forest* (RF). A validação temática foi realizada por matrizes de confusão, índice Kappa e exatidão global. Nesse contexto, foram investigadas cinco classes temáticas (água, área urbana, vegetação nativa, pastagem e agricultura). O classificador RF obteve melhor desempenho classificatório (Kappa= 0,68 e exatidão global = 79,1%) que o classificador SVM (Kappa= 0,64 e exatidão global = 75,7%). A coerência mostrou-se eficiente principalmente na identificação de corpos d'água e da área urbana. Os resultados foram satisfatórios para a classificação de uso e cobertura da terra do Distrito Federal, no entanto, houve confusão entre algumas classes e erros de comissão na classe área urbana em ambas as classificações.

Palavras-chave: uso e cobertura da terra, Interferometria, coerência interferométrica, Sentinel 1A, radar, Sensoriamento Remoto.

### Use and land cover classification of the Federal District, Brazil from interferometric coherence data

### ABSTRACT

The aim of this study was to evaluate the potential of Sentinel 1A (C band) satellite radar images to discriminate representative classes of land use and land cover in the Federal District, Brazil. The interferometric coherence images used in this study were obtained from pairs of *Single Look Complex* images (SLC) of June and July of 2018. An RGB color composition was generated from images of coherence, backscattering intensity and backscattering ratio. This image was classified by the Supervised Methods *Support Vector Machine* (SVM) and *Random Forest* (RF). Thematic validation was performed by matrices of confusion, Kappa index and overall accuracy. In this context, five thematic classes (water, urban area, native vegetation, pasture and agriculture) were investigated. The RF classifier obtained a better classificatory performance (Kappa= 0.68 and overall accuracy = 79.1%) than the SVM classifier (Kappa= 0.64 and overall accuracy = 75.7%). The coherence was shown to be efficient mainly in the identification of water and the urban area. The results were satisfactory for the classification of use and land cover of the Federal District, however, there was confusion between some classes and errors of commission in the urban area class in both classifications.

Keywords: use and land cover, Interferometry, interferometric coherence, Sentinel 1A, radar, Remote Sensing.

## Introdução

O estudo de uso e cobertura da terra é essencial para o entendimento da dinâmica ambiental e para a compreensão das possíveis implicações decorrentes de mudanças causadas pela ação antrópica. Nesse contexto, a utilização das imagens de sensores remotos na confecção de mapas de uso e cobertura da terra é uma técnica muito difundida, devido à necessidade de identificar a dinâmica espacial de mudanças sobre grandes áreas (Congalton et al., 2014).

Os sensores ópticos são mais fáceis de serem interpretados, porém, são sensíveis à visibilidade atmosférica. Este problema os torna pouco adequados à obtenção de imagens em algumas épocas do ano, devido à cobertura persistente de nuvens em algumas regiões. Já os sensores de micro-ondas, entre os quais se incluem os radares de abertura sintética (SAR), podem ser utilizados sob condições adversas de visibilidade.

As imagens SAR têm sido muito utilizadas em diversas aplicações, explorando diferentes sensores e técnicas de processamento. Tais sensores vem sendo explorados em estudos de monitoramento de enchentes (Chini et al., 2017; Schlaffer et al., 2017), áreas cobertas por gelo (Johansson et al., 2017; Wang et al., 2016), derramamento de óleo (Migliaccio et al., 2015; Skrunes et al., 2015), deslizamentos de terra (Confueorto et al., 2017), mapeamento de áreas agrícolas (Gibril et al., 2017; Erten et al., 2016), áreas urbanas (Khalil e Haque, 2018; Salentinig e Gamba, 2015), uso e cobertura da terra (Paradella et al., 2017; Baltzter et al., 2015) e estudos florestais (Minh et al., 2016).

Os sensores que operam com maiores comprimentos de onda (bandas C, L e P) permitem maior penetração do sinal, e conseqüentemente registram informações sobre a estrutura volumétrica dos alvos. Já os sensores de ondas menos longas (banda X) interagem mais superficialmente com a estrutura do alvo, sendo mais utilizados em estudos de detecção de alvos. Contudo, é necessário aprimorar técnicas de processamento desses dados, entre as quais encontra-se a interferometria (Khalil e Haque, 2018; Pôssa et al., 2018).

A interferometria SAR (InSAR) está baseada na combinação de duas imagens SAR, adquiridas sobre a mesma área, com uma geometria de aquisição ligeiramente diferente uma da outra, para garantir o efeito de interferometria, ou diferença de fase (Temporim et al., 2017).

A comparação entre as diferenças de fase de duas imagens de uma mesma região, obtidas a partir de antenas com ligeira diferença de geometria, torna possível encontrar as localizações dos pixels em três dimensões. A diferença de fase entre pixels de mesma coordenada nas imagens está relacionada à distância entre as duas trajetórias de pulsos de energia eletromagnética durante as aquisições (linha-base) e a altitude correspondente no solo. Por meio destes dados também pode-se gerar imagens de coerência interferométrica, muito úteis para fins de classificação (Olesk et al., 2016; Wegmüller et al., 2015).

Cada pixel de uma imagem de coerência representa a informação do módulo do coeficiente de correlação complexa de um par interferométrico. Este tipo de produto pode contribuir para a estratificação temática da paisagem, considerando que regiões florestadas apresentam baixa coerência interferométrica, em razão da instabilidade dos componentes florestais quando comparados a outras tipologias de uso e cobertura da terra, como, pastagem, solo exposto e regiões de vegetação esparsa (Olesk et al., 2016).

Combinando interferometria e polarimetria, que nada mais é que a natureza vetorial das ondas eletromagnéticas dos alvos imageados, é possível maximizar a coerência interferométrica, que é a medida da correlação entre as duas imagens utilizadas no processamento interferométrico. A coerência também é um indicativo da qualidade de fase do interferograma, visando a geração de modelos de elevação mais precisos (Mohammadimanesh et al., 2018; Pôssa et al., 2018).

Dessa forma, o objetivo desse estudo é avaliar o potencial das imagens de coerência interferométrica do Sentinel 1A, banda C, para discriminar classes representativas de uso e cobertura da terra do Distrito Federal. As imagens de coerência interferométrica utilizadas nesse estudo foram obtidas a partir de pares de imagens *Single Look Complex* (SLC) de junho e julho de 2018.

## Caracterização da área de estudo

A área de estudo, com uma extensão de 2.862,26 km<sup>2</sup>, corresponde à porção noroeste do Distrito Federal (DF) (Figura 1). A área selecionada engloba a cidade de Brasília, o Lago Paranoá, o Parque Nacional de Brasília, a Reserva Ecológica do IBGE, dentre outras feições.

O DF está localizado na região central do Brasil, onde são encontradas chapadas elevadas e nascentes de três das oito grandes bacias

hidrográficas brasileiras: Paraná, Tocantins e São Francisco (Neves et al., 2015).

