

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL

Elisiane Alba

**INFLUÊNCIA E ANÁLISE DA COBERTURA FLORESTAL NA
MODIFICAÇÃO DO ALBEDO COM O USO DE INTELIGÊNCIA
ARTIFICIAL E SENSORIAMENTO REMOTO**

Santa Maria, RS

2019

Elisiane Alba

**INFLUÊNCIA E ANÁLISE DA COBERTURA FLORESTAL NA MODIFICAÇÃO DO
ALBEDO COM O USO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO
REMOTO**

Tese apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Engenharia Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Doutora em Engenharia Florestal**.

Orientador: Prof. Dr. Rudiney Soares Pereira

**Santa Maria, RS
2019**

Alba, Elisiane

Influência e análise da cobertura florestal na
modificação do albedo com o uso de inteligência
artificial e sensoriamento remoto / ELISIANE ALBA.- 2019.
121 p.; 30 cm

Orientador: Rudiney Soares Pereira
Tese (doutorado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Engenharia Florestal, RS, 2019

1. Imagens Landsat 2. Albedo 3. Mudanças climáticas
4. Cobertura florestal I. Soares Pereira, Rudiney II.
Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

© 2019

Todos os direitos autorais reservados a Elisiane Alba. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

E-mail: elisianealba@gmail.com

Elisiane Alba

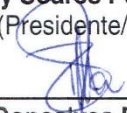
**INFLUÊNCIA E ANÁLISE DA COBERTURA FLORESTAL NA MODIFICAÇÃO DO
ALBEDO COM O USO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO
REMOTO**

Tese apresentada ao Curso de Doutorado
do Programa de Pós-Graduação em
Engenharia Florestal, da Universidade
Federal de Santa Maria (UFSM, RS), como
requisito parcial para obtenção do título de
Doutora em Engenharia Florestal.

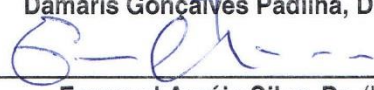
Aprovada em 18 de dezembro de 2019:



Rudiney Soares Pereira, Dr. (UFSM)
(Presidente/Orientador)



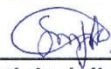
Damáris Gonçalves Padilha, Dra. (UFSM)



Emanuel Araújo Silva, Dr. (UFRPE)



Gabriel Paes Marangon, Dr. (UNIPAMPA)



Silvia Margareti de Juli Moraes Kurtz, Dra. (UFSM)

Santa Maria, RS

2019

*Dedico a minha mãe,
Vanilda Frigo Alba*

AGRADECIMENTOS

À Deus, autor de todas as obras, gratidão por todas as bênçãos;

À minha família, em especial a minha mãe Vanilda e meu pai Luís, por todos os ensinamentos de vida e apoio em toda a caminhada acadêmica. Todo o meu esforço é dedicado a vocês.

Ao André e família, que sempre dedicaram de todo apoio, compreensão e oração;

Ao meu orientador Rudiney, por todos os conhecimentos passados, pela oportunidade de crescimento dentro do Labsere, sendo um exemplo que levarei para toda vida.

Aos meus amigos de Labsere que tive a oportunidade de aprender e conviver: Xuqui, Lizi, Leka, Badin, Fábio, Jézus, Dioninha, Helena, Frigo, Robson, Roberta, Bruna e Matheus Z. Aos amigos de UFSM que proporcionaram momentos maravilhosos de distração Lú, Janderson e Pábulo.

Em especial, meus sinceros agradecimentos aos amigos Emanuel e Juliana, os quais fizeram toda a diferença na minha caminhada: Emanuel, responsável por me incentivar a ingressar na pós-graduação e desde então é o amigo de todas as horas; Juliana, pela amizade e sua dedicação nas atividades, em que sempre tive o seu apoio.

Ao professor Manoel, meu primeiro orientador da graduação, o qual me ensinou a base da pesquisa.

Aos professores integrantes da banca examinadora Damáris Gonçalves Padilha, Emanuel Araújo Silva, Gabriel Paes Marangon e Silvia Margareti de Juli Morais Kurtz, pelas contribuições para a melhoria deste trabalho.

E a todos que de alguma forma contribuíram para o desenvolvimento desse trabalho, bem como na minha formação pessoal.

RESUMO

INFLUÊNCIA E ANÁLISE DA COBERTURA FLORESTAL NA MODIFICAÇÃO DO ALBEDO COM O USO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO

AUTORA: Elisiane Alba
ORIENTADOR: Rudiney Soares Pereira

Os efeitos das mudanças climáticas influenciam em diferentes escalas, necessitando medidas que visem a redução da emissão de gases poluentes, assim como de medidas mitigatórias para esse problema. Nesse contexto, o albedo determina a fração da radiação solar incidente que retorna para a atmosfera e, portanto, corresponde a um parâmetro chave no orçamento de energia radiante da terra. O objetivo deste estudo foi investigar a influência da cobertura florestal nas variações do albedo de superfície em áreas do bioma Mata Atlântica durante o período de 1987 a 2017. Aliado a isso, utilizar dados espaciais e novas tecnologias de processamento de dados para a identificação de fisionomias da cobertura terrestre, bem como a relação destas com o albedo de superfície. O albedo foi obtido por meio do método de *Surface Energy Balance Algorithm for Land*, enquanto que o mapeamento do uso e cobertura da terra foi realizado pelo algoritmo classificador *Maxver* sendo identificado quatro classes temáticas. Por fim, realizou-se o cruzamento do albedo com as classes temáticas identificando o seu comportamento em função das mudanças na cobertura da terra. Algoritmos de aprendizado de máquina foram utilizados na identificação dos diferentes povoamentos florestais presentes na área de estudo, os quais também foram associados à variação do albedo. As modificações do albedo foram identificadas por meio da análise de tendência considerando uma série temporal de 30 anos obtidas a partir de imagens TM/Landsat 5 e OLI/Landsat 8 no período de verão. A influência da cobertura florestal no albedo foi estabelecida por meio do índice de vegetação de diferença normalizada. O albedo de superfície variou de 6 a 22%, sendo que o ano de 1987 concentrou valores à 2017, em decorrência da menor concentração de vegetação. O algoritmo *Support Vector Machine* (SVM) foi o que apresentou melhores resultados na identificação dos povoamentos florestais, no entanto, não diferiu significativamente do algoritmo *Artificial Neural Networks* (ANN). Os povoamentos de espécies de coníferas apresentaram albedo inferior à espécie de folhosa. Observou-se que a implantação da cobertura florestal reduziu o albedo em aproximadamente 60%, enquanto que mudanças na estrutura dessa cobertura resultou em um aumento de aproximadamente 20% nos valores de albedo. Desse modo, o estudo demonstrou que a cobertura florestal nativa do bioma Mata Atlântica, bem como os povoamentos florestais apresentam grande participação no balanço de energia, sendo importantes para a manutenção microclimática local e regional. O albedo por sua vez, apresenta-se como uma potencial variável a ser utilizada no estudo de diversos parâmetros estruturais na cobertura florestal.

Palavras-chave: Linguagem R. Análise de tendência. Mata Atlântica.

ABSTRACT

INFLUENCE AND ANALYSIS OF FOREST COVERAGE IN ALBEDO MODIFICATION WITH THE USE OF ARTIFICIAL INTELLIGENCE AND REMOTE SENSING

AUTHOR: Elisiane Alba

ADVISOR: Rudiney Soares Pereira

The effects of climate changes influence in different scale, necessitating measures aimed at reducing of emission of polluting gases, as well as measures mitigating for this problem. In this context, the albedo determines the fraction of incident solar radiation that returns to the atmosphere and therefore corresponds to a key parameter in the radiant energy budget of the earth. The aim of this study was to investigate the influence of forest cover on surface albedo variations in areas of the Atlantic Forest biome during the period from 1987 to 2017. In addition, using spatial data and new data processing technologies to identify land cover physiognomies and their relationship to surface albedo. The albedo was obtained by the Surface Energy Balance Algorithm for Land method, while the land use and land cover mapping was performed by the Maxver classifier algorithm, and four thematic classes were identified. Finally, albedo was crossed with thematic classes identifying the variation of albedo as a function of changes in land cover. Machine learning algorithms were used to identify different stands in the study area, which were also associated with albedo variation. Albedo modifications were identified by trend analysis considering a 30-year time series obtained from TM/Landsat 5 and OLI/Landsat 8 images in the summer period. The influence of forest cover on albedo was related through the normalized difference vegetation index. Surface albedo ranged from 6 to 22%, with 1987 concentrating higher albedo values than 2017, due to the lower vegetation concentration. The Support Vector Machine (SVM) algorithm presented the best results in forest stand identification, however, it did not differ significantly from the Artificial Neural Networks (ANN) algorithm. The stands of coniferous species presented lower albedo than the hardwood species. Implementation of forest cover reduced albedo by approximately 60%, while changes in the structure of this cover resulted in an increase of approximately 20% in albedo values. Thus, the study demonstrates that the native forest cover of the Atlantic Forest biome, as well as the forest stands have a large participation in the energy balance, being important for the local and regional microclimate maintenance. Albedo, in turn, is a potential variable applied in the study of several structural parameters in forest cover.

Keywords: R language. Trend analysis. Mata Atlântica.

LISTA DE ILUSTRAÇÕES

CAPÍTULO I

Figura 1 – Fluxograma da estrutura de uma árvore de classificação.....43

CAPÍTULO II

Figura 1 – Localização da área de estudo que abrange a Floresta Nacional de São Francisco de Paula - RS60

Figura 2 – Albedo de superfície na FLONA de São Francisco de Paula nos anos de 1987 (a) e 2017 (b) para as áreas de floresta nativa, plantios florestais, campo nativo e água65

Figura 3 – Uso e cobertura da terra para a FLONA de São Francisco de Paula nos anos de 1987 (a) e 2017 (b)67

Figura 4 – Classes temáticas e seus respectivos valores de albedo nos anos 1987 (a) e 2017 (b).....69

CAPÍTULO III

Figura 1 – Valores de acurácia obtidos no processo de validação cruzada para os diferentes algoritmos de aprendizado de máquina83

Figura 2 – Teste estatístico de Friedman e Nemenyi para os algoritmos de aprendizado de máquina ao nível de significância de 5%85

Figura 3 - Mapeamento das espécies florestais por meio da classificação manual (A) e dos algoritmos SVM (B), ANN (C) e RF (D) para a FLONA São Francisco de Paula.....89

Figura 4 - Reflectância das espécies florestais nas bandas B4 e B5 (a) e os valores de média e desvio padrão para as bandas B4 (b) e B5 (c)91

Figura 5 – Relação apresentada entre a cobertura florestal e o albedo de superfície na FLONA de Francisco de Paula.....93

Figura 6 - Distribuição dos valores de albedo para as espécies florestais (a) e seus respectivos valores médios e desvio padrão (b)95

Figura 7 - Relação da banda B4, B5 e do albedo de superfície para a identificação de espécies florestais96

CAPÍTULO IV

Figura 1 – Evolução da tendência do albedo para o período de verão de 1987-2017 para a FLONA de São Francisco de Paula109

Figura 2 – Tendências apresentada pelo albedo de superfície entre 1987 a 2017 em locais com tendência decrescente (a) e crescente (b)110

Figura 3 – Relação entre o verdor da vegetação (NDVI) e o albedo de superfície com tendência decrescente ao longo de 30 anos112

Figura 4 – Relação entre o verdor da vegetação (NDVI) e o albedo de superfície com tendência crescente ao longo de 30 anos114

LISTA DE TABELAS

CAPÍTULO I

Tabela 1 – Características dos satélites do Programa Landsat	36
Tabela 2 – Características da resolução espectral, espacial e temporal do satélite Landsat 5.....	37
Tabela 3 – Características da resolução espectral, espacial e temporal do satélite Landsat 8.....	38

CAPÍTULO II

Tabela 1 – Amplitude e abrangência das classes de albedo observadas na FLONA de São Francisco de Paula para os anos de 1987 e 2017	66
Tabela 2 – Quantificação do uso e cobertura da terra para 1987 e 2017 obtida na classificação supervisionada, em hectares e percentual, das classes em relação a área total da FLONA.....	68

CAPÍTULO III

Tabela 1 – Algoritmos de aprendizado de máquina e os respectivos parâmetros utilizados no processamento da imagem do ano de 2017	79
Tabela 2 – Valores de acurácia global e índice <i>Kappa</i> da classificação supervisionada de espécies florestais resultante de diferentes classificadores	82
Tabela 3 – <i>Ranking</i> dos algoritmos de aprendizado de máquina obtidos na validação cruzada.....	84
Tabela 4 – Matriz de confusão para a classificação supervisionada com o uso do algoritmo SVM para a FLONA São Francisco de Paula.....	87
Tabela 5 – Métricas de avaliação do modelo de classificação por SVM	88
Tabela 6 – Quantificação das classes temáticas em hectares (ha) e seus respectivos percentuais obtidos na classificação manual e por meio dos algoritmos de aprendizado de máquina.....	90

CAPÍTULO IV

Tabela 1 – Análise do total de <i>pixels</i> com tendência nos valores de albedo no período de verão de 1987-2017 para a FLONA de São Francisco de Paula	110
---	-----

LISTA DE EQUAÇÕES

CAPÍTULO I

Equação 1.....	35
Equação 2.....	35
Equação 3.....	39
Equação 4.....	39
Equação 5.....	46

CAPÍTULO II

Equação 1.....	62
Equação 2.....	62
Equação 3.....	62
Equação 4.....	63
Equação 5.....	63

CAPÍTULO IV

Equação 1.....	105
Equação 2.....	105
Equação 3.....	106
Equação 4.....	106
Equação 5.....	106
Equação 6.....	107
Equação 7.....	107
Equação 8.....	107
Equação 9.....	108

LISTA DE ABREVIATURAS

ANN	<i>Artificial Neural Networks</i>
CRAN	<i>Comprehensive R Archive Network</i>
DT	<i>Decision Tree</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
FLONA	Floresta Nacional
kNN	<i>K-Nearest Neighbor</i>
MSS	<i>Multispectral Scanner</i>
ND	Número digital
NDVI	<i>Normalized Difference Vegetation Index</i>
OLI	<i>Operational Land Imager</i>
<i>Pixel</i>	<i>Picture element</i>
RBV	<i>Return Beam Vidicom</i>
REM	Radiação Eletromagnética
RF	<i>Random Forest</i>
SEBAL	<i>Surface Energy Balance Algoritmo for Land</i>
SNUC	Sistema Nacional de Unidades de Conservação
SVM	<i>Support Vector Machine</i>
SR	Sensoriamento Remoto
TIRS	<i>Thermal Infrared Sensor</i>
TM	<i>Thematic Mapper</i>
USGS	<i>United States Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>
WGS84	<i>World Geodetic System 1984</i>
WMO	<i>World Meteorological Organization</i>

SUMÁRIO

CAPÍTULO I: ASPECTOS GERAIS	25
1 INTRODUÇÃO GERAL	25
2 HIPÓTESES DA PESQUISA	27
3 OBJETIVO GERAL	27
3.1 OBJETIVOS ESPECÍFICOS	27
4 REFERENCIAL TEÓRICO	29
4.1 BIOMA MATA ATLÂNTICA: FLORESTA OMBRÓFILA MISTA	29
4.1.1 Floresta Nacional de São Francisco de Paula	30
4.2 SENSORIAMENTO REMOTO	31
4.2.1 Interação da energia com a atmosfera terrestre	33
4.2.2 Interação da radiação solar com os alvos	34
4.2.3 Imagens landsat	35
4.2.4 Albedo	38
4.2.5 Classificação digital de imagens	40
4.3 INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA.....	41
4.3.1 Métricas de avaliação da classificação	44
4.4 ANÁLISE DE TENDÊNCIA.....	45
4.4.1 Mann-kendall (MK)	46
4.4.2 Teste de inclinação sen	47
4.5 AMBIENTE R	48
REFERÊNCIAS BIBLIOGRÁFICAS	49

CAPÍTULO II: INFLUÊNCIA DO USO E COBERTURA DA TERRA NO ALBEDO DE SUPERFÍCIE	57
RESUMO.....	57
ABSTRACT	57
1 INTRODUÇÃO	58
2 MATERIAL E MÉTODOS	60
2.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO	60
2.1.1 Dados espectrais	61
2.2.2 Albedo de superfície	62
2.2.3 Relação do albedo com o uso e cobertura da terra	63
3 RESULTADOS E DISCUSSÃO	64
4 CONCLUSÃO	70
REFERÊNCIAS BIBLIOGRÁFICAS	71

CAPÍTULO III: IDENTIFICAÇÃO DE ESPÉCIES FLORESTAIS USANDO INTELIGÊNCIA ARTIFICIAL: ESTUDO DA RELAÇÃO DAS ESPÉCIES FLORESTAIS COM O ALBEDO	75
RESUMO.....	75
ABSTRACT	75
1 INTRODUÇÃO	76
2 MATERIAL E MÉTODOS	77
2.1 ÁREA DE ESTUDO	77
2.2 IMAGEM OLI/LANDSAT 8	78
2.3 ALGORITMOS DE APRENDIZADO DE MÁQUINA	78
2.4 VALIDAÇÃO DA CLASSIFICAÇÃO	80

2.5	RELAÇÃO DO ALBEDO DE SUPERFÍCIE COM AS ESPÉCIES FLORESTAIS	80
3	RESULTADOS E DISCUSSÃO	81
3.1	VALIDAÇÃO DA CLASSIFICAÇÃO DOS ALGORITMOS	82
3.2	MAPEAMENTO DAS ESPÉCIES E FOM	88
3.3	RELAÇÃO DO ALBEDO COM AS ESPÉCIES FLORESTAIS	93
4	CONCLUSÃO	97
	REFERÊNCIAS BIBLIOGRÁFICAS	97
CAPÍTULO IV: ANÁLISE DE TENDÊNCIA DO ALBEDO NA COBERTURA FLORESTAL EM ÁREA DO BIOMA MATA ATLÂNTICA		101
	RESUMO	101
	ABSTRACT	101
1	INTRODUÇÃO	102
2	MATERIAL E MÉTODOS	104
2.1	DADOS ESPECTRAIS	104
2.2	RELAÇÃO DO ALBEDO COM O VERDOR DA VEGETAÇÃO	105
2.3	ANÁLISE DE TENDÊNCIAS	106
2.4	TESTE DE INCLINAÇÃO DE SEN	107
3	RESULTADOS E DISCUSSÃO	108
3.1	VARIAÇÃO DO ALBEDO NO PERÍODO DE 30 ANOS	108
3.2	RELAÇÃO DO ALBEDO COM O ÍNDICE NDVI	112
4	CONCLUSÃO	116
	REFERÊNCIAS BIBLIOGRÁFICAS	116
	CONCLUSÃO GERAL	121

CAPÍTULO I: ASPECTOS GERAIS

1 INTRODUÇÃO GERAL

A cobertura florestal tem concentrado estudos por parte da comunidade científica por apresentar benefícios econômicos, sociais e ambientais para a população humana. O crescente interesse nas alterações climáticas decorrentes da substituição das florestas nativas tem levado ao desenvolvimento de estudos que descrevem com maior precisão os mecanismos da interação solo-vegetação-atmosfera nesses ambientes.

As mudanças climáticas podem impactar em diferentes esferas como na agricultura, abastecimento de água e ocorrência de desastres naturais (SALVIANO et al., 2016). Nesse sentido, a vegetação arbórea corresponde a um importante receptor e armazenador de radiação solar devido à sua ação de absorção da energia incidente (JARVIS et al., 1997).

As florestas comportam-se como mediadores entre o fluxo de energia da superfície terrestre e da atmosfera, de modo que, alterações na cobertura vegetal podem desregular esses mecanismos de troca e conseqüentemente, influenciar o clima (DAVIN e NOBLET-DUCOUDRÉ, 2010; LUKES et al., 2016; HOVI et al., 2017). Mudanças na cobertura da terra provocam alterações nos valores de albedo da superfície terrestre e na evapotranspiração, as quais consistem nas principais variáveis biofísicas relacionadas ao clima (PLANQUE et al., 2017).

O albedo, por sua vez, determina a fração da radiação solar incidente que retorna para a atmosfera e, portanto, corresponde a um parâmetro chave no orçamento de energia radiante da terra (KUUSINEN et al., 2013; LUKES et al., 2016). Desse modo, Cunha et al. (2013) destacam que as mudanças no clima regional e global são decorrentes da alteração dos processos biofísicos e biogeoquímicos, os quais são resultantes de modificações da cobertura terrestre, que podem ser identificados em função das mudanças relacionadas ao albedo.

Diante do exposto, percebe-se a importância de estudos que identifiquem as causas e as dimensões dessas mudanças ocorridas no albedo de superfície. A identificação dos locais que estão sofrendo alguma tendência de modificação possibilita estimar os possíveis danos destas mudanças nas atividades

socioeconômicas, auxiliando os tomadores de decisão a respeito do risco caso nenhuma ação seja tomada (SALVIANO et al., 2016).

Dados espaciais, oriundos de sistemas orbitais, possibilitam a análise de fenômenos em um determinado período, identificando seu comportamento ao longo do tempo. Para Salviano et al. (2016), os dados espaciais permitem identificar quais regiões estão sob maior e/ou menor influência de mudanças significativas nas propriedades de interesse.

O uso de séries temporais para estimativa do albedo a partir de imagens MODIS ou Landsat permitem capturar a dinâmica da superfície terrestre com alta similaridade com os dados de campo coletados a partir da instalação de torres (WANG et al., 2017; ZHANG et al., 2019). Para Lukes et al. (2013) a reflectância da cobertura florestal obtida com dados de sensoriamento remoto em plataformas orbitais, correspondem ao único método possível para vincular mudanças quantitativas na estrutura da vegetação ao albedo para grandes regiões geográficas.

Além disso, a partir de imagens de satélite é possível identificar modificações no uso e cobertura da terra, bem como a diferenciação de espécies florestais, permitindo relacionar essas fisionomias com o albedo de superfície. Para tanto, com a evolução tecnológica, passou-se a utilizar a inteligência artificial visando a solução de problemas reais (FACELI et al., 2011). Dentro desse campo, se insere o aprendizado de máquina, o qual é aplicado com eficiência para a classificação tanto em processos supervisionados como não supervisionados.

O acesso gratuito aos dados Landsat e os avanços técnicos mencionados acima, indicam um potencial uso desses dados para a estimativa do albedo, bem como na identificação dos alvos presentes na superfície, especialmente em aplicações que requerem dados com resolução espacial mais refinada como o monitoramento de áreas fragmentadas (HE et al., 2018). A Mata Atlântica é um dos principais biomas brasileiros, entretanto encontra-se altamente fragmentado, restando apenas 12,5% de sua área original, quando contabilizados fragmentos acima de 3 hectares, desse modo, nos últimos 18 anos, o bioma perdeu aproximadamente 18.509 km² de área (SOS MATA ATLÂNTICA, 2015).

Devido à importância ecossistêmica do bioma Mata Atlântica, a Floresta Nacional (FLONA) de São Francisco de Paula é uma unidade de conservação de uso sustentável, caracterizada como uma área de cobertura florestal que apresenta espécies predominantemente nativas.

A cobertura nativa da FLONA corresponde aos campos de cima da serra (Estepe) e pelas matas com araucária, também denominada de Floresta Ombrófila Mista. A área é composta principalmente com fragmentos de floresta nativa e por plantios de *Araucaria angustifolia*, *Pinus taeda*, *Pinus elliottii* e *Eucalyptus* spp. (ICMBIO, 2019).

Diante da importância dessas composições florestais para a manutenção da biodiversidade e do fluxo de energia entre a atmosfera e a superfície é essencial investigar, ao longo do tempo, a interação do albedo com os parâmetros estruturais da vegetação. Desse modo, pode-se definir ações de manejo sobre as quais terão influência sobre o clima.

2 HIPÓTESES DA PESQUISA

- A cobertura florestal influencia diretamente nos valores de albedo de superfícies sendo importantes aliados na redução do fluxo de energia radiante para a atmosfera.
- Imagens de média resolução espacial quando associadas às técnicas de inteligência artificial permitem a identificação de espécies florestais.

3 OBJETIVO GERAL

O objetivo deste estudo foi investigar a influência da cobertura florestal nas variações do albedo de superfície em áreas pertencentes ao bioma Mata Atlântica durante o período de 1987 a 2017. Aliado a isso, utilizar informações espaciais e novas tecnologias de processamento de dados para a identificação de fisionomias da cobertura terrestre e a associação destas com o albedo de superfície.

3.1 OBJETIVOS ESPECÍFICOS

- Avaliar a influência da dinâmica de uso e cobertura da terra sobre o comportamento do albedo;
- Examinar a influência da estrutura (dossel) da cobertura florestal nos valores de albedo;

- Verificar a eficiência de algoritmos de aprendizado de máquina aplicados à identificação de espécies florestais;
- Examinar a presença de tendências de albedo em coberturas florestais no bioma Mata Atlântica (1987-2017).

4 REFERENCIAL TEÓRICO

4.1 BIOMA MATA ATLÂNTICA: FLORESTA OMBRÓFILA MISTA

O bioma Mata Atlântica estende-se ao longo do Rio Grande do Norte ao Rio Grande do Sul, sendo constituído principalmente pela costa litorânea brasileira, considerada um dos maiores repositórios de biodiversidade do mundo (EBLING, 2012). Os números indicam que esse bioma apresenta cerca de 60 mil espécies vegetais, com aproximadamente 12 mil (22%) espécies endêmicas desse ambiente (GIAM et al., 2010).

A Mata Atlântica apresenta formações florestais e ecossistemas associados como restingas, manguezais e campos de altitude. As formações florestais correspondem à Floresta Ombrófila Densa, Floresta Ombrófila Mista, Floresta Ombrófila Aberta, Floresta Estacional Semidecidual, Floresta Estacional Decidual (MMA, 2017a).

Neste contexto, destaca-se a formação Floresta Ombrófila Mista (FOM), também denominada de Mata de Araucárias. Essa formação se estende, em sua maioria, nos estados de Paraná, Santa Catarina e Rio Grande do Sul. A composição florística da Floresta Ombrófila Mista apresenta gêneros primitivos como *Drymis*, *Araucaria* (australásios) e *Podocarpus* (afro-asiáticos), oriundos de climas frios e quentes (EBLING, 2012). Embora essa fitofisionomia seja caracterizada por uma riqueza florística, é constituída predominante pela *Araucaria Angustifolia* (Bertol.) Kuntze no estrato superior (SONEGO et al., 2007).

A área de ocorrência é em clima úmido sem período seco, associado a temperaturas médias anuais de aproximadamente 18 °C (VIANA, 2015). A Mata de Araucária predomina em altitudes acima de 500 a 600 metros. Apesar da região sul do Brasil estar em região subtropical, permite a formação de florestas heterogêneas, similar às tropicais (ARAUJO et al., 2010).

Esse tipo de fisionomia, a FOM, apresenta relevância econômica, recursos madeireiros, além de ser considerada símbolo para a região pela presença da *Araucaria angustifolia* (PIRES et al., 2012). Essa formação tem ocorrência intercalada com áreas de savana e estepe, originando um sistema em mosaico característico de grande parte da fisionomia da região Sul do País (BACKES, 2001; SONEGO et al., 2007).

Desde o início da colonização, a FOM, assim como as demais formações fitofisionômicas, foram exaustivamente exploradas, sem vistas a sua preservação e a sustentabilidade dos recursos naturais (SONEGO et al., 2007). A Mata Atlântica é um dos biomas brasileiros com maior grau de degradação, destacando-se que nos últimos 18 anos, o bioma perdeu aproximadamente 18.509 km² de área, restando 12,5% de sua área original (SOS MATA ATLÂNTICA, 2015). Santos (2014) afirma que a redução da cobertura original desse bioma deve-se a intensa colonização juntamente com a urbanização e o avanço da agricultura.

Diante deste cenário, áreas protegidas como Unidades de Conservação são fundamentais para a manutenção de amostras representativas e viáveis da diversidade biológica e cultural da Mata Atlântica (MMA, 2017a). Segundo o Ministério do Meio Ambiente (2017), a cobertura de áreas protegidas na Mata Atlântica avançou expressivamente ao longo dos últimos anos, tendo contribuição dos governos federais, estaduais e mais recentemente dos governos municipais e iniciativa privada.

4.1.1 Floresta Nacional de São Francisco de Paula

Um dos principais instrumentos para a conservação e recuperação ambiental da Mata Atlântica consiste na Lei Federal nº 9.985/2000 que criou o Sistema Nacional de Unidades de Conservação (SNUC). O SNUC corresponde a um conjunto de unidades de conservação federais, estaduais e municipais com objetivos que se diferenciam quanto à forma de proteção e usos (MMA, 2017b).

O SNUC engloba dois grupos: áreas de proteção integral e áreas de uso sustentável. As unidades de conservação de uso sustentável incluem áreas de proteção ambiental, áreas de relevante interesse ecológico, florestas nacionais, reservas extrativistas, reservas de fauna, reservas de desenvolvimento sustentável e, reservas particulares do patrimônio natural (PIRES et al., 2012).

Neste contexto, destaca-se a Floresta Nacional (FLONA) de São Francisco de Paula que corresponde a uma unidade de conservação de uso sustentável, caracterizando-se como uma área com cobertura florestal de espécies predominantemente nativas. Parte da FLONA é abrangida pela Reserva da Biosfera da Mata Atlântica como Área Núcleo, sendo considerada uma região de alta a altíssima prioridade para a conservação do bioma a Mata Atlântica (MMA, 2002).

A FLONA de São Francisco de Paula foi criada em 1967 a partir do Decreto Federal nº 62.018/67, constituindo uma das três Florestas Nacionais presentes no estado do Rio Grande do Sul. A FLONA tem como objetivo desenvolver o uso múltiplo sustentável dos recursos florestais e a pesquisa científica, com ênfase em métodos para exploração sustentável de florestas nativas (EBLING, 2012).

