



ESTIMATIVA DO ESTOQUE FLORESTAL POTENCIAL
A PARTIR DOS DADOS DO
INVENTÁRIO FLORESTAL NACIONAL

LEANDRO MENEGUELLI BIONDO

DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS FLORESTAIS

FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL

**ESTIMATIVA DO ESTOQUE FLORESTAL POTENCIAL
A PARTIR DOS DADOS DO
INVENTÁRIO FLORESTAL NACIONAL**

LEANDRO MENEGUELLI BIONDO

ORIENTADOR: RENATO VINÍCIUS OLIVEIRA CASTRO
DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS FLORESTAIS

PUBLICAÇÃO: PPGEFL.DM - XXA/XX

BRASÍLIA/DF: SETEMBRO – 2016

FICHA CATALOGRÁFICA

BB615e	Biondo, Leandro Meneguelli Estimativa de Estoque Florestal Potencial a Partir dos Dados do Inventário Florestal Nacional / Leandro Meneguelli Biondo; orientador Renato Vinicius Oliveira Castro. -- Brasília, 2016. 120 p. Dissertação (Mestrado - Mestrado em Ciências Florestais) -- Universidade de Brasília, 2016. 1. Estimativa de Estoque Florestal Potencial. 2. Inventário Florestal Nacional . 3. Índices de Vegetação com PALSAR e RapidEye. 4. Interpolação Geoestatística com Krigagem. 5. Sistemas de Informações Geográficas com Software Livre. I. Castro, Renato Vinicius Oliveira, orient. II. Título.
--------	---

REFERÊNCIA BIBLIOGRÁFICA

BIONDO, L. M., Estimativa do Estoque Florestal Potencial a partir dos dados do Inventário Florestal Nacional. PPGEFL. DM-284/16. Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, 120p. 2016.

CESSÃO DE DIREITOS

AUTOR: Leandro Meneguelli Biondo

TÍTULO: Estimativa do Estoque Florestal Potencial a partir dos dados do Inventário Florestal Nacional

GRAU: Mestre

ANO: 2016

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Leandro Meneguelli Biondo
SQN 314 BL B 405, Asa Norte
70.767-020 Brasília – DF – Brasil.

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

“ESTIMATIVA DO ESTOQUE FLORESTAL POTENCIAL A
PARTIR DOS DADOS DO INVENTÁRIO FLORESTAL NACIONAL”

LEANDRO MENEGUELLI BIONDO

DISSERTAÇÃO DE MESTRADO ACADÊMICO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS, DO DEPARTAMENTO DE ENGENHARIA FLORESTAL, DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE.

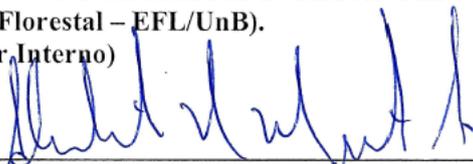
APROVADA POR:



Prof. Dr. RENATO VINÍCIUS OLIVEIRA CASTRO (Departamento de Engenharia Florestal – EFL/UnB);
(Orientador)



Prof. Dr. ERALDO APARECIDO TRONDOLI MATRICARDI (Departamento de Engenharia Florestal – EFL/UnB).
(Examinador Interno)



Dr. HUMBERTO NAVARRO DE MESQUITA JÚNIOR (Serviço Florestal Brasileiro – SFB);
(Examinador Externo)

Prof. Dr. EDER MIGUEL PEREIRA (Departamento de Engenharia Florestal – EFL/UnB);
(Examinador Suplente)

Brasília-DF, 22 de setembro de 2016.

AGRADECIMENTOS

Agradeço todos os colegas do Serviço Florestal Brasileiro, IBAMA e Ministério do Meio Ambiente que de algum modo contribuíram para este trabalho, sabendo ou não de sua existência. Especialmente ao Humberto Navarro que apoiou de forma incondicional a busca por respostas e informações, ao Charton Locks, Clayton Borges e Denilson Passo que me mostraram caminhos melhores no mundo do Sensoriamento Remoto, ao Joberto Veloso que sugeriu utilizar o IFN como fonte de dados de inventário, ao Luiz Motta e ao Renato Castro que com seu entusiasmo por métodos e desenvolvimento me ajudaram a caminhar a passos maiores do que eu poderia imaginar. Ao Prof. Eraldo Matricardi pelas suas contribuições técnicas e posteriores comentários que ajudaram a melhorar este texto.

Contribuíram também com ideias, discussões, revisões, brincadeiras e críticas que sempre me deram sorte para minhas escolhas, meus amigos e colegas Alexander Biondo, Juliana Gomes, Pedro Mendes, Ana Lyz Parreira, Heliane Hirata, Alcamenes Heródoto, Marta Minussi, Bernardo Trovão, Pedro Salles, Carlos Sturm, Jesse de Lima, Daniel Cruz Torres, Gigante Rafael Rossi, Hugo Machado, Edson Kurotsu e Rogério Oie.

Por óbvio agradeço à minha família que sempre me apoiou em tudo, e que tenho certeza sofreu mais do que eu nos momentos de dificuldades e também se orgulhou mais do que eu quando superei etapas e obstáculos nesta trajetória. Particularmente ao Arthur que também estudou bastante nestes dois anos, à Raquel que me sustentou todos os dias, aos meus pais Darlene e Aparício por tudo e por me ouvirem quando eu preciso, aos meus irmãos Caroline e Vinícius pelas importantes presenças, mesmo distantes.

Finalmente agradeço a meus avôs e avós, Odair e Marlene Meneguelli, Walter e Jaciara Biondo, que de forma irreverente e inocente contribuíram tanto para minha formação.

**Dedicado à minha esposa Raquel e ao meu filho Arthur,
que me inspiram e me tornam uma pessoa melhor.**

RESUMO

ESTIMATIVA DO ESTOQUE FLORESTAL POTENCIAL A PARTIR DOS DADOS DO INVENTÁRIO FLORESTAL NACIONAL.

Autor: Leandro Meneguelli Biondo

Orientador: Renato Vinícius Oliveira Castro

Programa de Pós-graduação em Ciências Florestais

Brasília, Setembro de 2016

Utilizando métodos com dados de campo e de sensoriamento remoto ambiental, interpolou-se o Inventário Florestal Nacional (IFN) para indivíduos com DAP maior ou igual a 10cm, com geoestatística e associação de informações de RADAR orbital. Foram desenvolvidas estimativas do estoque florestal potencial da Caatinga no estado do Ceará. Utilizando RADAR e sensores ópticos, foram reamostrados os dados de 20x20 km a até 500 m de resolução. Os resultados da modelagem por krigagem foram comparados com as informações de campo e foi utilizada máscara para filtro de Índice de Degradação Florestal por Radar (RFDI) nas estimativas de biomassa em áreas de interesse. Analizou-se geometrias de vegetação do PROBIO e imóveis rurais do Cadastro Ambiental Rural (CAR). Com a biomassa do Ceará estimada em 340 milhões de toneladas, encontrou-se a média de 33,8 ton/ha para “Savana Estepe Arborizada”, tipologia mais comum da Caatinga. Valores para outras tipologias comuns foram estimados, com 27,5 ton/ha para “Savana Estepe Parque”, 25,9 ton/ha para “Savana Estepe” enquanto áreas de “Floresta Estacionária SemiDecidual baixa 30” ou “Floresta Savana e Estacionária” indicaram vegetação densa, com mais de 70 ton./ha. Analisados 21.784 imóveis rurais de maio do CAR com área declarada em 2,8 milhões de hectares, ou 19,0% do estado. Na krigagem da biomassa, 28,6% estavam em imóveis rurais. A concentração de biomassa nos registros foi separada de acordo com tipo de imóvel, distribuídas com 53,3% em 21.275 propriedades rurais, 41,7% nos 507 assentamentos e 5,0% em 2 áreas de comunidades tradicionais. O método automatiza a estimativa de biomassa e aplicação de máscara de vegetação em todo o Ceará. Concluiu-se que este método deve ser considerado no uso do IFN em conjunto com índices de vegetação. Particularmente quando se pretende estimar estoque florestal espacialmente correlacionado, o que auxilia estudos de distribuição territorial de florestas e planejamento de recuperação ambiental..

ABSTRACT

ESTIMATING POTENTIAL FOREST STORAGE WITH DATA FROM THE NATIONAL FOREST INVENTORY.

Author: Leandro Meneguelli Biondo

Supervisor: Renato Vinícius Oliveira Castro

Programa de Pós-graduação em Ciências Florestais

Brasília, September 2016

Data from forest inventories and remote sensing was interpolated with the intention of spatially estimating forest storage on unvisited field areas. Using data from trees of 10cm or greater DBH (Diameter at Breast Height) for biomass estimation as part of the potential forest storage, processed with geostatistics and orbital RADAR derived information. The remote sensing together with kriging of the IFN (national forest inventory) to rescale the information from 20km to 500m resolution. Results from kriging were compared to field data and then a filter mask of PALSAR was applied in order to remove areas of low forest density from spatial estimatives. The information was then overlapped with rural properties registry from Rural Environmental Registry (CAR). The results showed a total of 340 million tonnes of biomass on Ceara State, with an average 33.8ton/ha for the most common vegetation typology (Arborized Savannah) and other common typologies ranging between 25.9 and 70.0 ton/ha. With 21.784 rural properties and 2.8 million hectares declared. Accounting for 19.0% of Ceara area, containing 28.6% of estimated biomass. The biomass average was distributed as 53.3% on 21.275 private registries, 41.7% on 507 settlements of agrarian reform and 5.0% on two traditional communities areas. This led to conclude that it is possible and feasible to use the discrete IFN data associated to geostatistics and vegetation indexes on forest storage spatial estimates. The results shown in this work might help future studies on territorial distribution and planning of forest or environmental managing and recovery.

SUMÁRIO

1. INTRODUÇÃO	6
2. OBJETIVOS	9
3. REVISÃO BIBLIOGRÁFICA.....	10
3.1. Inventário Florestal Nacional (IFN).....	10
3.2. Classes de uso da terra do IFN.....	13
3.3. Estoque Florestal em Biomassa	14
3.4. Sistemas Orbitais (Satélites) de Monitoramento do Ambiente.....	14
3.5. Radiação Eletromagnética e a Matéria - Sensores Passivos	14
3.6. Radiação Eletromagnética e a Matéria - Sensores Ativos	19
3.7. Imagens RapidEye, PALSAR e a derivação de Índices de Vegetação.....	21
3.8. NDVI (Índice de Vegetação por Diferença Normalizada)	24
3.9. RFDI - Índice de Degradação Florestal por RADAR.....	25
3.10. Geostatística e Krigagem de Dados.....	28
4. MATERIAL E MÉTODOS	31
4.1. Localização da Área de Estudo.....	31
4.2. Processamento e Análise dos Dados.....	33
4.3. Dados de Sensoriamento Remoto	33
4.4. Cadastro Ambiental Rural do Ceará (CAR)	40
4.5. Classificação do Estoque Florestal	41
5. RESULTADOS E DISCUSSÃO	43
5.1. Modelagem por regressão dos dados do IFN e SR.....	43
5.2. Regressão das Classes de Estoque Florestal	61
5.3. Interpolação do IFN por Krigagem Ordinária	72
5.4. Estimativa de Estoque Florestal com o RFDI.....	80
6. CONCLUSÃO	96
7. APÊNDICE 1 – ALGORITMOS E COMENTÁRIOS	101
7.1. Script SQL – Extração de dados do banco do IFN	102
7.2. Operações no Qgis Field Calculator	104
7.3. Scripts Python	107
7.4. Script R-CRAN no QGIS.....	119

LISTA DE SÍMBOLOS, NOMENCLATURA E ABREVIACÕES.

ALOS-PALSAR - Advanced Land Observing Satellite - Phased Array type L-band Synthetic Aperture Radar (satélite de observação avançada de solo – RADAR de abertura sintética banda L com matriz de fase).

ANA – Agência Nacional de Águas.

Banda L – Faixa de frequência de micro-ondas entre 950MHz e 1450MHz.

CAR – Cadastro Ambiental Rural.

DAP – Diâmetro na Altura do Peito, altura padrão utilizada para medida de diâmetro de vegetação, equivalente a uma altura de 1,30m do solo.

DB – Diâmetro da base de um indivíduo vegetal.

dB – Decibel, unidade logarítmica aqui utilizada para intensidade de energia.

EPSG – European Petroleum Survey Group (grupo europeu de pesquisa em petróleo), sigla utilizada em identificadores padronizados de sistemas de referência.

EVI – Enhanced Vegetation Index (índice de vegetação realçado).

FAO – Food and Agriculture Organization (Organização das Nações Unidas para a Alimentação e a Agricultura).

GNU – General Public License (licença pública geral).

GPS – Global Positioning System (sistema de posicionamento global).

HH – Banda de polarização de radar em que é emitida uma onda horizontalmente polarizada e utilizado uma detecção de polarização também horizontal.

HV – Banda de polarização de radar em que é emitida uma onda horizontalmente polarizada e utilizado uma detecção de polarização vertical.

IBGE – Instituto Brasileiro de Geografia e Estatística.

IFN – Inventário Florestal Nacional.

INPE – Instituto Nacional de Pesquisas Espaciais.

JAXA – Japan Aerospace Exploration Agency (agência japonesa de exploração espacial).

KO – Krigagem Ordinária, método geoestatístico.

MMA – Ministério do Meio Ambiente.

NDVI – Normalized Difference Vegetation Index (índice de vegetação por diferença normalizada).

NIR – Near Infrared (infravermelho próximo).

PROBIO - Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira

RADAR – Radio Detection And Ranging (Detecção e Telemetria por Rádio).

Rededge – Região de radiação infravermelha com mudança brusca de interação com a vegetação, entre o NIR e o vermelho.

RFDI – RADAR Forest Degradation Index (Índice de degradação florestal por RADAR).

RGB – Red-Green-Blue (vermelho-verde-azul), abreviatura de sistema de cores primárias aditivas para reprodução de cores em dispositivos eletrônicos.

SAR – Synthetic Aperture RADAR (RADAR de abertura sintética).

SICAR – Sistema Nacional de Cadastro Ambiental Rural.

SFB – Serviço Florestal Brasileiro.

Speckle – Ruído multiplicativo comum em dados de RADAR.

LISTA DE FIGURAS

Figura 1 – Diagrama esquemático das classes de uso ou cobertura de solo.....	11
Figura 2 – Representação da cruzeta de coleta de dados de um ponto do IFN.	11
Figura 3 - Curvas de radiação no topo da atmosfera e na superfície.....	15
Figura 4 - Ilustração das interações da matéria com as diferentes radiações eletromagnéticas	16
Figura 5 - Respostas macroscópicas da interação entre matéria e radiação.	17
Figura 6 - Curvas de refletância eletromagnética de diferentes coberturas de solo.	17
Figura 7 - Curvas de resposta e bandas do sensor remoto RapidEye.....	18
Figura 8 - Comprimentos de onda comuns no espectro eletromagnético e bandas de RADAR.....	19
Figura 9 - Esquema simplificado de emissão e resposta com RADAR.	20
Figura 10 - Geometria de imageamento de um SLAR.....	21
Figura 11 - Comparativo de imagem óptica e imagem de radar em uma mesma região do Ceará.	23
Figura 12 - Interação de radiação e vegetação.	24
Figura 13 – Utilização de dados do sensor RapidEye para identificação de vegetação.....	25
Figura 14 - Imagens do PALSAR, composição com as polarizações HH e HV mais o RFDI	27
Figura 15 – Exemplo de resposta do RFDI de acordo com a perda de biomassa	27
Figura 16 - Pontos de dados coletados pelo IFN.....	31
Figura 17 - Máscara de convolução utilizada em imagens	34
Figura 18 - Arquivo raster com o algoritmo de descompactação do PALSAR	36
Figura 19 - Quantidade de árvores com DAP maior do que 10cm que foi amostrada.....	37
Figura 20 - Exemplo de análise visual do Conglomerado CE-87	50
Figura 22 - Exemplo de análise visual do Conglomerado CE-40	50
Figura 23 - Exemplo de análise visual do Conglomerado CE-350.	51
Figura 24 - Exemplo de análise visual do Conglomerado CE-299.	51
Figura 25 - Exemplo de análise visual do Conglomerado CE-70	52
Figura 26 - Exemplo de análise visual do Conglomerado CE-236	52
Figura 26 - Localização do Conglomerado CE-101 em escala 1:250.000.	54
Figura 27 - Conglomerado CE-101 em escala 1:250.000 com palsar ao fundo.....	54
Figura 28 - Localização do Conglomerado CE-101 em escala 1:50.000.....	55
Figura 29 - Conglomerado CE-101 em escala 1:50.000 com palsar ao fundo.....	55
Figura 30 - Localização do Conglomerado CE-101 em escala 1:10.000.....	56
Figura 31 - Conglomerado CE-101 em escala 1:10.000 com palsar ao fundo.....	56
Figura 32 - Localização do CE-101 em escala 1:1.250.....	57
Figura 33 – Conglomerado CE-101 em escala 1:1.250 com palsar ao fundo.....	57
Figura 34 - Gráfico com as classes de Estoque Florestal definidos para as subunidades.	63
Figura 35 – Percentual de floresta de acordo com o uso de solo cadastrado no IFN.....	65
Figura 36 – Histograma de floresta de cada conglomerado estimado de acordo com a informação de cobertura florestal das quatro subunidades.....	65
Figura 37 - Histograma do total de indivíduos entre os 13.248 com DAP maior ou igual a 10cm.	66
Figura 38 – Histograma da biomassa calculada a partir de indivíduos.	66
Figura 39 - Histograma das médias por conglomerado de classe de estoque florestal	67
Figura 40 – Histograma das médias por conglomerado de classe de estoque florestal, estabelecida a partir das tipologias vegetais do IBGE publicadas do PROBIO 2002 do MMA.	67
Figura 41 – Histograma das médias por conglomerado de classe de estoque florestal, estabelecida a partir do RFDI derivado dos dados do PALSAR.....	68
Figura 42 – Histograma das médias por conglomerado de classe de estoque florestal, estabelecida a partir do nível de dB da polarização HH do PALSAR.....	68