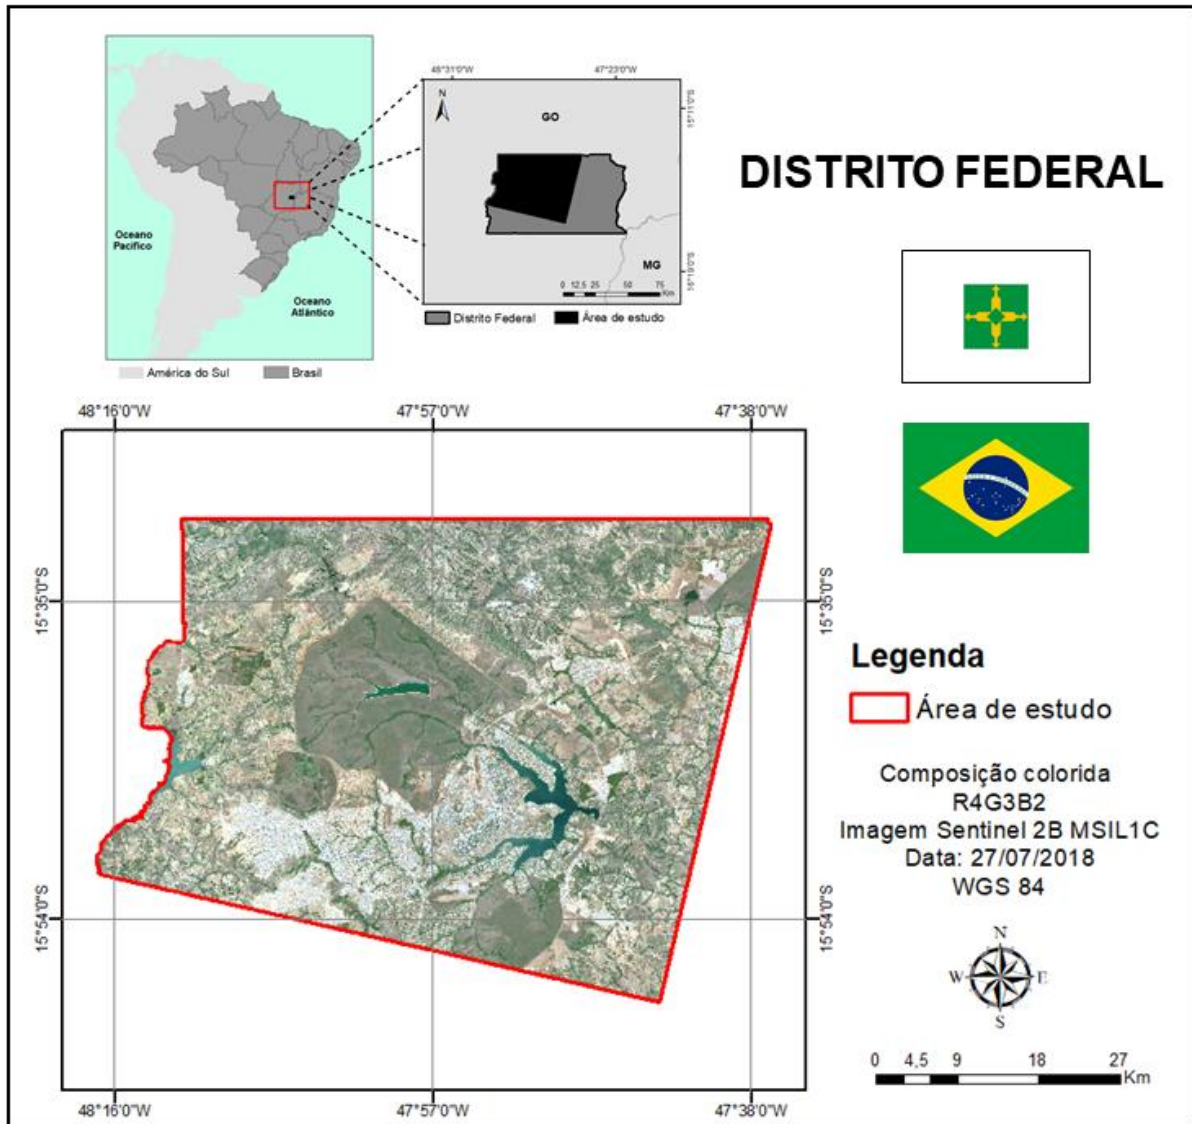


Figura 1. Localização da área de estudo.

A localização do DF evidencia a heterogeneidade de suas paisagens e consequentemente de sua apropriação pelo homem, com a concentração de áreas urbanas e o predomínio de agricultura de larga escala ao longo de sua área. A vegetação do DF é representativa do bioma Cerrado, isto é, apresenta um mosaico heterogêneo de formações campestres, savânicas e florestais (Marengo, 2010).

O clima predominante na área de estudo é a tropical com estações seca e chuvosa bem definidas (tipo Aw na classificação climática de Köppen), com temperaturas médias mensais superiores a 18 °C e precipitação média anual de

1.540 mm, concentrados entre os meses de outubro e abril (Marengo, 2010).

### Material e métodos

#### Dados utilizados

Neste trabalho, foram utilizadas imagens do Sentinel 1A (nível de processamento: SLC) da Agência Espacial Europeia (ESA), obtidas em 12 de junho e 18 de julho de 2018 (Tabela 1). Os dados foram processados no *Sentinel Application Platform* (SNAP) da ESA.

Tabela 1. Características das imagens Sentinel 1A.

Atributos	Sentinel 1A
Datas de aquisição	12/06/2018 e 18/07/2018
Modo	IW
Órbita	Descendente
Largura de faixa	250 km
Comprimento de onda (cm)	~ 30
Polarização	VV/VH
Ângulo de incidência	~ 20° - 45°
Resolução radiométrica	16 bits
Resolução espacial (m)	5 x 20

*Processamento de dados SAR*

Primeiramente, as imagens passaram pelo processo de *split* e correção de órbita, selecionando-se uma subárea menor, para minimizar o esforço computacional. Nas etapas de geocodificação das imagens, foi utilizado o modelo digital de elevação obtido pelo *Shuttle Radar*

*Topography Mission (SRTM)*. Nesta operação, os dados foram georeferenciados para o referencial geodésico WGS84 e reamostrados para uma resolução de 15 m por meio de uma interpolação bilinear. Ambas as imagens SAR foram convertidas para coeficiente de retroespalhamento ( $\sigma^0$ , unidade em decibéis - dB) (Figura 2).