Quanto as condições climáticas, a região apresenta uma pluviosidade superior a 2.000 mm, associada a uma temperatura média anual de aproximadamente 14,5°C (ICMBIO, 2019). Quanto ao uso e ocupação da FLONA São Francisco de Paula, a maior parte da área é ocupada por floresta nativa, sendo de aproximadamente 900 ha (ICMBIO, 2019), contando ainda com a presença de reflorestamentos de *Araucaria angustifolia*, *Pinus taeda*, *Pinus elliottii* e *Eucalyptus* spp. A FLONA apresenta outras espécies, com menor representatividade destinada a fins comerciais.

4.2 SENSORIAMENTO REMOTO

O sensoriamento remoto dispõe de inúmeros produtos que podem ser utilizados para a observação e monitoramento dos recursos naturais em diferentes escalas e espaço de tempo. Desse modo, cada vez mais tem surgido novas tecnologias para melhoria das informações coletadas e disponibilizadas aos usuários.

Para Meneses (2012), o termo Sensoriamento Remoto foi concebido para designar o desenvolvimento de instrumentos capazes de obter informações da superfície terrestre a distâncias remotas. São inúmeras as aplicações dos produtos disponíveis do sensoriamento remoto, destacando-se o mapeamento da cobertura florestal (QIAN et al., 2015), estimativas de propriedades biofísicas (PLANQUE et al., 2017; LUKES et al., 2016), vigor da vegetação florestal (PONZONI et al., 2012), dentre outros.

Um componente fundamental para entendermos o processo de aquisição dos dados é o conhecimento sobre a Radiação Eletromagnética (REM). Qualquer objeto na superfície terrestre que esteja a uma temperatura acima de zero absoluto, apresenta uma movimentação aleatória das partículas dos átomos e das moléculas. Assim, quando essas partículas se colidem, mudam o seu estado de energia e emitem REM (MENESES, 2012). Para o mesmo autor, no sistema planetário, o Sol é a mais potente fonte de radiação eletromagnética devido a sua alta temperatura de superfície, sendo aproximadamente de 6.000°C.

Neste contexto, o espectro eletromagnético refere-se ao conjunto de todas as radiações, desde os raios gama até as ondas de rádio, constituindo-se na ordenação das radiações em função do comprimento de onda e da frequência (MOREIRA, 2011). No sensoriamento remoto, as faixas espectrais do visível, infravermelho próximo, infravermelho médio, infravermelho termal e micro-ondas são mais utilizadas.

A região do visível (0,45 a 0,76 μm) corresponde a região do espectro solar com maior intensidade de fluxo radiante, proporcionando melhor janela atmosférica, bastante transparente, o que permite a passagem de uma grande quantidade de radiação (MOREIRA, 2011). Para a vegetação, as faixas de maior relação na região do visível correspondem a faixa do azul, verde e vermelho. A interação da REM nessa região é altamente relacionada com a concentração de pigmentos foliares.

A região do infravermelho é dividida em três porções: infravermelho próximo (0,7 – 1,1 μm), infravermelho médio (1,1 – 3,0 μm) e infravermelho distante (3,0 – 1.000 μm) (MOREIRA, 2011; JENSEN, 2009). O Infravermelho próximo, para a vegetação, é a região do espectro eletromagnético que apresenta maiores valores de reflectância devido ao espalhamento interno ocasionado pela disposição das células do mesófilo foliar (PONZONI et al., 2012). Outra região com respostas para a vegetação é a região do infravermelho médio, que segundo Jensen (2009), essa região é controlada pelo conteúdo de água nas células.

O infravermelho distante por sua vez, engloba o infravermelho termal (3,0 – 14 μm), nessa região a energia é basicamente proveniente de vibrações moleculares decorrentes da temperatura dos corpos (NOVO, 2010). Assim, Moreira (2011) define que todo corpo com temperatura superior a 0 K emite REM, dependendo especialmente de sua temperatura e da emissividade. A energia emitida pela terra tem comprimento de onda maior que a radiação solar, denominada de radiação de ondas longas.

A grande maioria dos sistemas sensores operam na região do visível e do infravermelho próximo, desse modo, não recebendo interferência da radiação emitida pela terra nos dados obtidos por meio do sensoriamento remoto (MOREIRA, 2011). Na região do infravermelho distante concentram-se faixas de absorção, o que inviabiliza seu uso para definir processos da superfície terrestre (NOVO, 2010).

Na sequência, encontram-se as radiações eletromagnéticas que se estendem pela região do espectro de 1 mm a 1 m denominadas de micro-ondas (MOREIRA,

2011). Nesse comprimento de onda os efeitos de absorção e espalhamento atmosférico são menores do que aqueles nas faixas espectrais do visível e infravermelho próximo (LORENZZETTI, 2015). Transmissão de micro-ondas de comprimentos de onda mais longos permite a obtenção de dados da superfície terrestre independente da REM emitida pelo sol, como é caso de sistemas sensores ativos como o Radar (*Radio detection and ranging*), Lidar (*Light Detection and Ranging*) e Sonar (*Sound, Navigation and Ranging*) (JENSEN, 2009).

4.2.1 Interação da energia com a atmosfera terrestre

A energia que atinge o topo da atmosfera pode chegar a 1.400 Wm^{-2} , porém, quando a radiação chega na atmosfera terrestre sofre atenuações causadas por reflexão, espalhamento ou absorção da REM (MOREIRA, 2011). Essa interferência é decorrente da interação da radiação solar com os constituintes atmosféricos, partículas dispersas e nuvens, as quais podem causar o espalhamento ou a absorção da radiação em determinados comprimentos de onda.

O espalhamento é um processo físico que se relaciona com o tamanho das partículas. Na atmosfera, as partículas que ocasionam o espalhamento de energia apresentam tamanhos variados, desse modo podem ocorrer três tipos de espalhamento: Rayleigh ou molecular, Mie e não seletivo (MOREIRA, 2011).

Quando as partículas apresentam tamanho muito menor que o comprimento de onda, o espalhamento obedece à lei de Rayleigh (NOVO, 2011). Para Moreira (2011), o espalhamento Rayleigh ou molecular é produzido, especialmente, por moléculas de gases constituintes da atmosférica. Nesse caso, o espalhamento ocorre quando o diâmetro efetivo das moléculas de ar, oxigênio e nitrogênio é muitas vezes menor (geralmente $<0,1$) que o comprimento de onda de REM incidente (JENSEN, 2009).

Assim, quanto menor o comprimento de onda, maior o espalhamento por partículas pequenas (NOVO, 2010). Esse tipo de espalhamento é responsável pela sensação visual azulada do céu durante o dia e avermelhada no pôr do sol (JENSEN, 2009).

O espalhamento Mie é decorrente de partículas com diâmetro da mesma ordem ou próximos ao tamanho do comprimento de onda da radiação (MOREIRA, 2011). Para a luz visível os principais são a poeira, fumaça e demais partículas cujo tamanho está em micrômetro. Assim, quanto maior a presença dessas partículas na atmosfera,

maior parte da luz na faixa do azul será removida, e apenas os comprimentos de onda maiores de luz laranja e vermelha chegarão aos nossos olhos, uma vez que nesse processo ocorre o espalhamento de comprimentos de onda maiores (JENSEN, 2009).

Quando o espalhamento se torna independente do comprimento de onda e do tamanho das partículas é denominado de não-seletivo, ocorrendo espalhamento em todos os comprimentos de onda não apenas a região do visível. As gotas de água e cristais de gelo que formam as nuvens e nevoeiros, espalham todos os comprimentos de onda na região do visível igualmente fazendo com que a nuvem tenha a coloração branca (JENSEN, 2009).

A REM pode ainda ser absorvida e posteriormente convertida em outras formas de energia. Jensen (2009) define que uma banda de absorção corresponde a um intervalo de comprimento de onda do espectro eletromagnético no qual a energia é absorvida por substância como a água, dióxido de carbono, oxigênio, ozônio, dentre outras.

4.2.2 Interação da radiação solar com os alvos

A radiação solar incidente na superfície terrestre interage de modo diferente com cada tipo de alvo (JENSEN, 2009). Esta diferença é determinada principalmente pelas diferentes composições físico-químicas dos objetos ou feições terrestres. Estes fatores fazem com que cada alvo terrestre tenha seu próprio comportamento espectral.

Para Koukal (2004), a REM age como um transmissor entre o objeto observado e o sensor que coleta as informações, desse modo a energia interage com o alvo situado na superfície terrestre tendo como resultado o comportamento espectral característico detectado pelo sensor. Ao analisar a relação da REM com a vegetação é fundamental o conhecimento do processo de interação, que envolve três fenômenos físicos: reflectância, transmitância e absortância espectral (PONZONI et al., 2012).

Jensen (2009) relata que uma folha sadia se caracteriza pela interceptação do fluxo radiante incidente (ϕ) proveniente do sol ou oriundo da radiação difusa espalhada sobre a folha. Assim, a quantidade de fluxo radiante refletido (ϕ_r), a quantidade de fluxo radiante absorvido (ϕ_a) e a quantidade de fluxo radiante transmitido por meio da folha (ϕ_t) podem ser medidos em função do balanço de energia (Equação 1). A normalização dessa inter-relação está demonstrada na Equação 2 (MOREIRA, 2011).

$$\phi_{i\lambda} = \phi_{\rho\lambda} + \phi_{\alpha\lambda} + \phi_{\tau\lambda} \quad (1)$$

$$1 = \rho + \alpha + \tau \quad (2)$$

Dessa forma, ρ , α e τ passam a ser denominados como reflectância, absorptância e transmitância, respectivamente, definindo a partir de seus valores as propriedades radiométricas do alvo. Segundo Moreira (2011), a energia refletida é a que apresenta relevância, já que é essa fração de energia que a maior parte dos sistemas sensores orbitais e suborbitais tem capacidade de armazenar para obter informações da superfície terrestre.

4.2.3 Imagens Landsat

A interação da REM com os alvos da superfície terrestre depende, sobretudo, das suas características e do ambiente que os cercam. Por meio do desenvolvimento tecnológico associado a análise da porção da REM refletida pelos alvos é possível medir suas propriedades espectrais, com razoável precisão e remotamente. Estas medidas são obtidas por meio de dispositivos denominados sistemas sensores. Segundo Novo (2010), os sensores correspondem a qualquer equipamento capaz de transformar alguma forma de energia em um sinal passível de ser convertido em informação sobre o ambiente (NOVO, 2010). Segundo Meneses (2012), atualmente o sensoriamento orbital é composto por uma constelação de satélites que disponibilizam imagens para atender as necessidades e demanda dos usuários.

Os satélites da série Landsat foram desenvolvidos pela *National Aeronautics and Space Administration* (NASA). O programa Landsat fornece dados para o Brasil desde 1973, permitindo o desenvolvimento de estudos relacionados ao ambiente atmosférico em diversas áreas de pesquisa, consolidando-se como um produto amplamente utilizado, demonstrando eficiência no mapeamento e monitoramento da superfície terrestre em grande escala.

Devido à resolução espacial dos sensores TM (*Thematic Mapper*), ETM+ (*Enhanced Thematic Mapper Plus*), OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*) esses sistemas têm sido amplamente usados na determinação do balanço de energia e estimativa de evapotranspiração para a gestão de recursos hídricos (RUHOFF et al., 2015).

O Landsat é o único sistema de satélite dos EUA projetado e operado para observar repetidamente a superfície terrestre global (USGS, 2019). Destacando-se ainda que os produtos gerados por esses sistemas apresentam uma escala moderada, o que permite a identificação de mudanças naturais, bem como aquelas induzidas pelo homem.

Segundo Novo (2010), a série Landsat tem como missão permitir a comparação do estado da superfície terrestre ao longo do tempo por meio da aquisição repetitiva de dados multiespectrais calibrados. Assim, os produtos da série Landsat tornaram-se fundamentais em análises da paisagem, permitindo longos registros da superfície terrestre, aliados a boa resolução espacial, sendo este, composto por oito satélites (Tabela 1).

Tabela 1 – Características dos satélites do Programa Landsat

Sistema	Operação	Sensores	Resolução espacial (m)	Revisita (dias)
Landsat 1	23/07/1972	RBV	80	18
	01/06/1978	MSS		
Landsat 2	22/01/1975	RBV	80	18
	25/02/1982	MSS		
Landsat 3	05/05/1978	RBV	30	18
	31/03/1983	MSS	80	
Landsat 4	16/07/1982	TM	30	16
	08/1993	MSS	80	
Landsat 5	01/03/1984	TM	30	16
	05/06/2011	MSS	80	
Landsat 6	10/05/1993	ETM+	15(pan)	16
	10/05/1993		30 (ms)	
Landsat 7	04/04/1999	ETM+	15(pan)	16
	a 2007		30 (ms)	
Landsat 8	11/02/2013	OLI	15(pan) 30 (ms)	16
		TIRS	100	

Fonte: Adaptação de Novo (2010).

Em que: pan corresponde a banda pancromática e ms as bandas multiespectrais.

Dentre a série, destaca-se o satélite Landsat 5 que apresentou maior tempo de operação, fornecendo dados que possibilitam a reconstrução do contexto histórico de evolução da superfície terrestre ao longo de uma longa série temporal. O sensor TM/Landsat 5 registra dados em 7 faixas espectrais com resolução espacial de 30 metros, conforme demonstrado na Tabela 2.

Tabela 2 – Características da resolução espectral, espacial e temporal do satélite Landsat 5

Banda	Faixa espectral (μm)	Resposta espectral	Resolução espacial (m)
B1	0,45 – 0,52	Azul	
B2	0,52 – 0,60	Verde	
B3	0,63 – 0,69	Vermelho	30
B4	0,76 – 0,90	IVP	
B5	1,55 – 1,75	IVM	
B6	10,40 – 12,50	Termal	120
B7	2,08 – 2,35	IVM	30

Fonte: Adaptação de USGS (2018).

Com o propósito de continuidade do programa, o Landsat 8 entrou em operação disponibilizando imagens a partir de 2013 com dois sistemas sensores a bordo, o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS). Uma das principais modificações observadas no Landsat 8 em relação aos demais de sua série, está na adição de bandas espectrais, aliado à maior capacidade de detecção de mudanças na superfície terrestre, uma vez que possui resolução radiométrica de 16 bits com um intervalo de 0 a 65.535 níveis de cinza (Tabela 3).

Uma parceria da NASA e o Serviço Geológico dos EUA, dará continuidade ao papel do programa Landsat no monitoramento, entendimento e gestão dos recursos da terra com o desenvolvimento do Landsat 9. Esse sistema está previsto para ser lançado em dezembro de 2020 (NASA, 2019). O Landsat 9 será uma reconstrução do Landsat 8, uma vez que a prioridade é o lançamento o mais breve possível para que não ocorra uma lacuna de dados dessa série.

Tabela 3 – Características da resolução espectral, espacial e temporal do satélite Landsat 8

Banda	Sensor	Faixa espectral (μm)	Resposta espectral	Resolução espacial (m)	
B1	OLI	0,43 – 0,45	Ultra-azul	30	
B2		0,45 – 0,51	Azul		
B3		0,53 – 0,59	Verde		
B4		0,64 – 0,67	Vermelho		
B5		0,85 – 0,88	IVP		
B6		1,57 – 1,65	IVM 1		
B7		2,11 – 2,29	IVM 2		
B8		0,50 – 0,68	Pan		15
B9		1,36 – 1,38	Cirrus		30
B10	TIRS	10,60 – 11,19	Termal 1	100	
B11		11,50 – 12,51	Termal 2	100	

Fonte: Adaptação de USGS (2019).

4.2.4 Albedo

O albedo é uma variável importante que rege o balanço de radiação de ondas curtas na superfície terrestre, determinando a porção de fluxo descendente refletido de volta para a atmosfera (LIANG, 2004), influenciando o clima da superfície terrestre. Berbet e Costa (2003) conceituam a reflectância como a proporção entre a radiação refletida e a incidente em um único comprimento de onda, enquanto o albedo é a integração da reflectância ao longo do espectro de radiação solar.

Nesse contexto, o uso de imagens orbitais corresponde a uma ferramenta a ser explorada em razão da sua característica espectral, que permite um aprofundamento de componentes agrometeorológicos como o albedo, índices de vegetação, temperatura de superfície, dentre outros (JENSEN, 2009). Para Planque et al. (2017), o albedo da cobertura florestal pode ser usado como uma variável para rastrear modificações na vegetação. Assim, a perda de cobertura de floresta gera um aumento do albedo de superfície, diminuindo a evapotranspiração e rugosidade da superfície,

o que leva ao aquecimento do clima (LI et al., 2008; DAVIN e NOBLET-DUCOUDRÉ, 2010).

Para Ruhoff et al. (2015), o método de estimativa de albedo apresenta melhora na acurácia de modelos de balanço de energia por meio do uso de coeficientes de peso baseados na irradiância solar média no topo da atmosfera. Diferentes algoritmos utilizaram variáveis que compõem o balanço de energia e evapotranspiração. O *Surface Energy Balance Algoritmo for Land* (SEBAL) desenvolvido por Bastiaanssen (1995) tem sido amplamente utilizado, apresentando bom ajuste em suas estimativas quando comparadas a observações de campo (LIBERATO, 2011). O modelo SEBAL tem aplicações em estudos sobre o equilíbrio de radiação (LOPES et al., 2013), alterações do uso e cobertura da terra (OLIVEIRA et al., 2014), alterações do balanço de energia (ALLEN et al., 2007; SILVA et al., 2016), dentre outros.

O albedo de superfície consiste na relação entre o albedo planetário, a radiação solar refletida pela atmosférica (α_p) e a transmissividade atmosférica (τ_{oc}^2) (Equação 3). O albedo atmosférico (α_{atm}) pode ser obtido por meio de um modelo de transferência radiativa, situando entre 0,025 e 0,04. A transmissividade para condições de céu claro é descrita por Allen et al. (2002) conforme demonstrado na Equação 4.

$$\alpha = \frac{\alpha_{toa} - \alpha_{atm}}{\tau_{oc}^2} \quad (3)$$

Em que α é o albedo de superfície; α_{toa} é o albedo no topo da atmosfera (planetário); α_{atm} corresponde ao albedo atmosférico; τ_{oc}^2 é a transmitância atmosférica.

$$\tau_{oc} = 0,35 + 0,627 \exp \left[-\frac{0,00146P_o}{K_t \cos Z} - 0,075 \left(\frac{W}{\cos Z} \right)^{0,4} \right] \quad (4)$$

Em que P_o é a pressão atmosférica local (kPa); K_t é o coeficiente de turbidez do ar (1,0 é para o ar limpo e 0,5 é para ar extremamente turvo ou poluído); Z é o ângulo zenital; W é precipitação da água (mm): $W = 0,14 e_a P_o + 2,1$; e_a corresponde a pressão parcial do vapor de água atmosférico (kPa).

O sensoriamento remoto dispõe de inúmeros produtos orbitais que podem ser utilizados para a estimativa do albedo. Em estudos relacionados a paisagem, destacam-se os sensores TM e OLI dos satélites Landsat 5 e 8, respectivamente. Os

quais passam pelo processo de calibração radiométrica, uma vez que se trabalha com valores de reflectância.

4.2.5 Classificação digital de imagens

Um dos principais objetivos do sensoriamento remoto é a extração das informações contidas nas imagens e a sua codificação em documentos que possam ser lidos nas formas de tabelas, gráficos ou mapas (MENESES e SANO, 2012). Os dados oriundos de sistemas sensores imageadores possibilitam a análise da resposta espectral dos alvos situados na superfície terrestre, agrupando-os em classes temáticas.

A classificação de imagens visa o reconhecimento automático de objetos em função de critérios de decisão (FLORENZANO, 2011). Para Moreira (2011) a classificação consiste em rotular cada pixel da imagem segundo sua ocupação da terra, similar ao que a análise visual realiza, utilizando algoritmos de classificação. Esse processo pode ser dividido em classificação supervisionada (classes definidas *a priori* pelo analista) e não supervisionada (classes são definidas *a posteriori*), havendo a possibilidade de dividir os classificadores em classificação por pixel ou por regiões (MENESES e SANO, 2012).

Para Moreira (2011), na abordagem supervisionada, realiza-se a etapa de treinamento, o qual consiste na amostragem contendo as assinaturas espectrais de cada uma das classes de ocupação da terra no perímetro imageado. Entretanto, a classificação por regiões, a decisão leva em consideração um agrupamento de pixels que corresponde a uma unidade de classificação (MENESES e SANO, 2012). Nesse tipo de classificação, o usuário identifica regiões pertencentes às classes de interesse e atribui ao algoritmo utilizado, a tarefa de localizar das demais regiões pertencentes aquela classe, a partir de uma estatística pré-estabelecida (FLORENZANO, 2011).

Na classificação por regiões, a análise da imagem compreende inicialmente a etapa de segmentação, que consiste num processo de agrupamento de pixels que possuem características semelhantes (BRITES et al., 2012) em que algumas dessas regiões são utilizadas como treinamento do classificador. No início do processo, a região pode ser representada por um pixel ou um conjunto de pixels, de modo que a agregação das regiões é realizada a partir dos critérios de similaridade e área (MOREIRA, 2011), ambos fornecidos pelo usuário. O autor destaca ainda, que a

similaridade corresponde ao valor mínimo abaixo do qual as classes serão consideradas similares e, portanto, agrupadas em uma única classe. Já o limiar de área define o número mínimo de pixels necessários para que uma área seja individualizada (BRITES et al., 2012).

A classificação por fim, identifica os polígonos com mesma resposta espectral em uma classe, atribuindo uma cor específica. Um dos algoritmos classificadores de destaque nesse processo de classificação é o *Maxver* (Máxima Verossimilhança). Esse classificador utiliza amostras de treinamento para estimar a probabilidade das classes incluídas no treinamento (MOREIRA, 2011). O classificador *Maxver* considera a distância euclidiana das matrizes da covariância entre duas amostras para avaliar o quão separado estatisticamente são um par de classes (BRITES et al., 2012).

Por outro lado, com o advento tecnológico no campo da informática, surgiram outras técnicas para a classificação de imagens. Os algoritmos de aprendizado de máquina, disponíveis dentro da área de inteligência artificial apresentam eficácia na solução de problemas que demandam processos de classificação, seja ela supervisionada ou não supervisionada (LARY et al., 2016).

4.3 INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA

A Inteligência Artificial (IA) é uma área de estudo preocupada com a construção e representação de entidades inteligentes, em que o termo IA foi usado pela primeira vez em 1956 (MONTAÑO, 2016). No entanto, somente a partir da década de 70 técnicas de IA passaram a ser utilizadas para solução de problemas reais, sendo anteriormente utilizadas essencialmente de forma teórica (FACELI et al., 2011).

A difusão da tecnologia computacional em empresas e aplicações abriram um leque de possibilidades de estudo no ramo da engenharia do conhecimento e cognição, que mais tarde evoluiu para o aprendizado de máquina, que é a área da IA responsável pelo desenvolvimento de teorias computacionais com foco no aprendizado automatizado (MONTAÑO, 2016).

Nesse contexto, o aprendizado de máquina tem por objetivo desenvolver algoritmos e técnicas computacionais capazes de adquirir conhecimento de forma automática a partir de um exemplo histórico, aperfeiçoando assim seu desempenho (GOLDSCHIMIDT, 2010). Os algoritmos de aprendizado de máquina apresentam eficácia tanto em trabalhos que necessitam do desenvolvimento de regressão, bem

como os que demandam da classificação, seja ela supervisionada ou não supervisionada (LARY et al., 2016).

Dado um problema de classificação, a tarefa de um aprendizado de máquina é induzir um classificador que seja capaz de separar cada um dos padrões de acordo com a classe a que estes pertencem (RUFINO, 2011). Existem vários algoritmos de aprendizado de máquina e cada um se utiliza de uma forma de representação dos dados e de busca, destacando-se os algoritmos *Naive Bayes*, *Decision Tree*, *K-Nearest Neighbor*, *Random Forest*, *Support Vector Machine* e *Artificial Neural Networks*. Estes algoritmos têm demonstrado excelente desempenho na análise de bases de dados de sensoriamento remoto que apresentam grande complexidade (LI et al., 2014).

O algoritmo *Naive Bayes* (NB) é um classificador probabilístico simples e eficaz, com premissas de independência (DUDA et al., 2000; ZANG et al., 2013). Uma vantagem do classificador NB é que ele requer apenas uma pequena quantidade de dados de treinamento para estimar os parâmetros de um modelo de classificação (KIM et al., 2008).

O algoritmo *Árvore de Decisão* (*Decision Tree* - DT) consiste numa árvore de classificação que possui uma estrutura hierárquica que inicia no *nó raiz*, passa pelos *nós internos* e termina em *nós respostas* (folha), em que a ligação entre os nós é realizada pelos ramos (FRIZZARINI, 2013). Para facilitar o entendimento do funcionamento desse algoritmo, a Figura 1 demonstra a estrutura de uma árvore de decisão.

Por outro lado, a *Floresta Aleatória* (*Random Forest* - RF) é uma técnica de aprendizado de máquina que agrupa várias árvores de modelos treinadas a partir de um conjunto de dados para predição, de forma que o resultado final é obtido por meio da consolidação dos resultados das árvores (MONTAÑO, 2016). Os modelos de árvore são denominados árvores de decisão para os casos de classificação e árvores de regressão para problemas de regressão (FACELI et al., 2011).

Figura 1 – Fluxograma da estrutura de uma árvore de classificação.



Fonte: Monard e Prati (2005).

O algoritmo k-Vizinho Mais Próximo (*k-Nearest Neighbor* - kNN) é uma extensão do algoritmo 1 Vizinho Mais Próximo (1-NN), em que quando o valor de k é maior que 1, para cada ponto de teste, são obtidos k vizinhos, e desse modo, cada vizinho vota em uma classe (FACELI et al., 2011).

Máquinas de vetores de suporte (*Support Vector Machine* - SVM) é um método de aprendizagem de máquina que pode ser usado para a solução de problemas de classificação e regressão, bem como para outras tarefas de aprendizagem. Com o algoritmo SVM, um hiperplano é primeiro construído com base no intervalo máximo dos conjuntos de amostras de treinamento fornecidos e, em seguida, classifica os objetos em uma das classes de cobertura da terra identificada (QIAN et al., 2015). Esse algoritmo é baseado na teoria do aprendizado estatístico (FACELI et al., 2011). Um dos principais elementos usados pelo método SVM é uma função de *kernel*, as quais podem ser Linear, Radial, Polinomial e Sigmoidal.

O *kernel* possui dois parâmetros importantes de ajuste o "*cost*" (C) e *gamma*, os quais podem afetar a precisão geral da classificação (QIAN et al., 2015). Os autores descrevem ainda que um valor C grande pode criar um modelo com excesso de ajuste, enquanto o ajuste de *gamma* influenciará na forma do hiperplano de separação. O valor

ótimo dos parâmetros C e γ é frequentemente estimado com o método exaustivo de busca (LIN e LIU, 2007), que utiliza uma grande variedade de valores para identificar o valor ótimo.

Por fim, o algoritmo de aprendizado de máquina denominado Redes Neurais Artificiais (*Artificial Neural Networks* - ANN) foi desenvolvido a partir da intenção de reproduzir o funcionamento do sistema nervoso, tendo o objetivo de simular a capacidade de aprendizado do cérebro humano na aquisição de conhecimento (FACELI, 2011). O mesmo autor descreve que as unidades de processamento são chamadas de neurônios artificiais, os quais são dispostos em uma ou mais camadas interligadas por diversas conexões, sendo que estas possuem valores associados que ponderam a entrada recebida por cada neurônio. Li et al. (2003) observaram que os algoritmos ANN e kNN foram mais eficientes que os métodos estatísticos tradicionais para classificar dados florestais. Desse modo, o algoritmo ANN é robusto além de apresentar uma aprendizagem eficiente (ZHENG et al., 2013).

Uma das formas de avaliação do ajuste dos algoritmos de aprendizado de máquina é a aplicação da validação cruzada (*cross-validation*) (DUDA et al., 2000). Nesse sistema os dados são separados em k grupos (*k-fold cross-validation*), para os quais um destes grupos é deixado para teste e os demais são utilizados na etapa de treinamento (MONTAÑO, 2016).

Esse autor descreve ainda, que a cada passo no processo de validação cruzada, um grupo é tomado para teste e os $k - 1$ restantes são usados para treinamento, sendo que esse processo se repete k vezes, até que todos os grupos tenham sido usados uma vez para teste. Em cada iteração, um modelo é treinado com os grupos de treinamento e testado com o grupo de teste. Ao final, calcula-se a média das correlações, que são usadas aqui como medida de qualidade. A grande vantagem destes métodos é que todos os dados são usados tanto para treinamento como para teste, o que o torna indicado para os casos em que a base de dados é menor (MONTAÑO, 2016).

4.3.1 Métricas de avaliação da classificação

No processo de classificação por meio de algoritmos de aprendizado de máquina, as métricas de avaliação são essenciais para fornecer maiores informações

quanto o ajuste do classificador. Dentre as métricas existentes, destacam-se a sensibilidade, especificidade, eficiência, valor predito positivo e valor predito negativo.

A sensibilidade ou taxa positiva de um classificador representa as amostras classificadas corretamente positivas para o número total de amostras positivas (THARWAT, 2018). Em outras palavras, a sensibilidade indica a capacidade do sistema em prever corretamente a condição de verdadeiro positivo, ou seja, determinar corretamente as classes onde elas ocorrem. Por outro lado, a especificidade ou taxa negativa indica a proporção de verdadeiros negativos, descrevendo a capacidade do algoritmo em prever corretamente a ausência para casos que realmente não a têm.

Na prática, a sensibilidade e especificidade seguem direções opostas, o que leva a busca de um modelo de decisão que represente o equilíbrio entre esses parâmetros. Desse modo, a eficiência corresponde à média aritmética desses parâmetros.

Por fim, os parâmetros referentes a valor predito positivo e valor predito negativo destinam-se a avaliar a proporção de verdadeiros positivos/negativos no total de predição positiva/negativa. Assim, analisam as predições realizadas pelo classificador, determinando se elas realmente correspondem a um valor verdadeiro, seja positivo (valor predito positivo) ou negativo (valor preditivo negativo).