Figura 43 – Histograma e das médias por conglomerado de classe de estoque florestal, estabelecida a partir do NDVI calculado com as imagens RapidEye.....	69
Figura 44 – Histograma das somatórias das médias por conglomerado de todas as classes de estoque florestal, estabelecidas a partir dos dados descritos nos histogramas anteriores.....	69
Figura 45 - Gráfico com os valores estimados com o modelo e os dados originais observados.....	70
Figura 46 - Parâmetros estimados na regressão com modelo exponencial das variáveis que apresentaram maior correlação com a quantidade de indivíduos de cada ponto do IFN..	71
Figura 47 – Variograma com melhor ajuste no R com algoritmo AutoFitVariogram, utilizado para a krigagem ordinária com modelo Linear para interpolação da biomassa do IFN.....	74
Figura 48 – Resultado da krigagem dos 223 pontos selecionados, em relação à biomassa observada nos conglomerados.....	78
Figura 49 – Resultado da interpolação dos 223 pontos selecionados para a krigagem.....	79
Figura 50 – Erros encontrados na interpolação final da biomassa do IFN.....	80
Figura 51 - Valores médios em ordem crescente de biomassa em Microrregiões administrativas censitárias do Ceará.....	88
Figura 52 - Resumo de krigagem em imóveis rurais por classe fundiária	92
Figura 53 - Resumo de krigagem em imóveis por classe fundiária em Módulos Fiscais (MF).....	93
Figura 51 - Imagem dos pontos do IFN. À esquerda o resultado da krigagem feita com os 376 pontos do IFN, no centro o resultado do mesmo método aplicado em 90% dos pontos,.....	94
Figura 52 - Imagem dos pontos do IFN. À esquerda o resultado da krigagem feita com os 376 pontos do IFN, no centro o resultado do mesmo método aplicado em 50% dos pontos.....	94

LISTA DE TABELAS

Tabela 1 - Limites de dimensões das subparcelas e seus indivíduos para coleta dos conglomerados do inventário florestal.....	12
Tabela 2 – Classes de cobertura da terra utilizadas nas subparcelas do IFN.....	13
Tabela 3 - Classes para histograma de valores em decibéis da polarização HH das imagens PALSAR em tabela de atributos dos pontos espacializados do IFN.....	40
Tabela 4 - <i>Resumo de indivíduos e suas variáveis dendrométricas médias em função das classes de uso da terra informadas em cada subparcela inventariada.....</i>	45
Tabela 5 - Resumo de indivíduos e suas variáveis dendrométricas médias em função das respostas sobre cobertura florestal. Foram utilizadas as respostas (resposta SIM/NÃO no formulário de campo) e as classes de uso da terra informadas em cada subparcela inventariada.	46
Tabela 6 - Categorias discretas de estoque florestal de acordo com o uso de solo classificado.....	58
Tabela 7 - Categorias discretas de estoque florestal do Ceará utilizando a resposta em dB.	59
Tabela 8 - Categorias discretas de estoque florestal do Ceará utilizando o NDVI.....	60
Tabela 9 - Categorização dos conglomerados de acordo com o RFDI.....	60
Tabela 10 - Categorização em níveis de estoque florestal de acordo com a tipologia do PROBIO 2002 a que cada conglomerado se sobrepôs.....	61
Tabela 11 - Classes de estoque florestal determinadas a partir dos dados de inventário e sensoriamento, para estimativa de potencial florestal..	62
Tabela 12 – Área, biomassa média e biomassa total estimada por tipologia do PROBIO para o Ceará com a krigagem do IFN.	87
Tabela 13 - Resumo de dados calculados para os imóveis rurais cadastrados no Ceará.....	89

LISTA DE EQUAÇÕES

Equação 1 - Biomassa acima do solo utilizado para a Caatinga no IFN.....	14
Equação 2 - Cálculo do Índice de Vegetação Por Diferença Normalizada.....	24
Equação 3 – Decodificação dos números digitais do PALSAR.....	26
Equação 4 - Cálculo do Índice de Degradação Florestal por RADAR.	26
Equação 5 – Estimativa com combinação ponderada por relação espacial de dados.	28
Equação 6 – Krigagem ordinária de dados para estimativa linear ponderada.....	29
Equação 7 – Sistema de ponderadores da Krigagem ordinária com pesos ótimos.	29

LISTA DE MAPAS

Mapa 1 - Biomassa Calculada por Conglomerado do IFN.....	75
Mapa 2 - RFDI calculado do PALSAR, estimativa de áreas com pouca estrutura vegetal.....	76
Mapa 3 - Krigagem Ordinária da Biomassa do IFN no Ceará.....	77
Mapa 4 - Krigagem Ordinária com Máscara de RFDI.....	83
Mapa 5 - Tipologias do PROBIO 2002 do Ceará.....	84
Mapa 6 - Biomassa dos Polígonos do PROBIO do Ceará.....	85
Mapa 7 - Biomassa de Polígonos de Imóveis do CAR.....	90

1. INTRODUÇÃO

O conhecimento de informações e características de florestas, de diferentes tipos e em diferentes regiões do mundo, tem uma relação importante com a sociedade que se relaciona com a fauna e flora presentes nestas florestas. Os métodos disponíveis para o levantamento e estudo das informações florestais incluem o inventário de dados florestais e a análise de dados de sensoriamento remoto ambiental (MMA, 2016).

Um inventário florestal permite o levantamento das características qualitativas e quantitativas de um povoamento florestal, de fundamental importância para avaliar a produção e obter informações que permitam a melhor utilização das florestas. Os inventários se utilizam dos dados de parte da população (amostra do povoamento), para gerar estimativas para a população total de uma floresta (CAMPOS, 2009). O uso da amostra pode resultar em um erro de amostragem, que depende do tamanho da amostra e do método de amostragem utilizado. Em áreas mais heterogêneas, por exemplo, o uso de algum procedimento de amostragem estratificada resulta em maior precisão da média da população, quando comparada à amostragem casual simples. De fato, um bom método de amostragem é aquele que permite gerar estimativas precisas e livres de tendência, com um baixo custo (CAMPOS, 2009).

De acordo com a documentação do Inventário Florestal Nacional (SFB-C, 2016), inventários florestais nacionais são levantamentos extensivos sobre os recursos florestais, realizados geralmente pelos governos dos países para a produção de informações estratégicas. Estes inventários foram realizados, em alguns casos, desde década de 1920, adotando-se este instrumento de informação após a Segunda Guerra Mundial para auxiliar na reconstrução dos territórios. Existem atualmente cerca de 70 países com inventários florestais nacionais implantados, em diferentes fases de execução (FAO, 2015). A consolidação dos inventários nacionais acompanha a sua institucionalização e execução repetida com regularidade para produção de informações atualizadas.

O IFN é uma ferramenta que pode ser associada a recursos de outras fontes de informação territorial e ambiental, principalmente por ser um dado espacializado por definição e que pretende ser utilizado como amostra espacial de um recurso natural que permita ser descrito em todo o território nacional. Um inventário total e contínuo de todo o território pode ser impossível de ser feito, tanto pelo tempo que seria necessário, quanto

pelo custo. Assim, busca-se uma forma de interpolar os dados pontuais do IFN para que possa extrapolar para toda a área, através de uma estimativa espacialmente coerente.

Dados de sensoriamento remoto constituem outro método possível para estudos de larga escala de estrutura e funcionamento de grandes áreas, para análises de cobertura de solo (ASNER, 2005). Entre as vantagens deste método estão a possibilidade de coletar dados de modo contínuo no território e diversas vezes ao longo do tempo, com um custo geralmente menor do que coletas de campo (SFB-A, 2016).

Para realizar análises de dados de sensoriamento remoto, faz-se necessário primeiramente ter acesso a estes dados, sejam eles imagens ou medições realizadas por sensores aerotransportados ou orbitais. Um dos conjuntos de imagens com cobertura mais completa do território e com alta resolução espacial disponível para o Brasil é o geocatálogo do MMA, composto por imagens adquiridas para utilização primária na execução do Cadastro Ambiental Rural previsto no Código Florestal do Brasil, vigente desde outubro de 2012 (MMA, 2016). O geocatálogo tem imagens dos sensores da constelação de satélites orbitais RapidEye, com dados referentes aos anos de 2011 a 2015, compostos por imagens em cinco faixas de frequências ópticas (visível e infravermelho próximo) para todo o território nacional.

A aquisição de imagens ópticas depende da ausência de cobertura de nuvens durante a varredura do sensor, sendo o radar de abertura sintética uma opção de sensoriamento de larga escala que não sofre influência de nebulosidade. Dados de radar adquiridos em comprimentos de onda da banda L (~23 cm) apresentam melhor desempenho para estudos florestais quando comparado aos radares banda C (LIMA, 2009). Dentre os sensores com esta tecnologia está o sistema orbital ALOS-PALSAR (*Advanced Land Observing Satellite - Phased Array type L-band Synthetic Aperture Radar*), lançado pela Agência Espacial Japonesa (JAXA) em 2006 (LIMA, 2009). Além da vantagem de não ser influenciado por nebulosidade, os dados adquiridos por sensores deste tipo têm uma resposta conceitualmente diferente da que é obtida por sensores ópticos. A resposta de cada sensor está relacionada às características diferentes da área imageada, resultando em um conjunto de dados que se complementam na descrição do ambiente (JENSEN, 2011).

A utilização conjunta de dados provenientes de sensores remotos passivos ópticos e de sensores ativos, como o radar, pode fornecer melhores estimativas de uso de solo e formação vegetal presente em áreas sem acesso ou que sejam distantes, ou seja, a ponto de

impossibilita uma revisita devido ao tempo necessário ou ao custo de execução. No caso das áreas de florestas públicas gerenciadas pelo SFB e das áreas em que está sendo realizado o IFN, é frequente o uso de dados de sensores ópticos para qualificação das áreas de concessão e para planejamento de outras atividades como visitas de campo ou estratégias de adensamento de pontos de coleta (FREITAS 2016). A continuidade de cobertura territorial dos dados de sensoriamento disponíveis tem potencial para complementar as informações amostrais discretas e detalhadas do inventário, com a interpolação dos dados de inventário assessorados pelas respostas espectrais de diferentes sensores.

O sensoriamento remoto é particularmente útil em regiões de difícil acesso, sendo sua aplicação mais complexa em locais com sazonalidade de atividade fotossintética, com variação significativa na detecção da cobertura de vegetação. No Brasil os biomas Cerrado e Caatinga aumentam as dificuldades de relacionar biomassa com índices de vegetação (KUNTSCHIK, 2004). Único bioma exclusivamente brasileiro - a Caatinga - corresponde a 11% do território nacional e boa parte de seu patrimônio biológico não pode ser encontrado em outro lugar do mundo, o que torna este bioma tão importante para o país (ICMBIO, 2016). Deste modo o objetivo do presente estudo foi o desenvolvimento e aprimoramento de técnicas e métodos de utilização dos dados provenientes de sensores remotos aplicados para o melhor entendimento do bioma Caatinga no Ceará.

2. OBJETIVOS

2.1. Objetivo Geral

Desenvolver métodos de estimativa do estoque florestal potencial utilizando dados do Inventário Florestal Nacional e de sensoriamento remoto.

2.2. Objetivos específicos

- Avaliar os estoques de biomassa em áreas mensuradas pelo IFN no estado do Ceará e classificar quantitativamente o estoque florestal das áreas vegetadas;
- Desenvolver um método que utilize os dados de sensores passivos (imagens ópticas) e ativos (RADAR Banda L) para estimativa de estoque florestal potencial. Utilizar este método para classificar áreas do Ceará, mapeando este potencial.
- Avaliar o desempenho da modelagem linear e o de modelagem geoestatística das amostras de inventário, a partir da sua relação com dados de sensoriamento remoto.
- Desenvolver uma metodologia de uso dos dados amostrais do IFN associado a dados de sensoriamento remoto, para estimativas regionais.

3. REVISÃO BIBLIOGRÁFICA

Floresta

Floresta é definida pela “Organização das Nações Unidas para Agricultura e Alimentação” como toda área acima de 0,5 hectares, composta por árvores maiores que 5 m de altura e superior a 10% de cobertura de copa ou árvores capazes de alcançar estes parâmetros in situ, não incluindo terra predominantemente com uso agrícola ou urbano (SFB-A, 2016).

3.1. Inventário Florestal Nacional (IFN)

As informações deste item foram elaboradas com base no manual de campo do Inventário Florestal Nacional (IFN) e da interpretação dos formulários e material de divulgação *on-line* do projeto (SFB-D, 2014 e SFB-A, 2016). O IFN é um projeto coordenado pelo Serviço Florestal Brasileiro (SFB) com o propósito de produzir informações sobre as florestas em todo o território brasileiro. Neste projeto estimam-se o volume de madeira em espécies arbóreas, bem como a biomassa e carbono de árvores, cactos, palmeiras, bambus e espécies arbustivas e/ou herbáceas.

O IFN é baseado em um sistema de amostragem sistemática, considerando uma grade regular de pontos amostrais de 20 km por 20 km, distribuídos em todo o território nacional. Em cada ponto da grade é instalada uma unidade amostral (conglomerado), que consiste de um conjunto de quatro subunidades de 20 m por 50 m cada. A coleta de dados de campo inclui variáveis biofísicas da floresta e respectivos dados socioambientais.

A definição de área com floresta utilizada no IFN é a mesma da Organização das Nações Unidas para a Alimentação e a Agricultura – FAO (SFB-D, 2014), sendo cada área de amostragem classificada segundo sua classe de cobertura de solo (*Figura 1*).

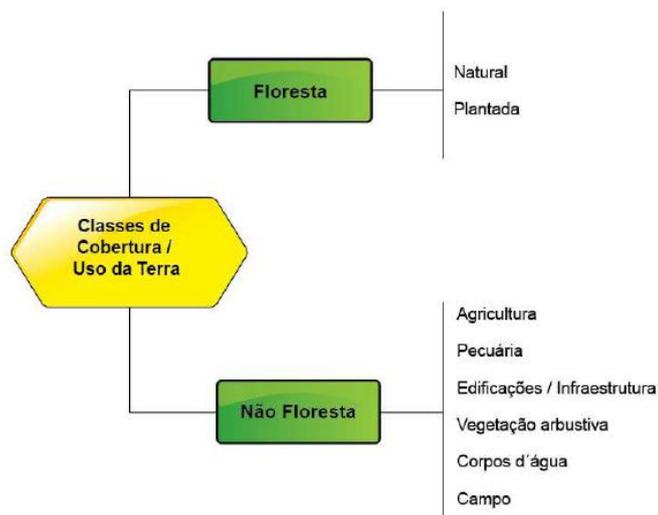


Figura 1 – Diagrama esquemático das classes de uso ou cobertura de solo onde as unidades amostrais são instaladas. (SFB-D, 2014)

A instalação dos conglomerados no IFN, onde são coletados os dados ambientais e as estimativas do estoque florestal (Biomassa, Volume e Carbono), possui cruzetas com estas mesmas orientações e características (**Figura 2**).

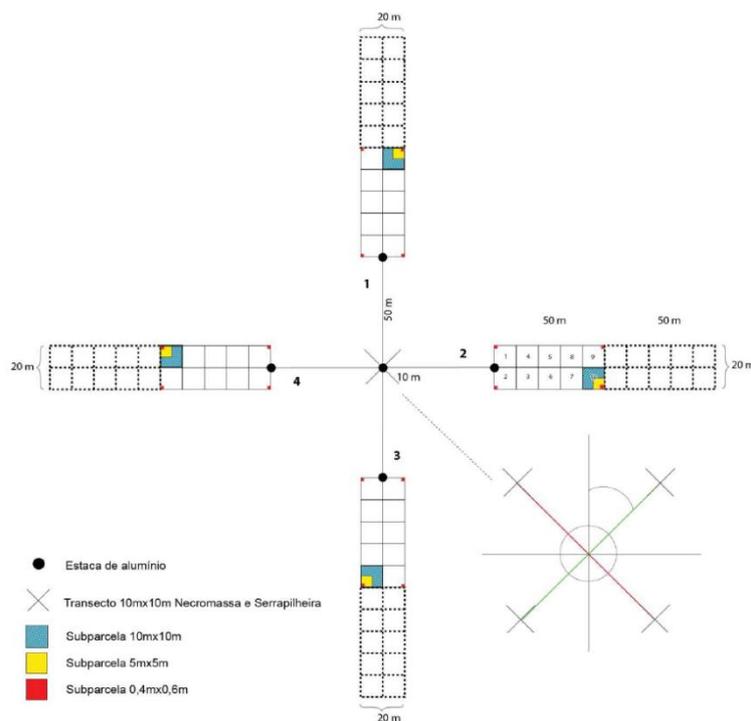


Figura 2 – Representação da cruzeta de coleta de dados de um ponto do IFN. Para regiões fora da Amazônia é realizada a coleta nas 10 subunidades mais próximas do centro do conglomerado, nas quatro direções. Assim têm-se dados de 40 subparcelas de 10x10m que formam quatro retângulos de 10 parcelas com dimensão de 20x50m distantes 50m do ponto central do conglomerado (SFB-D, 2014).

A avaliação de necromassa e serrapilheira é realizada no conglomerado, sendo também coletadas amostras de solo e mensurada os indivíduos nele contidos, conforme estratificação padrão (*Tabela 1*).

Tabela 1 - Limites de dimensões das subparcelas e seus indivíduos para coleta dos conglomerados do inventário florestal (SFB-D, 2014).