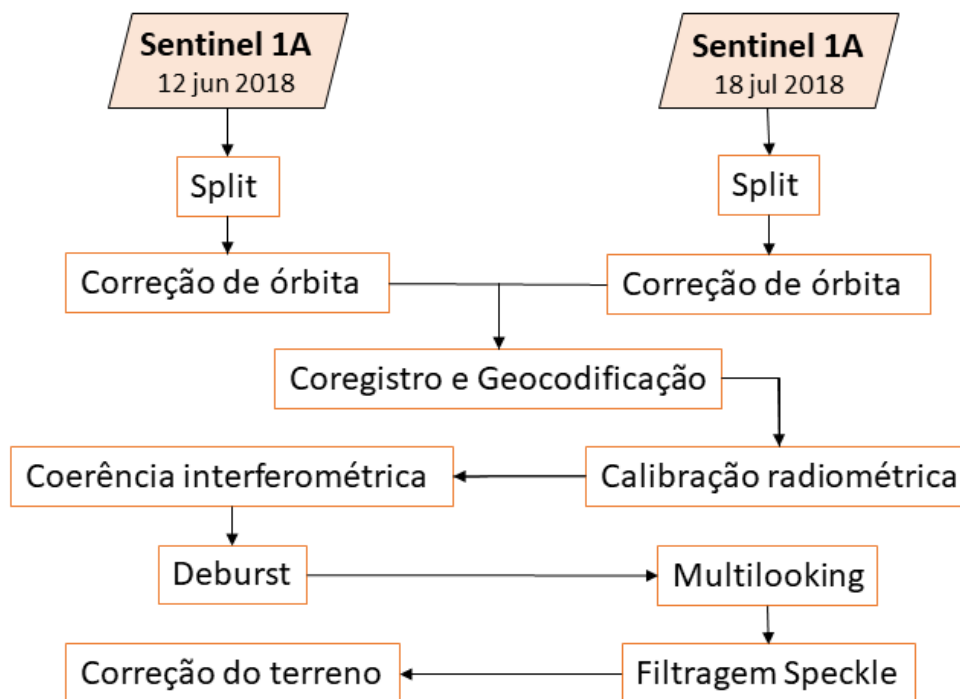


Figura 2. Fluxograma das etapas do processamento de dados SAR.

A coerência  $\gamma$  de duas imagens SAR complexas é definida de acordo com a seguinte equação:

$$\gamma = \frac{E\{uv^*\}}{\sqrt{E\{|u|^2\}E\{|v|^2\}}}$$

Onde  $E$  é o valor esperado,  $u$  e  $v$  são as duas imagens complexas coregistradas e  $v^*$  é o complexo conjugado de  $v$  (Wegmüller et al., 2015). O tamanho da janela de intervalo de coerência foi definido como 10 e o tamanho da janela de azimute de coerência foi de 1.

Em seguida, procederam-se as operações *deburst* para fundir as subfaixas de cada imagem e *multilooking* para converter as imagens de alcance inclinado em alcance no terreno. Para atenuar o ruído (*speckle*) das imagens, aplicou-se o filtro passa-baixa *Refined-Lee*, com uma janela de 5x5 (Lee, 1981; Pôssa et al., 2018). O *speckle* é um efeito multiplicativo e surge em razão da natureza coerente das ondas utilizadas no processo de aquisição, que ao interagirem com os diversos alvos independentes no terreno, podem sofrer interferências construtivas ou destrutivas, causando bruscas variações nos níveis de cinza da cena. Por fim, na etapa de ortorretificação, aplicou-se uma correção de terreno *Range-Doppler*.

### Classificação e Validação

Dos processamentos mencionados no item anterior, foram geradas três imagens: "coerência", "intensidade de retroespalhamento (*backscatter*)" e "razão de retroespalhamento". A razão de retroespalhamento foi gerada pois destaca as áreas onde ocorreu alguma mudança entre as datas das imagens (Khalil e Haque, 2018; Chini et al., 2017). A razão entre as duas imagens de intensidade de

retroespalhamento foi calculada de acordo com a seguinte equação:

$$\text{Mudança ou razão [dB]} = \left| 10 \cdot \log \frac{i_2}{i_1} \right|$$

Onde  $i_1$  e  $i_2$  são duas imagens de intensidade de retroespalhamento.

Esta composição RGB foi submetida à duas classificações supervisionadas: *Support Vector Machine* (SVM) e *Randon Forest* (RF). Os algoritmos de aprendizagem de máquina SVM têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (Zhang et al., 2016; Kumar et al., 2015).

Já o algoritmo de aprendizagem supervisionado RF consiste em uma coleção ou conjunto de preditores de uma árvore de decisões simples, capaz de produzir uma resposta quando apresentado com um conjunto de valores preditores. Para problemas de classificação, essa resposta assume a forma de uma associação de classe, que associa ou classifica um conjunto de valores preditores independentes a uma das categorias presentes na variável dependente. Em problemas de regressão, a resposta da árvore é uma estimativa da variável dependente dados os preditores (Belgiu e Drăgut., 2016).

Para examinar a eficiência do sensor Sentinel 1A em discriminar as diferentes características da imagem, foram definidas cinco classes de uso e cobertura da terra: área urbana, água, vegetação, pastagem e agricultura (Tabela 2):

Tabela 2. Descrição das classes de uso e cobertura da terra.

Classes	Descrição
Área urbana	Cidades consolidadas e condomínios habitacionais em consolidação.
Água	Corpos d'água (lagos e reservatórios).
Vegetação nativa	Áreas ocupadas por matas nativas de porte arbóreo.
Pastagem	Áreas campestres.
Agricultura	Áreas de cultivo perene ou permanente.

A seleção de amostras de treinamento de cada classe temática foi realizada utilizando-se de pontos de amostragem de uma imagem Sentinel-2 do dia 27 de julho de 2018 da área de estudo. A validação da classificação foi feita através da coleta de amostras de treinamento. Foram coletadas

amostras em uma composição colorida R11G8G5 de 10 m de resolução espacial. Essas bandas correspondem aos canais SWIR, NIR e vermelho do Sentinel-2, respectivamente.

Parte do conjunto amostral destinou-se ao treinamento do algoritmo de classificação,

enquanto outro conjunto de amostras foi destinado à validação do mapeamento, conforme descrito a Tabela 3.

Tabela 3. Número de pixels selecionados para cada classe.

	Classes	Número de pixels		Classes	Número de pixels
Treinamento	AU	27030	Validação	AU	9366
	AG	33205		AG	2239
	VN	18073		VN	1759
	PA	9698		PA	6543
	AR	1994		AR	1732

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

A banda 11 do Sentinel-2, naturalmente de 20 m de resolução precisou passar por um processo de reamostragem de pixels por vizinho mais próximo. Além dessa etapa, foi realizada a correção atmosférica da imagem através do algoritmo *Sen2Cor* dentro da plataforma SNAP.

Por fim, a acurácia da classificação supervisionada foi avaliada através de uma matriz de confusão, do índice *Kappa* e da exatidão global, baseando-se no conjunto amostral de referência para validação (Congalton e Green, 2012).

## Resultados e discussão

### Composição RGB

A composição RGB colorida, utilizada como referência no processo de classificação, foi gerada a partir das imagens de polarização VV. Essa escolha se sucedeu, pois, sabe-se que as co-polarizações (VV) estão mais relacionadas com a rugosidade da superfície (espalhamento superficial) e as polarizações cruzadas (VH) estão mais relacionadas com o espalhamento, dessa forma apresentam mais ruídos na imagem. Para a composição, colocou-se a imagem de intensidade de retroespalhamento, ou seja, a intensidade de retorno do sinal, no canal vermelho, a imagem de razão de intensidade de retroespalhamento no canal verde e a imagem de coerência no canal azul (Khalil e Haque, 2018). (Figura 3).

Os coeficientes médios de retroespalhamento ( $\sigma^0$ ) foram identificados para as cinco principais classes de uso e cobertura da terra

da área de estudo: água, área urbana, vegetação nativa, pastagem e agricultura. A Figura 4 apresenta a distribuição dos valores de retroespalhamento (*backscatter*) para cada classe de cobertura da terra de acordo com a data da imagem e a respectiva polarização da imagem, segundo os resultados da classificação SVM.