4.4 ANÁLISE DE TENDÊNCIA

A observação regular de um fenômeno proporciona a reconstrução do contexto histórico da evolução das mudanças na cobertura da terra em escala de paisagem devido a disponibilidade de dados multitemporais (ZHAI et al., 2014). Assim, a análise de tendência permite identificar fatores que estejam influenciando no fenômeno de interesse.

Uma abordagem frequentemente utilizada na modelagem de fenômenos ambientais é a regressão linear. Entretanto, por ser um método paramétrico, pode apresentar dificuldades na caracterização de tendências, referentes à capacidade de se determinar o quanto o coeficiente de declividade da reta ajustada difere significativamente de zero (WAGNER et al., 2013). O teste não paramétrico Mann-Kendall é indicado pela *World Meteorological Organization* (WMO) para identificar se

determinada série de dados possui uma tendência temporal de alteração estatisticamente significativa (SALVIANO et al., 2016).

4.4.1 Mann-Kendall (MK)

O teste Mann-Kendall é frequentemente utilizado para análise de tendências em séries de variáveis ambientais como precipitação (MENEZES e FERNANDES, 2016; DURÃES et al., 2016; BARRY et al., 2017), temperatura (SALVIANO et al., 2016; WANDERLEY et al., 2016), evapotranspiração (ALENCAR et al., 2011), cobertura vegetal (NEETI e EASTMAN, 2011), dentre outros.

De forma simplificada, o teste baseia-se em rejeitar ou não a hipótese nula (H_0), assumindo que não existe tendência na série de dados a partir do nível de significância adotado, que corresponde a probabilidade de cometer-se o erro de rejeitar H_0 quando esta for verdadeira (SALVIANO et al., 2016). A variável S aplicada para uma série de n dados do teste de Mann Kendall é obtida a partir da soma dos sinais da diferença, realizada para cada um dos pares, de todos os valores da série (x_i) em relação aos valores que a eles são futuros (x_j). A Equação 5 demonstra o cálculo para obter o coeficiente de correlação Mann Kendall.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{ sinal } (x_j - x_i) \quad (5)$$

Em que o sinal ($x_j - x_i$) é obtido por meio da Equação 6, S é a estatística do teste Mann Kendall, n é o número de elementos da série temporal, o sinal é a diferença dos valores de albedo subsequentes, x_j são os dados estimados da sequência de valores e o sinal ($x_i - x_j$) é igual a: -1 para ($x_i - x_j$) < 0; 0 para ($x_i - x_j$) = 0, e 1 para ($x_i - x_j$) > 0.

A estatística do teste Mann-Kendall considera a hipótese nula (H_0) quando os dados vêm de uma população na qual as variáveis aleatórias são independentes e identicamente distribuídas. Por outro lado, a hipótese alternativa (H_1) representa a existência de tendência monotônica (VILANOVA, 2014).

Por sua vez, o Z é a estatística de teste para amostrar com $n > 10$, a qual se aproxima da distribuição normal (Equação 6) (VILANOVA, 2014). Testando a

significância estatística de S para hipótese alternativa (H_1), usando um teste bilateral a H_1 , esta pode ser rejeitada para grandes valores da estatística Z .

$$Z = \begin{cases} \frac{(S-1)}{\sqrt{\text{Var}(S)}} & \text{se } S > 0 \\ 0 & \text{se } S = 0 \\ \frac{(S+1)}{\sqrt{\text{Var}(S)}} & \text{se } S < 0 \end{cases} \quad (6)$$

Com base na análise de estatística Z , é realizada a decisão de aceitar ou rejeitar H_0 . Ao confirmar a existência de tendência nos dados, rejeita-se a hipótese nula (WANDERLEY et al., 2016). A estatística Z segue a distribuição normal padrão com média zero e variância 1.

Um valor Z positivo indica uma tendência crescente, enquanto um valor negativo indica uma tendência decrescente. A probabilidade (p -valor) representa a medida observada para rejeitar a hipótese nula (ALENCAR et al., 2014). O p -valor pode ser estimado pela probabilidade acumulada da distribuição normal, desse modo se $p \leq \alpha$, o teste apresenta evidências rejeitando H_0 , identificando a presença de tendências na série (MOREIRA e NAGHETTINI, 2016).

4.4.2 Teste de inclinação Sen

O teste Mann-Kendall apesar da sua potencialidade em análises de tendências, não fornece a magnitude da tendência detectada (MOREIRA e NAGHETTINI, 2016). Assim, o estimador de declive proposto por Sen (1968) pode complementar o teste de Mann-Kendall. A tendência não-paramétrica de Sen é um método para estimar a inclinação de uma tendência linear.

A inclinação de Sen é descrito como sendo o estimador de estatística Q (Equação 7). Na estimativa do declive (Q) as variáveis X_i e X_j são valores da variável em estudo nos anos i e j .

$$Q_i = \frac{X_j - X_i}{j - i} \quad \text{para } i = 1, \dots, N \quad (7)$$

Os valores positivos indicam tendência crescente, enquanto que valores negativos descrevem uma tendência negativa. Se há n valores na série analisada, então o número de pares estimados de Q é dado por $N = n(n - 1)/2$, em que n é o número de período de tempo. O estimador de declive de Sen é a mediana dos N valores de Q_i . Para calcular o intervalo de confiança da estimativa da inclinação de Sen, o teste requer pelo menos 10 valores em uma série de tempo.

4.5 AMBIENTE R

A linguagem R é um ambiente livre utilizado para ações de computação estatística e gráficos, disponível para uma grande variedade de plataformas UNIX, Windows e MacOS (R PROJECT, 2017). O mesmo corresponde a um programa livre, desse modo seu código pode ser modificado e redistribuído livremente baseando-se nos termos da Licença Pública Geral (*General Public Licence - GNU*) que define as condições legais de distribuição de programa livre com disponibilidade do código-fonte (CASAJUS, 2013). O termo “ambiente” propõe tratá-lo como um sistema totalmente planejado e coerente, ao contrário de softwares de análise de dados, nos quais as ferramentas são muito específicas e inflexíveis (R PROJECT, 2017).

O ambiente R permite o compartilhamento de código, assim como o desenvolvimento colaborativo, adaptando o pacote segundo as demandas do usuário (FRÍAS et al., 2018). Esse ambiente possui uma plataforma principal que pode ser complementada por extensões desenvolvidas pelos usuários. A linguagem R é implementada no sistema base, já a manipulação de dados, cálculos e gráficos estatísticos são disponibilizados sob a forma de pacotes (BIVAND et al., 2008). O *Comprehensive R Archive Network* (CRAN) dispõe do sistema base, assim como os pacotes implementados.

A funcionalidade básica de computação estatística e gráficos do R foi implementada devido aos pacotes desenvolvidos por terceiros (LI e YAN, 2018). O mesmo autor enfatiza que os pacotes facilitam as atividades dos usuários, o que tornou esse ambiente aplicável dentro de muitos domínios de conhecimentos.

A linguagem de programação R tem sido utilizada para solucionar problemas nas mais diversas áreas da pesquisa. Destaca-se a grande variedade de estatística disponível nesse ambiente para análises de dados espaciais, permitindo estudos da fragmentação florestal, modelagem linear e não-linear e análises de séries temporais.

Entretanto, Li e Yan (2018) observaram no estudo de caso que a linguagem R é aplicada, em sua maioria, em estudos de domínio da biologia e das ciências da vida.

Atualmente existem inúmeros pacotes disponíveis no CRAN, sendo esses desenvolvidos pelos usuários destinados a análises estatísticas e de gráficos. Entretanto, inúmeras operações estatísticas, especialmente quando utilizado imagens orbitais, necessitam ainda de implementação em linguagem R.

REFERÊNCIAS BIBLIOGRÁFICAS

ALENCAR, L. P. et al. Tendências recentes nos elementos do clima e suas implicações na evapotranspiração da cultura do milho em Viçosa – MG. **Engenharia Agrícola**, Jaboticabal, v. 31, n. 4, p. 631-642, 2011. DOI: <https://doi.org/10.1590/S0100-69162011000400002>.

ALENCAR, L. P. et al. Variação temporal dos elementos climáticos e da ETo em Catalão, Goiás, no período de 1961-2011. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 8, p. 826-832, 2014. DOI: <http://dx.doi.org/10.1590/1807-1929/agriambi.v18n08p826-832>.

ALLEN, R. et al. **Surface energy balance algorithms for land (SEBAL), Idaho implementation**. Advanced training and users manual, version 1.0, 2002, 97 p.

ARAUJO, M. M. et al. Análise de agrupamento em remanescente de Floresta Ombrófila Mista. **Ciência Florestal**, v. 20, n. 1, p.1-18, 2010. Disponível: < <https://periodicos.ufsm.br/cienciaflorestal/article/view/1755/1024>>. Acesso em: 17 jan. 2018.

BASTIAANSEN, W. G. M.; MENENTI, M.; FEDDES, R. A.; HOLSLAG, A. A. M. A. Remote sensing surface energy balance algorithm for land (SEBAL) - Formulation. **Journal of Hydrology**, v.212-213, p.198-212, 1998. Disponível em: [http://dx.doi.org/10.1016/S0022-1694\(98\)00253-4](http://dx.doi.org/10.1016/S0022-1694(98)00253-4).

BACKES, A. Determinação da idade e regeneração natural de uma população de *Araucaria angustifolia* (Bertol.) Kuntze em um povoamento florestal localizado no município de Caxias do Sul, RS, Brasil. **Série Botânica**, v. 56, p.115-130, 2001.

BARRY, N. Y.; TRAORE, V. B.; NDIAYE, M. L.; ISIMEMEN, O.; CELESTRIN, H.; SAMBOU, B. Avaliação de tendências climáticas e cobertura de terra / dinâmica de uso dentro da bacia do rio Somone, Senegal. **American Journal of Climate Change**, v. 6, n. 3, 2017. Disponível em: <http://www.scirp.org/Journal/PaperInformation.aspx?PaperID=78771>>. Acesso em: 1 nov. 2017.

BERBET, M. L. C.; COSTA, M. H. Climate change after tropical deforestation: seasonal variability of surface albedo and its effects on precipitation change. **Journal of Climate**, v.16, p.2099-2104, 2003.

BIVAND, R. S.; PEBESMA, E. J.; GÓMEZ-RUBIO, V. **Applied Spatial Data Analysis with R**. Springer: New York, 2008, 374 p.

BRITES, R. S.; BIAS, E. S.; SANTA ROSA, A. N. C. **Classificação por regiões**. In: MENESES, P. R.; ALMEIDA, T. Introdução ao Processamento de imagens de Sensoriamento Remoto. Brasília, 2012.

CASAJUS, N. **Analyses spatiales sous R**. Université du Québec à Rimouski, Département de Biologie, Chimie et Géographie. 2013. Disponível em: <http://qcbs.ca/wiki/_media/gisonr.pdf>. Acesso em: 08 dez. 2017.

CUNHA, A. P. M. A.; ALVALÁ, R. C. S.; OLIVEIRA, G. S. Impactos das mudanças de cobertura vegetal nos processos de superfície na região semiárida do Brasil. **Revista Brasileira de Meteorologia**, v. 28, n. 2, p. 139-152, 2013.

DAVIN, E. L.; NOBLET-DUCOUDRÉ, N. Climatic impact of global-scale deforestation: radiative versus nonradiative processes. **Journal of Climate**, 23, 97–112, 2010. DOI: <https://doi.org/10.1175/2009JCLI3102.1>.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. New York: Wiley, 2001.

DURÃES, M. F.; MELLO, C. R. de; BESKOW, S. Trends in the hydrometeorological regime on an island in the South Atlantic Ocean. **Revista Brasileira de Climatologia**, v. 18, p. 242-255, 2016.

EBLING, A. A. **Dinâmica e projeção diamétrica em remanescente de floresta ombrófila mista na Flona de São Francisco de Paula, RS**. 2012. 126 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Estadual do Centro-Oeste, Irati, PR, 2012.

FACELI, K. et al. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2011.

FLORENZANO, T. G. Iniciação em sensoriamento remoto. 3 ed. São Paulo: Oficina de textos, 2011. 128 p.

FRÍAS, M. D. et al. An R package to visualize and communicate uncertainty in seasonal climate prediction. **Environmental Modelling & Software**, v. 99, p. 101-110, 2018. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1364815217305157>>. Acesso em: 13 jan. 2018. DOI: <https://doi.org/10.1016/j.envsoft.2017.09.008>.

FRIZZARINI, C. Algoritmo para indução de árvores de classificação para dados desbalanceados. 2013. 96 p. Dissertação (Mestrado em Sistemas de informações) – Universidade de São Paulo, São Paulo, SP, 2013.

FUNDAÇÃO SOS MATA ATLÂNTICA. **Relatório Anual**. 2015. Disponível em: <https://www.sosma.org.br/projeto/atlas-da-mata-atlantica/dados-maisrecentes/>. Acesso em: 19 jun 2017.

GIAM, X.; BRADSHAW, C. J. A.; TAN, H. T. W.; SODHI, N. S. Future habitat loss and the conservation of plant biodiversity. **Biological Conservation**, v.143, p. 1594–1602, 2010.

GOLDSCHIMIDT, R. R. **Inteligência Computacional**. 1ª ed. Rio de Janeiro: Instituto Superior de Tecnologia - Rio, 2010. 143 p.

HE, T. et al. Evaluating land surface albedo estimation from Landsat MSS, TM, ETM+, and OLI data based on the unified direct estimation approach. **Remote Sensing of Environment**, v. 204, p. 181-196, jan. 2018. Disponível: <<http://www.sciencedirect.com/science/article/pii/S0034425717304947>>. Acesso em: 17 jan. 2018. DOI: <https://doi.org/10.1016/j.rse.2017.10.031>.

HOVI, A.; LUKES, P.; RAUTIAINEN, M. Seasonality of albedo and FAPAR in a boreal forest. **Agricultural and Forest Meteorology**, v. 247, p. 331-342, 2017. Disponível em:<<https://www.sciencedirect.com/science/article/pii/S0168192317302770>>. Acesso em: 13 jan. 2018.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE - ICMBIO. **Floresta Nacional de São Francisco de Paula/RS**. 2019. Disponível em:<<http://www.florestanacional.com.br/flonasaochico.html>>. Acesso em: 3 de ago. 2019.

JARVIS, P. G.; MASSHERDER, J. M.; HALE, S. E.; MONCRIEFF, J. B.; RAYMENT, M.; SCOTT, S. L. Seasonal variation of carbon dioxide, water vapor, and energy exchanges of a boreal black spruce forest. **Journal of Geophysical Research**, v.102, n. D24, p. 28953-28966, 1997.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de José Carlos Neves Epiphânio (coordenador)...[et al.]. São José dos Campos, SP: Parêntese, 2009. 598 p.

LARY, D.J. et al. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016.

LI, K.; YAN, E. Co-mention network of R packages: Scientific impact and clustering structure. **Journal of Informetrics**, v. 12, n. 1, p. 87-100, 2018. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1751157717304108>>. Acesso em: 13 Jan 2018. DOI: <https://doi.org/10.1016/j.joi.2017.12.001>.

LI, C. et al. Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. **Remote Sensing**, v. 6, n. 2, p. 964 – 83, 2014. DOI:<https://doi.org/10.3390/rs6020964>.

LI, Z.; BHATT, U.S.; MÖLDERS, N. Impact of doubled CO₂ on the interaction between the global and regional water cycles in four study regions. **Climate Dynamics**, v. 30, p. 255–275, 2008.

LIANG, S. **Quantitative Remote Sensing of Land Surfaces**, John Wiley, Hoboken, 2004.

LIBERATO, A. M. Albedo de superfície a partir de imagens landsat 5 – TM em áreas de floresta e pastagem na Amazônia. **Revista de Geografia**, v. 28, n. 1, 2011.

LIN, S. L.; LIU, Z. Parameter selection in SVM with RBF kernel function. **J. Zhejiang Univ. Technol**, v. 35, n. 163, 2007.

LOPES, P. M. O. et al. Simulação do saldo de radiação na Serra da Mantiqueira. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.17, p.780-789, 2013. DOI: <http://dx.doi.org/10.1590/S1415-43662013000700013>.

LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. São Paulo: Blucher, 2015. 293 p.

LUKES, P. et al. Multidecadal analysis of forest growth and albedo in boreal Finland. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 296-305, 2016. DOI: <http://dx.doi.org/10.1016/j.jag.2016.07.001>

LUKES, P.; STENBERG, P.; RAUTIAINEN M. Relationship between forest density and albedo in the boreal zone. **Ecological Modelling**, v. 261-262, p. 74 – 79, 2013. DOI: 10.1016/j.ecolmodel.2013.04.009.

KENDALL, M. G. **Rank Correlation Methods**. London: Charles Griffin, 1975.

KIM, H. et al. **Internet traffic classification demystified: Myths, caveats, and the best practices**. Proc. ACM CoNEXT Conf., New York, 2008, pp. 1–12.

KOUKAL, T. **Nonparametric Assessment of Forest Attributes by Combination of Field Data of the Austrian Forest Inventory and Remote Sensing Data**. 2004. 115 f. Master Thesis – Universität für Bodenkultur Wien, Wien, Disponível em: <http://www.boku.ac.at/fileadmin/data/H03000/H85000/H85700/diss/Koukal_Dissertation.pdf>. Acesso em: 15 jan. 2016.

KUUSINEN, N; TOMPPO, E.; BERNINGER, F. Linear unmixing of MODIS albedo composites to infer subpixel land cover type albedos. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 324-333, 2013. DOI: DOI: 10.1016/j.jag.2012.10.005.

MENESES, P. R. **Princípios do Sensoriamento Remoto**. In: MENESES, P. R.; ALMEIDA, T. Introdução ao Processamento de imagens de Sensoriamento Remoto. Brasília, 2012.

MENESES, P. R.; SANO, E. E. **Classificação pixel a pixel de imagens**. In: MENESES, P. R.; ALMEIDA, T. Introdução ao Processamento de imagens de Sensoriamento Remoto. Brasília, 2012.

MENEZES, F. P.; FERNANDES, L. L. Análise de tendência e variabilidade da precipitação no estado do Pará. **Enciclopédia Biosfera**, v. 13, n. 24, p. 1580, 2016.

Disponível em: <
<http://www.conhecer.org.br/enciclop/2016b/sociais/analise%20de%20tendencia.pdf>>.
 Acesso em: 12 set. 2019.

MINISTÉRIO DO MEIO AMBIENTE – MMA. **Mata Atlântica**. 2017a. Disponível em: <
<http://www.mma.gov.br/biomas/mata-atlantica>>. Acesso em: 3 nov. 2017.

MINISTÉRIO DO MEIO AMBIENTE – MMA. **Sistema Nacional de Unidades Conservação - SNUC**. 2017b. Disponível em: < <http://www.mma.gov.br/areas-protegidas/sistema-nacional-de-ucs-snuc>>. Acesso em: 4 nov. 2017.

MINISTÉRIO DO MEIO AMBIENTE – MMA. **Avaliação e identificação de áreas e ações prioritárias para a conservação, utilização sustentável e repartição dos benefícios da biodiversidade nos biomas brasileiros**. Brasília: MMA/SBF, 2002. 404 p.

MONARD, M. C.; PRATI, R. C. **Aprendizado de máquina simbólico para mineração de dados**. In: WRCÓPIAS. XIII Escola Regional de Informática (ERI, 2005). WRCópias, 2005. p. 1-26. Disponível em: <
<http://sites.labic.icmc.usp.br/pub/mcmonard/eri05book.pdf>>. Acesso em 29 set. 2019.

MONTAÑO, R. A. N. R. et al. Artificial Intelligence Models to Estimate Biomass of Tropical Forest Trees. **Polibits**, v. 56, p. 29-37, 2017.

MOREIRA, A. M. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**. 4. ed. Viçosa: Editora UFV, 2011. 422p.

MOREIRA, J. G. V.; NAGHETTINI, M. Detecção de Tendências Monotônicas Temporais e Relação com Erros dos Tipos I e II: Estudo de Caso em Séries de Precipitações Diárias Máximas Anuais do Estado do Acre. **Revista Brasileira de Meteorologia**, v. 31, n. 4, p. 394-402, 2016.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION - NASA. **Landsat 9: Continuing the legacy – 2020 and beyond**. 2019. Disponível em: <
<https://landsat.gsfc.nasa.gov/landsat-9/>>. Acesso em: 19 ago. 2019.

NEETI, N; EASTMAN, J.R. A Contextual Mann-Kendall Approach for the Assessment of Trend Significance in Image Time Series. **Transactions in GIS**, v. 15, n. 5, p.599-611, 2011.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Edgard Blücher Ltda, 2010. 388 p.

OLIVEIRA, L. M. M. et al. Evapotranspiração real em bacia hidrográfica do Nordeste brasileiro por meio do SEBAL e produtos MODIS. **Revista brasileira de Engenharia Agrícola Ambiente**, v.18, n.10, p. 1039 – 1046, 2014.

PLANQUE, C.; CARRER, D.; ROUJEAN, J. L. Analysis of MODIS albedo changes over steady woody covers in France during the period of 2001–2013. **Remote Sensing of Environment**, v. 191, n. 2017, 13–29 p., 2017.

PIRES, P. T. L.; ZENI JUNIOR, D. M.; GAULKE, D. As unidades de conservação e a Floresta Ombrófila Mista no estado do Paraná. **Ciência Florestal**, v.22, n.3, p.589-603, 2012.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto aplicado ao estudo da vegetação**. 2. ed. São José Dos Campos: Saraiva, 2012. 160 p.

QIAN, Y. et al. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, v. 7, n. 1, p. 153 - 168, 2015. doi.org/10.3390/rs70100153

RUFINO, H. L. P. **Algoritmo de Aprendizado Supervisionado – Baseado em Máquinas de Vetores de Suporte – Uma contribuição para o reconhecimento de dados desbalanceados**. 2011. 107 f. Tese (Curso de Engenharia Elétrica)-Universidade Federal de Uberlândia, Uberlândia, MG, 2011.

RUHOFF, A. L.; NOVO, B. B. S.; ROCHA, H. R. Determinação da irradiância solar no topo da atmosfera para cálculo do albedo e balanço de energia a partir de imagens LANDSAT 8 OLI. **Anais...Simpósio de Sensoriamento Remoto, SBSR**, 17, 2015. João Pessoa, PB, 2015.

SALVIANO, M. F.; GROppo, J. D.; PELLEGRINO, G. Q. análise de tendências em dados de precipitação e temperatura no Brasil. **Revista Brasileira de Meteorologia**, v. 31, n. 1, p. 64-73, 2016.

SANTOS, P. Z. F. S. **Estudo da fragmentação florestal na Mata Atlântica com base em princípios da ecologia da paisagem: subsídio à elaboração do plano municipal de conservação e recuperação da mata atlântica em Niterói – RJ**. 2014. 55 f. Monografia (Curso de Engenharia Florestal)–Universidade Federal Rural do Rio Janeiro, Seropédica, RJ, 2014.

SEN, P. K. Estimates of the regression coefficient based on Kendall's Tau. **Journal of the American Statistical Association**, v. 63, p. 1379-1389, 1968.

SILVA, B. B. et al. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n.1, p. 3-8, 2016.

SONEGO, R. C.; BACKES, A.; SOUZA, A. F. Descrição da estrutura de uma Floresta Ombrófila Mista, RS, Brasil, utilizando estimadores não-paramétricos de riqueza e rarefação de amostras. **Acta Botanica Brasilica**, v. 24, n.4, p. 943-955, 2007.

SOUZA FILHO, J. D. C.; RIBEIRO, A.; COSTA, M. H. Variação sazonal do balanço de radiação em uma floresta tropical no nordeste da Amazônia. **Revista Brasileira de Meteorologia**, v. 21, n. 3b, p. 318-330, 2006.

R PROJECT. **R Project**. 2017. Disponível em: <<https://www.r-project.org/contributors.html>>. Acesso em: 08 dez. 2017.

UNITED STATES GEOLOGICAL SURVEY. **Landsat missions**. 2019. Disponível em: <http://landsat.usgs.gov/band_designations_landsat_satellites.php>. Acesso em: 10 fev. 2018.

VIANA, D.B. **Vulnerabilidade de biomas às mudanças climáticas: O caso da Mata Atlântica no Estado do Paraná**. 2015. 343 p. Tese (Programa de Planejamento Energético) – Universidade Federal Rio de Janeiro, Rio de Janeiro, RJ, 2015.

VILANOVA, M. R. N. Tendências hidrológicas anuais e sazonais na bacia do rio Paraibuna, Parque Estadual da Serra do Mar (SP). **Sociedade e Natureza**, v. 26, n. 2, p. 301-316, 2014.

WAGNER, A. P. L. et al. Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesquisa Agropecuária Brasileira**, v. 48, 9, p. 1192-1200, 2013. DOI: 10.1590/S0100-204X2013000900002.

WANDERLEY, H. S.; JUSTINO, F. B.; SEDIYAMA, G. C. Tendência da Temperatura e Precipitação na Península Antártica. **Revista Brasileira de Meteorologia**, v. 31, n. 2, p. 114-121, 2016.

WANG, Z. et al. Monitoring land surface albedo and vegetation dynamics using high spatial and temporal resolution synthetic time series from Landsat and the MODIS BRDF/NBAR/albedo product. **International Journal of Applied Earth Observation and Geoinformation**, v. 59, p. 104-117, 2017. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0303243417300715>>. Acesso em: 13 jan. 2018. DOI: <https://doi.org/10.1016/j.jag.2017.03.008>.

ZHAI, J. et al. Radiative forcing over China due to albedo change caused by land cover change during 1990–2010. **Journal of Geographical Sciences**, v. 24, n. 5, p. 789–801, 2014.

ZHANG, J. Z. et al. Internet Traffic Classification by Aggregating Correlated Naive Bayes Predictions. **IEEE Transactions on Information Forensics and Security**, v. 8, n.1, 2013.

ZHANG, G. et al. Time Series High-Resolution Land Surface Albedo Estimation Based on the Ensemble Kalman Filter Algorithm. **Remote sensing**, 11, 753, p. 1 – 24. DOI: <https://doi.org/10.3390/rs11070753>.

ZHENG, S. et al. Retrieval of forest growing stock volume by two different methods using Landsat TM images. **International Journal of Remote Sensing**, v. 35, p. 29-43. 2013.

CAPÍTULO II: INFLUÊNCIA DO USO E COBERTURA DA TERRA NO ALBEDO DE SUPERFÍCIE

RESUMO

O albedo de superfície controla o balanço de energia entre a superfície e a atmosfera, sendo uma variável primordial para identificar variações climáticas. O objetivo deste estudo foi avaliar o comportamento do albedo de superfície em diferentes padrões de uso e cobertura da terra presentes no bioma Mata Atlântica a partir de imagens TM/Landsat 5 e OLI/Landsat 8. As imagens utilizadas foram da órbita-ponto 221-080, as quais recobrem a Floresta Nacional de São Francisco de Paula nas datas de 1987 e 2017. O albedo foi obtido por meio do método de *Surface Energy Balance Algorithm for Land*. O mapeamento do uso e cobertura da terra foi realizado pelo algoritmo classificador *Maxver* sendo identificadas quatro classes temáticas. Por fim, realizou-se o cruzamento do albedo com as classes temáticas identificando a variação do albedo em função das mudanças na cobertura da terra. O albedo de superfície variou de 6 a 22%, sendo que o ano de 1987 concentrou valores de albedo superiores à 2017. A floresta nativa apresentou albedo superior aos plantios florestais em ambas as datas, em decorrência da estrutura do dossel dessas coberturas. A análise espacial do albedo expôs a relação dessa variável climática com a cobertura da superfície terrestre, desse modo, mudanças na cobertura vegetal tendem a gerar alterações no albedo, influenciando em mudanças na radiação e fluxos da atmosfera.

Palavras-chave: Cobertura florestal. Imagens Landsat. Mudanças climáticas.

ABSTRACT

The surface albedo controls the energy balance between the surface and the atmosphere, being a primordial variable to identify climatic variations. The objective of this study was to evaluate the behavior of the surface albedo in different uses and cover land in the Mata Atlântica biome from images TM/Landsat 5 and OLI/Landsat 8. The images used were path-row 221-080 which cover the Floresta Nacional de São Francisco de Paula on the dates of 1987 and 2017. The albedo was obtained by the method of *Surface Energy Balance Algorithm for Land*. The mapping of use and cover land was performed by the Maxver classifier algorithm and were identified four thematic category. Finally, the albedo was crossed with the thematics categories, identifying the variation of the albedo as a function of the changes in the land cover. The surface albedo ranged from 6 to 22%, with 1987 concentrating albedo values higher than 2017. The native forest presented superior albedo to the forest plantations in both dates due to the structure of the canopy of these coverings. The spatial analysis of the albedo exposes the relation of this climatic variable to the cover of the terrestrial surface, thus changes in the vegetation cover causes alterations in the albedo, influencing changes in the radiation and atmospheric fluxes.

Key-Words: Forest cover. Landsat images. Climate changes.

1 INTRODUÇÃO

O conhecimento sobre a dinâmica dos diferentes usos e coberturas da terra é importante para a modelagem e compreensão dos processos que ocorrem no planeta, como a sua influência sob o clima. Alterações na paisagem terrestre possuem diversas implicações, destacando-se as modificações no balanço de energia da atmosfera.

As atividades antrópicas baseadas em mudança no uso e cobertura da terra (*Changes of land use and land cover* (LULC)) têm gerado impactos em diversas regiões do planeta, a partir de mudanças das áreas nativas para vários propósitos (KARL e TRENBERTH, 2003), os quais aceleram os processos de degradação dos ecossistemas terrestres.

Listado pelo Sistema Global de Observação Climática, o albedo é uma das variáveis climáticas essenciais, considerado a chave que controla o balanço de energia radiativa planetária e a porção de energia entre a atmosfera e a superfície terrestre (LUKES et al. 2014), sendo conceituado por Berbet e Costa (2003) como a integração da reflectância ao longo do espectro de radiação solar. As alterações no albedo modificam os balanços de radiação e energia da superfície, que podem ser detectadas com seu monitoramento (SILVA et al., 2016).