Nível	Dimensões (m)	Área (m ²)	Limites de Inclusão
I	0,4 x 0,6	0,24	Plantas Herbáceas
II	5,0 x 5,0	25,00	$h \geq 1,3\text{m}$ e $\text{DAP} < 5 \text{ cm}$
III	10,0 x 10,0	100,00	$5 \text{ cm} \leq \text{DAP} < 10 \text{ cm}$
IV	20,0 x 50,0	1.000,00	$10 \text{ cm} \leq \text{DAP}$

DAP = Diâmetro à altura do peito

O diâmetro à altura do peito (DAP) constitui a principal variável biométrica do IFN. Todos os indivíduos arbustivos e arbóreos selecionados e numerados pelo critério de inclusão tem o DAP medido a 1,30 m acima do nível do solo, com auxílio de fita diamétrica. O ponto de medição do diâmetro (altura do peito ou na base) é marcado com o auxílio de um bastão graduado a 0,30 m (para DB) e a 1,30 m (para DAP), encostado ao tronco da árvore de acordo com a topografia do terreno e com a posição da árvore em relação ao solo. A medição do diâmetro é feita envolvendo o tronco do indivíduo com a fita diamétrica, na altura determinada pelo bastão, mantendo-a perpendicular ao eixo vertical do tronco (SFB-D, 2014).

Os indivíduos selecionados nas subparcelas de cada subunidade têm sua altura total e do fuste estimadas por meio de clinômetros ou varas graduadas. A altura total (HT) é a distância vertical entre o nível do solo e o ápice da árvore. A altura do fuste (HF) é a distância vertical entre nível do solo e a base da copa da árvore. A altura total e o DAP são utilizados para a estimativa de biomassa e volume dos indivíduos, que são agregados para divulgação dos totais calculados para os conglomerados. (SFB-D, 2014)

3.2. Classes de uso da terra do IFN

Outro componente de identificação dos conglomerados do IFN é o uso da terra observado pela equipe de inventário que o visita, importante para auxiliar a interpretação dos dados coletados (SFB-D, 2014). As subparcelas dos conglomerados são classificadas de acordo com as classes de cobertura ou uso da terra, constantes no manual de campo do IFN (*Tabela 2*).

Tabela 2 – Classes de cobertura da terra utilizadas nas subparcelas do IFN para classificação do uso das partes do conglomerado, realizada pelas equipes de campo (SFB-D, 2014).

		Classes de Cobertura/ Uso da Terra		Legenda
Natural	Floresta Madura			Fm
Antrópica	Vegetação Secundária Vs	Pioneiro/Inicial -1	Sem palmeiras - s	Vss1
			Com palmeiras - p	Vsp1
	Médio/Avançado -2	Só palmeiras - b	Vsb1	
		Sem palmeiras - s	Vss2	
		Com palmeiras - p	Vsp2	
	Agropecuária A	Agropecuária - Ag Pecuária - Ap	Só palmeiras - b	Vsb2
Agropecuária - Ag			Ag	
Agropecuária - Ap		Ap		
Florestamento/ Reflorestamento R	Agricultura - Ac	Culturas Permanentes - p	Agropecuária - Ac	Acp
			Culturas Cíclicas - c	Acc
		Acácia - a	Ra	
		Algaroba - g	Rg	
		Araucária - r	Rr	
		Eucalipto - e	Re	
		Misto (mais de um gênero) - m	Rm	
		Outros gêneros - Ou	Ou	
		Pinus - p	Rp	
		Recomposição com nativas - n	Rn	
		Seringueira - s	Rs	
		Urbana e Influência Urbana - Iu	Iu	
		Degradadas por mineiração - Im	Im	
Área indiscriminada (solo exposto) - Ai	Ai			
Outras	Dunas - Dun	Dun		
	Afloramentos rochosos - Afr	Afr		
	Superfície com água	Agu		

3.3. Estoque Florestal em Volume e Biomassa

Estoque florestal indica a quantidade de material florestal armazenado na vegetação, é formado pelo volume e biomassa florestais. Para a estimativa de estoque florestal do IFN no estado do Ceará, foram utilizadas variáveis dendrométricas medidas em campo para serem aplicadas na **Equação 1**, ambas representam grandezas derivadas de relações entre o DAP e a HT medidos. Um aumento de DAP ou HT leva a um aumento do estoque florestal.

Biomassa acima do solo, calculada para espécies arbóreas e palmeiras:

Equação 1 – Biomassa acima do solo utilizado para a Caatinga no IFN (SAMPAIO, 2005), em que BAc é a biomassa em quilos, DAP é o diâmetro na altura do peito e HT a altura total do indivíduo.

$$BAc = 0,0612 \times (DAP \times HT)^{1,581} \quad (1)$$

3.4. Sistemas Orbitais (Satélites) de Monitoramento do Ambiente

As imagens orbitais são essenciais na elaboração de zoneamentos, indicadores de competitividade, mapeamentos e monitoramentos do uso e da cobertura das terras. Pode-se verificar um esforço significativo de pesquisa em Sensoriamento Remoto com as informações de imagens obtidas por satélites orbitais (JENSEN, 2011).

O uso de sensores desta natureza é particularmente importante no caso de países com extensões continentais como o Brasil, em que os custos para levantamentos e medições em campo podem ser reduzidos devido a um melhor planejamento proporcionado pelas imagens orbitais, ou ainda a possibilidade de realizar parte dos trabalhos de campo antes de realizar deslocamento de pessoal. A quantidade de sistemas orbitais disponíveis e a qualidade dos dados coletados por eles acompanha a evolução tecnológica vista em circuitos eletrônicos, software e outros equipamentos como celulares e câmeras fotográficas, aumentando as possibilidades de aplicação de técnicas de análise de imagens para monitoramento e acompanhamento de questões territoriais e ambientais (JENSEN, 2011).

3.5. Radiação Eletromagnética e a Matéria - Sensores Passivos

Para a utilização de sensores orbitais passivos, é necessário que haja energia proveniente do alvo que se pretende medir, no caso dos sensores ópticos a radiação medida é aquela que foi refletida pelos objetos de uma cena coberta pelo sensor (JENSEN, 2011). Esta energia refletida, no caso dos sensores orbitais de monitoramento ambiental, foi primariamente gerada pelo Sol, que emite radiação eletromagnética em um amplo espectro,

emissão essa que pode ser descrita por uma curva com pico no comprimento de 0.4 μm , limites em 0.2 μm e 3.0 μm (JENSEN, 2011).

A energia solar chega às camadas superiores da atmosfera terrestre sem alterações, quando começa a interagir com os componentes químicos e físicos desta atmosfera, que gradativamente atenuam e modificam a curva de radiação. Esta transmissão atmosférica mantém o pico de energia nos comprimentos de onda visíveis, pois seus componentes absorvem energia principalmente nas faixas até 0.3 μm , entre 1.3 μm e 1.5 μm , entre 1.7 μm e 2.0 μm e maior que 2.6 μm (ozônio, oxigênio, água e outros gases) (HANGSUNG, 2015). A comparação entre as curvas típicas de radiação solar no topo da atmosfera e na superfície terrestre, para uma região sem nuvens, pode ser estabelecida (**Figura 3**).

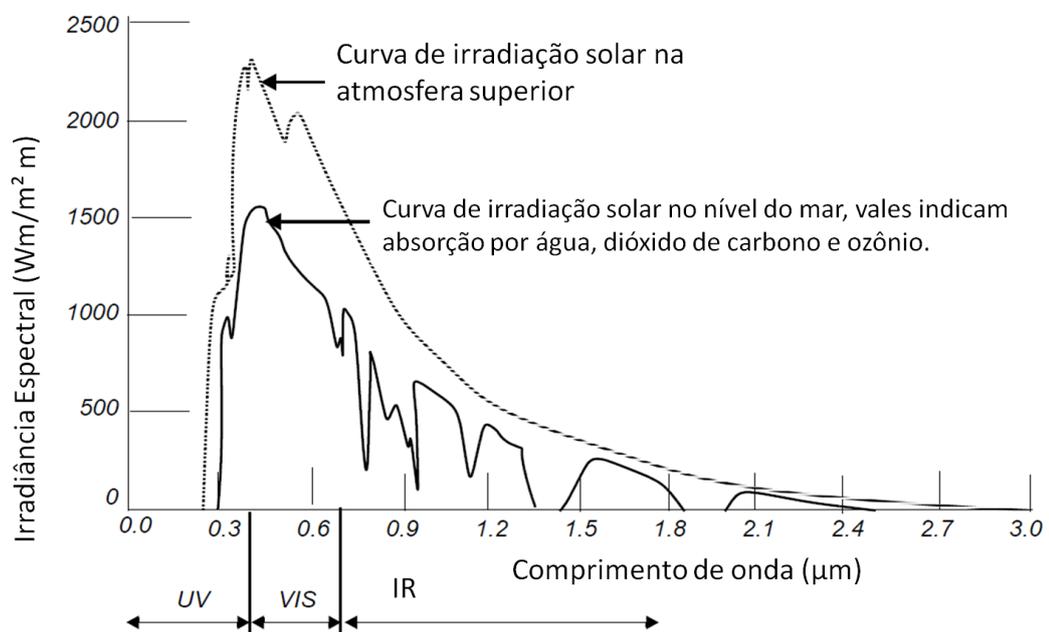


Figura 3 - Curvas de radiação no topo da atmosfera e na superfície (HANGSUNG, 2015). As imagens RapidEye são formadas por esta radiação após interagir com elementos da superfície.

A radiação que chega aos objetos interage com eles de formas diversas, dependendo principalmente do comprimento de onda da radiação e das propriedades físicas dos materiais que compõe os objetos (PHY-ASTR, 2014). As interações mais comuns e esperadas para os comprimentos de onda entre os Raios-X (mais energético, comprimento menor e frequência maior) e as micro-ondas (menos energético, comprimento maior e frequência menor) podem ser esquematizadas graficamente (**Figura 4**). Neste estudo são avaliadas as respostas de mudança de níveis eletrônicos (luz visível), as vibrações moleculares (infravermelho) e os efeitos da radiação de RADAR (micro-ondas), que provoca rotação e torção molecular.

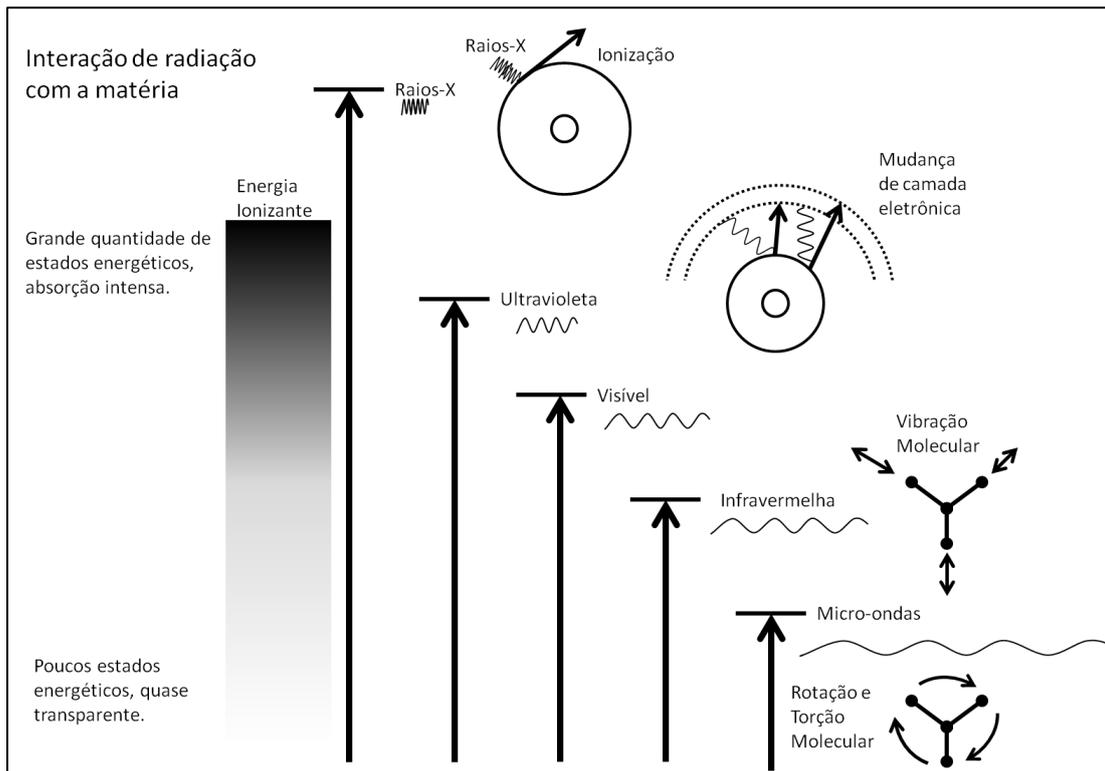


Figura 4 - Ilustração das interações da matéria com as diferentes radiações eletromagnéticas (PHY-ASTR, 2014). Os sensores remotos de monitoramento do ambiente detectam a resposta de interação da energia destas ondas com os alvos da superfície terrestre.

Apesar destas diferentes respostas da matéria, para o sensor orbital há apenas a chegada de radiação em diferentes comprimentos de onda, após interação com os alvos (PHY-ASTR, 2014). Assim, é importante que sejam entendidos os efeitos que cada radiação provoca para posterior interpretação da resposta medida pelo sensor, independente de alvo. Na visão macroscópica das interações, temos as percepções aparentes de um evento radiativo apresentado (**Figura 5**).

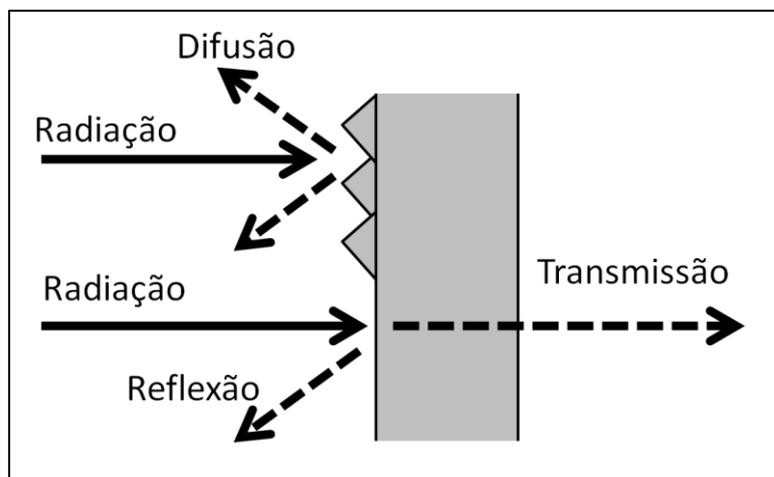


Figura 5 - Respostas macroscópicas da interação entre matéria e radiação (PHY-ASTR, 2014).

Assim, dado um alvo e diferentes comprimentos de onda eletromagnética que o atingem, podemos estimar o conteúdo deste alvo de acordo com os diferentes níveis de difusão, absorção, reflexão e transmissão observados (NASA, 2012). Neste estudo objetivou-se interpretar em conjunto a resposta de uma mesma região com radiação óptica com a resposta de RADAR banda L, levando em consideração que a interação detectada por ambos os sensores ocorre de formas distintas e não necessariamente com os mesmos objetos ou alvos presentes na área amostrada. As curvas de refletância de coberturas de solo diferentes podem ser utilizadas para classificar ou distinguir outros alvos que apresentem curvas semelhantes (**Figura 6**).

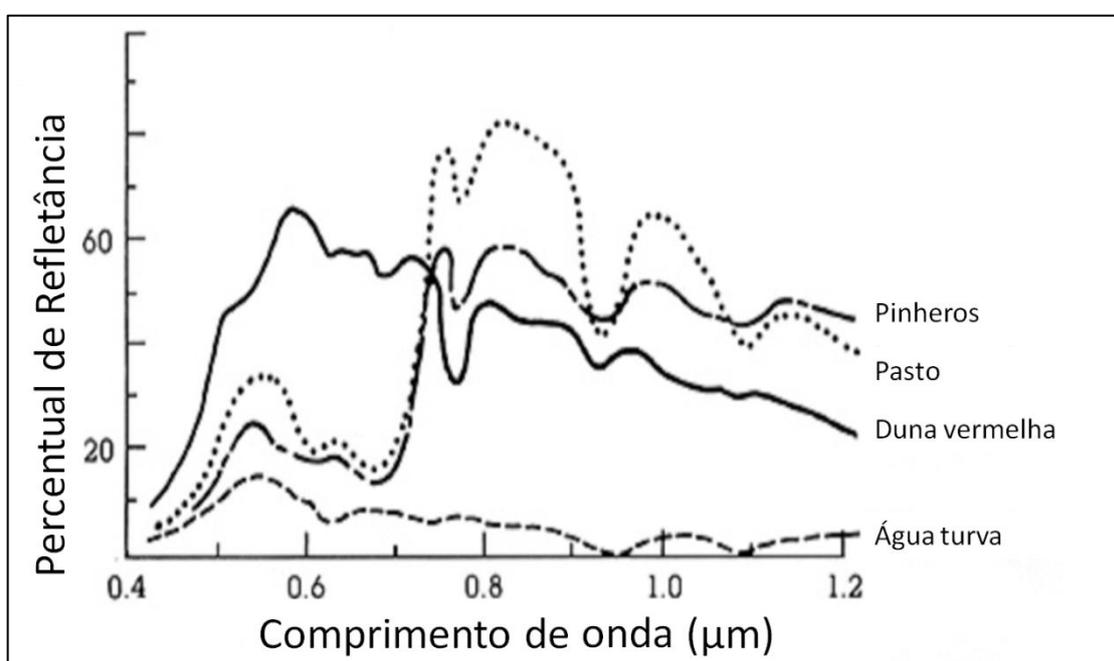


Figura 6 - Curvas de refletância eletromagnética de diferentes coberturas de solo (NASA, 2012).