Observou-se que a classe água apresentou os menores valores de intensidade de retroespalhamento. A maioria dos pixels ficaram situados na faixa de -19 a -17 dB na imagem do dia 12 de junho e -22 a -20 dB na imagem do dia 18 de julho. As classes agricultura e pastagem também apresentaram baixa intensidade de retroespalhamento, porém um pouco mais alta que os corpos d'água devido ao envolvimento da rugosidade da superfície do solo, variando de -18 a -10 dB de forma dominante para ambas as datas. Devido à homogeneidade relativamente alta, tanto a classe água como as classes que possuem áreas sem vegetação apresentaram baixos valores de coeficiente de retroespalhamento médio. Os valores mais altos foram observados nas áreas de vegetação, variando proeminentemente de -10 a -7 dB e -7 a -5 dB, respectivamente. Observa-se também que os valores de retroespalhamento são bem menores nas imagens de polarização VH. Esse aspecto pode ser identificado principalmente nas áreas sem vegetação, pois elas aparecerem mais escuras (menor  $\sigma^0$ ) nas imagens de polarização cruzada VH, indicando um domínio do espalhamento superficial (Lin et al., 2017).

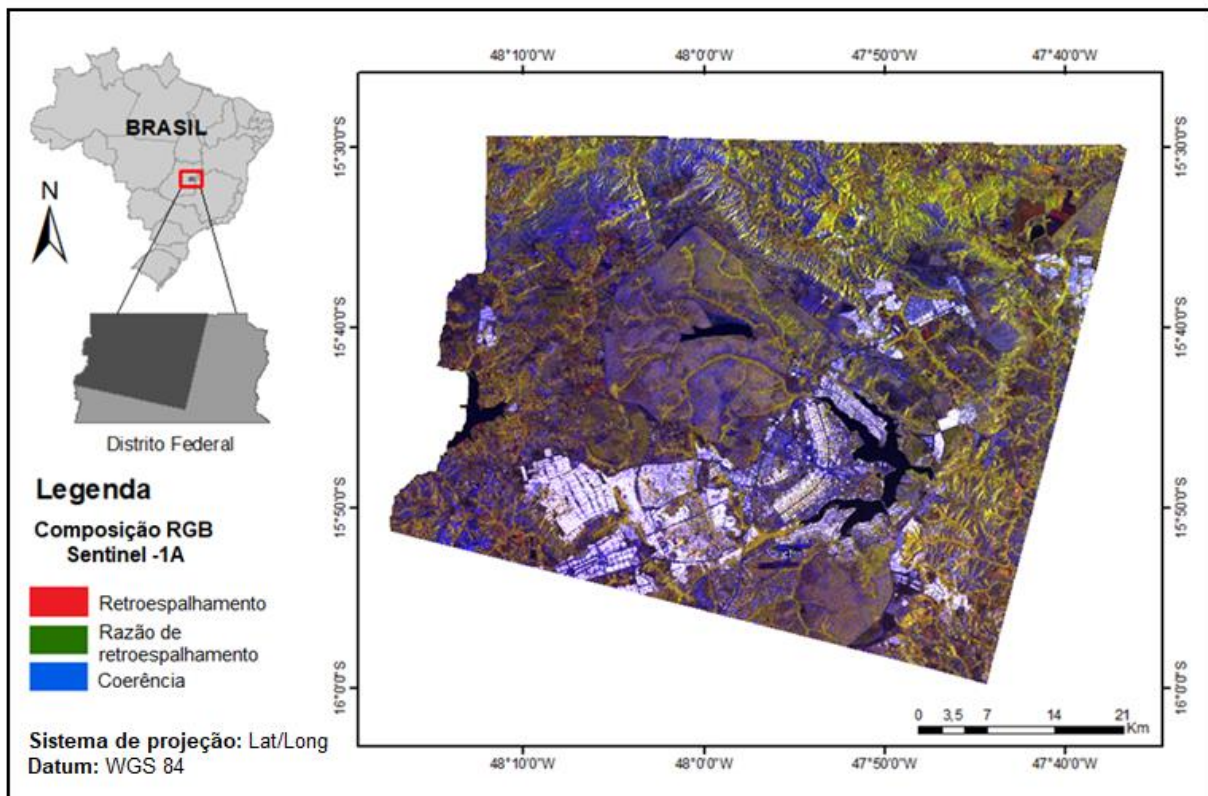


Figura 3. Composição colorida R (retroespalhamento VV) G (razão de retroespalhamento VV) B (coerência VV) de imagens Sentinel 1A.

#### *Análise da classificação supervisionada SVM*

Esses gráficos esclarecem como é bastante difícil discriminar as áreas urbanas de vegetação utilizando apenas o coeficiente de retroespalhamento. Dessa forma, a informação de coerência também foi incluída na composição RGB, junto a intensidade e razão de retroespalhamento, para distinguir as características da cobertura terrestre mais proeminente na classificação SVM.

A Figura 5 apresenta o padrão de distribuição da coerência para as diferentes classes de cobertura terrestre para a classificação SVM. Os valores mais altos foram observados para a classe área urbana, enquanto valores mais baixos foram observados para a pastagem, vegetação, agricultura e corpos d'água, respectivamente.

O valor de coerência varia de 0 a 1, sendo inversamente correlacionada com o grau de aleatoriedade dos dispersores entre as duas imagens SAR interferentes. Isto diminui com o movimento ou alterações físicas dos espalhadores, por exemplo, as áreas de vegetação ou floresta, entretanto, os alvos artificiais como as áreas urbanas podem permanecer coerentes por um

período relativamente mais longo, resultando em maior correlação (Lazecky et al., 2017; Watanabe et al., 2016).

De acordo com o resultado da classificação SVM (Figura 6), a maior parte da área de estudo é composta pela classe “vegetação”, com 45,4% do total da área, seguida pela classe “pastagem” com 41,3% do total. Já as outras classes apresentaram áreas bem menores. A classe “área urbana” apresenta 9% do total, seguida pela classe “agricultura” com 2,4% e o restante, cerca de 1,9% do total da área de estudo pertence à classe “água”.

A exatidão global e o índice Kappa da imagem classificada foram de 75,7% e 0,64, respectivamente. É possível notar algumas diferenças de contraste entre as classes de uso e cobertura da terra, principalmente nas classes “área urbana” e “água” na composição RGB. Esse destaque é previsível conforme já mencionado nos estudos de Strozzini et al. (2000) e Stehman (1997). A matriz de confusão está apresentada na Tabela 4.