Hahmann e Dickinson (1997) ao desenvolverem uma modelagem do clima, identificaram que as mudanças no albedo de superfície e na rugosidade da vegetação correspondem as duas propriedades biofísicas mais importantes que influenciam o clima local. Ao avaliar essa variável climática em relação ao uso e cobertura da terra Davin e Noblet-Ducoudré (2010) detectaram que a perda da cobertura de floresta gera um aumento do albedo de superfície, diminuindo a evapotranspiração e rugosidade da superfície, o que leva a alterações climáticas (LI et al., 2008).

A relação entre a superfície florestal e o seu albedo é complexa, sendo que para Lukes et al. (2013) essa variável é pouco estudada, especialmente com relação a influência dos distúrbios naturais e atividades humanas (manejo florestal) na variação do albedo. O comportamento dessa variável ainda é desconhecido quando se trata de florestas tropicais, como a Mata Atlântica.

A observação por sistemas sensores orbitais correspondem a um importante meio de monitoramento do albedo ao longo do tempo e do espaço (KUUSINEN et al., 2013). O sensoriamento remoto permite a integração de informações e processos

relativos às trocas entre biosfera e atmosfera, de carbono, gases, água e energia (LIBERATO, 2011).

Componentes agrometeorológicos como por exemplo o albedo e a temperatura de superfície, podem ser melhor explorados com o uso de imagens oriundas de sistemas sensores, uma vez que permitem a extração da característica espectral desses elementos (JENSEN, 2009). Assim, os dados provenientes do sensoriamento remoto permitem o conhecimento da reflectância da cobertura florestal, possibilitando vincular mudanças quantitativas na estrutura da vegetação ao albedo para regiões de interesse (LUKES et al., 2013).

A estimativa do albedo de superfície em grande escala é frequentemente realizada a partir de dados de reflectância de baixa e média resolução espacial (LUKES et al., 2014). Nessa perspectiva, os dados MODIS são utilizados para estimar o albedo de grandes regiões (PLANQUE et al., 2017; LUKES et al., 2016; LUKES et al., 2014; KUUSINEN et al., 2012), enquanto que imagens Landsat são destinadas para escalas menores (KUUSINEN et al., 2016; GIONGO e VETTORAZZI, 2014; LIBERATO, 2011).

Nesse sentido, o programa Landsat fornece dados do território brasileiro desde 1973, ancorando estudos relacionados ao ambiente atmosférico em diversas áreas de pesquisa, vindo a se consolidar como um produto amplamente utilizado, demonstrando eficiência no mapeamento e monitoramento da superfície terrestre em pequena, média e grande escala. Essa série é composta por oito satélites orbitais, dos quais destacam-se o satélite Landsat 5 com o sensor TM (*Thematic Mapper*) e Landsat 8 com dois sistemas sensores a bordo, o OLI (*Operational Land Imager*) e o TIRS (*Thermal Infrared Sensor*). Atualmente apenas o satélite Landsat 8 se encontra em plena operação, dando sequência ao programa de observação da terra, coletando aproximadamente 400 cenas diariamente.

Os dados Landsat apresentam um potencial para o uso em estimativas do albedo de superfície em aplicações que requerem dados com resolução espacial mais fina como o monitoramento de áreas fragmentadas (HE et al., 2018). Nesse sentido, o bioma Mata Atlântica encontra-se altamente fragmentado (MARCHESAN, 2017) e as áreas uniformes geralmente são de poucos hectares. Nessa perspectiva, os produtos MODIS albedo (MCD43A1) apresentam uma resolução espacial de aproximadamente 25 ha, não englobando as particularidades desses fragmentos, os quais podem ser melhores representados ao utilizar imagens Landsat.

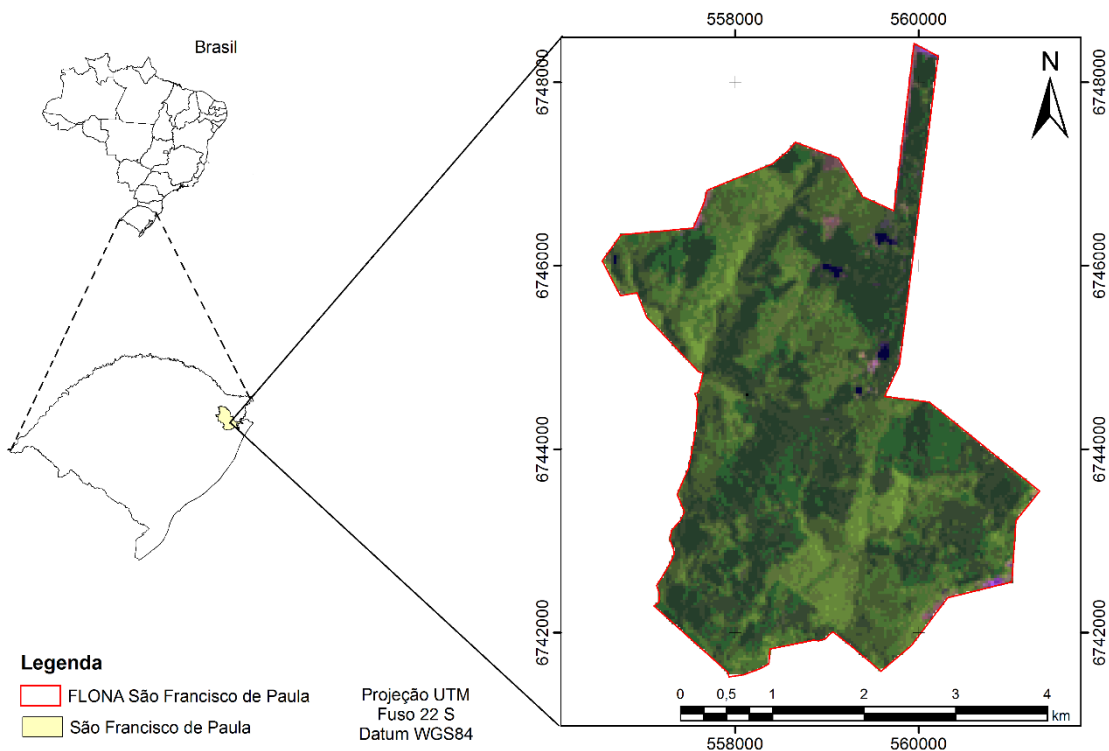
O objetivo deste estudo foi avaliar o comportamento do albedo de superfície em diferentes usos e cobertura da terra presentes no bioma Mata Atlântica a partir de imagens TM/Landsat 5 e OLI/Landsat 8.

2 MATERIAL E MÉTODOS

2.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A Floresta Nacional (FLONA) de São Francisco de Paula localiza-se no município de São Francisco de Paula, a nordeste do estado do Rio Grande do Sul, Brasil (Figura 1). Está situada entre as coordenadas 29°27'29,91" a 29°23'20,96" de latitude Sul e 50°24'53,47" a 50°22'39,01" de longitude Oeste. A área de estudo abriga uma grande biodiversidade de espécies da fauna e flora nativa do bioma Mata Atlântica (ICMBIO, 2019).

Figura 1 – Localização da área de estudo que abrange a Floresta Nacional de São Francisco de Paula - RS



Fonte: Autora.

A FLONA de São Francisco de Paula é caracterizada pelos Campos de Cima da Serra (Estepe) e pelas florestas com Araucária, denominada de Floresta Ombrófila Mista, ambas as fitofisionomias pertencem ao bioma Mata Atlântica. A região apresenta uma pluviosidade superior a 2.000mm, associada a uma temperatura média anual de aproximadamente 14,5°C (ICMBIO, 2019; KANIESKI et al., 2017). Temperaturas negativas podem ocorrer durante os meses de abril a novembro, já as geadas são frequentes, contando inclusive com a formação de neve nos invernos mais rigorosos (SONEGO et al., 2007).

A área total da FLONA é de aproximadamente 1.600 ha, sendo composta por reflorestamentos de *Araucaria angustifolia* (Bertol) Kuntze, *Pinus taeda* L., *Pinus elliottii* Engelm. e *Eucalyptus* spp. L'Hér. A FLONA apresenta outras espécies, com menor representatividade destinada a fins comerciais, totalizando uma cobertura por parte dos plantios florestais de aproximadamente 600 ha. Entretanto, a maior parte da FLONA é ocupada com a floresta nativa, sendo de aproximadamente 900 ha (GOMES, 2005).

2.1.1 Dados espectrais

O estudo utilizou duas imagens correspondendo a órbita-ponto 221-080 do satélite TM/Landsat 5 datada em 28/02/1987 e OLI/Landsat 8 na data de 13/01/2017, ambas no período de verão. A escolha das datas foi baseada na observação realizada por Couto (2009), o qual descreve que o albedo de superfícies vegetadas é controlado pela variação climática, especialmente em ambientes que apresentam uma sazonalidade marcante, uma vez que as propriedades fisiológicas da vegetação são influenciadas por fatores abióticos do clima.

A estimativa do albedo envolve valores de reflectância da superfície terrestre, desse modo, os dados foram submetidos a calibração radiométrica, a qual foi realizado pelo *Semi-Automatic classification Plugin – SCP*, disponível no *software* QGIS (QGIS DEVELOPMENT TEAM, 2019). A radiância espectral de cada banda (L_λ) do sensor TM/Landsat 5 foi calculada pela Equação 1, a qual corresponde a radiação de saída da banda observada no topo da atmosfera. A partir da radiância espectral, se obteve a reflectância planetária (ρ_λ) das faixas espectrais do sensor TM (Equação 2), conforme descrito pela USGS (2017).

$$L_{\lambda} = \frac{L_{\text{Máx}} - L_{\text{Min}}}{255} * ND + L_{\text{Min}} \quad (1)$$

$$\rho_{\lambda} = \frac{\pi * L_{\lambda} * d_r^2}{ESUN_{\lambda} * \cos \theta} \quad (2)$$

Em que:

ND= número digital de cada pixel;

$L_{\text{Máx}}$ e L_{Min} = constantes de calibração do sensor;

L_{λ} = radiância espectral de cada banda, expressa na unidade $\text{m}^2/\text{sr}/\mu\text{m}$;

$ESUN_{\lambda}$ = corresponde a irradiância exo-atmosférica solar para cada banda ($\text{W}/\text{m}^2/\mu\text{m}$);

$\cos \theta$ = cosseno do ângulo zenital e;

d_r = distância relativa Terra-Sol, disponível nos metadados.

A calibração radiométrica de imagens OLI/Landsat 8 apresenta modificações em relação aos demais satélites da série Landsat. Assim, a obtenção de valores de reflectância planetária se realiza por meio da Equação 3 (USGS, 2017).

$$\rho = \frac{M_{\rho} * Q_{\text{cal}} + A_{\rho}}{\text{Sin}(\Theta_{\text{SE}})} \quad (3)$$

Em que:

ρ = reflectância planetária no topo da atmosférica;

M_{ρ} = corresponde ao fator de redimensionamento multiplicativo da banda específica;

A_{ρ} = é fator de redimensionando aditivo específico da banda a partir dos metadados;

Q_{cal} = valor quantizado calibrado pelo pixel em ND;

Θ_{SE} = ângulo elevação solar.

2.2.2 Albedo de superfície

Para a estimativa do albedo foi utilizado o modelo *Surface Energy Balance Algorithm for Land* (SEBAL), proposto por Bastiaanssen (1995), conforme demonstrado na Equação 4. O albedo atmosférico (α_{atm}) foi obtido com o modelo de transferência radiativa, em que o valor dessa variável recomendado para o modelo SEBAL é 0,03 (LIBERATO, 2011; SILVA et al., 2016). A transmissividade para condições de céu claro é descrita por Allen et al. (2002) conforme demonstrado na Equação 5.

$$\alpha = \frac{\alpha_{toa} - \alpha_{atm}}{\tau_{oc}^2} \quad (4)$$

Em que:

α = albedo de superfície;

α_{toa} = albedo no topo da atmosfera (planetário);

α_{atm} = corresponde ao albedo atmosférico;

τ_{oc}^2 = transmitância atmosférica.

$$\tau_{oc} = 0,35 + 0,627 \exp \left[-\frac{0,00146P_o}{K_t \cos Z} - 0,075 \left(\frac{W}{\cos Z} \right)^{0,4} \right] \quad (5)$$

Em que:

P_o = pressão atmosférica local (kPa);

K_t = coeficiente de turbidez do ar (1,0 é para o ar limpo e 0,5 é para ar extremamente turvo ou poluído);

Z = ângulo zenital;

W = precipitação da água (mm): $W = 0,14 e_a P_o + 2,1$;

e_a = corresponde a pressão parcial do vapor de água atmosférico (kPa).

O α_{toa} é obtido por meio da combinação linear da reflectância de cada banda com seus respectivos pesos. Desse modo, para imagens do sensor TM/Landsat 5, foram utilizados os seguintes pesos: $0,293\rho_1 + 0,274\rho_2 + 0,233\rho_3 + 0,157\rho_4 + 0,033\rho_5 + 0,011\rho_7$, correspondendo as bandas 1, 2, 3, 4, 5 e 7, respectivamente. Entretanto, para as imagens do sensor OLI/Landsat 8 os pesos foram $0,300\rho_2 + 0,276\rho_3 + 0,233\rho_4 + 0,143\rho_5 + 0,035\rho_6 + 0,0119\rho_7$ para as bandas 2, 3, 4, 5, 6 e 7, respectivamente. A estimativa do albedo foi realizada em linguagem de programação R, versão 3.6.1 (R DEVELOPMENT CORE TEAM, 2019).

2.2.3 Relação do albedo com o uso e cobertura da terra

Para o mapeamento das classes temáticas presentes na FLONA de São Francisco de Paula foi realizada a classificação supervisionada de duas imagens, referentes aos anos de 1987 e 2017 pelo algoritmo Máxima Verossimilhança –

MAXVER, com limiar de aceitação de 99%. Para tanto, foi necessário a amostragem das classes de uso, referentes ao treinamento do algoritmo.

O processo de treinamento englobou a aquisição de amostras das classes Floresta nativa, que correspondeu a fragmentos da Floresta Ombrófila Mista; Plantios florestais, representados por talhões homogêneos de araucária, pinus e eucalipto; Campo nativo, que correspondeu a vegetação rasteira nativa desse ambiente e Água, sendo representada por reservatórios artificiais. Após a classificação das imagens foram elaborados mapas temáticos do uso e cobertura da terra para os anos de 1987 e 2017. Ambos os processos foram realizados no *software* Spring.

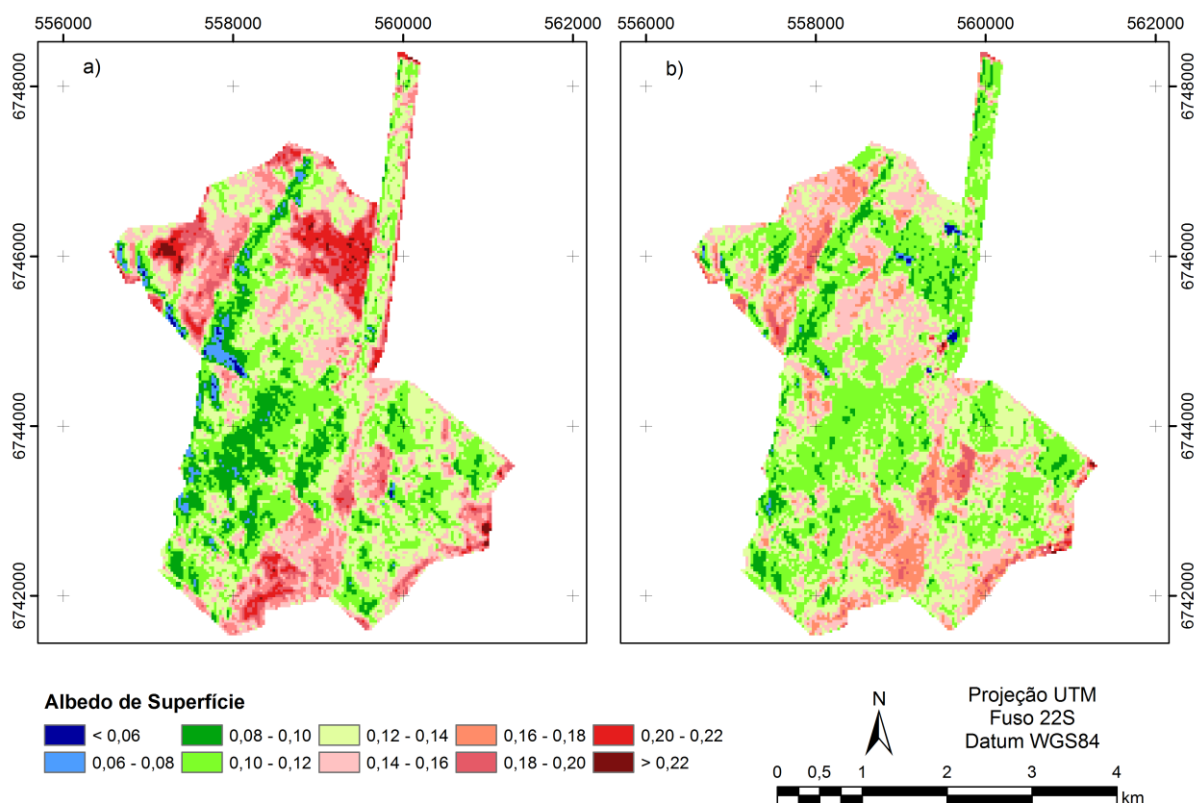
A fim de relacionar as informações de albedo com as classes de uso e cobertura da terra, cada classe temática foi transformada individualmente para vetor e posteriormente extraída as informações de albedo dessas classes. Por fim, realizou-se a média e desvio padrão dos valores de albedo para cada classe temática de uso e cobertura da terra. Essa análise estatística foi realizada por meio de funções em linguagem R.

3 RESULTADOS E DISCUSSÃO

Tendo em vista o comportamento do albedo de superfície apresentada pela FLONA de São Francisco de Paula, verificou-se que no ano de 1987 os valores expressos de albedo foram superiores quando comparados aos valores identificados em 2017, uma vez que se observou a maior presença de classes mais elevadas de albedo no início do monitoramento. A Figura 2 demonstra o mapeamento do albedo estimado por imagens Landsat.

Para a FLONA de São Francisco de Paula o albedo de superfície apresentou uma variação entre 0,06 e 0,22, considerando as duas datas de monitoramento. Giongo e Vettorazzi (2014) obtiveram valores de albedo entre 0,07 e 0,31 com o uso de imagens TM/Landsat 5 ao estudar diversas coberturas e uso da terra. Por outro lado, Dantas et al., (2010) com o uso de imagens AVHRR/NOOAA e TM/Landsat 5 obtiveram os valores de albedo variando de 0,04 a 0,34.

Figura 2 – Albedo de superfície na FLONA de São Francisco de Paula nos anos de 1987 (a) e 2017 (b) para as áreas de floresta nativa, plantios florestais, campo nativo e água



Fonte: Autora.

Os valores de albedo do presente estudo englobaram uma amplitude inferior àquela descrita na literatura, uma vez que a área de estudo é predominantemente ocupada com cobertura vegetal arbórea e não apresenta afloramento rochoso e/ou solo exposto, os quais tendem a apresentar uma maior perda de energia para a atmosfera, aumentando os valores de albedo registrado pelo sensor. A parte sudoeste apresentou valores inferiores de albedo em ambas as datas, enquanto que na parte nordeste da FLONA, após 30 anos ocorreu a redução dos valores nas regiões que anteriormente englobavam as maiores classes, correspondendo a valores superiores à 0,20.

A quantificação do albedo demonstrou o predomínio da classe 5 (0,12 a 0,14), no monitoramento de 1987, a qual representou 26,50% da área total (Tabela 1). Em 2017, a classe 4, com albedo variando de 0,10 a 0,12, englobou o maior percentual de área, correspondendo a 34,11% da FLONA.

Destaca-se que as classes de albedo 9 e 10, em 1987 representavam 4,65% da área total. Por outro lado, em 2017, essas mesmas classes englobaram 0,25% da área, confirmando o comportamento observado na análise qualitativa da FLONA, de redução dos valores extremos de albedo no ano de 2017.

Tabela 1 – Amplitude e abrangência das classes de albedo observadas na FLONA de São Francisco de Paula para os anos de 1987 e 2017

Classes	Albedo de superfície	Ano de 1987		Ano de 2017	
		ha	%	ha	%
1	< 0,06	3,60	0,22	3,06	0,19
2	0,06 --- 0,08	27,99	1,73	4,59	0,28
3	0,08 --- 0,10	172,08	10,66	85,86	5,32
4	0,10 --- 0,12	359,64	22,27	550,80	34,11
5	0,12 --- 0,14	427,86	26,50	431,28	26,71
6	0,14 --- 0,16	285,75	17,70	340,74	21,10
7	0,16 --- 0,18	163,89	10,15	156,78	9,71
8	0,18 --- 0,20	98,91	6,13	37,53	2,32
9	0,20 --- 0,22	66,96	4,15	2,97	0,18
10	> 0,22	8,10	0,50	1,17	0,07

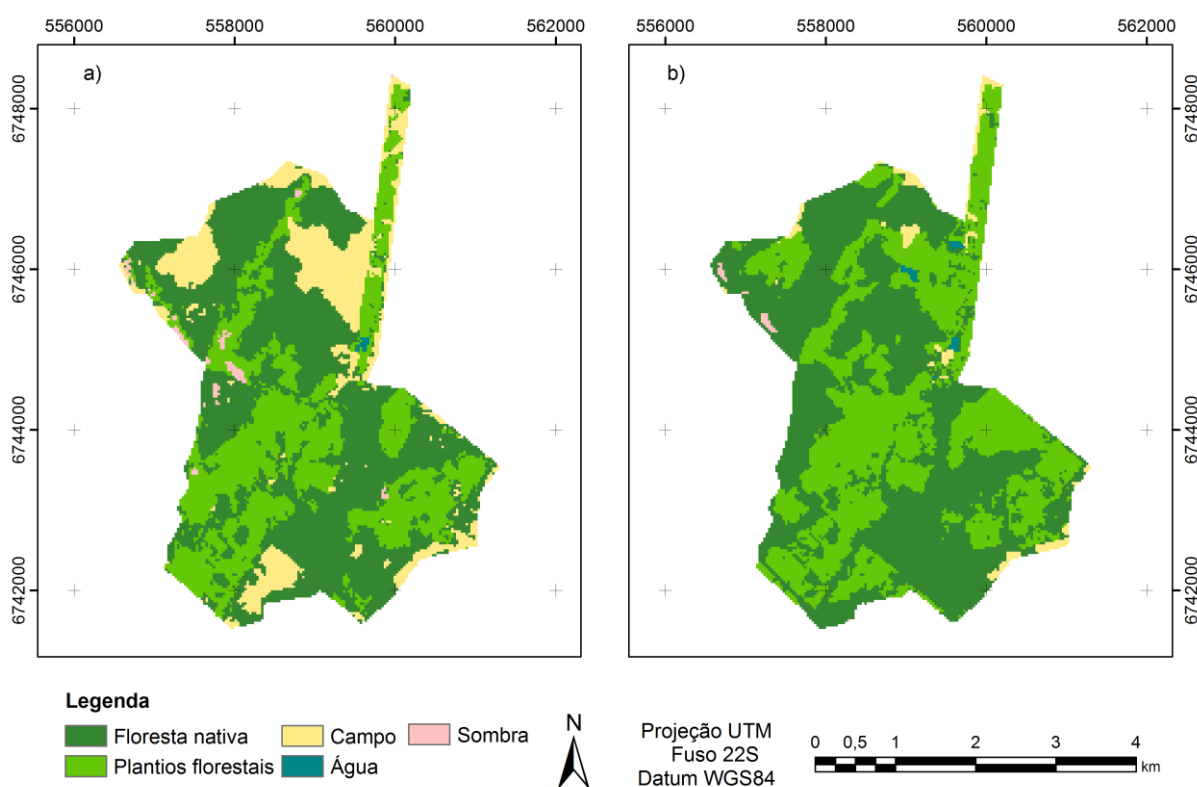
Fonte: Autora.

As diferenças no comportamento do albedo são decorrentes da predominância de determinados tipos de cobertura da superfície. Desse modo a Figura 3 demonstra o uso e cobertura da terra nos anos de 1987 e 2017, sendo possível perceber que o mapeamento condiz com os dados disponíveis no ICMBio (2019), em que a FLONA é composta predominantemente por Floresta nativa e Plantios florestais. A classe de campo é menos expressiva na área de estudo.

A região sudoeste, que expôs as menores classes de albedo, apresentou predomínio de Plantios florestais de culturas homogêneas. Em contrapartida, observou-se a presença da classe campo nativo no ano de 1987 (Figura 3a) nas mesmas regiões em que o albedo englobou as maiores classes temáticas (superior a 0,20).

São notórias as modificações no Campo nativo ao longo dos 30 anos de observação, demonstrando grandes perdas de área (Figura 3b). Visualmente é possível identificar que a maior parte da área abrangida por esta classe no início do monitoramento foi substituída por outros usos em 2017.

Figura 3 – Uso e cobertura da terra para a FLONA de São Francisco de Paula nos anos de 1987 (a) e 2017 (b)



Fonte: Autora.

Quantitativamente, a Floresta nativa correspondeu a principal cobertura, englobando aproximadamente 50% da FLONA de São Francisco de Paula em ambas as datas avaliadas (Tabela 2). Na sequência, destacam-se os plantios florestais, representando 33% e 43% da área total em 1987 e 2017, respectivamente.

Corroborando com a análise visual, verificou-se uma redução da classe Campo nativo após 30 anos, passando de 15,21% em 1987 para 2,31% em 2017, demonstrando uma redução de 12,90% da área total da FLONA ocupada pela classe. Ao final do monitoramento, o campo nativo cedeu espaço principalmente aos Plantios

florestais, os quais expandiram 10,30%, seguido da Floresta nativa com um aumento de 2,94% no período.

Menos expressiva, a classe Água apresentou um aumento de 0,24% na contabilização da área total. Após análise da área no *Google Earth pro®*, observou-se que as áreas de campo que foram substituídas por plantios florestais foram ocupadas, principalmente, por povoamentos de *Pinus spp.*

Tabela 2 – Quantificação do uso e cobertura da terra para 1987 e 2017 obtida na classificação supervisionada, em hectares e percentual, das classes em relação a área total da FLONA

Classes temáticas	Ano de 1987		Ano de 2017		Diferença
	ha	%	ha	%	%
Floresta nativa	825,21	51,10	872,73	54,04	+ 2,94
Plantios florestais	528,30	32,72	694,62	43,02	+ 10,30
Campo	245,61	15,21	37,35	2,31	- 12,90
Água	1,98	0,12	5,94	0,37	+ 0,25
Sombra	13,68	0,85	4,14	0,26	- 0,59
Total	1614,78	100,00	1614,78	100,00	0,00

Fonte: Autora.

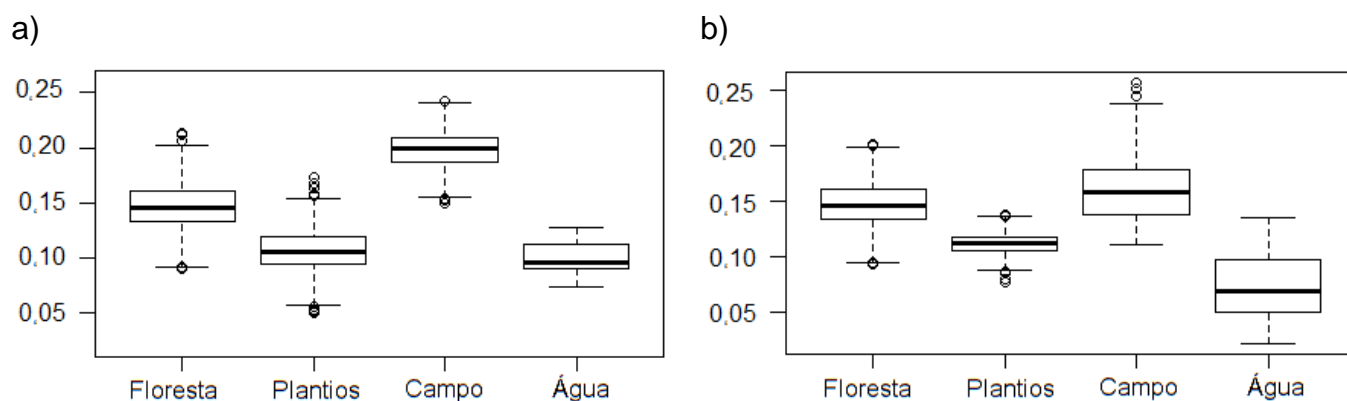
A análise do cruzamento entre o albedo de superfície e os diferentes tipos de uso e cobertura da terra demonstrou que os menores valores de albedo foram registrados pela classe água, expressando um valor de mediana de 0,09. Na área de estudo, as superfícies de água são representadas por reservatórios artificiais (Figura 4).

Os resultados obtidos nesse estudo corroboram com Giongo e Vettorazzi (2014), os quais obtiveram para as represas um percentual de albedo entre 0,06 e 0,11. Para Kuusinen et al. (2013), os corpos d'água apresentaram um valor médio de albedo de 0,056 associado a um dos menores desvios quando comparados aos demais tipos de uso e cobertura da terra.

Os valores mais elevados de albedo de superfície foram identificados em áreas com pouca ou com ausência de vegetação arbórea, correspondendo às áreas de

campo. Essa classe apresentou os maiores desvios em ambas as datas observadas dentre as fisionomias presentes nesse estudo, demonstrando maior dispersão dos dados em torno da mediana.

Figura 4 – Classes temáticas e seus respectivos valores de albedo nos anos 1987 (a) e 2017 (b)



Fonte: Autora.

A cobertura florestal, representada pela Floresta nativa e Plantios florestais, apresentou valores intermediários de albedo, tendo como mediana, valores inferiores a 0,14 ao analisar as duas datas de estudo. Comportamento similar foi relatado por Lukes et al. (2014), os quais observaram valores de albedo inferiores a 0,15 no período de verão ao estudar a florestal boreal da Finlândia com dados MODIS.

No entanto, os povoamentos florestais demonstraram englobar menores valores de albedo quando comparados à Floresta nativa. Assim, os Plantios florestais apresentaram valores de mediana 0,11 em ambas as datas, enquanto que a Floresta nativa foi de aproximadamente 0,14.