Ainda no campo das interações com luz óptica, os componentes de florestas têm como principais sensibilidades a identificação de pigmentos foliares, que absorvem luz visível (0,3 a 0,7 μm) e o mesófilo esponjoso, componente da estrutura foliar, que absorve principalmente no infravermelho (0,7 a 1,4 μm). Por outra perspectiva o conteúdo de água interage com os comprimentos maiores (até 2,6 μm) e tem a possibilidade de influenciar as estruturas das plantas, podendo conseqüentemente alterar sua forma e disposição geométrica, alterando a interação com qualquer radiação (JENSEN, 2011).

A análise do que é retornado pela superfície terrestre, após a interação da radiação solar, pode oferecer informações florestais (cobertura de solo, densidade de vegetação,

atividade fotossintética, entre outras) de áreas remotas, que para serem avaliadas diretamente, teriam custo ou acesso impraticável. As Bandas de medição eletromagnética dos sensores passivos dos satélites RapidEye (BlackBridge, 2012) podem ser classificadas pelas faixas de absorção:

- Verde - 0.5 a 0.6um - Vegetação reflete se saudável;
- Vermelho - 0.6 a 0.7um - Absorção por vegetação saudável, fronteira de uso de solo;
- Vermelho/Infravermelho próximo (rededge) - 0.69 a 0.73 - Área de variação drástica na absortância de radiação pela vegetação, entre o vermelho e o infravermelho.
- Infravermelho próximo - fonte: 0.76 a 0.85 - Sensível à área foliar saudável, identifica vegetação e contraste com solo. Mais reflexão com maior área.

As curvas de interação de diferentes coberturas de solo são obtidas com a radiação óptica, com informação adicional das bandas de detecção de radiação do sistema RapidEye, que mede as quatro faixas listadas anteriormente além da faixa de frequência no comprimento de onda visível Azul que é utilizada na correção atmosférica de alguns índices de vegetação (*Figura 7*).

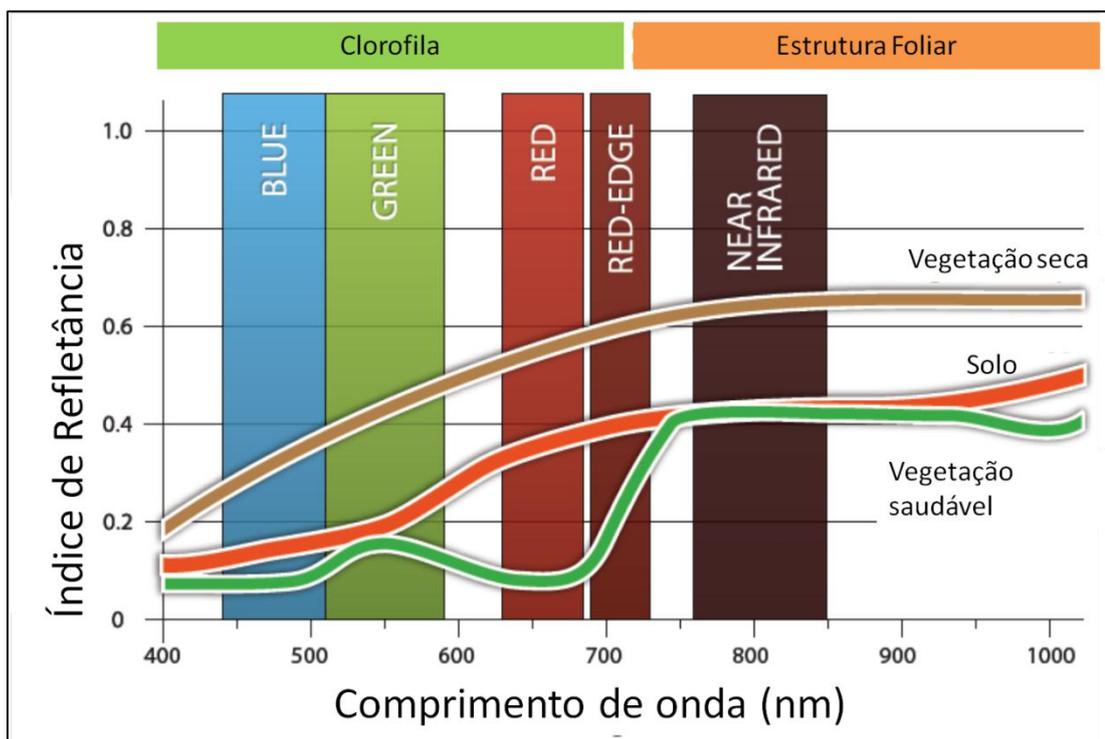


Figura 7 - Curvas de resposta e bandas do sensor remoto RapidEye para monitoramento de cobertura de solo, linha marrom indica a resposta de vegetação seca, linha verde de vegetação saudável e linha vermelha de solo nu (BLACKBRIDGE, 2012).

3.6. Radiação Eletromagnética e a Matéria - Sensores Ativos

Os radares imageadores são equipamentos que emitem radiação eletromagnética no comprimento das micro-ondas (**Figura 8**), detectando esta mesma radiação após interação com um alvo, para que a resposta dos alvos à incidência desta radiação específica depois seja analisada (**Figura 9**), conforme previamente descrito (BACELAR, 2004). Os sistemas de antena rotatória e os de visada lateral são utilizados para monitoramento ambiental. Sendo um sensor ativo, não depende da radiação solar, operando durante o dia e a noite, o que facilita a observação de pontos determinados da superfície terrestre (JENSEN, 2011).

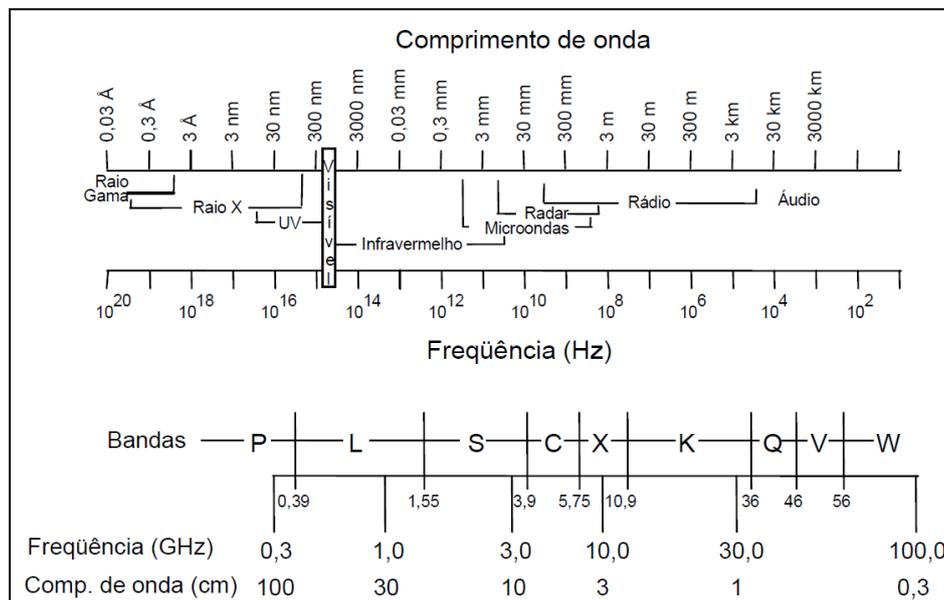


Figura 8 - Comprimentos de onda comuns no espectro eletromagnético e bandas de RADAR. O sistema PALSAR que coletou os dados utilizados neste estudo emitia ondas na banda L, com frequência central em 1,27 GHz em visada lateral com imageamento de faixas de 20 a 350 km na resolução de 7 a 90m.

Radares de visada lateral transportados em veículos (barco, aeronave, satélite), cobrem uma faixa de imageamento (**Figura 10**) e oferecem cobertura espacial e resolução temporal dependente do transporte (faixa com largura de 1 a 500 km com comprimento de acordo com o caminho percorrido). Esta modalidade de RADAR produz pontos em superfícies contínuas, indicado para identificação de alvos com menor variação temporal, mas que necessitem de uma resolução espacial melhor, como a cobertura de solo ou relevo.

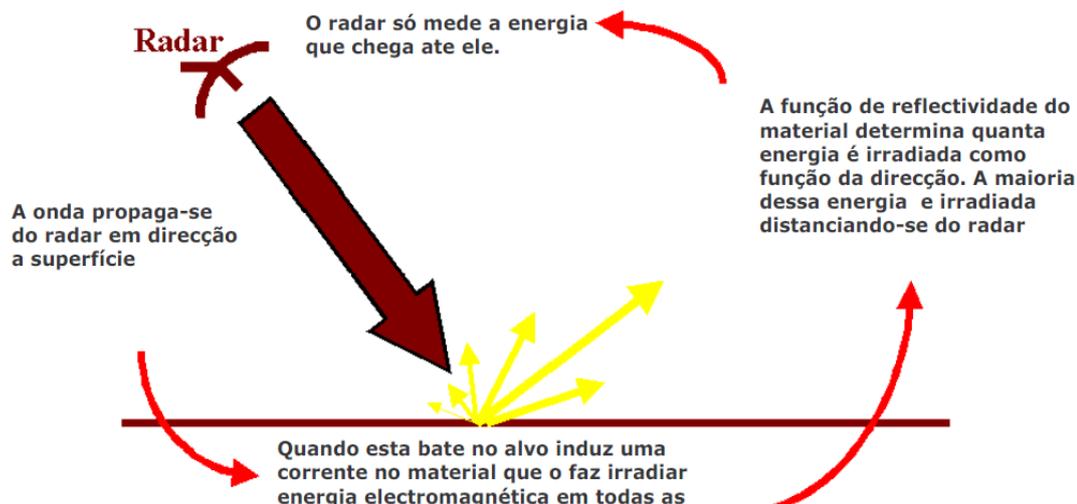


Figura 9 - Esquema simplificado de emissão e resposta com RADAR (BACELAR, 2004).

Na história mais recente, após a década de 1980, foram lançados satélites em missões orbitais civis com novos sensores, como os radares de abertura sintética (SAR), que usam a sua órbita para simular uma antena maior, que permite um aumento de sensibilidade de recepção das ondas refletidas pelo alvo. A frequência usada para monitoramento ambiental não interage com nuvens ou chuva, e sofre alteração apenas com a condição do alvo, o que é uma vantagem em relação aos sensores passivos (JENSEN, 2011).

Apesar da vantagem de não depender da cobertura de nuvens para obter uma imagem do alvo na superfície terrestre, o dado de um sensor SAR necessita de cuidados específicos por ter sua qualidade radiométrica afetada por fatores inerentes ao instrumento, bem como à geometria de iluminação (JENSEN, 2011). As duas principais causas de distorções radiométricas que prejudicam a interpretação das imagens de radar são: o efeito "Speckle" e o efeito do padrão da antena. O efeito *Speckle* é um dos principais fatores que degradam a qualidade das imagens SAR, sendo um tipo de ruído multiplicativo que é proporcional à intensidade do sinal recebido. O efeito visual deste ruído proporciona uma textura granulosa que pode dificultar a interpretação das imagens de radar, reduzindo a separabilidade entre classes de uso do solo, tipos litológicos etc. (INPE, 2016).

As necessidades crescentes e complexas no monitoramento e modelagem das florestas brasileiras exigem metodologias apropriadas, com o uso de todos os sensores possíveis, sendo o radar uma opção consistente para complementar os sensores tradicionais (INPE, 2016).

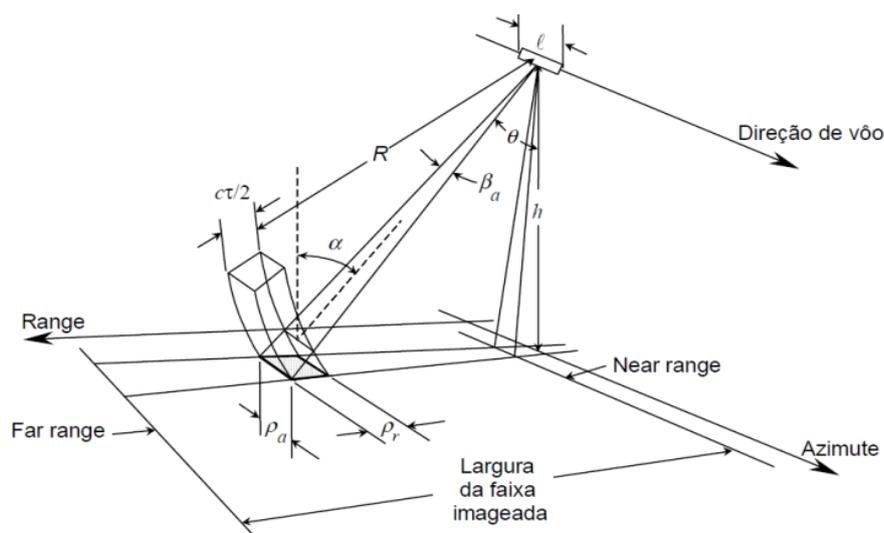


Figura 10 - Geometria de imageamento de um SLAR, onde se destacam os principais parâmetros relacionados ao imageamento, tais como o ângulo de incidência e de visada, as resoluções espaciais em ground range (direção no solo perpendicular à direção de voo) e em slant range (direção oblíqua perpendicular à direção de voo), a área imageada, a largura do feixe, entre outros (DUTRA, 2003).

3.7. Imagens RapidEye, PALSAR e a derivação de Índices de Vegetação com Imagens de Satélite (NDVI, EVI e RFDI)

A constelação RapidEye é formada por cinco satélites de sensoriamento remoto, idênticos e posicionados em órbita síncrona com o Sol, com igual espaçamento entre cada satélite (BLACKBRIDGE, 2012). Esta configuração permite atingir repetitividade de coleta e exatidão de informações geradas sobre a superfície da Terra. Cada satélite RapidEye efetua 15 voltas na Terra e seus sensores coletam imagens em uma faixa de 77 km de largura por até 1500 km de extensão (FELIX, 2009). Os satélites juntos geram cerca de 4,5 milhões de Km² de imagens por dia, produzindo imagens de qualquer ponto do globo, de forma programada e distribuição mais rápida e eficaz do que satélites anteriores (FELIX, 2009).

Os satélites são equipados com sensor multiespectral com scanners de linha de 12.000 pixels cada, captura imagens em cinco bandas espectrais ópticas, com comprimento de onda entre 440 µm e 850 µm (FELIX, 2009). Foi o primeiro sistema orbital com banda RedEdge, com sensibilidade específica para medição de atividade fotossintética, que mede variações que permitem a separação de espécies e monitoramento da saúde da vegetação. A resolução espacial original de cada banda é de 6,5 metros, e após a ortoretificação as

bandas são reamostradas para uma resolução de 5m, resultando em imagens corrigidas com precisão de detalhes compatível com escala 1:25.000. As imagens da RapidEye são normalmente fornecidas ortorretificadas e com correção atmosférica ao SFB.

As imagens do sistema RapidEye que foram utilizadas neste estudo são as do produto de nível três, Ortorretificado, composto por Imagens com correção radiométrica e geométrica a partir de DEM SRTM (Nível um DTED) ou melhor, com uso de pontos de controle. Podem atingir exatidão de 6m (12,7m CE90), compatível com escala 1:25.000.

As imagens de RADAR utilizadas foram obtidas no SFB, que mantém um banco de dados espaciais que incluem os dados de radar do sensor PALSAR (Radar de Abertura Sintética) do programa ALOS da JAXA (Agência de exploração aeroespacial do Japão, com quem o SFB tem um acordo de cooperação técnica) dos anos de 2007 a 2010 (SFB-A, 2016). Estes dados necessitam de uma interpretação adequada e podem ser úteis por serem adquiridos por sensores ativos em frequências que sofrem menos interferência de nuvens, assim podem auxiliar na classificação de cobertura de solo das áreas com ausência de informação de sensores passivos como o Landsat e o RapidEye (JENSEN, 2011).

Os dados ortorretificados do PALSAR foram disponibilizadas pela JAXA em formato compactado específico. Cada imagem formada por 2 a 5 pedaços de faixas de coleta da visada lateral do sensor PALSAR do ALOS cobre uma área de 1x1 grau do território, com cobertura de aproximadamente um milhão de hectares, a resolução das imagens é de 22,5m (JAXA, 2012). Foram usados os dados das imagens polarimétricas com polarização horizontal (HH) e vertical (HV), convertidas utilizando relações informadas pelo fornecedor dos dados, para determinação da grandeza física σ_0 ("Sigma zero"), que assume valores em decibéis do sinal de radar recebido pelo sensor. Esta intensidade recebida pode ser correlacionada com os objetos presentes no local a que o pulso de radar atinge (JAXA, 2012).

A resposta de interação dos objetos que cobrem o solo com a radiação incidente pode ser interpretada visualmente após o processamento, sendo o método mais intuitivo e comumente utilizado (DUTRA, 2003), produzindo imagens de sensores ativos e passivos (*Figura II*). As relações conhecidas das diferentes bandas ou polaridades oferecidas pelo sensor orbital podem representar informações específicas que não são facilmente identificadas com a interpretação dos dados individuais ou visuais. Desta forma, podem-se retirar informações que venham a auxiliar na interpretação futura.

Os Índices de Vegetação, uma derivação que busca maximizar a resposta de parâmetros biofísicos das plantas, normalizando os efeitos externos (ângulo solar, visada, interferência atmosférica) e internos (topografia, solo, substrato), podem ser uma das formas de extração para mais informações. É importante que o índice possa ser validado com parâmetros mensuráveis (JENSEN, 2011), obtendo-se um esquema com as interações que se pretende identificar com os índices, especificamente para o caso de cobertura de solo com e sem vegetação (*Figura 12*).