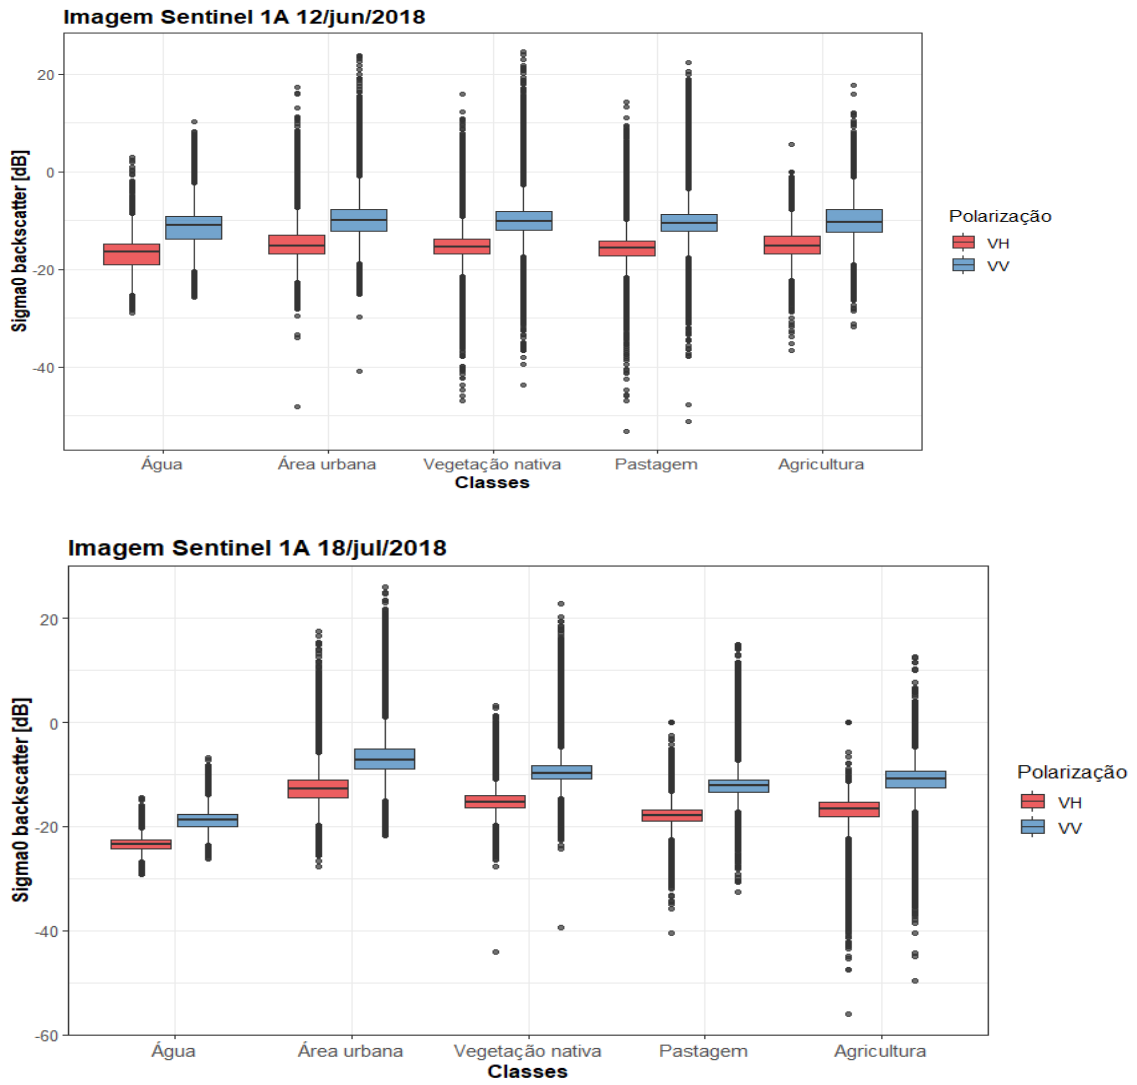


Figura 4. Box Plot da distribuição das intensidades de retroespalhamento de acordo com a classificação SVM da cobertura e do uso da terra do Distrito Federal.






Figura 5. Distribuição da coerência das classes de uso e cobertura da terra de acordo com a classificação SVM nas polarizações VH e VV.

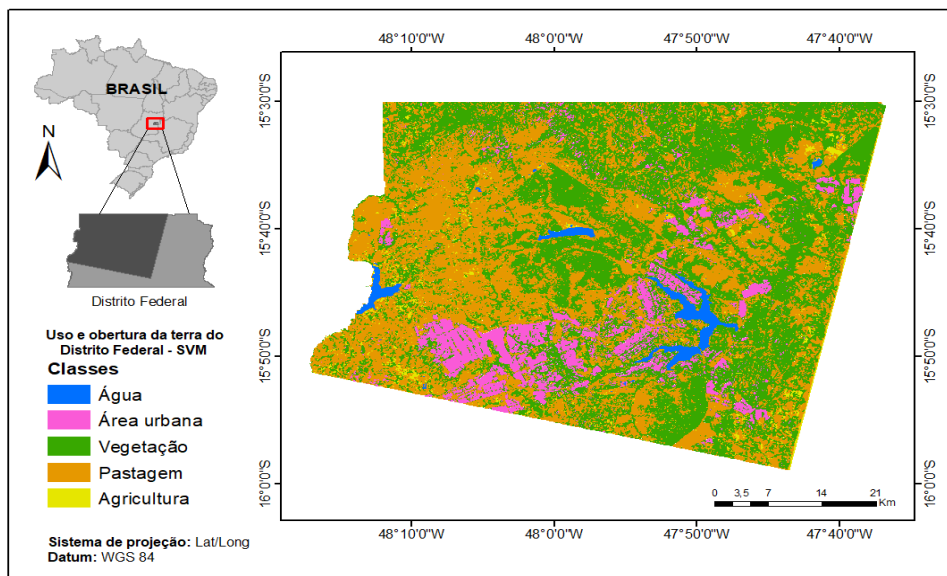


Figura 6. Resultado da classificação supervisionada de imagens do Sentinel-1A pelo algoritmo SVM.

Tabela 4. Matriz de confusão da classificação SVM do uso e cobertura da terra em [%].

	<b>AG</b>	<b>AU</b>	<b>VG</b>	<b>PA</b>	<b>AR</b>	<b>Acurácia do usuário</b>
<b>AG</b>	100	0	0	0	0	100
<b>AU</b>	0	53,29	1,81	0,96	4,5	96,21
<b>VN</b>	0	11,54	94,62	3,48	0	88,67
<b>PA</b>	0	17,91	1,89	84,41	27,73	16,66
<b>AR</b>	0	17,26	1,67	11,16	67,77	18,30
<b>Acurácia do produtor</b>	100	53,29	94,62	84,41	67,77	

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

De acordo com a matriz de confusão da classificação SVM, as classes “água” e “vegetação” obtiveram a maior acurácia, enquanto as classes “área urbana” e “agricultura” foram as classes que apresentaram as maiores confusões. O classificador não conseguiu detectar a diferença entre as classes “agricultura” e “pastagem”. Enquanto que para a classe “área urbana” houve erros de comissão de praticamente todas as classes, com exceção da classe “água”.

#### *Análise da classificação supervisionada RF*

A Figura 7 apresenta a distribuição dos valores de retroespalhamento para cada classe de cobertura da terra de acordo com a data da imagem e a respectiva polarização da imagem, segundo os resultados da classificação RF.

Os valores de coeficiente de retroespalhamento para cada classe, segundo a classificação RF foram muito semelhantes aos valores das classes para a classificação SVM. Não havendo grande diferença entre os valores.

Novamente, observa-se que os dados de intensidade de retroespalhamento da banda C não são apropriados para a separação das classes de cobertura terrestre, exceto para algumas áreas urbanizadas que possuem espalhadores artificiais, podendo ser separados devido aos altos valores do coeficiente de retroespalhamento e a corpos d’água superficiais devido aos valores muito baixos de retroespalhamento (Paradella et al., 2017; Alcântara et al., 2016).