As características estruturais das folhas, assim como a organização do dossel e sub-bosque influenciam na resposta espectral refletida e emitida pela cobertura florestal. Segundo Lukes et al. (2014) a arquitetura dos dosséis, compreendendo vários níveis hierárquicos corresponde a um dos principais fatores que difere o albedo das florestas. Aliado a isso, os Plantios florestais possuem um dos menores desvios, enquanto que as Florestas nativas demonstraram conter maior dispersão dos dados em torno do valor médio do albedo quando comparado essas duas classes, sendo esse comportamento melhor observado no ano de 2017.

Ao estudar o albedo, Giongo e Vettorazzi (2014) destacaram a influência da sazonalidade. Os autores observaram que a sazonalidade tem maior influência nos valores de albedo da água, para a qual foi identificada uma grande variação anual, enquanto que os plantios de eucalipto, cana-de-açúcar e pastagem apresentaram uma baixa, porém relevante, variação anual.

Para Kuusinen et al. (2013) o conhecimento do albedo das florestas sob diferentes práticas de gestão e composição de espécies permite melhor avaliar as contribuições da silvicultura para o clima em escala local, avançando nas questões de sequestro de carbono. Nesse contexto, estudos referentes ao albedo da cobertura florestal podem contribuir para desenvolver propostas de gerenciamento contemplando ambas as perspectivas.

4 CONCLUSÃO

O estudo do comportamento espectral dos diferentes padrões de uso e cobertura da terra presentes na FLONA de São Francisco de Paula, considerando as datas de 1987 e 2017, permitiu observar um comportamento de redução nos valores de albedo de superfície ao longo do tempo, os quais, após 30 anos, ficaram concentrados em classes inferiores de distribuição quando comparados ao primeiro imageamento.

Os plantios homogêneos de espécies florestais apresentam albedo inferior às demais classes temáticas, demonstrando que a estrutura desses dosséis influencia no fluxo de radiação entre a superfície e a atmosfera. Em que mudanças na cobertura vegetal ocasionam alterações no albedo, influenciando em modificações na radiação e fluxos da atmosfera.

A existência de uma relação do albedo com as espécies florestais pode subsidiar análises para a identificação de alterações na estrutura florestal, permitindo a observação rápida de fatores como estresses hídrico, ataque de patógenos, alterações nutricionais, entre outros. Assim, estudos mais aprofundados sobre as respostas das espécies arbóreas presentes na Mata Atlântica são essenciais para a manutenção desse bioma, bem como a expansão do setor de florestas plantadas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC) - Model. **Journal of Irrigation and Drainage Engineering**, v. 133, p.380-394, 2007. [http://dx.doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](http://dx.doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380)).

BASTIAANSEN, W. G. M. **Regionalization of surface flux densities and moisture indicators in composite terrain: A remote sensing approach under clear skies in Mediterranean climate**. Tesis. Netherlands: CIP Data Koninklijke Bibliotheek, Den Haag, 1995. 272 p.

BERBET, M. L. C.; COSTA, M. H. Climate change after tropical deforestation: seasonal variability of surface albedo and its effects on precipitation change. **Journal of Climate**, v. 16, p.2099-2104, 2003.

COUTO, D. L. N. **Albedo em cerrado sensu stricto como resposta à variação climática e biológica** – conexões com índices de vegetação, estoques de carbono e fluxos de CO₂. 2009. 93 p. Dissertação (Mestrado em Ciências) – Universidade de São Paulo, São Paulo, 2009.

DANTAS, F. R. C. et al. Determinação do albedo da superfície a partir de dados AVHRR/NOAA e TM/Landsat 5. **Revista Brasileira de Meteorologia**, v. 25, n.1, pg. 24-31, 2010. Disponível em: < <http://www.scielo.br/pdf/rbmet/v25n1/v25n1a03.pdf>>. Acesso em: 20 dez. 2017.

DAVIN, E. L.; NOBLET-DUCOUDRÉ, N. Climatic impact of global-scale deforestation: Radiative versus Nonradiative processes. **Journal of Climate**, 23, 97–112, 2010.

GIONGO, P. R.; VETTORAZZI, C. A. Albedo da superfície por meio de imagens TM-Landsat 5 e modelo numérico do terreno. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 8, p. 833 – 838, 2014.

GOMES, J. F. **Classificação e crescimento de grupos ecológicos na Floresta Ombrófila Mista da Flona de São Francisco de Paula, RS**. 2005. 89 p. Dissertação (Mestrado em Engenharia Florestal)-Universidade Federal de Santa Maria, RS, 2005.

HAHMANN, A. N. e DICKINSON, R. E. Modelo RCM2-BATS sobre a América do Sul tropical: aplicações ao desmatamento tropical. **Journal of Climate**, v. 10, p. 1944–1964, 1997.

HE, T. et al. Evaluating land surface albedo estimation from Landsat MSS, TM, ETM+, and OLI data based on the unified direct estimation approach. **Remote Sensing of Environment**, v. 204, p. 181-196, jan. 2018. Disponível: < <http://www.sciencedirect.com/science/article/pii/S0034425717304947>>. Acesso em: 17 jan. 2018. DOI: <https://doi.org/10.1016/j.rse.2017.10.031>.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE - ICMBIO. **Floresta Nacional de São Francisco de Paula/RS**. 2019. Disponível

em:<<http://www.florestanacional.com.br/flonasaochico.html>>. Acesso em: 03 de Ago. 2019.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de José Carlos Neves Epiphânio (coordenador)...[et al.]. São José dos Campos, SP: Parêntese, 2009. 598 p.

LI, Z.; BHATT, U.S.; MÖLDERS, N. Impact of doubled CO₂ on the interaction between the global and regional water cycles in four study regions. **Climate Dynamics**, v. 30, p. 255–275, 2008.

LIBERATO, A. M. Albedo à superfície a partir de imagens Landsat 5 –TM em áreas de floresta e pastagem na Amazônia. **Revista de Geografia**, v. 28, n. 1, 2011.

LUKES, P. et al. Multidecadal analysis of forest growth and albedo in boreal Finland. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 296-305, 2016. DOI: <http://dx.doi.org/10.1016/j.jag.2016.07.001>.

LUKES, P. et al. Geographical gradients in boreal forest albedo and structure in Finland. **Remote Sensing of Environment**, v. 152, p. 526-535, 2014.

LUKES, P.; STENBERG, P.; RAUTIAINEN M. Relationship between forest density and albedo in the boreal zone. **Ecological Modelling**, v. 261-262, p. 74 – 79, 2013.

KANIESKI, M. R. et al. Caracterização florística e diversidade na floresta nacional de São Francisco de Paula, RS, Brasil. **Revista Floresta**, v. 47, n. 2, 2017.

KARL, T.R.; TRENBERTH, K.E. Modern Global Climate Change. **Science**, v. 302, p. 1719-1723, 2003. <http://dx.doi.org/10.1126/science.1090228>

KUUSINEN, N. et al. Structural factors driving boreal forest albedo in Finland. **Remote sensing of environment**, v. 175, n. 9, p. 43-51, 2016.

KUUSINEN, N; TOMPPPO, E.; BERNINGER, F. Linear unmixing of MODIS albedo composites to infer subpixel land cover type albedos. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 324-333, 2013.

KUUSINEN, N. et al. Seasonal variation in boreal pine forest albedo and effects of canopy snow on forest reflectance. **Agricultural and Forest Meteorology**, 164, 53–60, 2012.

MARCHESAN, J. **Análise espacial da fragmentação florestal em áreas do bioma Mata Atlântica utilizando linguagem R**. 2017. 130 p. Dissertação (Mestrado em Engenharia Florestal)-Universidade Federal de Santa Maria, RS, 2017.

PLANQUE, C.; CARRER, D.; ROUJEAN, J. L. Analysis of MODIS albedo changes over steady woody covers in France during the period of 2001–2013. **Remote Sensing of Environment**, v. 191, n. 2017, 13–29 p., 2017.

QGIS DEVELOPMENT TEAM, 2019. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <<http://www.qgis.org/>>. Acesso em: 22 dez. 2019.

R DEVELOPMENT CORE TEAM. R: **The language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2019. Recuperado de <http://www.R-project.org>.

SILVA, B. B.; BRAGA, A.; BRAGA, C.; OLIVEIRA, L. M. M.; MONTENEGRO, S. M. G. L.; BARBOSA JUNIOR, B. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 1, p. 3-8, 2016.

SONEGO, R. C.; BACKES, A.; SOUZA, A. F. Descrição da estrutura de uma Floresta Ombrófila Mista, RS, Brasil, utilizando estimadores não-paramétricos de riqueza e rarefação de amostras. **Acta Botânica Brasílica**, v. 24, n.4, p. 943-955, 2007.

UNITED STATES GEOLOGICAL SURVEY. **Landsat missions**. 2017. Disponível em: <http://landsat.usgs.gov/band_designations_landsat_satellites.php>. Acesso em: 06 set. 2017.

CAPÍTULO III: IDENTIFICAÇÃO DE ESPÉCIES FLORESTAIS USANDO INTELIGÊNCIA ARTIFICIAL: ESTUDO DA RELAÇÃO DAS ESPÉCIES FLORESTAIS COM O ALBEDO

RESUMO

O objetivo do estudo foi avaliar a capacidade dos algoritmos de aprendizagem de máquina na identificação de povoamentos de espécies florestais utilizando imagens OLI/Landsat 8, bem como obter a relação das espécies florestais com o albedo de superfície. Inicialmente foi elaborado um arquivo contendo polígonos de amostras da Floresta Ombrófila Mista (FOM) e de povoamentos florestais das espécies *Araucaria angustifolia*, *Eucalyptus* spp. e *Pinus* spp. A classificação dessas fisionomias foi por meio de aprendizado de máquina baseando-se nos algoritmos *Naive Bayes* (NB), *Decision Tree* (DT), *K-Nearest Neighbor* (kNN), *Random Forest* (RF), *Support Vector Machine* (SVM) e *Artificial Neural Networks* (ANN). Os critérios de escolha do método de classificação de espécies florestais foram a Exatidão Global e o índice Kappa. A avaliação do ajuste dos algoritmos baseou-se na técnica de validação cruzada, utilizando 30 repetições. Para comparar os resultados da acurácia e verificar se os algoritmos diferiram significativamente entre si, foi utilizado o teste de Friedman e Nemenyi. O algoritmo SVM apresentou melhores resultados para a identificação das espécies florestais, demonstrando uma acurácia média de 0,9700 e Kappa 0,9577. Entretanto, estatisticamente, o algoritmo SVM não diferiu significativamente, a nível de confiança de 95%, do algoritmo ANN. Os povoamentos florestais apresentaram valores inferiores de albedo de superfície quando comparados à FOM, enquanto que os povoamentos de espécies de coníferas apresentaram albedo inferior à espécie de folhosa. Assim, o uso de algoritmos de aprendizado de máquina para a identificação de povoamentos florestais mostrou-se eficiente. Cabe destacar ainda, que os povoamentos florestais apresentam grande contribuição para o balanço de energia radiativa planetária, por meio de sua relação intrínseca com o albedo de superfície.

Palavras-chave: Aprendizado de máquina. Imagens OLI/Landsat 8. Linguagem R.

ABSTRACT

The aim of this study was to evaluate the ability of machine learning algorithms to identify stands of forest species using OLI / Landsat 8 images, as well as to obtain the relationship between forest species and surface albedo. It was elaborated a file containing polygons of samples from the Mixed Ombrophilous Forest (FOM) and forest stands of *Araucaria angustifolia*, *Eucalyptus* spp. and *Pinus* spp. The classification of these physiognomies was by machine learning based on the *Naive Bayes* (NB), *Decision Tree* (DT), *K-Nearest Neighbor* (kNN), *Random Forest* (RF), *Support Vector Machine* (SVM) and *Artificial Neural Networks* (ANN). The criteria for choosing the forest species classification method were Global Accuracy and Kappa Index. The evaluation of the fit of the algorithms was based on cross-validation with 30 repetitions. To compare the accuracy results and verify if the algorithms differ significantly from each other, the Friedman and Nemenyi test was used. The SVM algorithm presented

the best results for the identification of forest species, showing an average accuracy of 0.9700 and Kappa 0.9577. However, statistically, the SVM algorithm did not differ significantly at a 95% confidence level from the ANN algorithm. Forest stands presented lower surface albedo values than FOM, while stands of coniferous species showed lower albedo than hardwood species. Thus, the use of machine learning algorithms for the identification of forest stands proved to be efficient, demonstrating that forest stands make a major contribution to the planetary radiative energy balance, through its intrinsic relationship to surface albedo.

Key-words: *Machine learning. OLI/Landsat 8 images. R language.*

1 INTRODUÇÃO

As florestas possuem papel primordial para manutenção das condições adequadas para a sobrevivência humana, representando uma fonte imprescindível de recursos. As plantações florestais, por outro lado, são fundamentais na redução da pressão sob as florestas nativas contribuindo assim para a diminuição das taxas de desmatamento, assumindo funções não apenas de produção, mas também de conservação.

A vegetação florestal pode contribuir ainda, nas trocas de fluxo da atmosfera. Desse modo, o albedo é um parâmetro importante no balanço de radiação de uma superfície e frequentemente é utilizado em modelos climáticos e agrometeorológicos (LEITÃO et al., 2002). Assim, o estudo do comportamento do albedo com relação as espécies florestais podem contribuir para a observação rápida de alterações de sua estrutura, tendo potencial para representar uma importante ferramenta de análise das mudanças na cobertura florestal.

Nesse sentido, a identificação das espécies florestais, bem como a sua contribuição à manutenção dos fatores climáticos, são informações essenciais para subsidiar o manejo e expansão do setor florestal. A identificação das espécies é uma atividade fundamental para ações de produção e preservação das florestas. Essa operação a campo, requer tempo e a disponibilidade de recursos financeiros expressivos para a realização de inventários florestais nas áreas de interesse.

O sensoriamento remoto oferece métodos potencialmente econômicos e alternativos para a discriminação de espécies de vegetação (ADAM et al., 2012). Com a evolução das tecnologias de aquisição de informações sobre a cobertura terrestre, juntamente com as inovações tecnológicas da ciência de computação, permitiram que

a identificação de fisionomias pudesse ser realizada de forma célere, com menores custos e com alta periodicidade de informações.

No entanto, existem fatores que dificultam o processo de identificação de fisionomias por meio de imagens. Assim, destaca-se a heterogeneidade das paisagens dos ambientes tropicais (LI et al., 2014) que aumenta a complexidade das cenas retratadas nas imagens. Essa complexidade, aumenta a confusão espectral entre os diferentes tipos de cobertura da terra que podem apresentar respostas espectrais semelhantes (SOUZA et al., 2016).

Nesse sentido, a partir da década de 70 passaram a ser utilizadas as técnicas de inteligência artificial (IA) para a solução de problemas reais, as quais eram inicialmente utilizadas de forma teórica (FACELI et al., 2011). Dentro do campo de IA insere-se os algoritmos de aprendizado de máquina. Segundo Lary et al. (2016), as técnicas de aprendizado de máquina são eficazes para regressão e classificação, possibilitando utilizar milhares de variáveis. Dentre os algoritmos, destacam-se o *Naive Bayes* (NB), *Decision Tree* (Árvore - DT), *Random Forest* (Floresta Aleatória - RF), *K-Nearest Neighbor* (K- vizinho mais próximo – kNN), *Support Vector Machine* (Máquina de Vetor de Suporte - SVM) e *Artificial Neural Networks* (Redes Neurais Artificiais – ANN).

O objetivo do estudo foi avaliar a capacidade dos algoritmos de aprendizado de máquina na identificação de povoamentos de espécies florestais utilizando imagens OLI/Landsat 8, bem como obter a relação das espécies florestais com o albedo de superfície.

2 MATERIAL E MÉTODOS

2.1 ÁREA DE ESTUDO

A Floresta Nacional de São Francisco de Paula está situada no município de São Francisco de Paula, na região nordeste do Estado do Rio Grande do Sul, Brasil. A área de estudo está inserida no bioma Mata Atlântica, sendo caracterizada por Campos de Cima da Serra (Estepe) e pela Mata de Araucária, denominada de Floresta Ombrófila Mista. A FLONA está localizada entre as coordenadas 29°27'29,91" a 29°23'20,96" de latitude Sul e 50°24'53,47" a 50°22'39,01" de longitude Oeste.

A área de estudo abrange aproximadamente 1.600 ha, abrigando uma grande biodiversidade de flora e fauna (ICMBIO, 2019). A área é predominantemente ocupada por floresta nativa, sendo aproximadamente de 900 ha (GOMES, 2005). Inclui ainda reflorestamentos de *Araucaria angustifolia* (Bertol.) Kuntze, *Pinus taeda* L., *Pinus elliottii* Engelm e *Eucalyptus* spp. L'Hér. A FLONA apresenta outras espécies, com menor representatividade destinada a fins comerciais, totalizando uma cobertura de aproximadamente 600 ha.

2.2 IMAGEM OLI/LANDSAT 8

O estudo dispôs de imagem do sensor OLI (*Operational Land Imager*) acoplado ao satélite Landsat 8, datada em 13/01/2017, na órbita/ponto 221-080. Fizeram parte do estudo as bandas 1 até a 7, uma vez que apresentam maior resposta a vegetação. A imagem foi convertida para reflectância de superfície por meio de funções desenvolvidas em Linguagem de programação R, versão 3.6.1 (CORE TEAM, 2019).

Para a classificação da imagem OLI/Landsat 8, foi criado um arquivo do tipo *shapefile* contendo polígonos de amostras de treinamento da Floresta Ombrófila Mista (FOM) e de povoamentos florestais das espécies *Araucaria angustifolia*, *Eucalyptus* spp. e *Pinus* spp. Na área de estudo, estão incluídas áreas de campo nativo, reservatórios artificiais de água e sombras devido ao relevo acidentado, os quais foram incluídos na classe denominada de outros usos. Essa amostragem foi realizada no *software* QGIS versão 3.4 (QGIS DEVELOPMENT TEAM, 2019).

A identificação das amostras de cada classe foi realizada com base na resposta espectral das fisionomias, bem como por meio da interpretação visual de imagens acessadas no *Google Earth Pro* e a composição falsa cor (RGB - 654) da imagem OLI/Landsat 8, sob a qual foram vetorizados polígonos de cada classe temática presente na área de estudo.

2.3 ALGORITMOS DE APRENDIZADO DE MÁQUINA

Utilizou-se algoritmos de aprendizado de máquina destinados à classificação supervisionada de espécies florestais. Os algoritmos testados foram o *Naive Bayes*, *Decision Tree* (Árvores de Decisão), *K-Nearest Neighbor* (K- Vizinho Mais Próximo),

Random Forest (Florestas Aleatórias), *Support Vector Machine* (Máquina de Vetor de Suporte) e *Artificial Neural Networks* (Redes Neurais Artificiais) (Tabela 1).

Tabela 1 – Algoritmos de aprendizado de máquina e os respectivos parâmetros utilizados no processamento da imagem do ano de 2017

Algoritmo	Sigla	Tipo de parâmetro	Parâmetro
<i>Naive Bayes</i>	NB	<i>laplace</i> : suaviza dados categóricos a fim de evitar que o cálculo da probabilidade seja igual a zero	0
<i>Decision Tree</i>	DT	<i>cp</i> : controla o tamanho da árvore de decisão	0.001
		<i>maxdepth</i> : profundidade máxima do nó da árvore final	30
<i>K-Nearest Neighbor</i>	kNN	k: identificados por uma medida de distância, a qual compara os vetores de características marcadas e o conjunto de instâncias de treinamento obtidas pelo classificador	1
<i>Random Forest</i>	RF	<i>mtry</i> : número de variáveis amostradas aleatoriamente	Sqrt(p)
		<i>ntree</i> : número de árvores	500
<i>Support Vector Machine</i>	SVM	<i>kernel</i> : tipo de função kernel utilizada na predição, pode ser Radial, Linear, Polinomial e Sigmoidal	Radial
		C: ajusta a sensibilidade da margem de decisão de vetores de suporte classificados errados	1
<i>Artificial Neural Networks</i>	ANN	<i>maxit</i> : número máximo de interações	100
		<i>weights</i> : peso para cada exemplo	1

Fonte: Adaptação de Souza et al. (2016).

Para os seis algoritmos de aprendizado de máquina foi utilizada a mesma base de amostras para o treinamento. Porém, a configuração ideal dos parâmetros de ajuste foi determinada separadamente para cada classificador. Para escolher os

parâmetros a serem usados no treinamento dos algoritmos, foram realizados testes preliminares e escolhidas as combinações de parâmetros que apresentaram maior precisão durante os ajustes dos modelos, conforme descrito por Souza et al. (2016).

A classificação supervisionada de imagem orbitais foi desenvolvida em Linguagem R, versão 3.6.1 (R DEVELOPMENT CORE TEAM, 2019), a partir de uma abordagem não paramétrica. Para isto, foram utilizados os pacotes *raster* (HIJMANS, 2016), *caret* (KUHN et al, 2016), *rgdal* (BIVAND et al., 2016), *RandonForest* (LIAW, 2018) e *nnet* (VENABLES e RIPLEY, 2002).

2.4 VALIDAÇÃO DA CLASSIFICAÇÃO

Os critérios de escolha do melhor algoritmo de aprendizado de máquina para a classificação de espécies florestais foram a acurácia global (exatidão global) e o índice *Kappa*. A avaliação do ajuste dos algoritmos baseou-se na validação cruzada, com 30 repetições, observando para cada algoritmo implementado, o valor do índice de acurácia. A acurácia global foi o parâmetro utilizado na validação, uma vez que tem como propriedade estatística informar quanto um valor é correto e isento de erros, o que a torna uma ferramenta de análise chave no processo de avaliação da qualidade da classificação de imagens.

De posse dos valores de acurácia das 30 repetições de cada algoritmo, atribuiu-se pesos, os quais foram ordenados de acordo com a sua eficiência. Desse modo, foi atribuído o peso 1 para o algoritmo mais eficiente e assim sucessivamente, estabelecendo um *ranking*, conforme método descrito por Thiersch (1997).

Para comparar os resultados das acurácias e verificar se os algoritmos diferem significativamente entre si, foi utilizado o teste de Friedman e Nemenyi. Após a escolha dos melhores algoritmos de aprendizado de máquina para a classificação de espécies florestais foi realizado a espacialização dos povoamentos florestais e vegetação nativa do bioma Mata Atlântica para toda a área de estudo.

2.5 RELAÇÃO DO ALBEDO DE SUPERFÍCIE COM AS ESPÉCIES FLORESTAIS

De acordo com o desempenho dos algoritmos de aprendizado de máquina voltados à classificação supervisionada da cobertura florestal, foi realizado a escolha do melhor classificador a partir dos critérios estatísticos. Baseando-se na imagem

classificada da área de estudo, de acordo com as classes temáticas já descritas neste capítulo, foi possível verificar a contribuição destas para as trocas de energia da atmosfera por meio da análise do albedo de superfície.

Foi realizado o cruzamento da imagem correspondente a classificação da cobertura florestal com a imagem do albedo de superfície, permitindo desse modo, identificar quais espécies apresentam melhores respostas quanto aos fatores climáticos. O albedo de superfície foi obtido a partir do modelo *Surface Energy Balance Algorithm for Land* (SEBAL), proposto por Bastiaanssen (1995).

Para a operacionalização do cruzamento dos dois arquivos *raster* foi utilizada a linguagem de programação R, em que foi realizada a individualização dos polígonos de cada uma das coberturas florestais e posteriormente, elaborada a relação destas com o albedo de superfície. Essa operação teve como resultado um arquivo *raster* contendo o albedo para cada classe temática individualmente, o qual foi estruturado no formato de planilha para as análises posteriores. A análise da relação dessas variáveis foi realizada por meio de estatísticas descritivas, gráfico do tipo *boxplot*, apresentada pelas classes: FOM, *Araucaria angustifolia*, *Eucalyptus* spp. e *Pinus* spp.

3 RESULTADOS E DISCUSSÃO

Todos os algoritmos apresentaram valores superiores a 0,75 de acurácia e 0,65 para o índice *Kappa*. Esses resultados são considerados excelentes ao considerar a classificação proposta por LANDIS e KOCH (1977). Desse modo, a Tabela 2 ilustra os valores obtidos para os índices de acurácia global e *Kappa* para todos os classificadores utilizados.

Ao analisar os algoritmos e seus respectivos ajustes, o SVM foi o que apresentou o melhor desempenho, demonstrando uma acurácia no processo de classificação de 0,9734, seguido pela ANN (0,9649). Por outro lado, o algoritmo DT foi o que englobou maiores erros na classificação supervisionada das espécies florestais, expressando um valor de 0,7649 de acurácia global.

Tabela 2 – Valores de acurácia global e índice *Kappa* da classificação supervisionada de espécies florestais resultante de diferentes classificadores

Algoritmos	Acurácia Global	Kappa
SVM	0,9734	0,9624
ANN	0,9649	0,9507
RF	0,9541	0,9353
kNN	0,9208	0,8884
NB	0,8964	0,8581
DT	0,7649	0,6638

Fonte: Autora.

Corroborando com esses resultados, Qian et al. (2015) observaram que o SVM apresentou melhores resultados na classificação do uso e cobertura da terra quando comparado ao kNN, NB e DT, resultando numa acurácia de 0,92% e coeficiente kappa de 0,9075. Do mesmo modo, no estudo desenvolvido por Gaiad et al. (2017) o SVM foi que demonstrou maior valor de kappa (0,9790) ao classificar o uso e cobertura da terra com imagem Landsat 8, enquanto que a ANN foi o segundo algoritmo com melhor desempenho.

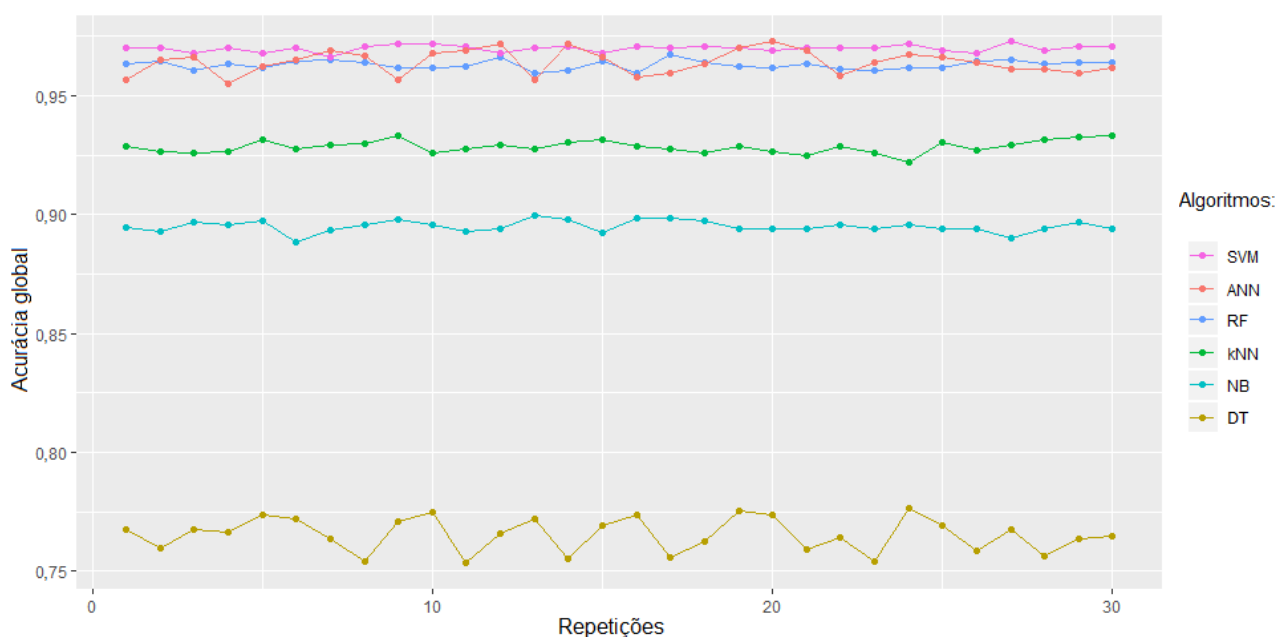
Em estudo desenvolvido por Petropoulos et al. (2012) os classificadores SVM e ANN produziram resultados próximos, porém o algoritmo SVM foi mais eficiente na descrição da distribuição espacial e da densidade de cobertura de cada categoria de cobertura da terra ao utilizar imagens hiperespectrais.

3.1 VALIDAÇÃO DA CLASSIFICAÇÃO DOS ALGORITMOS

No processo de classificação por aprendizado de máquina, uma etapa fundamental é a validação das estimativas. Na Figura 1 são apresentados os algoritmos de aprendizado de máquina e a respectiva acurácia obtida no processo de validação cruzada, baseando-se nas 30 repetições realizadas. A partir dos valores de acurácia apresentados pelos algoritmos para a classificação das espécies florestais, gerou-se a Tabela 3, a qual ilustra a posição dos algoritmos no *ranking* de acordo com sua precisão.

Os algoritmos RF, SVM e ANN foram os que apresentaram melhores resultados, demonstrando valores de acurácia global superiores a 0,95 no processo de validação. Entretanto, o algoritmo SVM com o *Kernel* do tipo Radial apresentou resultados superior aos demais, demonstrando uma acurácia média de 0,9700.

Figura 1 – Valores de acurácia obtidos no processo de validação cruzada para os diferentes algoritmos de aprendizado de máquina



Fonte: Autora.

Do mesmo modo que na classificação (utilizando um único conjunto de dados), o processo de validação demonstrou que o algoritmo DT apresenta os menores valores de acurácia quando comparado aos demais algoritmos. Segundo Hussain et al. (2013), o algoritmo DT pode mostrar desvantagens, uma vez que a árvore pode conter muitas ramificações, o que torna a interpretação da classificação difícil.

Destaca-se que na maioria das observações o SVM foi o melhor modelo, tendo como média o valor de 1,1. Na sequência, os algoritmos ANN e RF ficaram na segunda e terceira posição, respectivamente, com os escores médios no valor de 2,3 e 2,6.