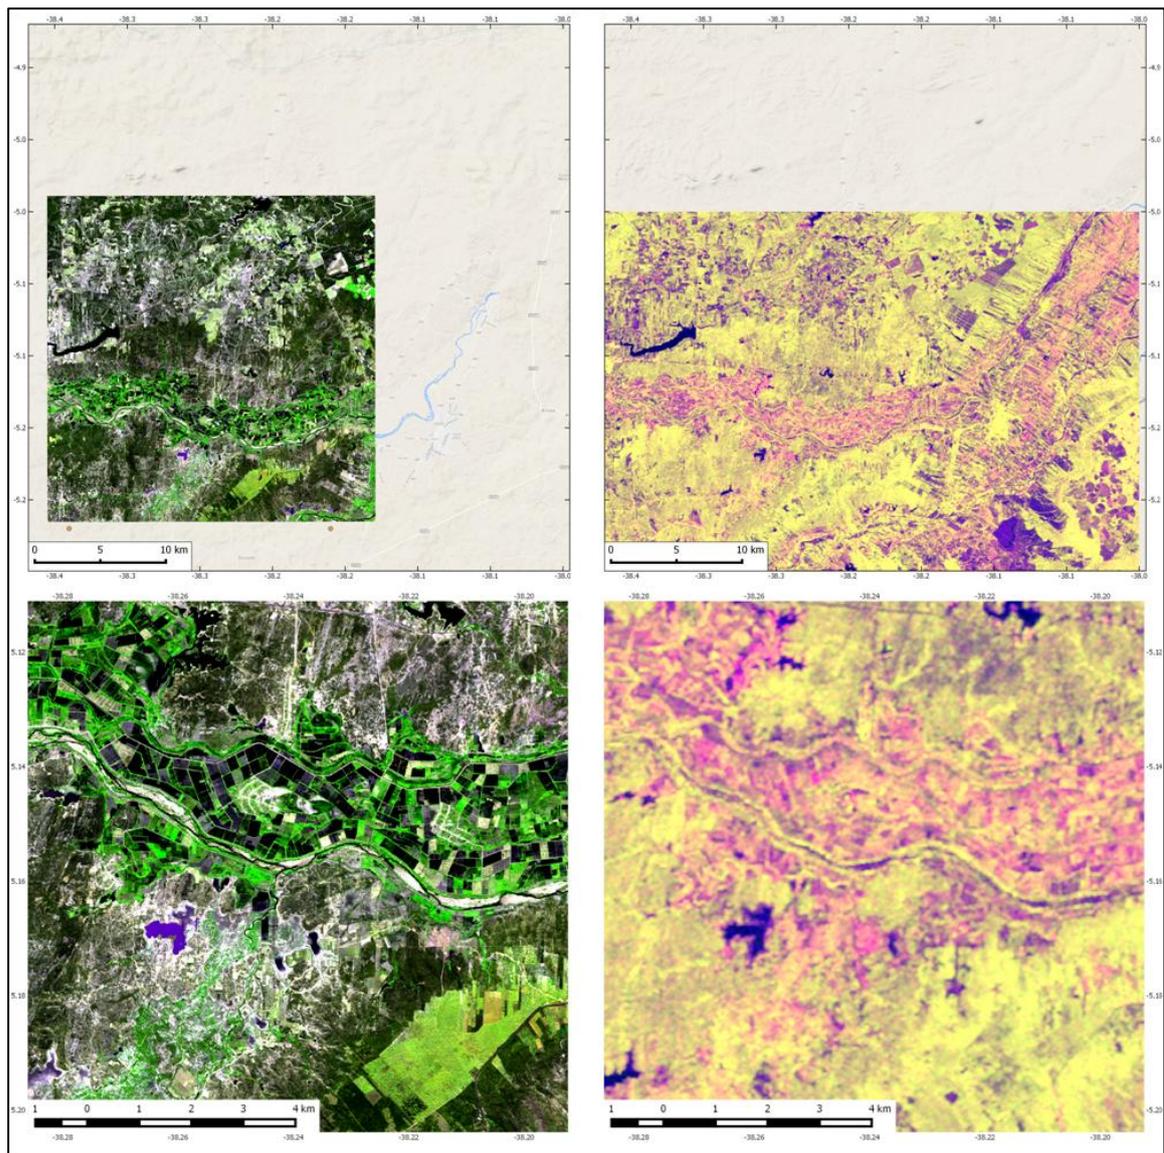


Figura 11 - Comparativo de imagem óptica e imagem de radar em uma mesma região do Ceará, à esquerda composição em resolução de 5m com bandas 4-5-2 do RapidEye (rededge-infravermelho-verde) e à direita imagem com resolução de 22m da resposta em polarização HH do PALSAR. Imagens com coordenada central 5,16S 38,24W (Sirgas 2000, EPSG:4674) entre os municípios de Morada Nova e Limoeiro do Norte.

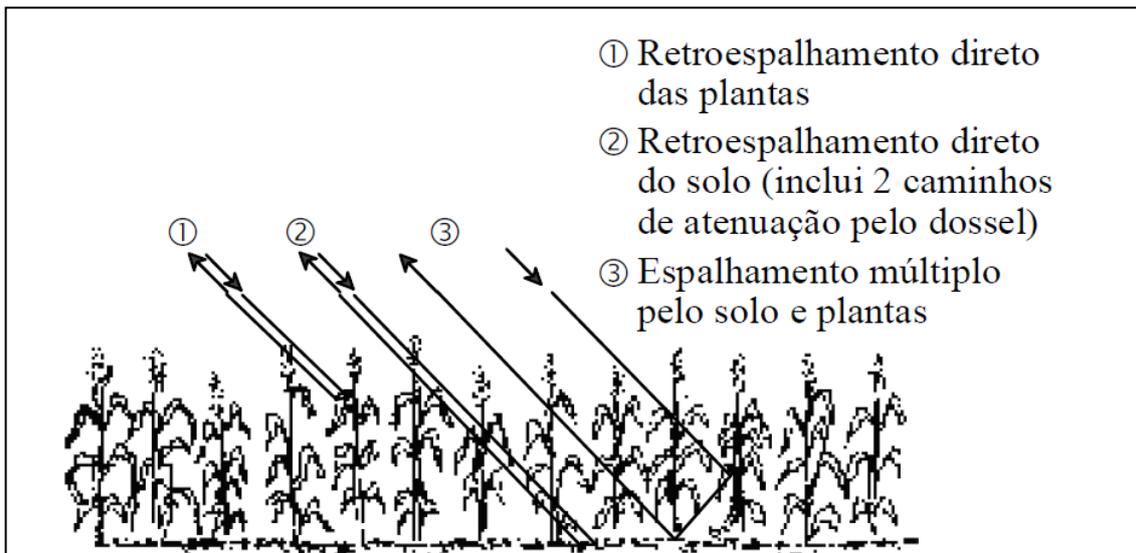


Figura 12 - Interação de radiação e vegetação (LUCIANO, 2003).

3.8.NDVI (Índice de Vegetação por Diferença Normalizada)

O NDVI (*Normalized Difference Vegetation Index*) ou Índice de Vegetação por Diferença Normalizada está relacionado às diversas propriedades das plantas, utilizado para a estimativa da biomassa verde e a saúde vegetal. Influenciado por nuvens e condições climáticas, satura em condições de dossel mais denso (JENSEN, 2011), sendo calculado a partir da *Equação 2*.

Desenvolvido em 1973 (ROUSE, 1973), onde NIR (Near Infrared) é a refletância na faixa óptica do infravermelho próximo e Red na faixa do vermelho. O índice pode ser aplicado para realçar a vegetação de uma imagem RapidEye (*Figura 13*).

Equação 2 - Cálculo do Índice de Vegetação Por Diferença Normalizada, em que NDVI é o índice de vegetação por diferença normalizada, NIR é a refletância na banda infravermelha próxima e Red é a refletância na banda vermelha.

$$NDVI = (NIR - Red)/(NIR + Red) \quad (2)$$

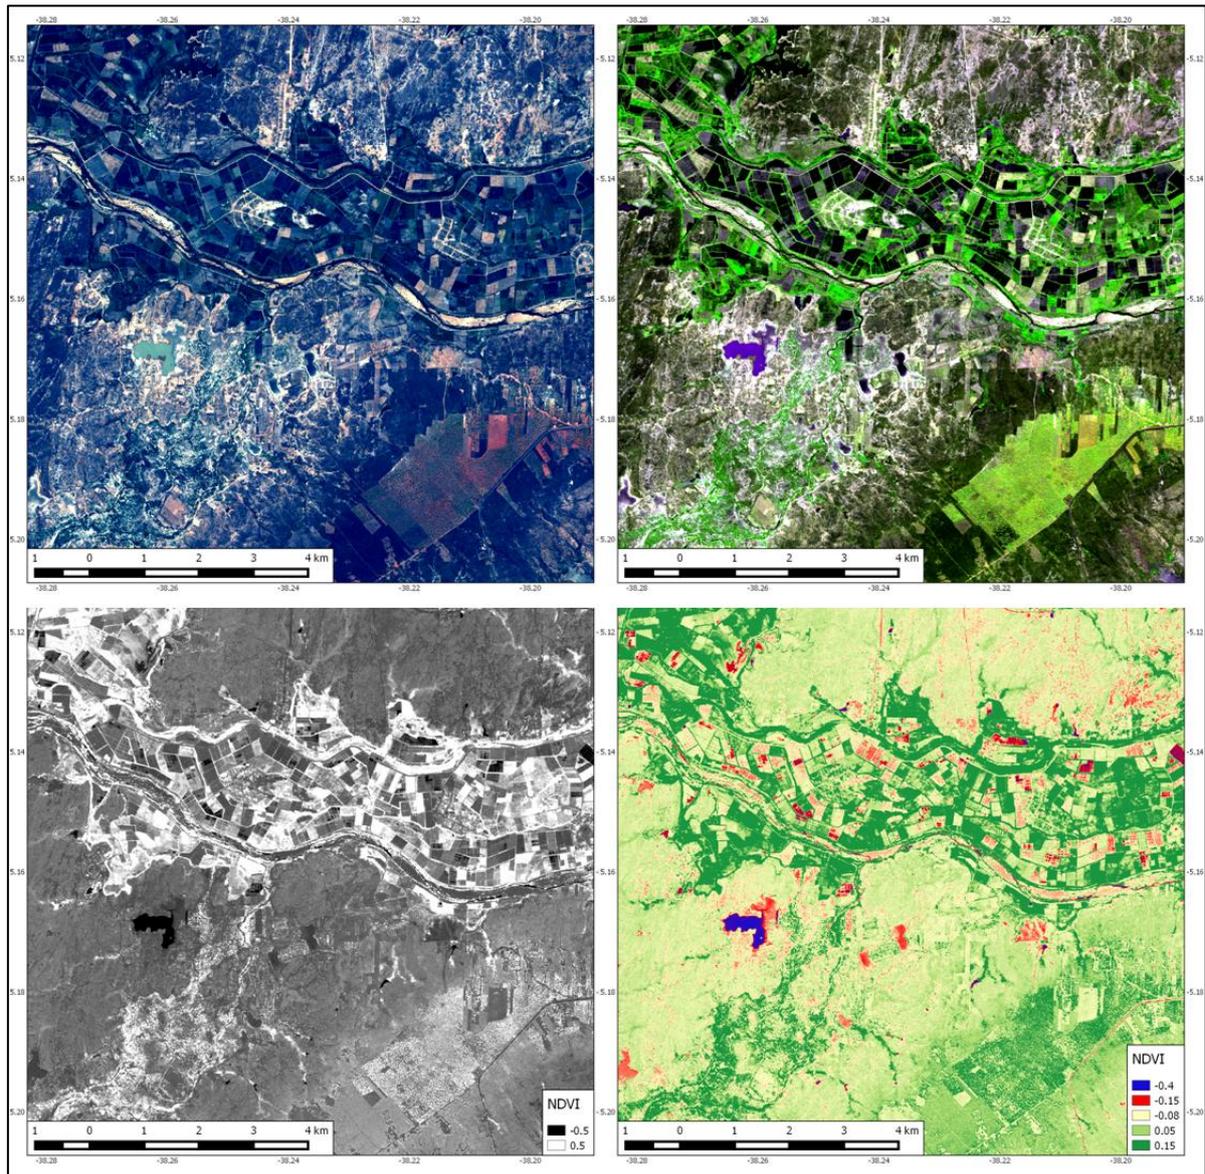


Figura 13 – Utilização de dados do sensor RapidEye para identificação de vegetação. Na linha superior imagem óptica (R-G-B com bandas 3-2-1) à esquerda, realçada para vegetação (bandas 4-5-2) à direita. Na linha inferior, o NDVI calculado (tons de cinza) calculado à esquerda e NDVI realçado com cores à direita (vermelho para valor baixo e verde para valor alto). Imagens na mesma região da **Figura 11**.

3.9.RFDI - Índice de Degradação Florestal por RADAR

O RFDI (Radar Forest Degradation Index) é um índice normalizado derivado das respostas horizontal (HH) e vertical (HV) do PALSAR ou outro radar polarimétrico, proposto pela Jaxa para composição de imagens com interpretação visual semelhante às de imagens provenientes de sensores ópticos (JAXA, 2012). Trata-se de uma relação em que

se espera a distinção de áreas com mais retorno no HH do que no HV. Quando há mais florestas a resposta esperada para este índice é maior do que quando se imageia uma área degradada ou sem floresta (MITCHARD, 2012). Os dados PALSAR de cada polarização são fornecidos em arquivos binários com tabelas de 4500x4500 números de 8bits que para uso devem ser descompactados caso se pretenda processar os níveis de resposta em decibel (dB), isto é feito com a **Equação 3** (JAXA, 2012).

Equação 3 – Decodificação dos números digitais do PALSAR, em que σ_0 (sigma zero) é a resposta normalizada por área dos objetos amostrados no pixel, DN é o número digital registrado no arquivo binário e CF é um coeficiente de correção informado no produto.

$$\sigma_0 = 10\log_{10}(DN^2) + CF \quad (3)$$

Equação 4 - Cálculo do Índice de Degradação Florestal por RADAR, em que RFDI é o índice de degradação florestal, HH a resposta medida em polarização de emissão e recepção horizontais, enquanto HV é a resposta medida em emissão horizontal e recepção vertical.

$$RFDI = \frac{HH-HV}{HH+HV} \quad (4)$$

Aplicado aos DN (número digital, valor do pixel em cada ponto) das imagens de polarização Horizontal-Horizontal (emissão-recepção, HH) e Horizontal-Vertical (HV), permite o cálculo do RFDI (Radar Forest Degradation Index), conforme **Equação 4** (BLUE, 2014). Um exemplo de aplicação composta e realçada do RFDI pode ser feito na mesma área das **Figuras 11 e 13 (Figura 14)**.

O RFDI pode ser associado aos dados HH e HV para criar uma imagem RGB que contém a uma composição das respostas em polarização horizontal e vertical em um formato visualmente semelhante a composições de cores para imagens visíveis, de interpretação mais natural do que dados originais de RADAR (BLUE, 2014). Conforme podem ser observados (**Figura 15**), os valores normais de RFDI ficam entre 0,4 e 0,8, sendo esperada uma maior presença de estoque florestal para valores mais baixos e áreas degradadas para valores superiores a 0.6 (HAGEN, 2014).

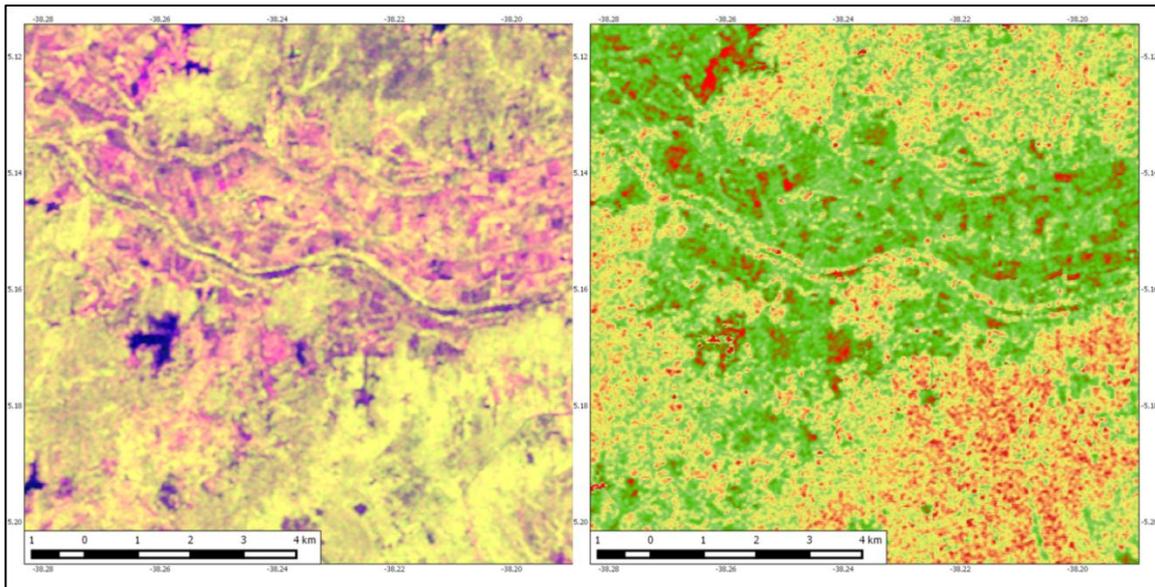


Figura 14 - Imagens do PALSAR, à esquerda composição R-G-B com as polarizações HH e HV mais o RFDI, à direita o RFDI realçado. Mesma região das Figuras 15 a 17. A composição nesta combinação facilita a interpretação visual dos dados de RADAR enquanto o RFDI auxilia a localizar locais com diferentes quantidades de estoque florestal (biomassa, carbono, volume).