A Figura 8 apresenta o boxplot com o padrão de distribuição da coerência para as diferentes classes de cobertura terrestre segundo a classificação RF. Os valores mais altos também foram observados para a classe “área urbana”, enquanto valores mais baixos foram observados para a pastagem, vegetação, agricultura e corpos d’água, respectivamente, seguindo o mesmo padrão que a classificação SVM (Olesk et al., 2015).

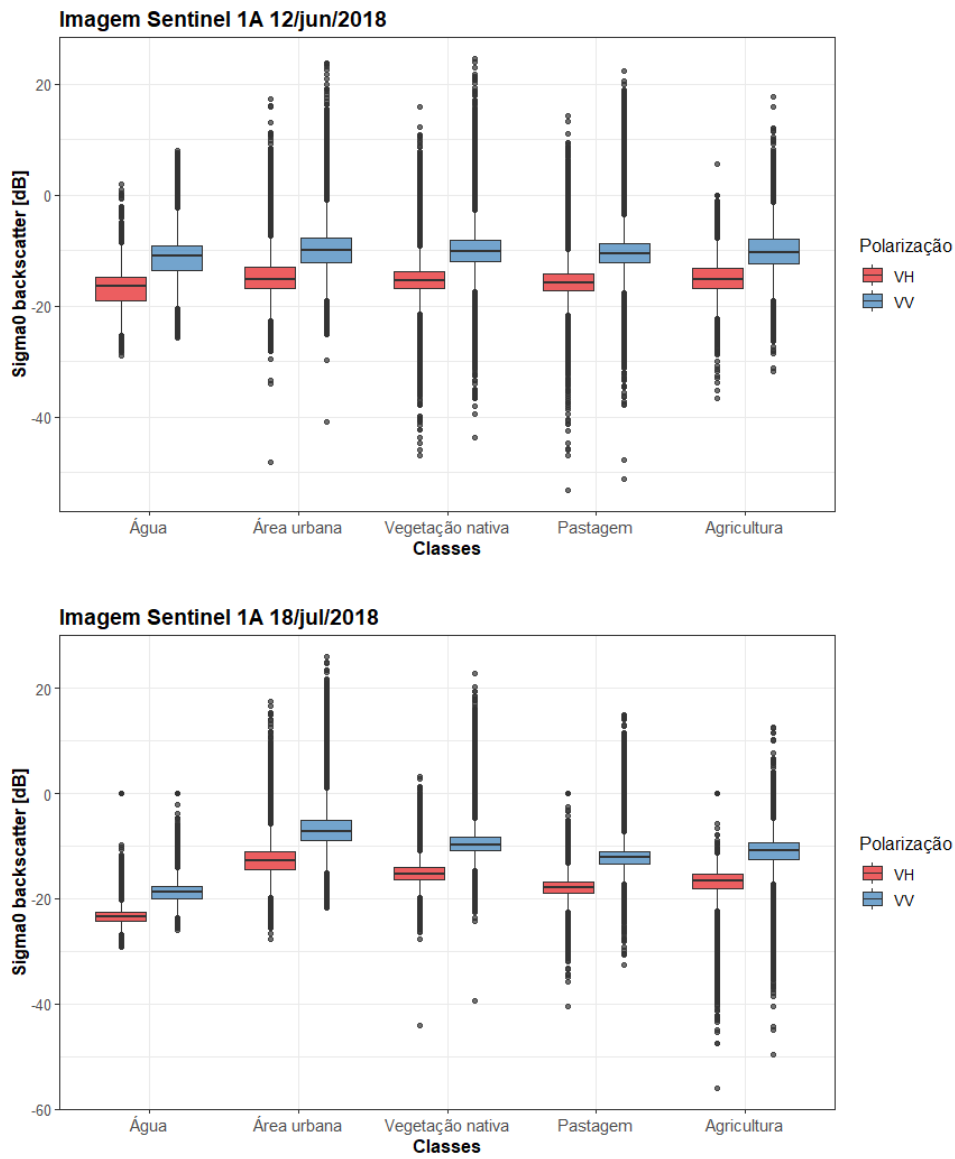


Figura 7. Box Plot da distribuição das intensidades de retroespalhamento de acordo com a classificação RF da cobertura e do uso da terra do Distrito Federal.




Figura 8. Distribuição da coerência das classes de uso e cobertura da terra de acordo com a classificação RF nas polarizações VH e VV.

A área de estudo apresentou um valor de coerência médio muito baixo em ambas as classificações, devido principalmente à cobertura vegetal dominante na área (Olesk et al., 2016). Nesse contexto, é preciso ressaltar que as imagens utilizadas nesse estudo correspondem a estação seca do Distrito Federal, que se inicia em maio e termina em setembro e, conseqüentemente, muitas árvores perdem as suas folhas, mudando os padrões de vegetação para se adequar a estação sem chuvas.

Os resultados mostram que o uso de coerência interferométrica contribuiu para uma melhor classificação de uso da terra e identificação

de mudanças temporais, em relação ao uso somente de coeficiente de retroespalhamento e razão de retroespalhamento (Wegmüller et al., 2015).

De acordo com a classificação RF (Figura 9), a maior parte da área de estudo é composta pela classe “vegetação”, com 34,72% do total da área, seguida pela classe “área urbana” com 26,3% do total e “pastagem” com 24,1% do total. Já as classes agricultura e água apresentaram áreas bem menores, com 13,12% e 1,76% do total da área respectivamente.