Para Tharwat (2018), os resultados dos algoritmos de aprendizado precisam ser avaliados e analisados cuidadosamente, de modo a viabilizar a avaliação de diferentes algoritmos de aprendizado. Assim, o teste de Friedman e Nemenyi foi

aplicado a esses escores a fim de verificar a existência de diferenças significativas, especialmente entre o SVM e ANN.

Tabela 3 – *Ranking* dos algoritmos de aprendizado de máquina obtidos na validação cruzada


Repetições	SVM	ANN	RF	kNN	NB	DT
1	1	3	2	4	5	6
2	1	2	3	4	5	6
3	1	2	3	4	5	6
4	1	3	2	4	5	6
5	1	2	3	4	5	6
6	1	2	3	4	5	6
7	2	1	3	4	5	6
8	1	2	3	4	5	6
9	1	3	2	4	5	6
10	1	2	3	4	5	6
11	1	2	3	4	5	6
12	2	1	3	4	5	6
13	1	3	2	4	5	6
14	2	1	3	4	5	6
15	1	2	3	4	5	6
16	1	3	2	4	5	6
17	1	3	2	4	5	6
18	1	3	2	4	5	6
19	1	2	3	4	5	6
20	2	1	3	4	5	6
21	1	2	3	4	5	6
22	1	3	2	4	5	6
23	1	2	3	4	5	6
24	1	2	3	4	5	6
25	1	2	3	4	5	6
26	1	3	2	4	5	6
27	1	3	2	4	5	6
28	1	3	2	4	5	6
29	1	3	2	4	5	6
30	1	3	2	4	5	6
Média dos escores	1,1	2,3	2,6	4,0	5,0	6,0

Fonte: Autora.

A distância crítica (CD - *Critical Distance*), obtida pelo teste de Friedman e Nemenyi, foi de 1,37. Desse modo, os algoritmos SVM e ANN apresentaram uma

distância de 1,2 ($2,3 - 1,1$), o que indica que não existe diferença significativa entre eles, pois o valor da distância entre os algoritmos é menor que a distância crítica. Assim, não é possível afirmar, estatisticamente, que o SVM é superior ao ANN no processo de identificação de espécies florestais com imagens OLI/Landsat 8, conforme demonstrado na Figura 2.

Figura 2 – Teste estatístico de Friedman e Nemenyi para os algoritmos de aprendizado de máquina ao nível de significância de 5%



Fonte: Autora.

Os algoritmos SVM, ANN e RF apresentaram diferenças significativas quando comparados aos algoritmos KNN, NB e DT, demonstrando que podem gerar melhores resultados no processo de classificação de imagens orbitais com base nos valores de reflectância. Esse resultado corrobora com o estudo realizado por Gaiad et al. (2017), o qual demonstrou que o algoritmo SVM apresentou um desempenho superior quando comparado aos demais algoritmos de aprendizado de máquina para a classificação do uso e cobertura da terra.

Esses resultados têm implicações importantes na seleção de classificadores apropriados. Nesse sentido, o SVM e ANN apresentaram-se como os melhores classificadores para a individualização de povoamentos florestais, especialmente em regiões similares à objeto do presente estudo, com predomínio de áreas com relevo acidentado, o que gera sombreamento em áreas declivosas ocupadas pela cobertura florestal.

O melhor desempenho expressado pelo algoritmo SVM pode ser atribuído ao fato de que o mesmo resulta em uma única solução ótima. Já o algoritmo ANN pode

apresentar muitas soluções de acordo com os pesos e configurações iniciais do processamento (BURGES, 1998).

Para Petropoulos et al. (2012), a maior precisão da classificação por SVM é atribuída, principalmente, à capacidade desse classificador na identificação de um hiperplano ideal para a separação de classes, o que permite um baixo erro de generalização, produzindo assim a melhor separação possível de classes. Por outro lado, os autores enfatizam que o algoritmo ANN é capaz de aprender padrões complexos, o que por sua vez lhe permite um bom desempenho.

Entretanto, os resultados obtidos demonstraram a existência de diferença significativa entre o algoritmo SVM e RF, uma vez que seus escores apresentaram uma distância (1,44) maior que a distância crítica (1,37) obtida pelo teste de Friedman e Nemenyi. Esse comportamento evidencia que o SVM apresenta resultados superiores quando comparado ao RF.

Na Tabela 4 encontram-se os valores da matriz de confusão obtida para o algoritmo de melhor desempenho nos valores de acurácia. Assim, as colunas referem-se à classe estimada no processo de classificação e as linhas a verdade terrestre, ou seja, as amostras coletadas manualmente para cada classe com base no *Google Earth Pro*, em que a diagonal principal representa previsões corretas e a demais indicam as incorretas.

A partir da análise da matriz de confusão, observou-se que a identificação de espécies florestais por SVM englobou maiores erros na classificação de povoamentos de *Araucaria angustifolia*. Ainda que 92,98% dos *pixels* foram classificados corretamente, houve confusão com os povoamentos de *Pinus* spp. (3,51%) e outros usos (3,51%). A confusão gerada na classificação de Araucária e Pinus pode ser justificada em razão de ambas serem espécies coníferas, as quais tendem a apresentar comportamento similar na resposta espectral. A classe outros usos englobaram áreas sombreadas, as quais apresentaram, por vezes, resposta espectral similar às áreas com Araucária.

Tabela 4 – Matriz de confusão para a classificação supervisionada com o uso do algoritmo SVM para a FLONA São Francisco de Paula

	FOM	<i>Araucaria angustifolia</i>	<i>Eucalyptus</i> spp.	<i>Pinus</i> spp.	Outros usos
FOM	143 (97,95%)	0 (0,00%)	0 (0,00%)	1 (2,94%)	0 (0,00%)
<i>Araucaria angustifolia</i>	2 (1,37%)	53 (92,98%)	0 (0,00%)	1 (2,94%)	0 (0,00%)
<i>Eucalyptus</i> spp.	0 (0,00%)	0 (0,00%)	20 (100,0%)	0 (0,00%)	1 (1,64%)
<i>Pinus</i> spp.	0 (0,00%)	2 (3,51%)	0 (0,00%)	33 (97,06%)	0 (0,00%)
Outros usos	1 (0,68%)	2 (3,51%)	0 (0,00%)	0 (0,00%)	60 (98,36%)
TOTAL	146 (100,0%)	57 (100,0%)	20 (100,0%)	34 (100,0%)	61 (100,0%)

Fonte: Autora.

A identificação de plantios homogêneos de *Eucalyptus* spp. não apresentaram confusão, tendo 100% de acurácia na classificação dessa classe. Esse ajuste foi gerado devido a essa classe englobar uma pequena porção de área na FLONA de São Francisco de Paula, o que proporcionou poucas áreas para efetuar a amostragem dos povoamentos de *Eucalyptus* spp. Por outro lado, a classificação de *Pinus* spp. pelo algoritmo SVM expôs 97,06% de acertos dos *pixels* incluídos na amostra.

A classificação da FOM apresentou 97,95% de acerto, em que a confusão pode ser atribuída a presença de indivíduos de *Araucaria angustifolia* nas áreas de floresta, uma vez que é uma espécie nativa, característica desse tipo de formação florestal. Já a classe outros usos englobaram áreas de campo, água e sombra, desse modo, esses elementos estão presentes nas composições da vegetação nativa da FLONA de São Francisco de Paula.

Corroborando com o presente trabalho, Petropoulos et al. (2012) observaram que tanto o classificador SVM quanto ANN apresentam maiores precisões para as classes de florestas de folhas largas, áreas urbanas e mar, encontrando-se na sequência, as classes florestas de coníferas e áreas queimadas.

No entanto, o desempenho da classificação é frequentemente representado por diferentes métricas, como a precisão, sensibilidade e especificidade (THARWAT,

2018). Na Tabela 5 encontram-se as principais métricas utilizadas para avaliar predições realizadas pelo algoritmo SVM.

Tabela 5 – Métricas de avaliação do modelo de classificação por SVM

Métricas	FOM	<i>Araucaria angustifolia</i>	<i>Eucalyptus spp.</i>	<i>Pinus spp.</i>	Outros usos
Sensibilidade	0,9298	0,9706	1,0000	0,9795	0,9836
Especificidade	0,9885	0,9930	0,9966	1,0000	0,9883
Eficiência	0,9592	0,9818	0,9983	0,9897	0,9859
Valor predito positivo	0,9464	0,9429	0,9524	1,0000	0,9524
Valor predito negativo	0,9847	0,9965	1,0000	0,9829	0,9961

Fonte: Autora.

Para o objeto de estudo, o algoritmo SVM apresentou resultados satisfatórios, expressando valores próximos de um para todas as métricas de avaliação do modelo e para as cinco classes modeladas. Entretanto, destaca-se que os povoamentos de *Eucalyptus* e *Pinus* apresentaram melhores resultados em todas as métricas de ajuste, uma vez que possuem um padrão espectral mais uniforme.

A FOM apresentou menor valor quanto a proporção de acertos positivos (sensibilidade) e valor predito positivo quando comparado às demais classes temáticas. Esse comportamento que pode ser explicado devido a maior heterogeneidade da resposta espectral do dossel.

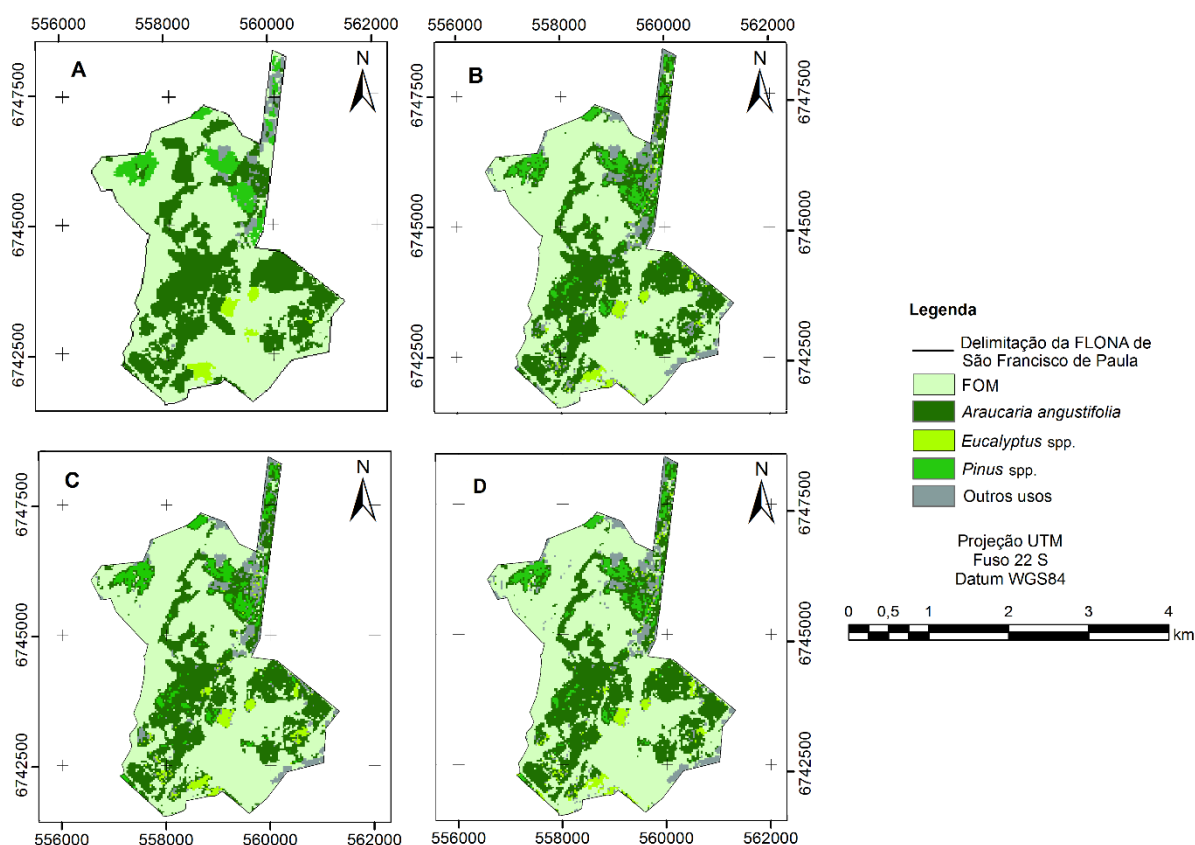
3.2 MAPEAMENTO DAS ESPÉCIES E FOM

A classificação temática para a FLONA de São Francisco de Paula, obtida a partir da aplicação dos modelos gerados pelos algoritmos com melhor desempenho pode ser visualizada na Figura 3. De modo geral, os povoamentos de *Pinus spp.* concentraram-se ao norte da área estudo, enquanto que plantios de *Eucalyptus spp.* foram identificados na porção sul, compondo pequenos povoamentos.

O mapeamento das espécies florestais ao longo da área de estudo corrobora com os dados divulgados pelo órgão ambiental (ICMBIO, 2019), demonstrando predomínio da cobertura nativa, a FOM, seguida dos povoamentos homogêneos de

Araucaria angustifolia. Quanto aos povoamentos de *Eucalyptus* spp. e *Pinus* spp., os mesmos demonstraram menor expressividade em termos de área ocupada dentro da FLONA no mapeamento de ambos algoritmos.

Figura 3 - Mapeamento das espécies florestais por meio da classificação manual (A) e dos algoritmos SVM (B), ANN (C) e RF (D) para a FLONA São Francisco de Paula



Fonte: Autora.

A quantificação das classes temáticas obtidas a partir da classificação manual e dos algoritmos de aprendizado de máquina de melhor desempenho na validação pode ser visualizada na Tabela 6. A classificação manual pode ser considerada como o parâmetro de referência na avaliação da qualidade das classificações obtidas por meio do algoritmo SVM, ANN e RF.

Tabela 6 – Quantificação das classes temáticas em hectares (ha) e seus respectivos percentuais obtidos na classificação manual e por meio dos algoritmos de aprendizado de máquina

Classes temáticas	Classificação manual		SVM		ANN		RF	
	ha	%	ha	%	ha	%	ha	%
FOM	858,60	53,17	868,77	53,80	894,78	55,41	882,69	54,66
<i>Araucaria angustifolia</i>	555,29	34,39	525,96	32,57	498,87	30,89	514,62	31,87
<i>Pinus</i> spp.	96,57	5,98	75,15	4,65	83,07	5,14	74,88	4,64
<i>Eucalyptus</i> spp.	32,04	1,98	31,77	1,97	38,43	2,38	43,29	2,68
Outros usos	72,28	4,48	113,13	7,01	99,63	6,17	99,30	6,15
Total	1614,78	100,00	1614,78	100,00	1614,78	100,00	1614,78	100,00

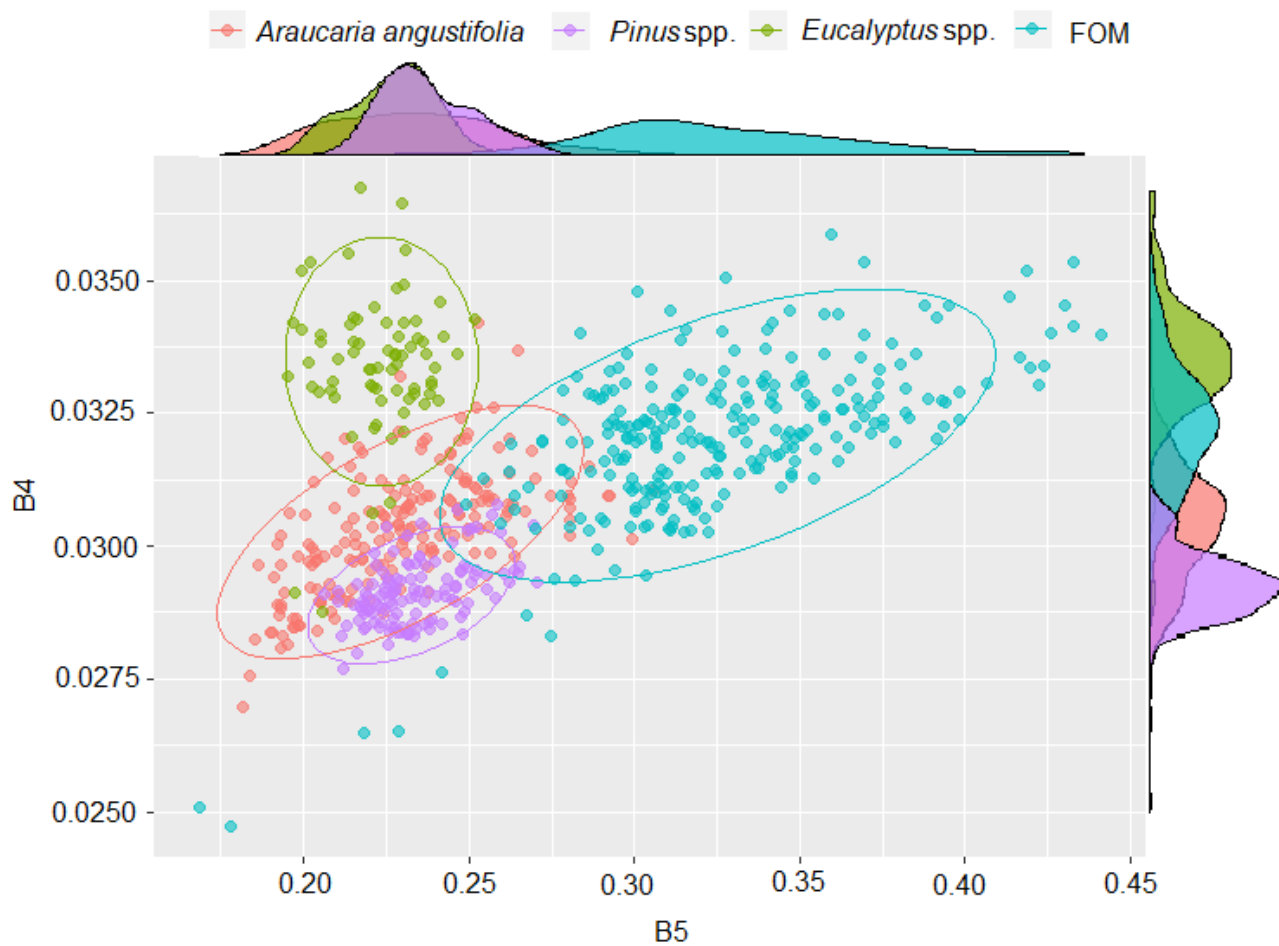
Fonte: Autora.

Corroborando os valores de acurácia, bem como o número de acertos visualizados na matriz de confusão, a quantificação das classes obtida pelo o algoritmo SVM foi mais similar à classificação manual se comparado aos demais classificadores. Os povoamentos florestais de *Eucalyptus* spp. foram facilmente identificados pelo algoritmo SVM, o qual quantificou 31,77 ha, equivalente a 1,97% para essa classe, enquanto que na classificação manual, a área registrada foi de 32,04 ha, correspondendo a 1,98% do total. Dentre os povoamentos florestais, observou-se maiores diferenças na identificação de *Araucaria angustifolia* e *Pinus* spp., respectivamente.

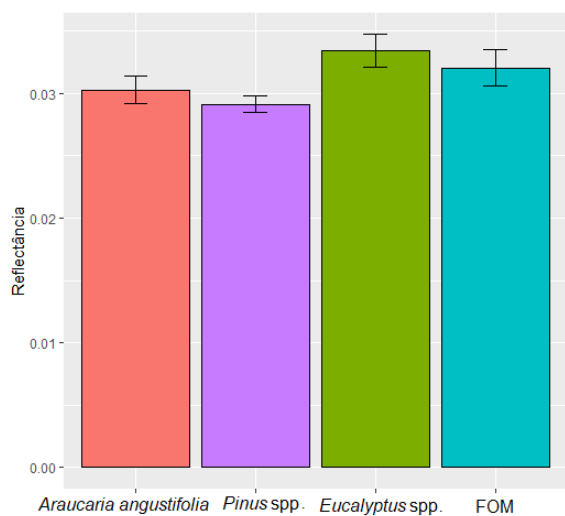
A fim de auxiliar no entendimento dos resultados apresentados no mapeamento e quantificação da cobertura florestal, a Figura 4 ilustra o comportamento da resposta espectral para os diferentes povoamentos florestais nas faixas do vermelho (B4) e infravermelho próximo (B5) do sensor OLI/Landsat 8, bem como os respectivos valores de média e desvio padrão.

Figura 4 - Reflectância das espécies florestais nas bandas B4 e B5 (a) e os valores de média e desvio padrão para as bandas B4 (b) e B5 (c)

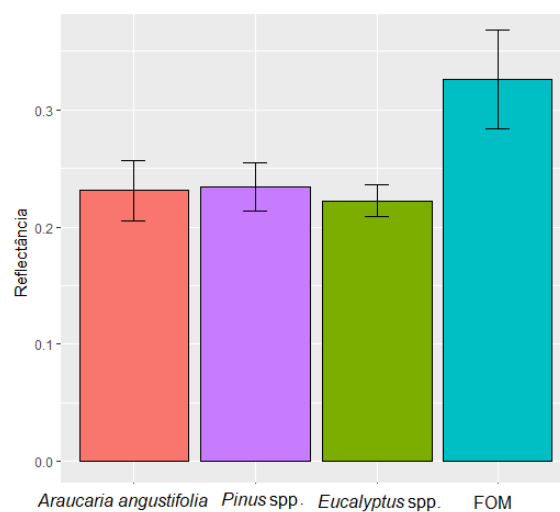
a)



b)



c)



Fonte: Autora.

Observou-se que a resposta espectral dos povoamentos considerando apenas as bandas B4 e B5 permitiram, de forma substancial, a diferenciação das espécies. Desse modo, a inclusão de outras faixas espectrais no modelo, bem como o uso de técnicas de inteligência artificial, maximizou o processo de classificação das imagens, permitindo o mapeamento dos povoamentos florestais de FOM, *Araucaria angustifolia*, *Pinus spp.* e *Eucalyptus spp.*

A banda B4 demonstrou melhor individualização dos povoamentos florestais quando comparado à banda B5, conforme pode ser visualizado na distribuição da densidade (Figura 4a), bem como nos valores médio e desvio padrão (Figura 4b). Assim, a inclusão dessa faixa do espectro eletromagnético nos modelos de predição é primordial para a identificação de espécies florestais.

Por outro lado, a banda B5 permitiu a diferenciação entre a floresta nativa e a floresta plantada, uma vez que as amostras oriundas da FOM (Floresta nativa), apresentaram valores mais elevados quando comparado as demais classes (plantios florestais), fato esse que favoreceu a distinção dessas diferentes coberturas. Assim, essa faixa espectral pode ser utilizada em estudos cujo objetivo seja a separação das áreas ocupadas pela cobertura florestal nativa e dos plantios florestais.

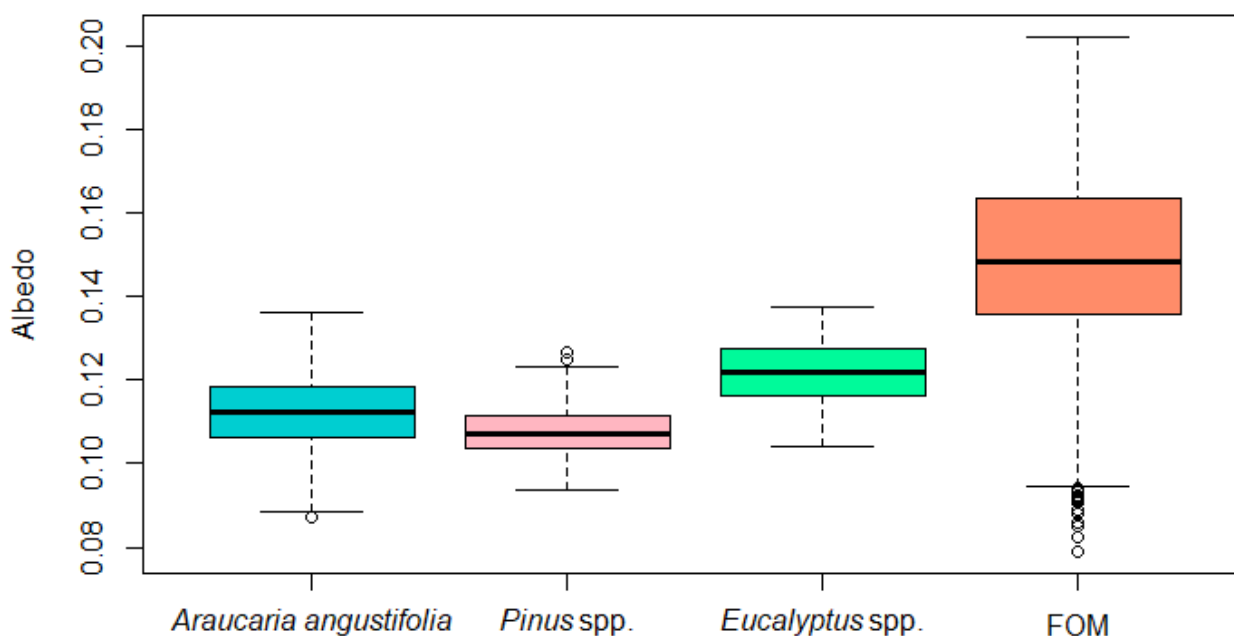
Dentre os povoamentos florestais, observou-se que os valores de reflectância das espécies de araucária e pinus apresentaram maior confusão que as demais classes (Figura 4b e c). Esse comportamento pode estar associado à sua estrutura de copa, mais densa que as espécies de folhosas, como é o caso da FOM, a qual apresenta um dossel heterogêneo com diferentes níveis de dossel.

Observou-se que os valores de média e desvio padrão das espécies de coníferas foram próximos entre si em ambas as faixas espectrais. Esse resultado demonstra que isoladamente, as bandas do sensor OLI/Landsat 8 não foram eficientes na identificação dessas espécies, necessitando a análise combinada das bandas. Corroborando com esses resultados, Murariu et al. (2017) descreve que quaisquer mudanças no status da vegetação não podem ser reduzidas e descritas apenas pelas mudanças no domínio infravermelho, necessitando da inclusão de outras faixas espectrais.

3.3 RELAÇÃO DO ALBEDO COM AS ESPÉCIES FLORESTAIS

Observou-se que a cobertura nativa da FLONA, a FOM, apresentou maior variação nos valores de albedo, demonstrando ainda a presença de *outliers* na análise do gráfico do tipo boxplot (Figura 5). Esse comportamento pode ser atribuído a grande mistura espectral nos *pixels* dessa classe, uma vez que a FOM apresenta um dossel heterogêneo composto de árvores de grande porte, como por exemplo, indivíduos de araucária, bem como de indivíduos de espécies do extrato médio e inferior da floresta.

Figura 5 – Relação apresentada entre a cobertura florestal e o albedo de superfície na FLONA de Francisco de Paula.



Fonte: Autora.

Ao analisar os povoamentos florestais, os quais são caracterizados por um dossel homogêneo, destaca-se que as espécies de coníferas, nesse estudo representadas por *Araucaria angustifolia* e *Pinus spp.*, apresentaram valores inferiores de albedo quando comparadas à espécie de folhosa e a composição florestal nativa da FLONA. A característica de copa das coníferas, com maior presença de ramos e consequentemente folhas/acículas, permite que maior quantidade de radiação incidente sobre a essa superfície seja absorvida para seus processos fotossintéticos,

ou seja, menor quantidade de REM retorna à atmosfera. Assim, esses resultados demonstram a grande contribuição da atividade florestal para a manutenção do balanço de energia planetária entre a superfície e a atmosfera, com vistas à manutenção de fatores (albedo) que influenciam o clima regional e global.

Os povoamentos florestais presentes na área de estudo são compostos por espécies de coníferas e folhosas. Nessa perspectiva, Kuusinen et al. (2013) identificou um albedo médio de 0,105 para florestas de coníferas, enquanto que espécies decíduas apresentaram um albedo de 0,143 em uma floresta boreal.

Lukes et al. (2014) estudaram o comportamento do albedo em florestas decíduas e coníferas, de modo que as maiores diferenças foram observadas durante o inverno decorrente da perda de folhas pelas espécies decíduas, enquanto que na primavera ficam menos evidentes as diferenças. No entanto, os autores demonstraram que o albedo de espécies coníferas foi sistematicamente inferior ao de decíduas durante todo o ano, sendo assim, esse estudo corrobora com os resultados obtidos ao analisar remanescentes da Mata Atlântica e as principais espécies florestais com fins econômicos no país.


Destaca-se ainda, que os valores de albedo da FOM apresentaram maior variabilidade quando comparados às demais espécies. Essa maior dispersão dos dados de albedo de superfície pode ser observada na Figura 6.

Ao analisar os valores de média e desvio padrão do albedo de superfície com relação às espécies florestais, os mesmos apresentaram comportamento similar ao observado com os valores de reflectância, uma vez que os valores expressados pela Araucária e Pinus se situaram próximos, conforme a Figura 6b. Assim, o albedo de superfície, como variável isolada, pode não diferir os povoamentos de coníferas englobadas pelo estudo. Por outro lado, baseando-se nos valores médios e desvios, o albedo pode ser indicado como uma variável potencial para a identificação de povoamentos de *Eucalyptus* spp. e a FOM.