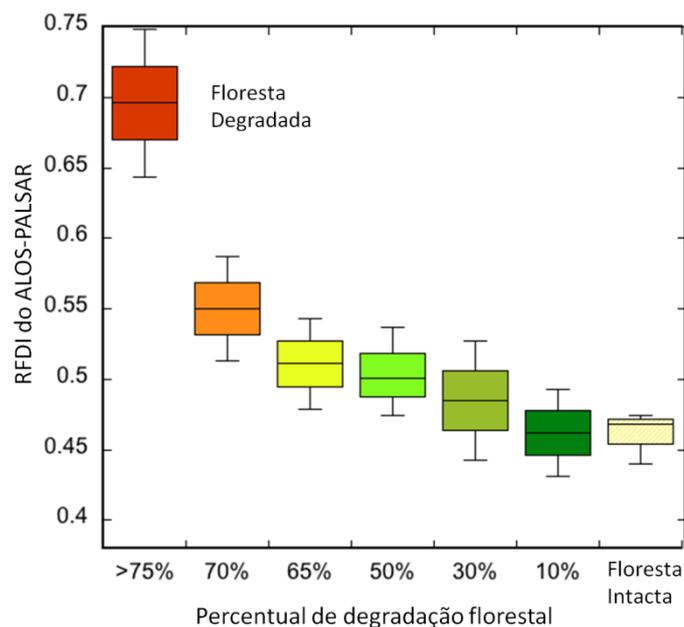


Figura 15 – Exemplo de resposta do RFDI de acordo com a perda de biomassa verificada para uma área de floresta da Indonésia (HAGEN, 2014).

Uma análise de componente principal das três bandas resulta em uma componente primária que distingue água e vegetação, uma secundária que pode estimar a altura da vegetação (resolução de 12m) com as quais é possível estimar a biomassa. (HONG, 2012)

3.10. Geoestatística e Krigagem de Dados

A geoestatística estuda fenômenos que variam no espaço, o tempo e são espacialmente correlacionados (YAMAMOTO, 2013). Seu uso tem se intensificado desde a década de 1980, pois é uma estatística de algoritmos matriciais que são computacionalmente exigentes para serem aplicados (BOHLING, 2005). A caracterização desta correlação espacial é feita pela análise de variogramas, funções que medem a variação de uma variável em relação a sua própria amostragem (YAMAMOTO, 2013). No caso da geoestatística, esta análise leva em consideração ainda à distância e a orientação entre as amostras (YAMAMOTO, 2013). Com a geoestatística, pode-se interpolar o estoque florestal a partir da estimativa nos pontos do IFN, utilizando uma relação espacial semelhante à representada na *Equação 5*.

Equação 5 – Estimativa com combinação ponderada por relação espacial de dados, onde u refere-se a uma localização qualquer, $Z^*(u)$ é o valor estimado nessa localização, sendo que existem n dados $Z(u_i)$, com $i = 1, 2, 3 \dots n$ na circunvizinhança com λ_i referindo-se aos pesos calculados para cada dado amostral.

$$Z^*(u) = \sum_{i=1}^n \lambda_i Z(u_i) \quad (5)$$

Uma das técnicas que fazem parte da geoestatística é a *Krigagem*, um método de interpolação de dados que consiste em prever o valor de uma função em determinado ponto computando-se uma média ponderada dos valores vizinhos conhecidos (YAMAMOTO, 2013). A krigagem é similar a uma análise de regressão, sendo a krigagem direcionada a estimar uma única realização do processo em um campo aleatório, enquanto a regressão utiliza múltiplas observações de um conjunto de dados multivariado (OLEA, 2010). A *krigagem* ordinária pode ser descrita pela *Equação 6*, em que é feita uma estimativa linear ponderando dados de um local não amostrado u_0 com n valores amostrados em pontos adjacentes (YAMAMOTO, 2013).

Equação 6 – Krigagem ordinária de dados para estimativa linear ponderada, onde u_0 refere-se a uma localização qualquer, $Z^*(u)$ é o valor estimado nessa localização, sendo que existem n dados $Z(u_i)$, com $i = 1, 2, 3 \dots n$ na circunvizinhança com λ_i (YAMAMOTO, 2013)

$$Z_{KO}^*(u_0) = \sum_{i=1}^n \lambda_i(u_0) \times Z(u_i) \text{ com } \sum_{i=1}^n \lambda_i(u_0) = 1 \quad (6)$$

Para que esta estimativa ponderada de dados tenha a melhor estimativa possível, deve-se determinar com o método os pesos λ_i ótimos que podem ser obtidos minimizando-se a variância do erro, que conforme Yamamoto (2013), resulta na **Equação 7** que é um sistema normal de equações que descreve os ponderadores da krigagem ordinária.

Equação 7 – Sistema de ponderadores da Krigagem ordinária com pesos ótimos, em que λ_j são os pesos ótimos, u_0 refere-se a uma localização qualquer, u_i a localização em que se pretende encontrar os pesos ótimos com $i = 1, 2, 3 \dots n$, e u_j o ponderador ótimo.

$$\sum_{i=1}^n \lambda_j Cov(u_i, u_j) = Cov(u_i, u_0) \text{ para } i = 1, 2, \dots, n \quad (7)$$

A krigagem é utilizada para interpolação de dados espaciais de forma mais ampla, com dados de mineração em que se têm amostras dispersas de solo ou minerais em uma área e se quer estimar a distribuição de suas propriedades de forma contínua (YAMAMOTO, 2013). Este método de krigagem foi utilizado, majoritariamente em estudos anteriores a 2008, em diferentes aplicações para dados florestais incluindo distribuição de biomassa (FREEMAN, 2006; SALES, 2007) e planejamento florestal (GUNNARSON, 1996), inclusive com associação de krigagem com sensoriamento remoto (SIAN, 2005). A krigagem ordinária é realizada apenas com a própria variável que se deseja estimar, utilizando-se de um modelo de acordo com a natureza do que se deseja tratar, com semi-variograma para chegar a uma interpolação ótima dos dados (YAMAMOTO, 2013).

A krigagem visa correionalizar o Estoque Florestal dos pontos inventariados pelo IFN com índices de vegetação calculados sobre imagens de sensores ativos e passivos. Assim os dados destes sensores destas áreas inventariadas são considerados os atributos colocados com a variável que se quer interpolar (Estoque Florestal). Os atributos sobrepostos formam a estrutura de análise a ser usada no modelo de krigagem, que visa descrever a estimativa de estoque para as partes não inventariadas do estado, com informações mais finas, em uma resolução de 500m x 500m (para todo o estado do Ceará), a partir da grade de 20km x 20km do IFN. Como as imagens são contínuas no território do estado, elas servem como auxiliares na definição de contornos e detalhes de concentração

de vegetação e estrutura florestal que influenciem na interpolação do Estoque Florestal (SFB-A, 2016).

Com a krigagem o resultado da interpolação tende a apresentar variância menor do que o dado original, com uma superestimativa dos valores mais baixos de estoque e uma subestimativa dos mais altos (GUNNARSON, 1996), isto reforça o objetivo de mapear diferenças em níveis de estoque florestal estimado, abrangendo faixas de valores possíveis para a variável estimada, sendo reclassificada por meio da distribuição de valores discretos da imagem (arquivo raster ou tabela de pixels) resultante do processo.

Os dados resultantes da *krigagem* são úteis principalmente para a avaliação da distribuição da grandeza interpolada em uma área, pois os dados são espacializados e podem ser comparados a outras informações ambientais geolocalizadas. Deste modo, causas e efeitos de diferentes fontes de dado ambiental podem ser discutidos em relação às estimativas interpoladas de estoque florestal. Assim, mesmo que o valor estimado não indique a quantidade de biomassa ou volume de cada ponto, o mapeamento de diferenças permite interpretações que auxiliam no entendimento de ambos na área de estudo (YAMAMOTO, 2013).

4. MATERIAL E MÉTODOS

4.1. Localização da Área de Estudo

O estado do Ceará (14.880.000 hectares) é a área selecionada para estudo. Os pontos amostrais da grade regular do IFN no Estado foram utilizados por possuírem 100% da sua área inventariada. Particularmente, foram utilizadas as informações referentes às árvores medidas nos pontos amostrais e às quantidades de Biomassa estimadas pela equipe do IFN no SFB. As unidades consideradas foram deste modo medidas nos pontos de coleta entre 18/10/2013 e 25/06/2014 (*Figura 16*).

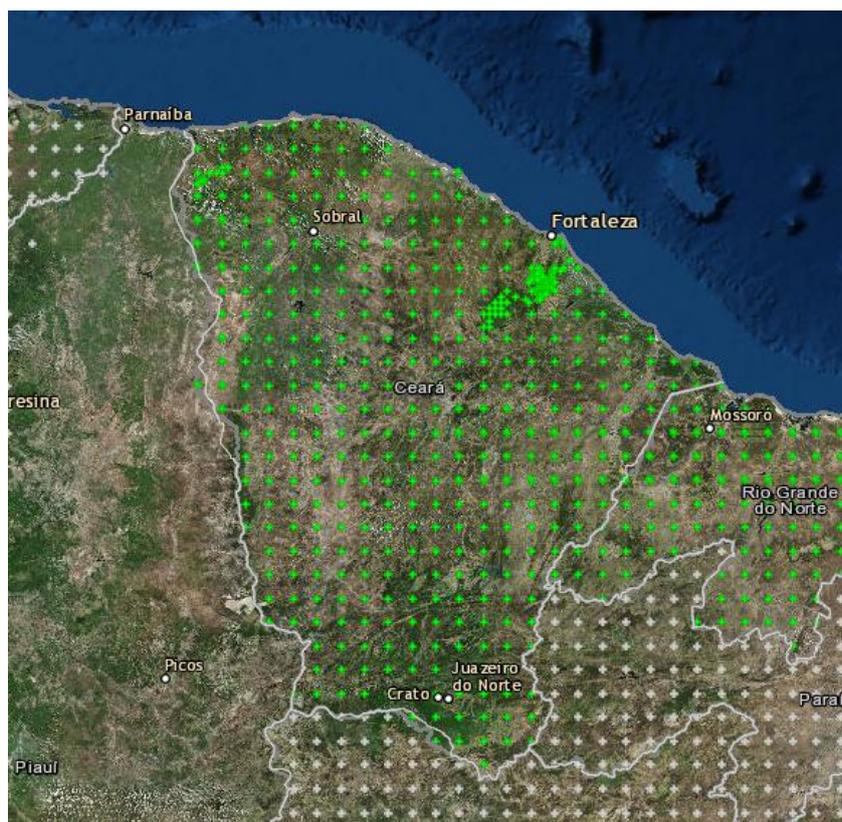


Figura 16 - Pontos de dados coletados pelo IFN (SFB-C, 2016).

O Ceará foi escolhido ainda por ser predominantemente inserido no bioma Caatinga, encontrado apenas no Brasil e formado por uma vegetação que apresenta

particularidades de distribuição e resposta espectral, que a tornam mais complexa de avaliar por sensores remotos do que os outros biomas brasileiros (ICMBIO, 2016).

Foram processadas imagens de todo o estado do Ceará, tanto por amostragem em áreas próximas dos conglomerados do IFN, quanto de forma contínua na geração de imagens e mapas para análise visual. Foi feita também uma análise de demonstração do uso dos dados processados e interpolados do Ceará, em conjunto com dados do Cadastro Ambiental Rural (CAR), também gerenciado pelo SFB. O foco desta demonstração foi a estimativa de componentes de estoque florestal inseridos em propriedades particulares declaradas no CAR, principalmente em área de Reserva Legal e de Remanescente de Vegetação Nativa declarados.

Ao analisar a distribuição espacial de propriedades, do estoque florestal estimado por métodos geoestatísticos aplicados ao IFN e do estoque estimado por meio do índice de degradação florestal de RADAR, foram observadas também as relações com as sub-bacias hidrográficas e o relevo do estado. Estes resultados foram exibidos e tentou-se explicar os prováveis motivos, por exemplo, de existirem propriedades grandes em determinadas regiões com menor densidade de estoque florestal estimado ou menores propriedades próximas de rios e em áreas com maior estoque florestal médio.

A grandeza escolhida para quantificar as florestas foi o Estoque de Biomassa Florestal Potencial por agregar diferentes estimativas derivadas das medidas dos indivíduos vegetais. Esta definição menos precisa acompanhou o intuito de qualificar regiões fora dos pontos de inventário com mais ou menos estoque relativamente ao conjunto de regiões que formam a área de estudo. Não houve pretensão de quantificar com exatidão o conteúdo de biomassa de cada ponto não amostrado, mas sim apontar em que locais este conteúdo tem potencial de ser menor ou maior.

Foram considerados neste estudo apenas os indivíduos com 10cm ou mais de DAP, que são amostrados nas 40 subparcelas de cada conglomerado do IFN.

4.2. Processamento e Análise dos Dados

No processamento dos arquivos geométricos e imagens foram utilizados Sistemas de Informação Geográfica, *softwares* de análise e *scripts* conforme as necessidades encontradas. Primariamente foram utilizados os softwares Qgis 2.8.2 com *scripts* na linguagem Python 2.7 utilizando principalmente as bibliotecas GDAL/OGR, Numpy, Scipy e PIL em conjunto com *scripts* "R" dentro do próprio Qgis, que acessa o ambiente e as bibliotecas do software estatístico R-Project. Todos os dados geográficos e imagens (dados raster) foram convertidos para o sistema de referência WGS1984 (EPSG:4326) antes de sua utilização, para compatibilidade de informações e simplificação dos algoritmos de análise e processamento desenvolvidos. Para cálculo de áreas em metros foi utilizada a projeção Albers - South America Equal Area Conic (EPSG:102032).

Foi dada preferência à utilização de ferramentas com licença GNU-GLP ou equivalente (*software* livre) para possibilitar a replicação dos resultados atingidos por qualquer interessado, bem como o uso dos algoritmos desenvolvidos para outros propósitos.

4.3. Dados de Sensoriamento Remoto

4.3.1. Imagens de RADAR Orbital - PALSAR/ALOS – JAXA

Os dados PALSAR estavam em arquivos binários compactados (*16bit little endian unsigned integer*), abertos e processados com *Python* (BIONDO, 2014). Primeiramente os dados de cada imagem foram abertos em uma matriz 4500 por 4500 em que é aplicado um filtro de média local para supressão do efeito "*Speckle*" (LEE, 1986). O filtro utilizou uma matriz de convolução (FURUIE, 2010) e foi aplicado em duas etapas, primeiro na convolução desta matriz com os valores numéricos e uma matriz 5 por 5. O valor de cada pixel da matriz a ser filtrada foi substituído pela média do próprio pixel com os 24 pixels vizinhos mais próximos. Em seguida foi realizada a convolução com uma matriz 3x3 com peso 2 no centro. Na **Figura 17** foi apresentado um exemplo de convolução de um pixel com uma matriz 9 por 9 com peso 1 para todos os elementos, em que o valor do pixel foi substituído pela média dele com a de seus 8 vizinhos mais próximos.

Máscara de convolução

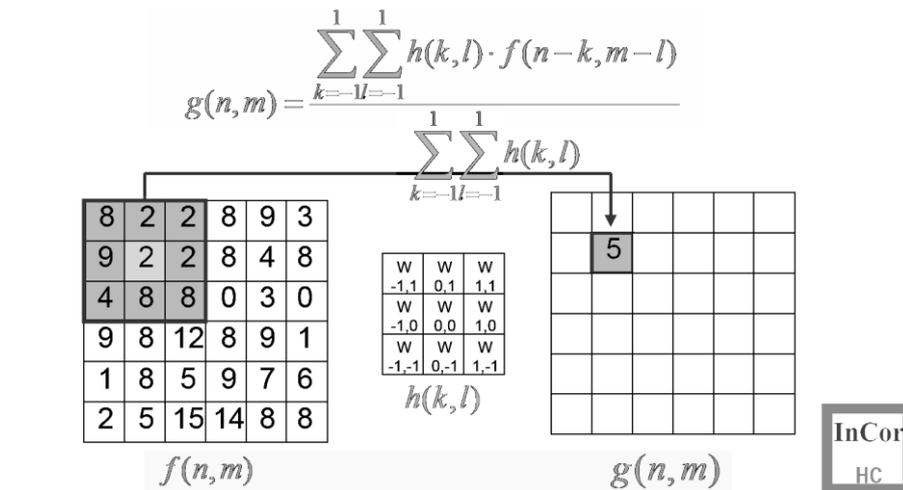


Figura 17 - Máscara de convolução utilizada em imagens médicas, que foram utilizados para redução de ruído Speckle nos dados PALSAR (FURUIE, 2010).

A convolução consistiu na substituição do valor de cada célula de uma matriz por uma multiplicação de uma submatriz quadrada com centro na própria célula por uma matriz quadrada de mesmo tamanho com pesos conforme o resultado que se pretendeu, para a média simples de matriz 3 por 3 indicada na figura o peso foi 1 e dividiu-se o resultado por 9 (FURUIE, 2010).

Após redução do ruído nas imagens, foi realizada a conversão dos valores numéricos em 16bit do mosaico filtrado resultante em valores de intensidade em decibéis (dB) calibrada conforme especificações do produto "SAR25m_mosaic". Os valores numéricos do PALSAR foram convertidos para decibéis de sinal detectado através da **Equação 3**.

Assim estimou-se σ_0 que foi a intensidade medida em dB para o pixel com valor numérico DN (Digital Number) e fator de correção CF (Correction Factor, no caso para as imagens utilizadas foi uma constante igual a '-83,0'). Em seguida foram avaliadas imagens de calibração para classificação dos pixels conforme a intensidade medida, com o uso de imagens Landsat para identificação de valores compatíveis com áreas de floresta e de não floresta. Foram utilizadas as imagens polarizadas HH, HV e o RFDI calculado a partir da diferença normalizada de ambas.