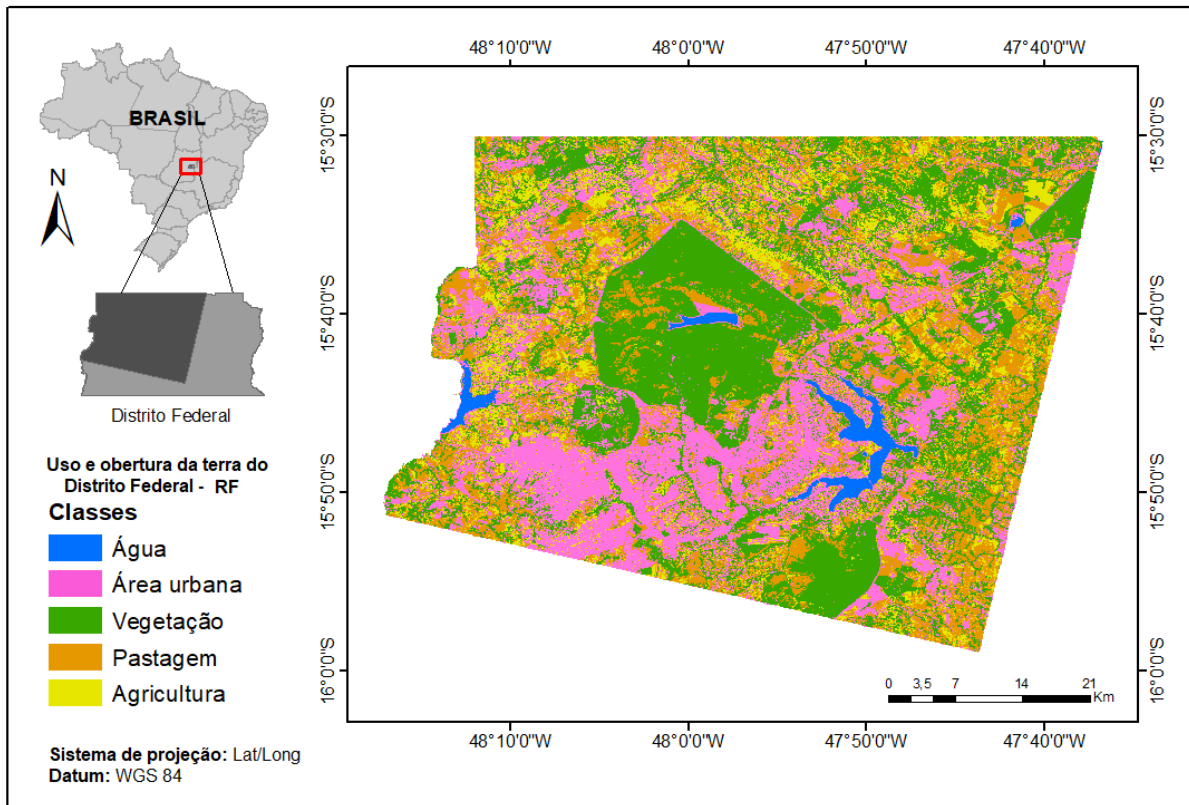


Figura 9. Resultado da classificação supervisionada de imagens do Sentinel 1A pelo algoritmo RF.

Comparando os resultados das duas classificações (Tabela 5), nota-se que a classificação RF apresentou uma área de pastagem quase seis vezes maior e uma área urbana três vezes maior que a classificação SVM detectou, enquanto isso, as classes vegetação nativa e pastagem foram

bem menos representativas na classificação RF do que na classificação SVM.

Já a classe água permaneceu praticamente com a mesma área nas duas classificações.

Tabela 5. Comparação das classificações SVM e RF.

Classes	Área – SVM [km <sup>2</sup> ]	Porcentagem [%]	Área – RF [km <sup>2</sup> ]	Porcentagem [%]
<b>AU</b>	257,64	9	753,126	26,3
<b>AG</b>	54,595	1,9	50,457	1,76
<b>VN</b>	1301,5	45,4	993,791	34,72
<b>PA</b>	1182	41,3	689,179	24,1
<b>AR</b>	68,282	2,4	375,71	13,12

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

A exatidão global e o índice Kappa da imagem classificada pelo algoritmo RF foram de 79,1% e 0,68, respectivamente. A classificação RF obteve um desempenho melhor que a classificação pelo algoritmo SVM, pois apresentou valores de índice Kappa e exatidão global um pouco superior (Kussul et al., 2017; Du et al., 2015).

Adam et al. 2014, ao compararem o desempenho dos algoritmos SVM e RF para a classificação do uso e cobertura da terra também obtiveram desempenhos similares nestes dois algoritmos, sendo que a maior acurácia foi alcançada pelo RF.

Segundo a matriz de confusão apresentada na Tabela 6, as classes “agricultura” e “pastagem” apresentaram as maiores confusões entre as classes, assim como na classificação SVM.

Já as classes “água” e “vegetação nativa” apresentaram a maior acurácia. Comparando com a classificação SVM, a classe “área urbana” apresentou menos erros de comissão, apesar de

apresentar uma área maior para essa classe do que a classificação SVM.

Os resultados indicaram que a combinação de coerência com intensidade de retroespalhamento contribuiu para uma classificação de uso e cobertura da terra considerada boa (Kappa 0,61~0,80) tanto para RF como para o SVM, de acordo com a classificação de Congalton e Green (2012).

Tabela 6 - Matriz de confusão da classificação RF do uso e cobertura da terra em [%].

	AG	AU	VG	PA	AR	Acurácia do usuário
AG	98,91	0	0	0	0	100
AU	1,09	67,34	1,68	1,73	4,8	97,77
VN	0	8,1	94,32	1,33	0	88,58
PA	0	12,67	2,52	85,86	27,64	16,35
AR	0	11,89	1,47	11,07	67,55	18,5
Acurácia do produtor	98,91	67,34	94,32	85,86	67,55	

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

### Conclusões

O presente estudo avaliou o potencial da coerência interferométrica do Sentinel 1A para a classificação do uso e cobertura da terra do Distrito Federal. A análise e os resultados do estudo indicaram que a combinação de coerência, intensidade de retroespalhamento e razão de retroespalhamento pode ser efetivamente utilizada como uma composição colorida para a discriminação das diferentes classes de uso e cobertura da terra.

Os resultados mostraram o bom potencial da coerência interferométrica do Sentinel 1A para a classificação supervisionada SVM, apresentando um índice kappa de 0,64 e 75,7% de exatidão global e também para a classificação RF, com índice Kappa de 0,68 e exatidão global de 79,4%. Nesse estudo, o algoritmo RF apresentou um melhor desempenho que o algoritmo SVM.

A imagem de coerência mostrou-se eficiente principalmente na identificação de corpos d’água e da área urbana na imagem, entretanto, houve confusão entre as áreas agrícolas e de pastagem e erros de comissão na classe área urbana para ambas as classificações.

Nesse contexto, os resultados enfatizaram que o uso de coerência interferométrica contribuiu para uma melhor classificação de uso da terra e

identificação de mudanças temporais, em relação ao uso somente de coeficiente de retroespalhamento e razão de retroespalhamento.

Sugere-se que futuras pesquisas sejam realizadas com imagens do Sentinel 1A e Sentinel 1B para aprimorar ou formular novas técnicas.

### Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa de Desenvolvimento Tecnológico e Industrial (DTI) à primeira autora.

### Referências

- Adam, E., Mutanga, O., Odindi, J., & Abdel-Rahman, E. M., 2014. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing* 35, 3440-3458.
- Alcântara, E., Watanabe, F., Rodrigues, T., Bernardo, N., Rotta, L., Carmo, A., Imai, N., 2016. Field measurements of the backscattering coefficient in a cascading reservoir system: first results from Nova Avanhandava and Barra Bonita Reservoirs