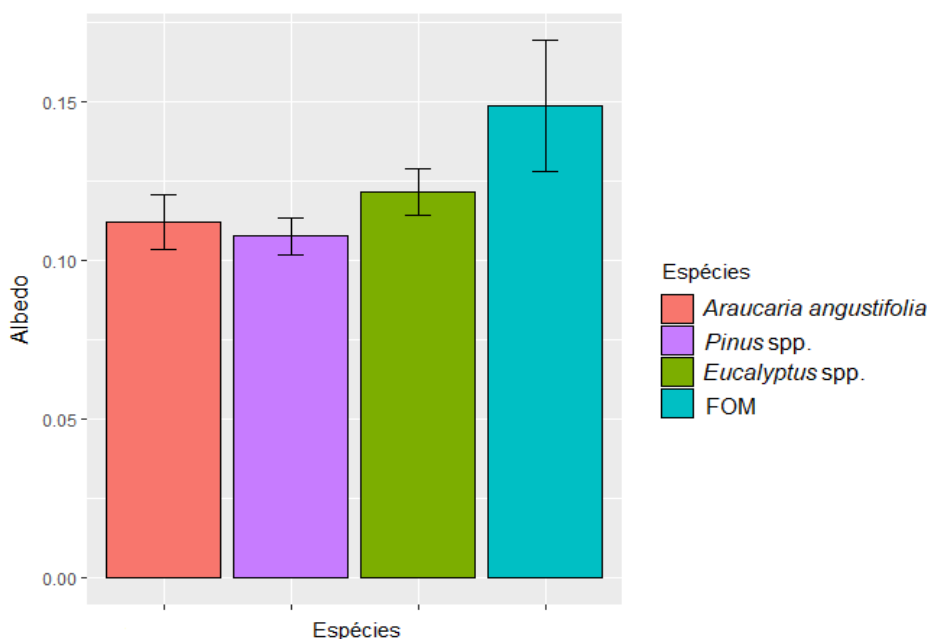
Nesse sentido, na Figura 7 pode-se visualizar o comportamento da B4, B5 e albedo de superfície, voltados à identificação das espécies florestais. Tanto a B5, quanto o albedo, mostraram-se eficientes na separação da floresta nativa dos povoamentos florestais. Enquanto a B4, demonstrou grande potencial para a identificação entre os povoamentos florestais. Desse modo, observou-se que a inclusão do albedo como variável explicativa pode agregar qualidade ao processo de classificação da floresta nativa com relação aos povoamentos florestais homogêneos.

Figura 6 - Distribuição dos valores de albedo para as espécies florestais (a) e seus respectivos valores médios e desvio padrão (b)

a)



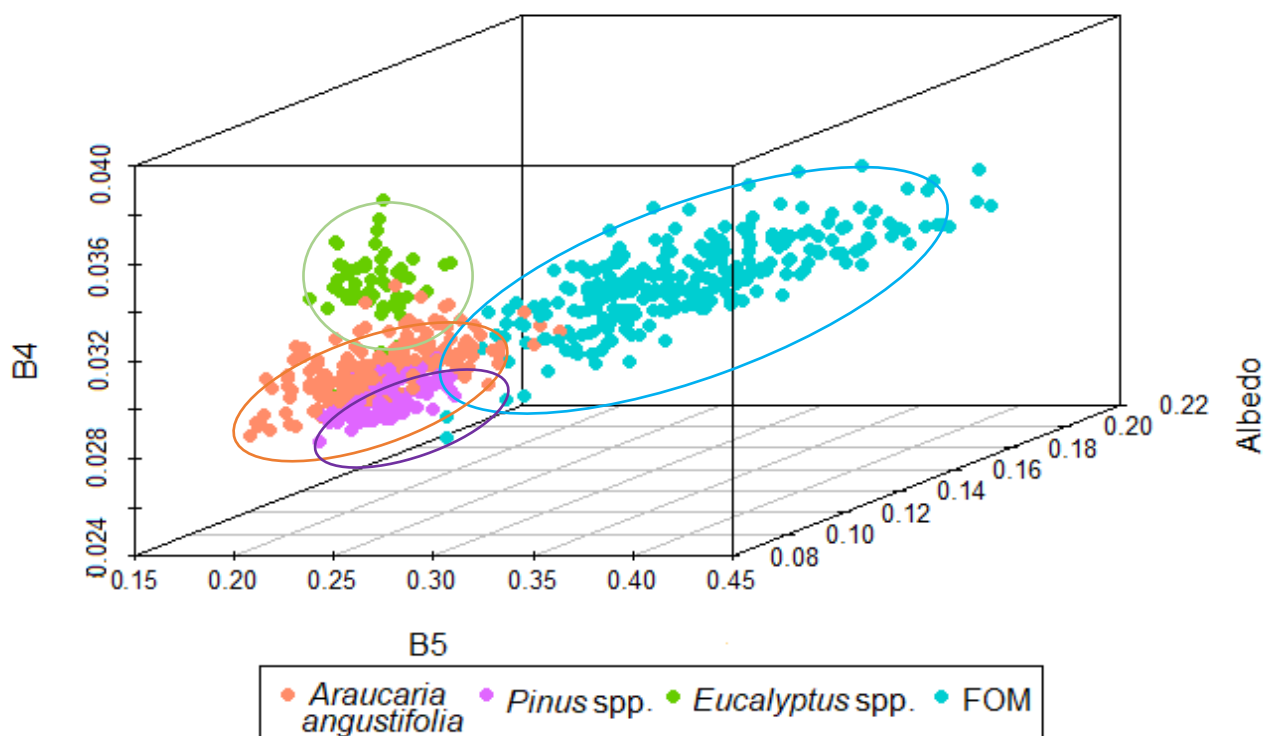
b)



Fonte: Autora.

Nesse âmbito, estudos sobre o albedo em florestas sob diferentes sistemas de manejo e composição florística, podem contribuir para desenvolver propostas de gerenciamento do setor florestal. Do mesmo modo, possibilita uma melhor avaliação das contribuições da silvicultura para o clima em escala local, avançando nas questões de sequestro de carbono (KUUSINEN et al., 2013).

Figura 7 - Relação da banda B4, B5 e do albedo de superfície para a identificação de espécies florestais



Fonte: Autora.

Esses resultados demonstraram o potencial uso do albedo como variável resposta sobre a estrutura da cobertura florestal, uma vez que o mesmo se mostrou sensível as variações da composição do dossel. Desse modo, o albedo de superfície pode ser incorporado como uma das variáveis de estudo no processo de classificação, bem como na modelagem de parâmetros estruturais da cobertura florestal nativa e/ou para o manejo de povoamentos florestais.

Assim como os índices de vegetação (NDVI, SAVI, IAF, entre outros) e índices de textura, o albedo de superfície apresenta uma infinidade de aplicações, possibilitando a soluções de problemas reais dentro das ciências florestais a partir do uso das geotecnologias disponíveis. As respostas obtidas das propriedades de interesse a partir da utilização do albedo como variável espectral podem ser mais efetivas com uso de técnicas disponíveis na área da inteligência artificial, como as aplicadas nesse estudo.

4 CONCLUSÃO

O uso de algoritmos de aprendizado de máquina para a identificação de povoamentos florestais, mostram-se eficientes, destacando-se os algoritmos SVM, ANN e RF, os quais apresentaram valores superiores para os parâmetros de Acurácia global e índice *Kappa*. Dentre esses algoritmos, o SVM apresentou estatísticas de precisão mais elevadas, entretanto, não diferiu significativamente do algoritmo ANN. Assim, ambos podem ser utilizados com eficiência na identificação da FOM e de povoamentos de *Araucaria angustifolia*, *Pinus* spp. e *Eucalyptus* spp.

Ao analisar as respostas da classificação supervisionada com o algoritmo SVM, observou-se que a identificação de povoamentos de *Araucaria angustifolia* apresentou maior confusão nesse processo, quando comparado às demais classes. Esses povoamentos foram, em parte, interpretados erroneamente como sendo povoamentos de *Pinus* spp.

Quanto a contribuição da cobertura florestal no albedo, observa-se que a floresta nativa, com dossel heterogêneo, apresenta valores de albedo mais elevados que os povoamentos florestais com dossel homogêneo, os quais absorvem maior quantidade da REM. Assim, os povoamentos florestais apresentam grande contribuição para o balanço de energia radiativa planetária.

Por fim, o presente estudo traz o albedo como uma possível variável a ser utilizada na modelagem de parâmetros da floresta, demonstrando grande potencial para o uso da mesma como ferramenta para estudos de diversas variáveis estruturais da cobertura florestal, bem como na identificação de espécies florestais. O albedo de superfície juntamente com as técnicas de inteligência artificial, proporcionam maior precisão nos produtos gerados por imagens gratuitas e de média resolução espacial, permitindo a realização de análises mais aprofundadas sobre a cobertura florestal e sua interação com o ambiente.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAM, E. M.; MUTANGA, O.; RUGEGE, D.; ISMAIL, R. Discriminating the papyrus vegetation (*Cyperus papyrus* L.) and its co-existent species using random forest and hyperspectral data resampled to HYMAP. **International Journal of Remote Sensing**, v. 33, n. 2, p. 552-569, 2012.

BIVAND, R.; KEITT, T.; ROWLINGSON, B. **rgdal**: Bindings for the Geospatial Data Abstraction Library. R package version 1.2-6. Disponível em: '<https://CRAN.R-project.org/package=rgdal>'. Acesso em 21 de dez. 2018.

BURGES, C. J. C. **A Tutorial on Support Vector Machines for Pattern Recognition**. Data Mining and Knowledge Discovery, 2, p.121-167, 1998. Disponível em: <<http://dx.doi.org/10.1023/A:1009715923555>>. doi: 10.1023/A:1009715923555

FACELI, K. et al. **Inteligência Artificial**: Uma abordagem de Aprendizado de Máquina. Rio de Janeiro: LTC, 2011, 396 p.

GAIAD, N. P. et al. Uso e cobertura da terra apoiados em algoritmos baseados em aprendizado de máquina: o caso de Mariana – MG. **Enciclopédia Biosfera**, v. 14, n. 25, p. 1212-1220, 2017.

GOMES, J. F. **Classificação e crescimento de grupos ecológicos na Floresta Ombrófila Mista da Flona de São Francisco de Paula, RS**. 2005. 89 p. Dissertação (Mestrado em Engenharia Florestal)-Universidade Federal de Santa Maria, RS, 2005.

HIJMANS, R. J. **Raster**: Geographic data analysis and modeling. R package version 2.5-8. Disponível em: '<https://CRAN.R-project.org/package=raster>'. Acesso em 21 de dez. 2018.

HUSSAIN, M. et al. Change Detection from Remotely Sensed Images: From Pixel-Based to Object-Based Approaches. ISPRS Journal of Photogrammetry and Remote Sensing 80 (June). **International Society for Photogrammetry and Remote Sensing**, p. 91–106, 2013.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE - ICMBIO. **Floresta Nacional de São Francisco de Paula/RS**. 2019. Disponível em:<<http://www.florestanacional.com.br/flonasaochico.html>>. Acesso em: 03 de Ago. 2019.

KUHN, M. **CARET: Classification and Regression Training**. R package version 6.0-71. Disponível em: '<https://CRAN.R-project.org/package=caret>'. Acesso em 21 de dez. 2018.

KUUSINEN, N; TOMPPONEN, E.; BERNINGER, F. Linear unmixing of MODIS albedo composites to infer subpixel land cover type albedos. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 324-333, 2013.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, v.33, n.3, p.159-179, 1977. Disponível em: <<http://dx.doi.org/10.2307/2529310>>. doi: 10.2307/2529310

LARY, D. J. et al. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016.

LEITÃO, M. M. V. B. R.; SANTOS, J. M. dos; OLIVEIRA, G. M. Estimativas do albedo em três Estimativas do albedo em três ecossistemas da floresta amazônica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.6, n.2, p.256-261, 2002.

LI, C. et al. Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. **Remote Sensing**, v 6, n. 2, p. 964–83. 2014. doi:10.3390/rs6020964.

LIAW, A. **Breiman and Cutler's Random Forests for Classification and Regression**. R package version 4.6-14. Disponível em: < <https://cran.r-project.org/web/packages/randomForest/randomForest.pdf>>. Acesso em 09 de ago. de 2019.

LUKES, P. et al. Multidecadal analysis of forest growth and albedo in boreal Finland. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 296-305, 2016. DOI: <http://dx.doi.org/10.1016/j.jag.2016.07.001>

MURARIU, G. et al. Forest monitoring method using combinations of satellite and UAV aerial images. Case study - Bălăbănești forest. **International Journal of Conservation Science**, v. 8, n. 4, p. 703 – 714, 2017.

PETROPOULOS, G. P.; ARVANITIS, K.; SIGRIMIS, N. Hyperion hyperspectral imagery analysis combined with machine learning classifiers for land use/cover mapping. **Expert Systems with Applications**, v. 39, n. 3, p. 3800-3809, 2012.

QIAN, Y. et al. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, v. 7, n. 1, p. 153 - 168, 2015. doi.org/10.3390/rs70100153

QGIS DEVELOPMENT TEAM, 2019. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <<http://www.qgis.org/>>. Acesso em: 22 dez. 2019.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2019. Recuperado de <http://www.R-project.org>.

SOUZA, C. G. et al. Algoritmos de aprendizagem de máquina e variáveis de sensoriamento remoto para o mapeamento da cafeicultura. **Boletim de Ciências Geodésicas**, v. 22, n. 4, p. 751-773, 2016.

THARWAT, A. Classification assessment methods. **Applied Computing and Informatics**, v. 21, 2018.

THIERSCH, A. **A eficiência das distribuições diamétricas para prognose da produção de Eucalyptus camaldulensis**. 1997. 155f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 1997.

VENABLES, W. N.; RIPLEY, B. D. **Modern Applied Statistics with S**. Nova Iorque: Editora: Springer-Verlag, 2002. 498p.

CAPÍTULO IV: ANÁLISE DE TENDÊNCIA DO ALBEDO NA COBERTURA FLORESTAL EM ÁREA DO BIOMA MATA ATLÂNTICA

RESUMO

O objetivo deste capítulo foi investigar a possível ocorrência e as causas associadas às tendências do albedo de superfície dentro do bioma Mata Atlântica durante trinta anos (1987 – 2017), avaliando a influência da estrutura da cobertura florestal na tendência do albedo. O estudo teve como base imagens do sensor TM/Landsat 5 e OLI/Landsat 8 ao longo do período de 1987 a 2017. O albedo de superfície foi obtido a partir do algoritmo SEBAL, o qual inclui em suas variáveis, os valores de reflectância de cada banda, a radiação solar refletida e transmissividade atmosférica. A análise de tendência foi realizada pelo teste Mann-Kendall verificando a existência de tendências significativas ao longo de 30 anos. Posteriormente, foi avaliada a influência do verdor da vegetação na tendência apresentada pelo albedo de superfície. Aproximadamente 92% dos pixels com tendência significativa estão associados a tendência decrescente do albedo. A tendência decrescente foi observada com a mudança do campo para a cobertura florestal, enquanto as tendências crescentes foram influenciadas pela alteração da cobertura florestal no período de monitoramento. Povoamentos florestais presentes em áreas do bioma Mata Atlântica possuem grande participação no balanço de energia, os quais expõem uma redução de aproximadamente 60% do albedo de superfície com sua implantação, evidenciando a sua importância para a redução da emissão de energia para a atmosfera. O padrão espacial da distribuição de tendências do albedo de superfície está relacionado com a concentração e vigor da vegetação arbórea.

Palavras-chave: Mann-Kendall. Floresta Nacional de São Francisco de Paula. Índice de vegetação.

ABSTRACT

The objective of this chapter was to investigate the possible occurrence and causes associated with surface albedo trends within the Mata Atlântica biome during the last thirty years (1987 - 2017), evaluating the influence of albedo trends on the structure of the forest cover. The study covered TM/Landsat 5 and OLI/Landsat 8 images over the period 1987 to 2017. The surface albedo was obtained from the SEBAL algorithm, which includes in its variables, reflectance values of each band, reflected solar radiation and atmospheric transmissivity. The trend analysis was performed by the Mann-Kendall test verifying the existence of significant trends over 30 years. Subsequently, was evaluate the influence of vegetation greenery on the trend presented by the surface albedo. Approximately 92% of the pixels with a significant tendency are associated with the decreasing tendency of the albedo. The decreasing trend was observed with the change from the field to the forest cover, while increasing trends were influenced by the change in forest cover in the monitoring period. Forest stands in areas of the Mata Atlântica biome have a large participation in the energy balance, which expose a reducing approximately 60% of the surface albedo with its

implantation, showing its importance for reducing the emission of energy to the atmosphere. The spatial pattern of the trend distribution of the surface albedo is related to the concentration and vigor of the arboreal vegetation.

Key-words: Mann-Kendall. National Forest of São Francisco de Paula. Vegetation index.

1 INTRODUÇÃO

Temáticas relacionadas às mudanças climáticas vêm sendo constantemente pauta de discussões internacionais ao longo das últimas décadas no intuito de estabelecer medidas que visem a redução da emissão de gases poluentes como também, encontrar medidas mitigatórias para esse problema. Neste contexto, as florestas apresentam relevância devido ao seu potencial de armazenamento e captura de poluentes da atmosfera.

A vegetação arbórea é mediadora entre o fluxo de energia da superfície terrestre e da atmosfera. Sendo assim, Davin e Noblet-Ducoudré (2010) consideram que as alterações ocorridas na cobertura vegetal podem interferir no ciclo das trocas de fluxos e conseqüentemente, influenciar o clima. Uma variável estreitamente relacionada ao balanço de radiação atmosférica corresponde ao albedo (LUKES et al., 2016).

Para Schaaf (2009), o albedo de superfície é uma das variáveis climáticas com maior relevância e, modificações nessa propriedade alteram o balanço de radiação e energia da superfície, os quais podem ser detectadas com o monitoramento dessa variável ambiental (SILVA et al., 2016). Planque et al. (2017) destacam que o albedo apresentado pela cobertura florestal representa uma variável importante para rastrear modificações na vegetação, de modo que alterações no verdor da vegetação têm mostrado influenciar os valores de albedo da superfície (TIAN et al., 2014). Desse modo, o Índice de Vegetação de Diferença Normalizado (*Normalized Difference Vegetation Index* – NDVI), obtido a partir da razão entre a diferença da reflectância na faixa do infravermelho próximo e da faixa do vermelho, avalia a variabilidade espectral e as mudanças nas taxas de crescimento da vegetação. Este índice está relacionado a quantidade e condição da vegetação verde (MATOS et al., 2015).

A observação regular de um fenômeno proporciona a reconstrução do contexto histórico da evolução da cobertura da terra na escala da paisagem a partir da

continuidade temporal (ZHAI et al., 2014, ZHANG et al., 2019). Assim, as imagens orbitais fornecem informações sobre a superfície terrestre em escala local, regional e global, evidenciando possíveis alterações na variável de interesse. O uso de séries temporais para estimativa do albedo a partir de imagens MODIS ou Landsat podem capturar a dinâmica da superfície terrestre de alta similaridade com dados de campo coletado a partir da instalação de torres (WANG et al., 2017). O monitoramento da vegetação com sistemas sensores em longos períodos de tempo é fundamental para obter uma melhor compreensão dos processos relacionados à mudança da mesma (YIN et al., 2012).

Associado as informações disponíveis em séries temporais, a análise de tendência permite o conhecimento do comportamento de um determinado fenômeno ao longo do tempo. Essa análise é frequentemente utilizada para identificar variações significativas em séries de variáveis ambientais como precipitação (MENEZES e FERNANDES, 2016; DURÃES et al., 2016), temperatura (SALVIANO et al., 2016; WANDERLEY et al., 2016), evapotranspiração (ALENCAR et al., 2011), cobertura vegetal (NEETI e EASTMAN, 2011; LUKES et al., 2016; PLANQUE et al., 2017), dentre outras.

Para Alencar et al. (2014), a análise de tendência refere-se à alteração tanto contínua quanto sistemática, observada em uma série temporal, a qual descreve o grau de acréscimo ou decréscimo dos dados ao longo de um período. Do mesmo modo, Some'e et al. (2012) ressalta que a presença de tendências em séries temporais pode demonstrar o comportamento dos dados observados frente a um fenômeno ambiental. Para a caracterização de tendências de fenômenos ambientais é frequentemente utilizada uma abordagem não paramétrica devido à sua capacidade de se determinar o comportamento das variáveis (WAGNER et al., 2013).

Nesse sentido, a identificação de tendências do albedo em áreas ocupadas com cobertura florestal torna-se importante para elucidar as contribuições da vegetação no fluxo de radiação para atmosfera. Desse modo, a Mata Atlântica é um dos ecossistemas mais ricos do mundo, sendo composto por formações florestais e ecossistemas associados (MMA, 2017), contribuindo significativamente para a captura de poluentes da atmosfera, sendo primordial o seu acompanhamento ao longo dos anos. Visando a preservação desses ecossistemas, criou-se as áreas prioritárias para a conservação da biodiversidade, em que parte da Floresta Nacional (FLONA) de São Francisco de Paula é abrangida pela Reserva da Biosfera da Mata Atlântica

como Área Núcleo, sendo considerada uma região de “alta” a “altíssima prioridade” para a conservação (MMA, 2002). A FLONA é uma unidade de conservação de uso sustentável, a qual caracteriza-se como uma área de cobertura florestal nativa associada a plantios florestais e campo nativo.

Os plantios florestais têm sido propostos como estratégia para mitigar as mudanças climáticas, sendo que os benefícios climáticos geralmente são avaliados em termos de potencial de sequestro de carbono, ignorando os processos biofísicos (NABUURS et al., 2007). Entretanto, os impactos das variáveis biofísicas como o albedo, são cruciais para analisar as respostas das mudanças da cobertura da terra (*Land Cover Changes - LUCC*) sobre o clima (PLANQUE et al., 2017), especialmente no caso de florestas tropicais como a Mata Atlântica.

O objetivo deste capítulo foi investigar a possível ocorrência e causas associadas as tendências do albedo de superfície dentro do bioma Mata Atlântica durante trinta anos (1987 – 2017), avaliando a influência da estrutura da cobertura florestal na tendência do albedo.

2 MATERIAL E MÉTODOS

2.1 DADOS ESPECTRAIS

A área de estudo corresponde a FLONA de São Francisco de Paula, a qual está situada entre as coordenadas 29°27'29,91" a 29°23'20,96" de latitude Sul e 50°24'53,47" a 50°22'39,01" de longitude Oeste. A área foi monitorada ao longo de 30 anos, sendo observado anualmente o período de verão entre 1987 a 2017. Os dados espectrais utilizados neste capítulo correspondem às imagens dos sensores TM/Landsat 5 e OLI/Landsat 8 os quais apresentam uma resolução espacial de 30 m.

A partir das imagens TM/Landsat 5 e OLI/Landsat 8 foi estimado o albedo de superfície por meio da Equação 1. O albedo foi calculado seguindo o modelo SEBAL, proposto por Bastiaanssen (1995), em que o albedo atmosférico (α_{atm}) pode ser obtido por meio de um modelo de transferência radiativa, situando entre 0,025 e 0,04 (ALLEN et al., 2002), sendo recomendado o valor de 0,03 para o modelo SEBAL (LIBERATO, 2011; SILVA et al., 2016). A transmissividade para condições de céu claro é descrita por Allen et al. (2002) conforme ilustra essa Equação 2.

$$\alpha = \frac{\alpha_{toa} - \alpha_{atm}}{\tau_{oc}^2} \quad (1)$$

Em que:

α = albedo de superfície;

α_{toa} = albedo no topo da atmosfera (planetário);

α_{atm} = albedo atmosférico; τ_{oc}^2 é a transmitância atmosférica.

$$\tau_{oc} = 0,35 + 0,627 \exp \left[-\frac{0,00146P_o}{K_t \cos Z} - 0,075 \left(\frac{W}{\cos Z} \right)^{0,4} \right] \quad (2)$$

Em que:

P_o = pressão atmosférica local (kPa);

K_t = coeficiente de turbidez do ar (1,0 é para o ar limpo e 0,5 é para ar extremamente turvo ou poluído);

Z = ângulo zenital;

W = precipitação da água (mm): $W = 0,14 e_a P_o + 2,1$;

e_a = pressão parcial do vapor de água atmosférico (kPa).

O α_{toa} foi obtido atribuindo pesos a cada uma das bandas, sendo que para as imagens do sensor TM/Landsat 5 foram utilizados os seguintes pesos: $0,293\rho_1 + 0,274\rho_2 + 0,233\rho_3 + 0,157\rho_4 + 0,033\rho_5 + 0,011\rho_7$, correspondendo as bandas 1, 2, 3, 4, 5 e 7. Entretanto, para as imagens do sensor OLI/Landsat 8 os pesos foram $0,300\rho_2 + 0,276\rho_3 + 0,233\rho_4 + 0,143\rho_5 + 0,035\rho_6 + 0,0119\rho_7$ para as bandas 2, 3, 4, 5, 6 e 7, respectivamente.

2.2 RELAÇÃO DO ALBEDO COM O VERDOR DA VEGETAÇÃO

Visando relacionar o verdor da vegetação com a variação dos valores de albedo de superfície, utilizou-se o índice de vegetação NDVI. Os índices de vegetação exploram as propriedades espectrais da vegetação, principalmente nas regiões do vermelho e do infravermelho próximo. Contudo, vegetações densas refletem pouco na região do vermelho, assim foi desenvolvido por Rouse et al. (1974) o NDVI, apresentando um intervalo de -1 a +1, obtido pela notação matemática descrita na Equação 3. Esse índice de vegetação é amplamente conhecido e utilizado para o monitoramento da vegetação, uma vez que se relaciona ao vigor vegetativo da mesma.

$$\text{NDVI} = \frac{\rho_{\text{IVP}} - \rho_{\text{V}}}{\rho_{\text{IVP}} + \rho_{\text{V}}} \quad (3)$$

Em que:

ρ_{IVP} = reflectância na região do infravermelho próximo;

ρ_{V} = reflectância na região do vermelho.

2.3 ANÁLISE DE TENDÊNCIAS

Para identificar as tendências nas séries temporais foi empregado o teste estatístico não paramétrico Mann-Kendall (KENDALL, 1975; MANN, 1945), indicado pela *World Meteorological Organization* (WMO) para análises de variáveis ambientais como o albedo. O teste de tendência Mann-Kendall foi aplicado na série temporal das imagens Landsat, observando um período de 30 anos e considerando um nível de significância de 5%.

A estatística do teste Mann-Kendall considera a hipótese nula (H_0) quando os dados vêm de uma população na qual as variáveis aleatórias são independentes e identicamente distribuídas. Por outro lado, a hipótese alternativa (H_1) representa a existência de tendência monotônica (VILANOVA, 2014).

A variável S aplicada para uma série de n dados do teste de Mann-Kendall foi obtida a partir da soma dos sinais da diferença, realizada para cada um dos pares, de todos os valores da série (x_i) em relação aos valores que a eles são futuros (x_j). A Equação 4 e 5 demonstram essa operação.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sinal}(x_j - x_i) \quad (4)$$

Em que:

S = estatística do teste Mann-Kendall;

n = número de elementos da série temporal - o sinal é a diferença dos valores de albedo subsequentes;

x_i = valores da série;

i e j = índices de tempo.

$$\text{sinal}(x_j - x_i) = \begin{cases} +1 & \text{se } (x_j - x_i) > 0 \\ 0 & \text{se } (x_j - x_i) = 0 \\ -1 & \text{se } (x_j - x_i) < 0 \end{cases} \quad (5)$$

Para conjunto de dados sem elementos vinculados (valores iguais), a estatística S do teste apresenta média $E(S)$ e variância $Var(S)$ conforme exposto na Equação 6 e 7. A significância do teste de tendência é verificada por meio do teste bilateral, a partir da estatística padronizada Z (Equação 8).

$$E[S] = 0 \quad (6)$$

$$Var[S] = \frac{[n(n-1)(2n+5)]}{18} \quad (7)$$

$$Z = \begin{cases} \frac{(S-1)}{\sqrt{Var(S)}} & \text{se } S > 0 \\ 0 & \text{se } S = 0 \\ \frac{(S+1)}{\sqrt{Var(S)}} & \text{se } S < 0 \end{cases} \quad (8)$$

Com base na análise de estatística Z , é realizada a decisão de aceitar ou rejeitar H_0 . Assim, se confirmar a existência de tendência nos dados, rejeita-se a hipótese nula (WANDERLEY et al., 2016). A estatística Z segue a distribuição normal padrão com média zero e variância 1. Um valor Z positivo indica uma tendência crescente, enquanto um valor negativo indica uma tendência decrescente. A probabilidade (p -valor) representa a medida observada para rejeitar a hipótese nula (ALENCAR et al., 2014).

Posteriormente, foi realizada a análise pontual em áreas que apresentaram tendência quando avaliado o albedo de superfície. A amostra englobou 20 unidades (*pixels*) com tendência crescente e decrescente, respectivamente. Do mesmo modo, foi observado nesses pontos os valores de NDVI a fim de relacionar as duas variáveis. Para essas amostras foi realizada a análise da estatística padronizada de Mann-Kendall assim como a estimativa de inclinação de Sen.

2.4 TESTE DE INCLINAÇÃO DE SEN

O teste de Mann-Kendall não fornece a magnitude das tendências detectadas. Dessa forma, o estimador de declive proposto por Sen (1968) pode ser utilizado de forma combinada com a análise de tendência indicando o grau de inclinação dos

dados, seja ela crescente ou decrescente (Equação 9). Na estimativa do declive (Q) as variáveis X_i e X_j são valores da variável em estudo nos anos i e j .

$$Q_i = \frac{X_j - X_i}{j - i} \quad \text{com} \quad i < j \quad (9)$$

Em que X_i e X_j são os valores da variável em estudo nos anos i e j . Os valores positivos indicam tendência crescente, enquanto que valores negativos descrevem uma tendência negativa. Se há n valores na série analisada, então o número de pares estimados de Q é dado por $N = n(n - 1)/2$, em que n é o número de período de tempo. O estimador de declive de Sen é a mediana dos N valores de Q_i .

A análise de tendência foi desenvolvida em linguagem de programação R versão 3.6.1 (R DEVELOPMENT CORE TEAM, 2019). Entretanto, o *software* QGIS versão 2.16.3 (QGIS DEVELOPMENT TEAM, 2019) foi utilizado para o recorte da área de estudo e a reprojeção das imagens.