O objetivo do processamento foi separar as florestas de áreas desmatadas e classificar o potencial de estoque florestal das que são vegetadas. Para isso foram testados diversos limiares de σ_0 em busca da melhor segregação possível. Foi verificado em estudos anteriores (MESQUITA JR, 2009) que os valores superiores de σ_0 (maior retorno, maior que -1,0dB) interferem menos no resultado e mais na introdução de ruídos nas áreas de floresta, principalmente se não existirem grandes concentrações de alvos antropogênicos diversos de desmatamentos. De acordo com estudos anteriores (MESQUITA JR, 2009), o limiar superior que melhor removeu os ruídos sem desconsiderar as áreas florestais foi em torno de -0,5dB e, portanto, valores de resposta maiores do que estes foram descartados ou analisados separadamente.

Já na separação entre as florestas e desmatamentos esperou-se a melhor resposta em uma intensidade próxima a -9,5dB que é uma grandeza compatível com valores de Sigma listados dos mesmos estudos, com uso de radar onde valores entre -7,1 e -9,7 dB foram utilizados na identificação de florestas primárias de diferentes biomas (MESQUITA JR 2009). Após a separação dos extremos do que pode ser considerado pelos dados do PALSAR como floresta, determinaram-se então os limiares intermediários que puderam ser referência para a posterior classificação de potencial de estoque florestal para a modelagem.

Para facilitar a visualização e interpretação dos dados PALSAR foi utilizado o script Python do algoritmo “7.8. Python 1 – Decodificação PALSAR em imagem R-G-B” apresentado no *Apêndice 1*. Este script descompactou os arquivos binários das duas polarizações recebidas (HH e HV) de uma cena de 1x1 grau. Em seguida processou e armazenou os resultados em duas matrizes que são filtradas pela convolução de média nove citada anteriormente. O processo utilizou então as matrizes filtradas para calcular o RFDI de cada ponto desta matriz, armazenando o resultado em uma terceira matriz. As três matrizes de 4500x4500 elementos foram então processadas como bandas independentes de um raster.

Para formar uma imagem RGB, fez-se uma ampliação de contraste de cada banda com a redistribuição dos valores da matriz para novos valores entre os inteiros 0 e 255, que posteriormente se tornaram valores de pixel que formaram a imagem. O aumento de contraste foi feito utilizando o mínimo e o máximo valor de elemento existente em cada matriz, transformando todos os valores da matriz com uma relação linear. Assim, o mínimo

passou a ser 0 e o máximo passa a ser 255. Por fim, gerou-se uma imagem GeoTIFF com três camadas, com os dados das três matrizes. A imagem (arquivo raster no formato GeoTIFF) resultante apresentou HH na banda um (vermelho), HV na banda dois (verde) e RFDI na banda três (azul) e foi georreferenciada de acordo com o nome do arquivo PALSAR binário original que mostra a latitude e longitude de referência. Quando estes arquivos foram abertos no Qgis com as configurações padrão, ficaram com aparência de uma imagem de bandas visíveis exemplificado na **Figura 18** em que foi possível identificar áreas amareladas em que houve mais concentração de estrutura de vegetação que se distinguiram das áreas escuras com tons roxos de regiões com menor quantidade de estrutura florestal.



Figura 18 - Arquivo raster (imagem) com bandas R-G-B geradas com o algoritmo de descompactação do PALSAR em que foram colocados os dados dos arquivos HH, HV e o RFDI calculado a partir deles.

4.3.2. Processamento do Inventário Florestal Nacional do Ceará

Existiam 374 pontos da grade regular do IFN contidos no Estado do Ceará (1.496 subunidades com 14.960 subparcelas amostrais). Destes pontos verificou-se haver dados necessários para o estudo de estoque florestal em 340 pontos (90,9%) com conglomerados de inventário que abrigam 1.360 subunidades (as partes Norte, Leste, Sul e Oeste) com um total de 13.600 subparcelas de amostragem em que foram coletados dados dos indivíduos vegetais com DAP maior do que 5cm, estes indivíduos não foram considerados pelo SFB para as estimativas de biomassa utilizadas na modelagem deste estudo. Os dados referentes a todas as árvores do inventário foram armazenados em um banco de dados

PostgreSQL com cartucho espacial PostGIS. Para extração dos dados tabulares foi utilizada consulta SQL que está incluída no apêndice. Esta consulta resultou em uma tabela completa com os dados que posteriormente foram utilizados no tratamento e espacialização das informações florestais.

Os indivíduos que atenderam os critérios do IFN foram distribuídos em 5.959 subparcelas (39,8% do total do Ceará) com 1 a 97 indivíduos cada, sendo até 10 indivíduos por subunidade na maior parte dos casos (5.548), em seis delas foram observadas mais de 90, especificamente em bananais. Como os indivíduos com DAP entre 5 e 10cm foram medidos apenas na décima subunidade de cada subparcela, sendo descartados aqueles nesta classe e considerados apenas os com DAP maior do que 10cm, chegando então a 5.604 subparcelas com 1 a 18 indivíduos, que resultou em conglomerados (formados por 40 subparcelas cada) com 1 a 420 indivíduos, os totais foram analisados para os indivíduos com DAP>10, por conglomerado (**Figura 19**).

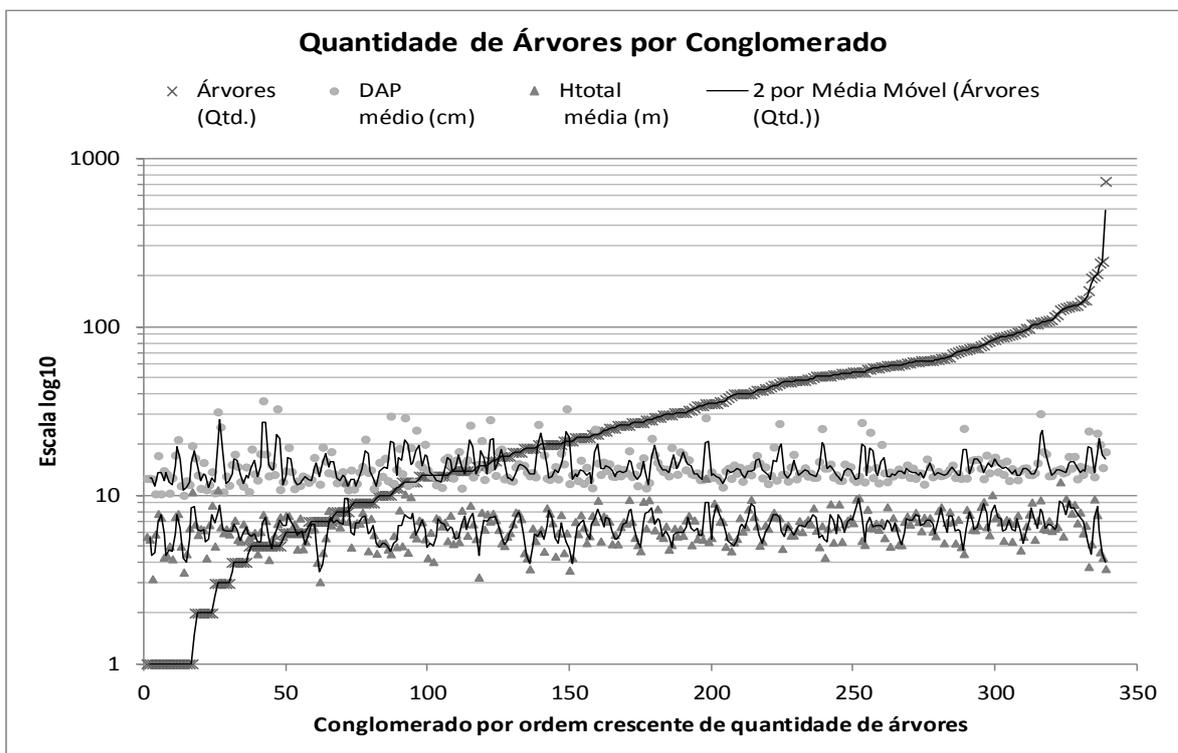


Figura 19 - Quantidade de árvores com DAP maior do que 10cm que foi amostrada por conglomerado do Ceará, os dados estão plotados em ordem crescente de número de indivíduos. No mesmo gráfico foram incluídos os DAP e Htotal médios (diâmetro na altura do peito em centímetros e altura total do indivíduo em metros).

No conjunto de subparcelas foram armazenados todos os fustes que atenderam aos critérios do IFN, devidamente associados a um código único de árvore por subunidade. Nos 340 pontos há 23.263 fustes com mais de 5cm de DAP, dos quais 16.002 com mais de 10cm que fizeram parte de 12.070 indivíduos inventariados (árvores, palmeiras ou cactáceos que continham de 1 a 16 fustes cada). Os indivíduos apresentaram altura entre 0,6 e 26,6 metros e DAP entre 10 (critério mínimo considerado) e 95,7 centímetros. Foram descartados 23 indivíduos que apresentaram valores irreais para as espécies que eles deveriam representar, como cacto de 20m de altura e palmeira com 5m de DAP.

4.3.3. Sensoriamento Remoto do Ceará

A cobertura completa por RADAR do Ceará foi composta por 42 arquivos do PALSAR/ALOS com 5000 por 5000 pixels de 22,5m cada, sendo metade com polarização HH e metade HV. Cada arquivo apresentou apenas uma banda com os números digitais que representam a resposta medida pelo radar. Foram utilizados estes arquivos devidamente decodificados, e a composição das polarizações conhecida por RFDI. A mesma cobertura foi composta por 322 arquivos RapidEye brutos de 5000x5000 pixels de 5m cada, com cinco bandas (Azul, Verde, Vermelho, RedEdge e Infravermelho próximo) de medição, que por sua vez derivaram oito índices de vegetação e clorofila que foram considerados (razão direta, NDVI, EVI, NDVI-rededge, VARI-rededge, Clorofila Green, Clorofila RedEdge e Clorofila MTCI). Assim teve-se a cobertura de todo o estado com 16 variáveis de SR, sendo sete diferentes dados de sensores remotos (dois de fonte ativa e cinco de fonte passiva) mais nove índices derivados que representaram informações de vegetação como estrutura física (radar), presença de folhas (índices de vegetação) com atividade fotossintética (índices de clorofila).

Para que fosse possível processar este conteúdo foi necessária uma abordagem automatizada de acesso aos arquivos e sua utilização, bem como uma estrutura de armazenagem e posterior análise de resultados que permitisse compreensão ampla e compartilhamento completo. Como as informações primárias de sensoriamento deste estudo foram espacializadas (dados de satélite georreferenciados) e houve acesso à grade geolocalizada de pontos de amostragem do IFN, foram desenvolvidos aplicativos (*scripts*)

que uniram as informações de inventário em um formato sempre espacializado. Assim a comparação entre dados amostrados em campo foi feita considerando-se uma área representativa do ponto em relação a um conjunto de pixels dos dados de sensoriamento que representaram a mesma região. Com os pontos de inventário distantes 20km um do outro e formados por conglomerados com cerca de 100 metros de raio em torno de cada ponto, foi proposto representar a distribuição florestal próxima, em conjunto com as resoluções de cinco e 22,5 metros dos dados usados, sendo escolhido o processamento dos dados representativos de cada ponto com um raio de 200m nas imagens. Estes buffers de 200m em torno de cada ponto do IFN abrangeram uma área que permite garantir que os dados amostrados estão contidos na região, pois o erro de localização dos GPS e outros fatores avaliados nos pontos coletados do IFN mostraram uma variação menor do que 20 metros no centro e 50 metros em todas as bordas, incluindo rotação e translação. Ao mesmo tempo a área escolhida (125.000m²) permitiu uma amostragem suficiente para utilizar as estatísticas das imagens de 22,5m de resolução (247 pixels para cada ponto do IFN) e as de 5m de resolução (5.000 *pixels* por ponto).

Para a análise dos pixels representativos de cada conglomerado, inicialmente foi realizado um histograma de valores encontrados em cada região associada a cada ponto do IFN, armazenados em tabelas de atributos dos pontos espacializados. Por exemplo, para a banda HH do PALSAR transformaram-se todos os números digitais em níveis de dB conforme especificação do produto, em seguida fez-se a contagem dos pixels que se encontravam dentro de cada região de cada ponto, acumulando-se a contagem nas faixas de dB (bins) conforme exemplo na **Tabela 3**, com os limites considerados.

Tabela 3 - Classes para histograma de valores em decibéis da polarização HH das imagens PALSAR em tabela de atributos dos pontos espacializados do IFN.

Classe	Limites
dBmaior	HH > -0,5dB
dBm1p0	-0,5 >= HH > -1,0
dBm3p0	-1,0 >= HH > -3,0
dBm5p0	-3,0 >= HH > -5,0
dBm7p0	-5,0 >= HH > -7,0
dBm9p0	-7,0 >= HH > -9,0
dBm9p5	-9,0 >= HH > -9,5
dBmenor	HH < -9,5dB.

As faixas escolhidas detalharam as diferentes respostas de radar entre os valores que foram considerados floresta (-0,5 >= HH > -9,5), ainda armazenados o mínimo e o máximo, a média, a moda e o desvio padrão de cada variável em cada região relacionada à grade do IFN. Assim os pontos espacializados armazenaram as contagens do histograma e estatística simples dos pixels amostrados em seus atributos, que puderam ser comparadas com as informações provenientes do IFN para cada ponto.

4.4. Cadastro Ambiental Rural do Ceará (CAR)

O Cadastro Ambiental Rural – CAR, parte do Sistema Nacional de Informação sobre Meio Ambiente – SINIMA foi criado pela Lei 12.651/12, conhecida como “Novo Código Florestal” (TROVAO, 2016).. O cadastro foi definido como “registro público eletrônico de âmbito nacional, obrigatório para todos os imóveis rurais, com a finalidade de integrar as informações ambientais das propriedades e posses rurais, compondo base de dados para controle, monitoramento, planejamento ambiental e econômico e combate ao desmatamento” (TROVAO, 2016). Entre os dados publicados do CAR estavam os boletins mensais informativos, com estatísticas gerais sobre o que já foi cadastrado no sistema e o "Atlas CAR", conjunto de mapas com dados de cobertura de superfície dos imóveis e das componentes ambientais declaradas (SFB-B, 2016). As componentes publicadas foram Reserva Legal, Área de Proteção Permanente, Nascentes e Remanescente de Vegetação Nativa.

As informações presentes no Atlas CAR foram separadas por tema e região geográfica e são passíveis de retificação por parte dos proprietários. Apesar de oferecer um panorama de abrangência nacional de ocupação e uso do solo, deve ser visto com cuidado por não estar validado pelos estados, responsáveis pela homologação das declarações (SFB-B, 2016). Os dados de limite de imóveis e limites de reserva legal declarada foram utilizados para uma análise preliminar em áreas privadas de estoque florestal potencial modelado por krigagem. A análise consistiu em cruzar as áreas de cobertura do Atlas com os valores estimados pela modelagem. Os conjuntos de raster, como as imagens rapideye ou os dados do PALSAR, foram primeiramente agrupados em uma imagem virtual (VRT), convertidos em um raster único. Foram então gerados polígonos dos imóveis rurais que estavam cadastrados no sistema até Maio de 2016, para aplicação do plugin "*Zonal Statistics*" do Qgis, que extrai estatísticas simples da parte do raster sobreposta com cada feição das propriedades rurais. Para casos em que outras informações eram necessárias, como a contagem de um determinado valor de pixel, foram desenvolvidas ferramentas em Python específicas incluídas no *Apêndice 1* deste estudo.

4.5. Classificação do Estoque Florestal

Buscou-se, primeiramente, identificar se havia relação entre as variações de resposta medidas pelos sensores remotos utilizados, ou seja, correlacionar a variação do NDVI, EVI e outros índices de vegetação e fotossíntese que foram gerados a partir dos canais na faixa de radiação eletromagnética óptica de sensores passivos, com a variação do RFDI, gerado a partir das respostas de duas polarizações de um RADAR. Após a identificação de semelhanças e diferenças entre os sensores, avaliou-se as características de cobertura de solo e estrutura vegetal de acordo com o tipo de onda envolvida e pelas características de cada sistema orbital.

A grade de análise dos dados coincidiu com os pontos de conglomerados do IFN. Fez-se análises das respostas de sensores remotos de áreas em torno de cada conglomerado para que fossem comparadas com os dados amostrados no inventário. Com os dados dos diferentes espectros e sensores analisados, buscou-se testar se os dados dos sensores podiam explicar os dados de inventário, utilizando a variação dos índices médios calculados de cada célula, preferencialmente com uso conjunto dos índices de sensores

passivos com índices de sensores passivos. Foram testados modelos lineares para determinação dos estoques florestais e selecionados aqueles com maior precisão nas estimativas. Também foram realizadas modelagens geoestatísticas com krigagem ordinária dos dados de estoque florestal do IFN. Como a krigagem é uma interpolação espacializada de dados, o modelo foi validado com a retirada de parte dos dados originais da grade do Ceará e comparação dos resultados para todo o estado com a interpolação utilizando todos os pontos da grade.

Para que o modelo fosse considerado adequado, foi necessário que se pudesse prever os dados de uma área inventariada utilizando apenas os índices de vegetação desta área aplicados no próprio modelo, que foi ajustado a partir do inventário e imagens de sensoriamento remoto de outras áreas distintas. Caso o modelo conseguisse prever estoque florestal compatível com os dados de inventário, foram determinados limiares de previsão para que áreas não inventariadas pudessem ser classificadas, de acordo com seu potencial de estoque florestal. A classificação resultante possuiu seis limiares de potencial:

- Sem potencial de estoque florestal (Zero);
- Muito baixo potencial de estoque florestal (0 a 20t/ha);
- Baixo potencial de estoque florestal (20 a 35t/ha);
- Médio potencial de estoque florestal (35 a 50t/ha);
- Alto potencial de estoque florestal (50 a 65t/ha);
- Muito alto potencial de estoque florestal (mais de 65t/ha).

Estes limiares foram determinados em conjunto com colaboradores do SFB que realizam o planejamento de concessões florestais, empresas que exploram áreas com manejo florestal sustentável e proprietários rurais que utilizam e convivem com as florestas brasileiras.