- (São Paulo, Brazil). *Remote Sensing Letters* 7, 417-426.
- Balzter, H., Cole, B., Thiel, C., Schmuilius, C., 2015. Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using random forests. *Remote Sensing* 7, 14876-14898.
- Belgic, M., Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114, 24-31.
- Chini, M., Hostache, R., Giustarini, L., Matgen, P., 2017. A hierarchical split-based approach for parametric thresholding of SAR images: Flood inundation as a test case. *IEEE Transactions on Geoscience and Remote Sensing* 55, 6975-6988.
- Confuorto, P., Di Martire, D., Centolanza, G., Iglesias, R., Mallorqui, J. J., Novellino, A., Calcaterra, D., 2017. Post-failure evolution analysis of a rainfall-triggered landslide by multi-temporal interferometry SAR approaches integrated with geotechnical analysis. *Remote sensing of environment* 188, 51-72.
- Congalton, R. G., Green, K., 2012. Assessing the accuracy of remotely sensed data: principles and practices. Second edition. CRC press, pp 174.
- Congalton, R. G., Gu, J., Yadav, K., Thenkabail, P.; Ozdogan, M., 2014. Global land cover mapping: A review and uncertainty analysis. *Remote Sensing* 6, 12070-12093.
- Du, P., Samat, A., Waske, B., Liu, S., & Li, Z., 2015. Random forest and rotation forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS Journal of Photogrammetry and Remote Sensing* 105, 38-53.
- Erten, E., Lopez-Sanchez, J. M., Yuzugullu, O., Hajnsek, I., 2016. Retrieval of agricultural crop height from space: A comparison of SAR techniques. *Remote Sensing of Environment* 187, 130-144.
- Gibril, M. B. A., Bakar, S. A., Yao, K., Idrees, M. O., Pradhan, B., 2017. Fusion of RADARSAT-2 and multispectral optical remote sensing data for LULC extraction in a tropical agricultural area. *Geocarto international* 32, 735-748.
- Johansson, A. M., King, J. A., Doulgeris, A. P., Gerland, S., Singha, S., Spreen, G., Busche, T., 2017. Combined observations of Arctic sea ice with near-coincident colocated X-band, C-band, and L-band SAR satellite remote sensing and helicopter-borne measurements. *Journal of Geophysical Research: Oceans* 122, 669-691.
- Khalil R. Z., Haque, S. 2018. InSAR coherence-based land cover classification of Okara, Pakistan. *The Egyptian Journal of Remote Sensing and Space Science* 21, S23-S28.
- Kumar, P., Gupta, D. K., Mishra, V. N., Prasad, R., 2015. Comparison of support vector machine, artificial neural network, and spectral angle mapper algorithms for crop classification using LISS IV data. *International Journal of Remote Sensing* 36, 1604-1617.
- Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A., 2017. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters* 14, 778-782.
- Lazecky, M., Hlavacova, I., Bakon, M., Sousa, J. J., Perissin, D., Patricio, G., 2017. Bridge displacements monitoring using space-borne X-band SAR interferometry. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10, 205-210.
- Lee, J.S., 1981. Speckle Analysis and Smoothing of Synthetic Aperture. *Computer Graphics and Image Processing* 17, 24-32.
- Lin, B., Shao, W., Li, X., Li, H., Du, X., Ji, Q., Cai, L., 2017. Development and validation of an ocean wave retrieval algorithm for VV-polarization Sentinel-1 SAR data. *Acta Oceanologica Sinica* 36, 95-101.
- Marengo, J. A., 2010. Vulnerabilidade, impactos e adaptação à mudança do clima no semiárido do Brasil. *Parcerias Estratégicas* 13, 149-176.
- Migliaccio, M., Nunziata, F., Buono, A., 2015. SAR polarimetry for sea oil slick observation. *International Journal of Remote Sensing* 36, 3243-3273.
- Minh, D. H. T., Le Toan, T., Rocca, F., Tebaldini, S., Villard, L., Réjou-Méchain, M., Chave, J., 2016. SAR tomography for the retrieval of forest biomass and height: Cross-validation at two tropical forest sites in French Guiana. *Remote Sensing of Environment* 175, 138-147.
- Mohammadimanesh, F., Salehi, B., Mahdianpari, M., Motagh, M., Brisco, B., 2018. An efficient feature optimization for wetland mapping by synergistic use of SAR intensity, interferometry, and polarimetry data. *International journal of applied earth observation and geoinformation* 73, 450-462.

- Neves, G., Sena-Souza, J. P., Gomes, M. P., Reatto, A., Nardoto, G. B., de Souza Martins, É., Junior, A. F. C., 2015. Relação entre a dinâmica da expansão das atividades agropastoris e o relevo da bacia hidrográfica do rio São Bartolomeu, Planalto Central Brasileiro. Anais... XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE, 2015-2022.
- Olesk, A., Praks, J., Antropov, O., Zalite, K., Arumäe, T., Voormansik, K. 2016. Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM-X data. *Remote Sensing* 8, 700-715.
- Olesk, A., Voormansik, K., Vain, A., Noorma, M., Praks, J., 2015. Seasonal differences in forest height estimation from interferometric TanDEM-X coherence data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8, 5565-5572.
- Paradella, W. R., dos Santos, A. R., Veneziani, P., Morais, M. C., 2017. Synthetic Aperture Radar for geological applications in the moist tropics: experiences from the Brazilian Amazon region. *Revista Brasileira de Geociências* 30, 538-542.
- Pôssa, E. M., Gama F. F, Santos J. R., Mura, J. C., Bispo, P. C., 2018. Análise de uso da terra e cobertura florestal na Amazônia central, a partir de dado polarimétrico PALSAR/ALOS-1 e coerência interferométrica TanDEM-X. *Revista Brasileira de Geografia Física* 11, 2094-2108.
- Salentinig, A., Gamba, P., 2015. Combining SAR-based and multispectral-based extractions to map urban areas at multiple spatial resolutions. *IEEE Geoscience and Remote Sensing Magazine* 3, 100-112.
- Schlaffer, S., Chini, M., Giustarini, L., Matgen, P., 2017. Probabilistic mapping of flood-induced backscatter changes in SAR time series. *International Journal of Applied Earth Observation and Geoinformation* 56, 77-87.
- Skrunes, S., Brekke, C., Eltoft, T., Kudryavtsev, V., 2015. Comparing near-coincident C-and X-band SAR acquisitions of marine oil spills. *IEEE Transactions on Geoscience and Remote Sensing* 53, 1958-1975.
- Stehman, S. V., 1997. Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment* 62, 77-89.
- Strozzi, T., Dammert, P. B., Wegmuller, U., Martinez, J. M., Askne, J. I.; Beaudoin, A., Hallikainen, N. T., 2000. Land use mapping with ERS SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing* 38, 766-775.
- Temporim, F. A., Gama, F. F., Mura J. C., Paradella, W. R., Silva, G. G., 2017. Application of persistente scatterers interferometry for surface displacements monitoring in N5E open pit iron mine using TerraSAR-X data, in Carajás Province, Amazon region. *Brazilian Journal of Geology* 47, 225-235.
- Wang, L., Scott, K. A., Xu, L., Clausi, D. A., 2016. Sea ice concentration estimation during melt from dual-pol SAR scenes using deep convolutional neural networks: A case study. *IEEE Transactions on Geoscience and Remote Sensing* 54, 4524-4533.
- Watanabe, M., Thapa, R. B., Ohsumi, T., Fujiwara, H., Yonezawa, C., Tomii, N., Suzuki, S., 2016. Detection of damaged urban areas using interferometric SAR coherence change with PALSAR-2. *Earth, Planets and Space* 68, 131.
- Wegmüller, U., Santoro, M., Werner, C., 2015. On the estimation and interpretation of Sentinel-1 TOPS InSAR coherence. In: *Proceedings of FRINGE*, ESA SP. European Space Agency.
- Zhang, Y., Lu, S., Zhou, X., Yang, M., Wu, L., Liu, B., Wang, S. 2016. Comparison of machine learning methods for stationary wavelet entropy-based multiple sclerosis detection: decision tree, k-nearest neighbors, and support vector machine. *Simulation* 92, 861-871.