3 RESULTADOS E DISCUSSÃO

3.1 VARIAÇÃO DO ALBEDO NO PERÍODO DE 30 ANOS

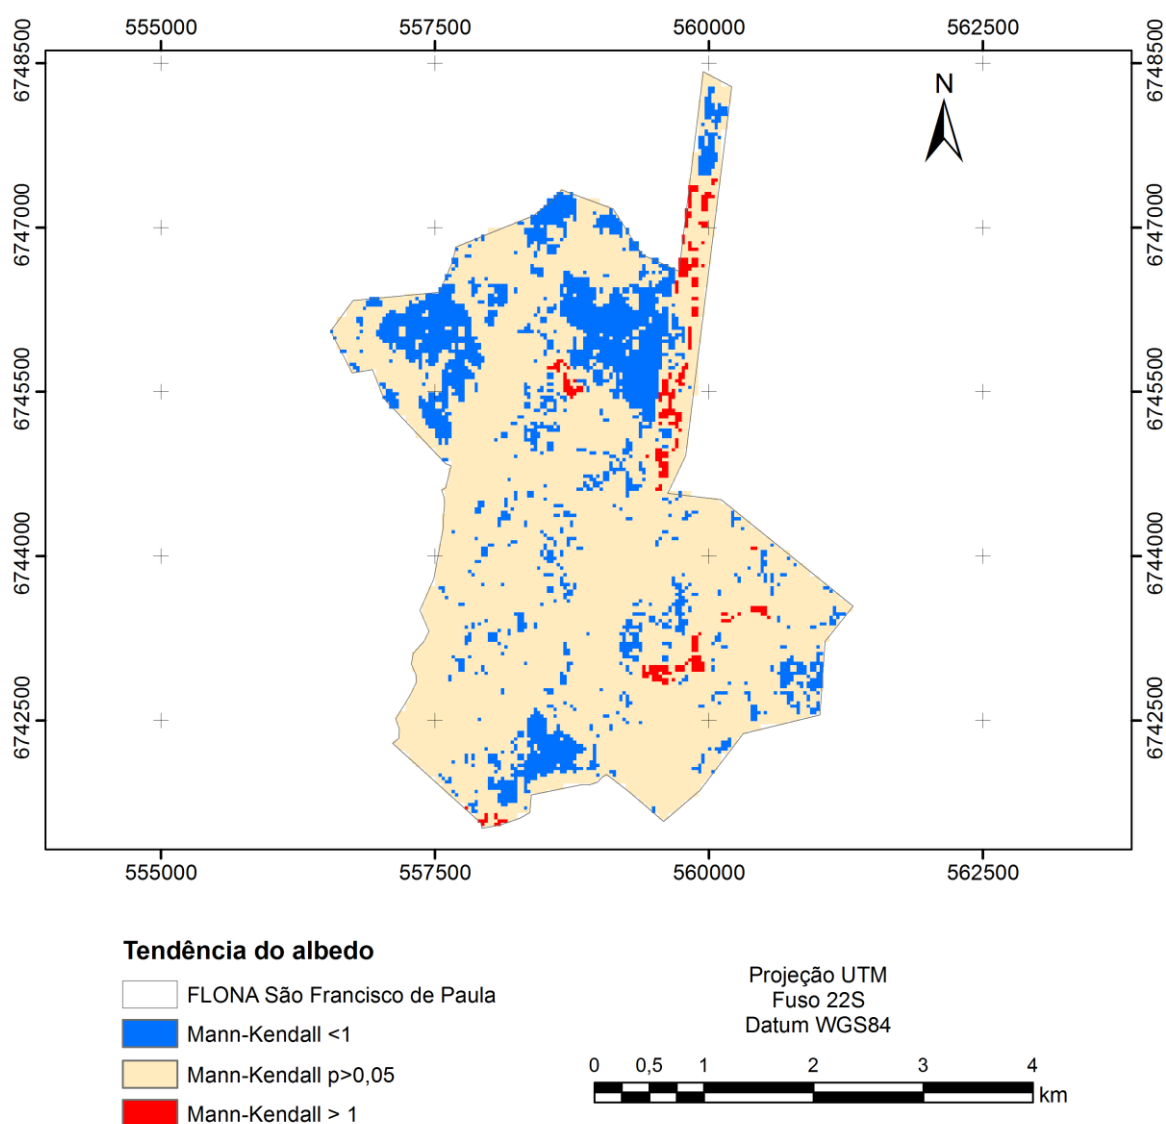
Após a análise do albedo ao longo de 30 anos foi aplicado o teste de tendência buscando padrões no comportamento do albedo ocorridos durante o período observado. Para cada pixel foi realizado o teste Mann-Kendall considerando a série de verão de 1987 a 2017. Na Figura é possível observar os pontos em que a hipótese nula de ausência de tendência na série foi rejeitada ao nível de significância de 5% para o albedo de superfície.

As alterações significativas do albedo estão indicadas em azul e vermelho, correspondendo a tendência decrescente e crescente, respectivamente. O ajuste de um modelo linear simples aos valores de albedo de superfície anuais evidenciou predomínio de variações não significativas (p -valor $> 0,05$) para a FLONA de São Francisco de Paula.

A área de estudo envolveu 17.496 *pixels*, sendo que deste total 13.899 *pixels* apresentaram tendência não significativa ($p > 0,05$), enquanto que 3.597 *pixels* mostraram tendência significativa, correspondendo a 20,6% dos pixels da imagem.

Dentre os pixels significativos, 3.303 pixels foram identificados com tendência negativa do albedo, equivalente a 18,9% da área de estudo, enquanto que 294 pixels evidenciaram tendência positiva, correspondendo a 1,7% (Tabela 1). Assim, 91,8% dos pixels significativos apresentaram tendência decrescente do albedo de superfície.

Figura 1 – Evolução da tendência do albedo para o período de verão de 1987-2017 para a FLONA de São Francisco de Paula



Fonte: Autora.

Em estudo desenvolvido por Planque et al. (2017), analisando a tendência do albedo na França com dados obtidos do sensor Modis, observaram que aproximadamente 3,5% da área de estudo apresentou tendência significativa, sendo

que deste total, 94% dos *pixels* foram identificados com tendência decrescente. Do mesmo modo, Salviano et al. (2016) quando analisaram a tendência da precipitação no Brasil, identificaram que mais de 70% do território brasileiro não apresentou tendências significativas.


Tabela 1 – Análise do total de *pixels* com tendência nos valores de albedo no período de verão de 1987-2017 para a FLONA de São Francisco de Paula

Análise da Tendência	Número de pixels	Área ocupada	
		ha	%
Tendência decrescente	3.303	300,06	18,90
Tendência não significativa	13.899	1.287,00	79,40
Tendência crescente	294	27,72	1,70

Fonte: Autora.

Para as amostras com decréscimo temporal, o albedo de superfície variou entre 0,2139 (1991) e 0,0930 (2007), apresentando um valor médio de 0,1457 (Figura 2a). O teste de estimador de inclinação de Sen identificou um valor de declive de 0,0038 para a amostra com tendência decrescente, ou seja, uma queda dos valores de albedo de superfície ao longo do período de estudo de 0,114 (Inclinação de Sen multiplicado pelo período). Portanto, uma diminuição do albedo de aproximadamente 60% entre 1987 a 2017.

Figura 2 – Tendências apresentada pelo albedo de superfície entre 1987 a 2017 em locais com tendência decrescente (a) e crescente (b)



Fonte: Autora.

As áreas amostradas com inclinação positiva do albedo expressaram uma relação significativa de 0,03099, apresentando um valor mínimo de 0,0850 em 1997, enquanto que o ano de 2017 expressou o valor máximo, sendo esse de 0,1305 (Figura 2b). A inclinação para as amostras com tendência crescente segundo o teste de declive de Sen foi de 0,00073, representando um acréscimo de 0,0219 nos valores de albedo no período observado.

Assim, as amostras com tendência positiva apresentaram um aumento de 19,6% no albedo ao longo dos últimos 30 anos. De modo geral, a variação das amostras no sentido crescente foi menos acentuada que o demonstrado pelas amostras em decréscimo.

Um exame mais aprofundado, com o auxílio de imagens de alta resolução espacial disponíveis no *GoogleEarth Pro™* (GOOGLE INC., 2018), constatou que os pontos amostrados com tendência decrescente correspondem a áreas que no início do monitoramento (1987) eram ocupadas por campo nativo. Entretanto, posteriormente essa cobertura foi substituída por povoamentos homogêneos de *Pinus* spp. Essa mudança na cobertura resultou em uma alteração no padrão da curva espectral do albedo, o qual passou a apresentar uma tendência decrescente ao longo do período observado.

Assim, observa-se um decréscimo no período do verão, próximo a 60% na radiação refletida ou emitida para a atmosfera na área de estudo ao implantar plantios florestais. Esses resultados corroboram com o estudo desenvolvido por Planque et al. (2017) em florestas lenhosas, os quais identificaram a diminuição do albedo devido ao maior grau de desenvolvimento da vegetação arbórea. Comportamento similar foi observado por Davin e Noblet-Ducoudré (2010), os quais detectaram que a ausência de cobertura florestal resulta no aumento dos valores de albedo de superfície.

Em pontos amostrados com tendência crescente do albedo foi observado alterações na composição da vegetação. Embora as áreas apresentassem cobertura vegetal ao longo do período observado, ocorreram modificações quanto a sua estrutura. Esses locais no início do monitoramento estavam ocupados por povoamentos florestais homogêneos com estrutura de dossel bem formado, entretanto, foram substituídos pela cobertura natural referente a fitofisionomia Floresta Ombrofila Mista ou Mata de Araucária, a qual possui desenvolvimento lento e com influência do sub-bosque na resposta espectral da vegetação, especialmente nos anos iniciais de sua implantação. O histórico das mudanças na cobertura da Flona


corroborar com os baixos valores de albedo de superfície identificados, os quais são associados à cobertura florestal (albedo inferior a 14%).

Com esses resultados, observou-se que o aumento da cobertura vegetal influencia diretamente nos valores de albedo, entretanto a estrutura da floresta também apresenta relação com a variação dessa variável. Assim, foi analisada a evolução temporal do NDVI para compreender os fenômenos que ocorrem nas áreas de cobertura florestal.

3.2 RELAÇÃO DO ALBEDO COM O ÍNDICE NDVI

Observou-se uma relação inversamente proporcional entre o albedo de superfície e o NDVI (verdor da vegetação), uma vez que ocorreu a diminuição do albedo de superfície com o aumento dos valores de NDVI, sendo esse comportamento mais acentuado nos últimos anos do monitoramento (Figura 3). O NDVI apresentou uma relação significativa (p -valor = 0,00731) expressando uma inclinação de 0,0036, ou seja, um aumento de 0,108 nos valores de NDVI entre os anos de 1987 a 2017.

Figura 3 – Relação entre o verdor da vegetação (NDVI) e o albedo de superfície com tendência decrescente ao longo de 30 anos



Analisando o comportamento das variáveis ao longo de 30 anos, observou-se que o albedo e NDVI no período de 1998 a 2003 apresentaram valores próximos entre si. Entretanto, a partir de 2003 observou-se uma mudança no comportamento assumido por essas variáveis, evidenciando a relação inversa.

Conforme descrito acima, a área inicialmente abrigava campo nativo, caracterizado por vegetação esparsa, com influência do solo exposto na resposta espectral, porém atualmente as imagens demonstraram um aumento significativo da vegetação e por consequência, aumento nos valores de NDVI, enquanto que os valores de albedo apresentaram uma redução gradual. A partir de 2004, o distanciamento entre as curvas foi mais acentuado devido a inexistência de mudanças abruptas nos índices de verdor da vegetação nos pontos amostrados.

Imagens de alta resolução espacial disponíveis no *GoogleEarth Pro™* (GOOGLE INC., 2018) confirmaram a mudança da cobertura em que o Campo nativo cedeu espaço para os Plantios florestais nos *pixels* amostrados com inclinação negativa. Nesse sentido, ao relacionar o albedo de superfície com o índice NDVI foi possível identificar, informações sobre mudanças abruptas na cobertura da área, a qual explica as variações na componente ambiental, o albedo.

Esse resultado vem ao encontro do estudo desenvolvido por Planque et al. (2017), os quais observaram uma correlação quase que exata entre o aumento do NDVI e diminuição do albedo a partir do albedo do produto MODIS para a cobertura florestal da França. Os autores verificaram que os pixels estudados correspondiam a áreas florestais predominantemente ocupadas por espécies latifoliadas.

A correlação negativa entre o albedo estimado por sensores orbitais e propriedades da vegetação foi constatada em outros estudos de florestas coníferas boreais (HOVI et al., 2017). Lukes et al. (2016) analisaram a relação entre a densidade florestal e o albedo a partir de dados do sensor MODIS, identificando correlações lineares negativas relativamente fortes entre a densidade florestal e o albedo na faixa do visível.

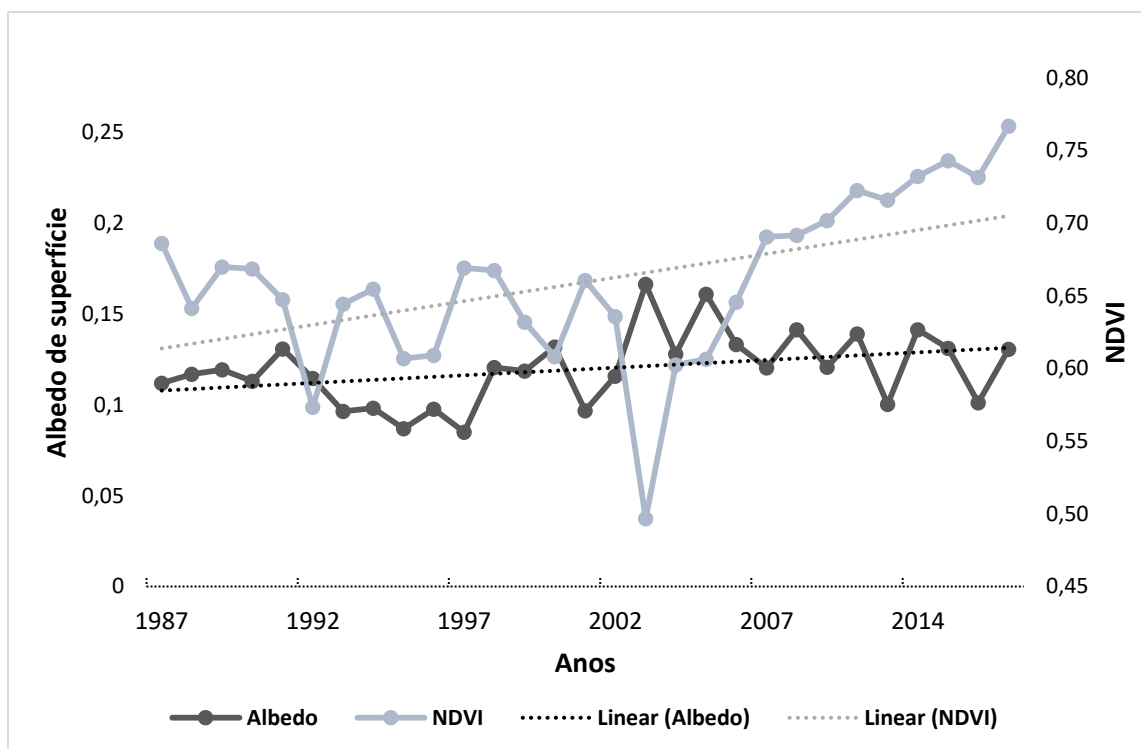
Para Otto et al. (2014), o albedo é sensível ao manejo florestal. Durante o ciclo vegetativo o albedo do dossel é regido pela composição de espécies arbóreas, se estendendo até o estabelecimento do dossel, a partir dessa etapa, o albedo é conduzido pelo manejo florestal.

Desse modo, o fenômeno que ocorreu em áreas de Floresta Ombrófila Mista da Mata Atlântica pode estar relacionado a estrutura do dossel, uma vez que com o

desenvolvido dos povoamentos, as copas se tornam mais densas e com isso ocorre a diminuição do albedo estimado por dados Landsat. Com o desenvolvimento de uma floresta, a estrutura de dossel evolui atingindo um nível hierárquico superior com maior número de brotos e galhos, acarretando em maior absorção da energia incidente e consequentemente diminuição do albedo (PLANQUE et al., 2017).

Para os pontos com tendência crescente do albedo, o NDVI evidenciou uma relação significativa ao nível confiança de 5%, expressando um p-valor de 0,0000043 com uma inclinação de 0,0050 correspondendo à 0,15 no período de análise. Do mesmo modo, nessa condição foi identificada a relação do verdor da vegetação com as alterações dos valores de albedo (Figura 4). Neste cenário, até o ano de 2001 o comportamento entre as variáveis foi similar, porém no ano de 2003 identificou-se uma quebra nos valores de NDVI, sendo que por fim, a partir de 2006 percebeu-se uma redução gradual dos valores de albedo associado a um acréscimo nos valores de NDVI.

Figura 4 – Relação entre o verdor da vegetação (NDVI) e o albedo de superfície com tendência crescente ao longo de 30 anos



Fonte: Autora.

Os *pixels* com tendência crescente de albedo englobaram ao longo do período estudado áreas destinadas a cobertura florestal, porém nos anos iniciais do monitoramento, observou-se valores similares entre o albedo e o NDVI, podendo ser atribuído ao fato dos povoamentos florestais estarem com a estrutura de dossel formada e sem mudanças estruturais, desse modo não apresentando tendência significativa do NDVI. Assim, em 2003 observou-se uma mudança abrupta no verbor da vegetação associada ao aumento do albedo.

Embora não se tenha imagens de alta resolução dessa data, é possível inferir que nesse período (2003) possa ter ocorrido o corte dos indivíduos e a partir de então o desenvolvimento gradual da floresta nativa, o que corrobora o comportamento do albedo e do NDVI após essa data: aumento do NDVI com o desenvolvimento da floresta, enquanto expressou uma redução dos valores de albedo de superfície. Assim, ao dar sequência no monitoramento da área poderá ser identificado um comportamento decrescente mais acentuado do albedo decorrente do desenvolvimento da estrutura da floresta nativa.

Neste sentido, a composição de espécies influencia na resposta espectral da cobertura florestal. A Floresta Ombrófila Mista é a cobertura nativa da FLONA sendo composta por espécies de coníferas e folhosas. Lukes et al. (2016) realizaram uma análise separadamente para espécies de coníferas e decíduas a partir de uma máscara. Desse modo, observaram que as áreas ocupadas, predominantemente por espécies decíduas, apresentavam um albedo maior que as áreas com coníferas associada à valores inferiores de NDVI. Assim, o NDVI é um índice de vegetação importante e amplamente utilizado em análises multidisciplinares e suas informações em grande escala espaço-temporal, representando um importante indicador da oscilação e sucessão do ecossistema terrestre (HOU et al., 2012). Segundo Gandhi et al. (2015), o índice NDVI pode ser aplicado para examinar a relação entre a variabilidade espectral e as mudanças nas taxas de crescimento da vegetação devido a sua relação com essas propriedades.

Nesse sentido, confirma que a vegetação arbórea remanescente do bioma Mata Atlântica corresponde a um importante receptor e armazenador de radiação solar decorrente de sua ação de absorção da maior parte da energia incidente. Ressaltando ainda, a importância da cobertura florestal para a manutenção do fluxo

de energia entre a superfície e a atmosfera tendo grande influência, especialmente, sob os fatores que interferem no clima local.

4 CONCLUSÃO

Aproximadamente 92% dos *pixels* com tendência significativa estão associados a tendência decrescente do albedo de superfície. O teste de Mann-Kendall revelou a existência de inclinação negativa para *pixels* onde o Campo nativo foi substituído por Plantios florestais quando observado um período de 30 anos.

Desse modo, o estudo demonstra que os povoamentos florestais presentes em áreas do bioma Mata Atlântica apresentam grande participação no balanço de energia, os quais expõem uma redução de aproximadamente 60% do albedo de superfície no período de verão com sua implantação, evidenciando a sua importância para a redução da emissão de energia para a atmosfera.

Identificou-se um padrão espacial da distribuição de tendências do albedo de superfície ao longo da área de estudo, o qual está relacionado à concentração e vigor da vegetação arbórea. Análises complementares sobre o verdor da vegetação obtido com base no índice NDVI sugerem que essa variável climática é regida pelas alterações significativas do NDVI (p -valor $<0,05$), causada pela implantação da cobertura florestal. Assim, o NDVI pode ser utilizado como uma variável indicadora do albedo de superfície para florestas tropicais como a Mata Atlântica.

REFERÊNCIAS BIBLIOGRÁFICAS

ALENCAR, L. P. et al. Tendências recentes nos elementos do clima e suas implicações na evapotranspiração da cultura do milho em Viçosa – MG. **Engenharia Agrícola**, Jaboticabal, v. 31, n. 4, p. 631-642, 2011.

ALENCAR, L. P. et al. Variação temporal dos elementos climáticos e da ETo em Catalão, Goiás, no período de 1961-2011. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 8, p. 826-832, 2014. DOI: <http://dx.doi.org/10.1590/1807-1929/agriambi.v18n08p826-832>.

ALLEN, R. et al. Surface energy balance algorithms for land (SEBAL), Idaho implementation – Advanced training and users manual, version 1.0, 2002, 97 p.

BASTIAANSEN, W. G. M. et al. Remote sensing surface energy balance algorithm for land (SEBAL) - Formulation. **Journal of Hydrology**, v.212-213, p.198-212, 1998. Disponível em: [http://dx.doi.org/10.1016/S0022-1694\(98\)00253-4](http://dx.doi.org/10.1016/S0022-1694(98)00253-4).

DAVIN, E. L.; NOBLET-DUCOUDRÉ, N. Climatic impact of global-scale deforestation: Radiative versus Nonradiative processes. **Journal of Climate**, 23, 97–112, 2010.

DURÃES, M. F.; MELLO, C. R. de; BESKOW, S. Trends in the hydrometeorological regime on an island in the South Atlantic Ocean. **Revista Brasileira de Climatologia**, v. 18, p. 242-255, 2016.

FUNDAÇÃO SOS MATA ATLÂNTICA. Relatório Anual. 2015. Disponível em: <https://www.sosma.org.br/projeto/atlas-da-mata-atlantica/dados-maisrecentes/>. Acesso em: 19 jun 2017.

GANDHI, G. M. et al. Ndvi: Vegetation Change Detection Using Remote Sensing and Gis – A Case Study of Vellore District. **Procedia**, v. 57, 2015, p.1199-1210.

GOOGLE - Inc. **Google Earth Pro**. Disponível em: <<https://www.google.com/earth/>>. Acesso em: 05 jan. 2018.

HOVI, A.; LUKES, P.; RAUTIAINEN, M. Seasonality of albedo and FAPAR in a boreal forest. **Agricultural and Forest Meteorology**, v. 247, p. 331-342, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168192317302770>. Acesso em: 13 jan. 2018.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE - ICMBIO. **Floresta Nacional de São Francisco de Paula/RS**. 2019. Disponível em:<<http://www.florestanacional.com.br/flonasaochico.html>>. Acesso em: 03 de Ago. 2019.

LIBERATO, A. M. Albedo à superfície a partir de imagens landsat 5 – TM em áreas de floresta e pastagem na Amazônia. **Revista de Geografia**, v. 28, n. 1, 2011.

LUKES, P. et al. Multidecadal analysis of forest growth and albedo in boreal Finland. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 296-305, 2016. DOI: <http://dx.doi.org/10.1016/j.jag.2016.07.001>.

KENDALL, M. G. **Rank Correlation Methods**. London: Charles Griffin, 1975.

MANN, H. B. Nonparametric Tests Against Trend. **Econometrica**, v. 13, n. 3, p. 245, jul. 1945.

MATOS, R. C. M. et al. Análise multitemporal do albedo, NDVI e temperatura no entorno do reservatório de Itaparica – PE: anos de 1985 e 2010. **Revista Brasileira de Cartografia**, v. 67, n.3, 2015. Disponível em: <<http://www.lsie.unb.br/rbc/index.php/rbc/article/view/1211>>. Acesso em 10 nov. 2017.

MENEZES, F. P.; FERNANDES, L. L. Análise de tendência e variabilidade da precipitação no estado do Pará. **Enciclopédia Biosfera**, v. 13, n. 24, p. 1580-1591, 2016.

MINISTÉRIO DO MEIO AMBIENTE – MMA. **Mata Atlântica**. 2017a. Disponível em: <<http://www.mma.gov.br/biomas/mata-atlantica>>. Acesso em: 3 nov. 2017.

MINISTÉRIO DO MEIO AMBIENTE – MMA. **Avaliação e identificação de áreas e ações prioritárias para a conservação, utilização sustentável e repartição dos benefícios da biodiversidade nos biomas brasileiros**. Brasília: MMA/SBF, 2002. 404 p.

NABUURS, G. et al. Forestry. In: Metz, B., Davidson, O.R., Bosch, P.R., Dave, R., Meyer, L.A. (Eds.), *Climate Change 2007: Mitigation of climate change Contribution of Working Group III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge Univ. Pr, Cambridge, United Kingdom and New York, NY, USA, pp. 541–584, 2007.

NEETI, N; EASTMAN, J.R. A Contextual Mann-Kendall Approach for the Assessment of Trend Significance in Image Time Series. **Transactions in GIS**, v. 15, n. 5, p.599-611, 2011.

OTTO, J. et al. Forest summer albedo is sensitive to species and thinning: how should we account for this in Earth system models? **Biogeosciences**, v. 11, p. 2411–2427, 2014.

PLANQUE, C.; CARRER, D.; ROUJEAN, J. L. Analysis of MODIS albedo changes over steady woody covers in France during the period of 2001–2013. **Remote Sensing of Environment**, v. 191, n. 2017, 13–29 p., 2017.

QGIS DEVELOPMENT TEAM, 2019. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <<http://www.qgis.org/>>. Acesso em: 22 dez. 2019.

R DEVELOPMENT CORE TEAM. R: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2019. Recuperado de <http://www.R-project.org>.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. In: *ERTS Symposium, 3.*, 1974, Washington. **Anais...** Washington: NASA, 1974. p. 309-317.

SALVIANO, M. F.; GROppo, J. D.; PELLEGRINO, G. Q. análise de tendências em dados de precipitação e temperatura no Brasil. **Revista Brasileira de Meteorologia**, v. 31, n. 1, p. 64-73, 2016.

SCHAAF, C. B. **Assessment of the status of the development of the standards for the terrestrial essential climate variables**. T8 albedo and reflectance anisotropy. Rome: NRC, Food and Agriculture Organization of the UN (FAO), 1–2, 2009.

SEN, P. K. Estimates of the regression coefficient based on Kendall's Tau. **Journal of the American Statistical Association**, v. 63, p. 1379-1389, 1968.

SILVA, B. B. et al. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n.1, p. 3-8, 2016.

SOME'E, B. S.; EZANI, A.; TABARI, H. Spatiotemporal trends and change point of precipitation in Iran. **Atmospheric Research**, v.133, p.1-12, 2012.

TIAN, L., ZHANG, Y., ZHU, J. Decreased surface albedo driven by denser vegetation on the Tibetan Plateau. **Environmental Research Letters**, v. 9, n. 10, 2014. DOI: 10.1088/1748-9326/9/10/104001.

VILANOVA, M. R. N. Tendências hidrológicas anuais e sazonais na bacia do rio Paraibuna, Parque Estadual da Serra do Mar (SP). **Sociedade e Natureza**, v. 26, n. 2, p. 301-316, 2014.

WAGNER, A. P. L. et al. Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesquisa Agropecuária Brasileira**, v. 48, 9, p. 1192-1200, 2013. DOI: DOI: 10.1590/S0100-204X2013000900002.

WANDERLEY, H. S.; JUSTINO, F. B.; SEDIYAMA, G. C. Tendência da Temperatura e Precipitação na Península Antártica. **Revista Brasileira de Meteorologia**, v. 31, n. 2, p. 114-121, 2016.

WANG, Z. et al. Monitoring land surface albedo and vegetation dynamics using high spatial and temporal resolution synthetic time series from Landsat and the MODIS BRDF/NBAR/albedo product. **International Journal of Applied Earth Observation and Geoinformation**, v. 59, p. 104-117, 2017. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0303243417300715>>. Acesso em: 13 jan. 2018. DOI: <https://doi.org/10.1016/j.jag.2017.03.008>.

ZHAI, J. et al. Radiative forcing over China due to albedo change caused by land cover change during 1990–2010. **Journal of Geographical Sciences**, v. 24, n. 5, p. 789–801, 2014.

ZANZARINI, F. V. et al. Correlação espacial do índice de vegetação (NDVI) de imagem Landsat/ETM+ com atributos do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 6, p. 608-614, jun. 2013. DOI: <http://dx.doi.org/10.1590/s1415-43662013000600006>.

ZHANG, G. et al. Time Series High-Resolution Land Surface Albedo Estimation Based on the Ensemble Kalman Filter Algorithm. **Remote sensing**, 11, 753, p. 1 – 24. DOI: <https://doi.org/10.3390/rs11070753>.

CONCLUSÃO GERAL

O albedo de superfície corresponde a uma variável primordial para o monitoramento do fluxo de energia da atmosfera e da superfície terrestre. Nesse sistema complexo a cobertura florestal apresenta grande contribuição, especialmente devido a sua ação de absorção da radiação incidente.

A resposta espectral dos povoamentos florestais e da FOM demonstraram relação com o albedo de superfície. Assim, mudanças na cobertura florestal provocam alterações nos valores de albedo, sendo esta, uma importante variável para a identificação de modificações na estrutura florestal de forma rápida e econômica.

O uso de inteligência artificial para a identificação de espécies florestais mostrou-se eficiente, com destaque para os algoritmos de aprendizado de máquina SVM, ANN e RF. De modo geral, as espécies de coníferas apresentam valores de albedo inferiores às folhosas englobadas no estudo, devido a sua arquitetura de dossel, com diferentes níveis hierárquicos.

O albedo de superfície apresenta uma tendência de distribuição que se relaciona com a concentração e vigor da vegetação arbórea. Desse modo, quanto maior o verdor da vegetação, menor o valor de albedo de superfície. Nesse sentido, a implantação de uma cobertura florestal pode ocasionar uma redução significativa do albedo, contribuindo para a manutenção das condições climáticas. O albedo de superfície mostrou-se uma variável potencial para a análise e monitoramento de alterações na estrutura de dossel da cobertura florestal, sendo útil para a gestão dos remanescentes florestais do bioma Mata Atlântica, quanto para o manejo dos povoamentos florestais.