5. RESULTADOS E DISCUSSÃO

5.1. Modelagem por regressão dos dados do IFN e SR

A comparação de 16 variáveis de SR com os valores calculados de biomassa calculados pelo SFB no IFN, utilizando General Regression Model (RGM), foi encontrado R múltiplo de até 0,6 e R^2 máximo de 0,37 com diferentes combinações. Esta melhor combinação na fase inicial de análise de dados foi encontrada para representar o logaritmo da biomassa utilizando 16 variáveis, sendo quatro bins de ndvi, seis bins de rfdi mais média e desvio padrão de ndvi, rfdi e dB. Em uma análise inicial chegou-se a constatações que nortearam uma reavaliação dos dados de estoque florestal que estão no site de divulgação de resultados do IFN e que se planejou utilizar. Com a constatação de que as variáveis de SR não conseguiam explicar de forma satisfatória os dados de biomassa, procedeu-se com uma revisão por estes dados originais de estimativas dendrométricas terem sido classificados e calculados. Estava sendo utilizando o percentual de floresta de cada conglomerado associado aos dados do IFN, o que não levou a melhorias nos resultados.

Criou-se um campo nos dados tabulados do IFN que informa "SIM" ou "NÃO" para cobertura florestal de cada subparcela, portanto dividindo o conglomerado em quatro partes que podem ou não ser floresta, dado preenchido em campo pela equipe de inventário na tentativa de também associar a informação das componentes de estoque florestal com o percentual de floresta e os dados de SR, sem sucesso. Foi verificado que os dados de percentual de floresta do mapa de resultados do IFN (SFB, 2016) não são compatíveis com as respostas de existência ou não de cobertura florestal do formulário, pois foram estimados utilizando o uso do solo identificado.

A dificuldade de relacionar os dados se deve provavelmente à origem e ao uso de cada informação, pois os dados de biomassa que estavam sendo considerados como valores médios para a área representativa de cada conglomerado, foram, na realidade, calculados a partir da classificação de uso do solo da equipe do IFN, em que foi classificada cada subunidade de acordo com o manual (SFB-D, 2014). Este uso do solo, no caso da Caatinga, indicou provável presença de floresta sempre que as classes foram de vegetação

secundária e apenas os indivíduos associados à subparcelas de floresta tiveram seus volumes e biomassa calculados, posteriormente somados e os valores publicados foram na verdade a soma da biomassa, calculados para as subparcelas florestais de cada conglomerado.

Desta mesma classificação de solo a equipe do IFN estimou o percentual de floresta de cada conglomerado, levando em conta que 40 subparcelas com uso de solo com vegetação secundária ou floresta madura resultaram em quatro subunidades de floresta e um conglomerado 100% floresta. Este método permitiu que os percentuais de floresta dos conglomerados tivessem 42 possibilidades (sem dado, 0% floresta e 40 níveis de percentual entre 2,5% e 100% em passos de 2,5%) contra as esperadas seis possibilidades derivadas da resposta de cobertura florestal (sem dado, 0%, 25%, 50%, 75% e 100%). Assim, o campo SIM/NÃO de cobertura florestal do questionário foi uma referência para auxiliar na classificação do solo, mas não aquela que definiu a quantidade de floresta no conglomerado para o cálculo de biomassa ou volume de madeira. Este conjunto causou dúvidas no processamento de dados e que tiveram de ser substituídos por uma classificação de tipologias florestais em três níveis, sendo adotada nas etapas seguintes do IFN de modo a tornar mais clara a informação de presença de floresta.

Para auxiliar no entendimento das diferentes abordagens de classificação da existência ou não de floresta em um dado conglomerado, foram realizados resumos quantitativos de indivíduos inventariados, baseados apenas nos dados de inventário. Deste modo, foi realizado um resumo por classes de uso do solo nas subparcelas separadas em florestais e não florestais (*Tabela 4*) e outro resumo por classes de uso separadas pelas respostas de cobertura florestal do formulário (*Tabela 5*). Os totais de conglomerados que resultaram como florestas nos dois resumos tiveram uma diferença de menos de 10% (12.378 conglomerados com uso do solo florestal contra 12.006 com resposta SIM para cobertura florestal). Porém esta diferença mostrou-se significativa quando considerada a quantidade de subparcelas utilizadas no levantamento de indivíduos na estimativa de estoque, pois 485 subparcelas com vegetação secundária foram classificadas como não florestais pelas equipes de campo (resposta NÃO no formulário), mas tiveram suas biomassas calculadas. Por outro lado, 226 subparcelas estavam em áreas consideradas florestas pelas equipes de campo (resposta SIM no formulário) e não foram contabilizadas na mensuração devido ao uso do solo declarado não ter sido considerado florestal.

Tabela 4 - Resumo de indivíduos e suas variáveis dendrométricas médias em função das classes de uso da terra informadas em cada subparcela inventariada. A metade superior tem os dados de classes que foram consideradas não florestais, com a parte inferior sendo consideradas de floresta.

Resumo de Indivíduos por Uso de Solo das Subparcelas				
	Uso Solo IFN	Árvores (Qtd.)	DAP médio (cm)	Htotal média (m)
Uso do solo Não Florestal	(vazio)	13	13.4	7.4
	Agricultura Cíclica	158	13.9	5.3
	Agricultura Permanente	745	18.1	3.7
	Afloramento Rochoso	36	14.6	5.5
	Água	53	14.7	5.1
	Área Indiscriminada	90	17.4	6.0
	Pecuária	309	18.6	6.2
	Urbano	66	19.0	5.9
	Total Não Flor.	1470	17.5	4.8
Uso do solo Florestal	Outros	804	17.2	6.3
	Reflorestamento Algaroba	28	19.3	9.2
	Reflorestamento Misto	115	13.5	9.0
	Veg. Sec. Pioneira Só Palmeiras	55	29.4	4.5
	Veg. Sec. Média Só Palmeira	69	27.7	10.5
	Veg. Sec. Pioneira com Palmeira	458	20.1	4.7
	Veg. Sec. Média com Palmeira	400	25.5	7.8
	Veg. Sec. Pioneira sem Palmeira	2296	14.4	6.0
	Veg. Sec. Média com Palmeira	8153	14.0	7.1
Total Flor.	12378	15.0	6.8	
Total geral	13848	15.3	6.6	

Com estes resultados, foi realizada uma nova análise espacializada de todas as subparcelas que formavam o inventário do Ceará, buscando validar a relação dos dados amostrais com imagens de satélite das proximidades do local de coleta. Existiam chaves de banco de dados que relacionavam os indivíduos às subparcelas em que foram amostrados, porém o único dado vetorial existente era o conjunto de pontos centrais dos conglomerados. Com a distribuição teórica das subparcelas para todos os conglomerados (**Figura 17**), foi criado um arquivo vetorial com polígonos (quadrados) que representavam todas as subunidades dos pontos centrais conhecidos.

Tabela 5 - Resumo de indivíduos e suas variáveis dendrométricas médias em função das respostas sobre cobertura florestal. Foram utilizadas as respostas (resposta SIM/NÃO no formulário de campo) e as classes de uso da terra informadas em cada subparcela inventariada. A parte superior tem os dados em que foi respondido NÃO para cobertura florestal, a parte central as com resposta SIM para cobertura florestal e a parte inferior as subparcelas em que não havia resposta informada. Os valores sublinhados foram as quantidades que foram classificadas de forma diferente quando se utilizou a resposta de cobertura florestal do formulário ao invés da classificação de uso do solo.

Resumo de Indivíduos por Uso de Solo e Resposta de Cobertura Florestal de Subparcelas				
Resposta Formulário	Uso Solo IFN	Árvores (Qtd.)	DAP médio (cm)	Htotal média (m)
Sem cobertura florestal (resposta NÃO)	Agricultura Cíclica	10	17.1	8.2
	Agricultura Permanente	745	18.1	3.7
	Água	42	14.9	4.3
	Área Indiscriminada	34	18.4	5.6
	Pecuária	205	18.7	6.4
	Urbano	23	20.0	6.6
	<u>Outros</u>	<u>388</u>	<u>16.4</u>	<u>5.1</u>
	<u>Veg. Sec. Pioneira Só Palmeiras</u>	<u>4</u>	<u>36.8</u>	<u>6.8</u>
	<u>Veg. Sec. Pioneira sem Palmeira</u>	<u>81</u>	<u>13.3</u>	<u>5.6</u>
	<u>Veg. Sec. Média com Palmeira</u>	<u>12</u>	<u>14.2</u>	<u>8.7</u>
	(vazio)	21	14.0	5.1
	Total Resp. Não	1565	17.4	4.7
Com cobertura florestal (resposta SIM)	<u>Agricultura Cíclica</u>	<u>148</u>	<u>13.7</u>	<u>5.1</u>
	<u>Afloramento Rochoso</u>	<u>14</u>	<u>14.6</u>	<u>5.8</u>
	<u>Água</u>	<u>11</u>	<u>14.1</u>	<u>8.1</u>
	<u>Área Indiscriminada</u>	<u>56</u>	<u>16.8</u>	<u>6.3</u>
	<u>Pecuária</u>	<u>102</u>	<u>18.7</u>	<u>5.7</u>
	<u>Urbano</u>	<u>43</u>	<u>18.4</u>	<u>5.5</u>
	Outros	416	18.0	7.5
	Reflorestamento Algaroba	28	19.3	9.2
	Reflorestamento Misto	115	13.5	9.0
	Veg. Sec. Pioneira Só Palmeiras	51	28.9	4.4
	Veg. Sec. Média Só Palmeira	69	27.7	10.5
	Veg. Sec. Pioneira com Palmeira	458	20.1	4.7
	Veg. Sec. Média com Palmeira	390	25.7	7.9
	Veg. Sec. Pioneira sem Palmeira	2164	14.5	6.0
Veg. Sec. Média com Palmeira	7928	13.9	7.1	
(vazio)	13	13.4	7.4	
Total Resp. Sim	12006	15.0	6.8	
Vazio para Cobertura (sem resposta)	Afloramento Rochoso	1	27.8	8.5
	Pecuária	2	12.5	5.5
	Veg. Sec. Média com Palmeira	10	16.8	5.6
	Veg. Sec. Pioneira sem Palmeira	51	12.1	4.6
	Veg. Sec. Média com Palmeira	213	15.0	6.9
Total Vazio	277	14.6	6.4	
Total geral		13848	15.3	6.6

Como o IFN aceitou um erro de até 10 metros na posição do centro do conglomerado e erros adicionais foram esperados para outras etapas da montagem da área de coleta de dados em campo, estes foram feitos com fitas métricas, bússolas e GPS de navegação. Foram marcados ainda cinco pontos com coordenadas do GPS para cada conglomerado, sendo eles o ponto central e o início das subunidades Norte, Leste, Sul e Oeste (entre as subparcelas um e dois de cada orientação) que puderam ser usados como referência. Deslocamentos de até 15 metros também puderam ocorrer no posicionamento das imagens RapidEye e PALSAR, que associado ao erro de localização partes do conglomerado permitiu, grosso modo, que um pixel que contivesse uma árvore amostrada no início de uma subunidade pudesse estar na imagem a até de 25 metros da coordenada de GPS tomada em campo. Como os erros puderam ser maiores do que uma subparcela, não houve aplicação prática na construção da geometria dos conglomerados utilizando os pontos tomados com GPS no campo.

As imprecisões descritas anteriormente foram aceitas para a montagem e posicionamento dos conglomerados provavelmente porque a metodologia do IFN buscou uma precisão suficiente para que as amostras fossem representativas do ponto de inventário nacional, a um custo exequível para os 20 mil pontos de todo o país. O método também permitiu que em outras etapas de inventário nacional, ou reamostragens, subparcelas equivalentes fossem demarcadas e os resultados em anos diferentes pudessem ser comparados. Por outro lado, estas imprecisões impossibilitariam, por exemplo, a relação direta de um indivíduo amostrado com uma imagem de satélite.

Assim, foram construídas subparcelas teóricas na construção geométrica dos conglomerados. Levou-se em consideração apenas a declinação magnética, construindo as subparcelas vetorizadas alinhadas com o campo magnético da terra em cada conglomerado. O conglomerado era formado por quatro subunidades conforme descrito na metodologia, foi construído com seus eixos Norte-Sul e Leste-Oeste perpendiculares. Por sua vez, cada subunidade foi formada por 10 subparcelas alinhadas e representadas por um quadrado de 10 metros de lado. Os dados vetoriais continham 40 subparcelas quadradas que formaram cada conglomerado, compondo-se com estas características uma representação vetorial de um conglomerado e suas subparcelas teóricas (*Figura 21*).

Nesta nova análise foi incluída a classificação de uso de solo destas subparcelas, para verificar em qual tipologia de vegetação do IBGE mapeado no PROBIO/MMA se encontrava cada região amostral de cada conglomerado. Foi realizado então um processo invertido de dados do inventário, levando cada indivíduo com $DAP \geq 10\text{cm}$ ao centroide de sua subunidade de origem, o que resultou em uma distribuição espacial que permitiu avaliar como o percentual de floresta e o estoque florestal estimado de fato se encontravam em torno do ponto central do conglomerado. A partir destes novos esquemas de informação foi possível uma melhor descrição do que se poderia esperar do SR para a região do conglomerado. Dentre os indivíduos inventariados no Ceará, foram identificadas cerca de 250 espécies diferentes, sendo que as 40 espécies mais frequentes (16%) concentraram 82% da biomassa do estado, concentração que interferiu na representatividade de biomassa, impactando na relação entre a resposta espectral da vegetação e a biomassa provável em um mesmo local.

Após a espacialização dos dados de subparcelas e indivíduos, associando as geometrias dos arquivos vetoriais com o banco de dados do inventário do Ceará, foi verificado que aproximadamente 65% das subparcelas foram classificadas com uso do solo que indicou presença de floresta enquanto 71% das subunidades dos conglomerados tiveram sua cobertura de solo classificada como florestal pelas equipes de campo (resposta SIM no formulário). Os dados referentes a esta análise foram então resumidos e apresentados (*Tabelas 4 e 5*). Comparativamente, o estado do Ceará apresentou 8.597.737 hectares de floresta em seus 14.882.600ha de território de acordo com os dados do SNIF (SFB-A, 2016), equivalentes a 58% de cobertura florestal, enquanto 89% das subparcelas do IFN foram consideradas com uso do solo florestal e 86% das subunidades como florestas pelas equipes de campo. A diferença de aproximadamente 30% entre a cobertura do SNIF e as características dos conglomerados pode ser explicada pela definição de floresta adotada pelo IFN, em que uma área com 10% de cobertura florestal foi classificada como floresta, além de ter sido uma comparação entre uma estimativa territorial com SR e outra amostral em uma grade discreta.

Os dados de árvores e classificação de cobertura e uso do solo foram analisados de forma amostral em que foi observada uma representatividade visual entre o dado amostrado e as informações presentes nas imagens de satélite de altíssima resolução (5 metros). Para este processo foi utilizado o software Qgis com o plugin OpenLayers e a camada de satélite mundial do Google, junto a imagens R-G-B do PALSAR. Apresentou-

se uma sequência de imagens que exemplificou esta análise visual (*Figura 23* até a *Figura 36*), geradas com conglomerados do Ceará e seus dados reposicionados nas subparcelas com imagens de referência para análise e processamento.

Para esta avaliação, a cruzeta de amostragem com as subparcelas foi posicionada com o centro em sua localização geográfica ideal conforme a grade do IFN, e rotacionada de forma que o seu eixo vertical ficasse alinhado com o Norte-Sul magnético (correção de declinação magnética). Os quadrados que formaram a cruzeta representam as subparcelas de 10 m por 10 m ideais - e foram coloridos de verde quando a classificação de uso do solo foi considerada Florestal, associada à quantidade de fustes com 10 ou mais centímetros, inventariados no centroide das subparcelas (*Figura 21*).

Casas, árvores, ruas e áreas de campo e 27 das 40 subparcelas tiveram uso de solo classificado como vegetação secundária (*Figura 21*). Apesar de algumas subparcelas sobre a rua estarem aparentemente na posição correta, o conglomerado pode ter tido um erro de até 10 metros em seu centro, a rotação pode ter levado a um erro na ponta externa da cruzeta também desta ordem e as subparcelas podem ter tido sua posição um pouco deslocada devido ao método de amostragem do IFN. Portanto, mesmo que a sobreposição exata das ruas com algumas das subparcelas não florestais tenham sido apenas coincidência, foi possível notar que realmente houve árvores e a cobertura de solo foi predominantemente de floresta em um raio de 150 metros do centro do conglomerado, e a amostragem deste ponto foi compatível com o que pode ser observado na imagem de satélite. O mesmo pode ser visto nas 16 das 40 subparcelas que foram consideradas florestais (*Figura 22*). Foram apresentadas ainda as subparcelas com apenas uma subparcela florestal (*Figura 23*) e as classificadas como 12, 10 e 7 partes (respectivamente *Figuras 24, 25 e 26*) de uso de solo florestal.



Figura 20 - Exemplo de análise visual do Conglomerado CE-87 com as subparcelas coloridas de acordo com a classe de uso de solo (apenas as de usos florestais com tons de verde). Este conglomerado apresentou 27/40 subparcelas com uso florestal.



Figura 21 - Exemplo de análise visual do Conglomerado CE-40 com 16/40 subparcelas com uso florestal. Área com vegetação esparsa e copas de árvores identificáveis em torno da cruzeta idealmente posicionada.



Figura 22 - Exemplo de análise visual do Conglomerado CE-350 com 01/40 subparcelas com uso florestal. Área com poucas árvores identificáveis, uma lagoa e predominância de pasto.



Figura 23 - Exemplo de análise visual do Conglomerado CE-299 com 12/40 subparcelas com uso florestal. Área próxima a um corpo d'água com vegetação predominantemente arbustiva e algumas árvores próximas a uma estrada, algumas regiões com solo exposto.

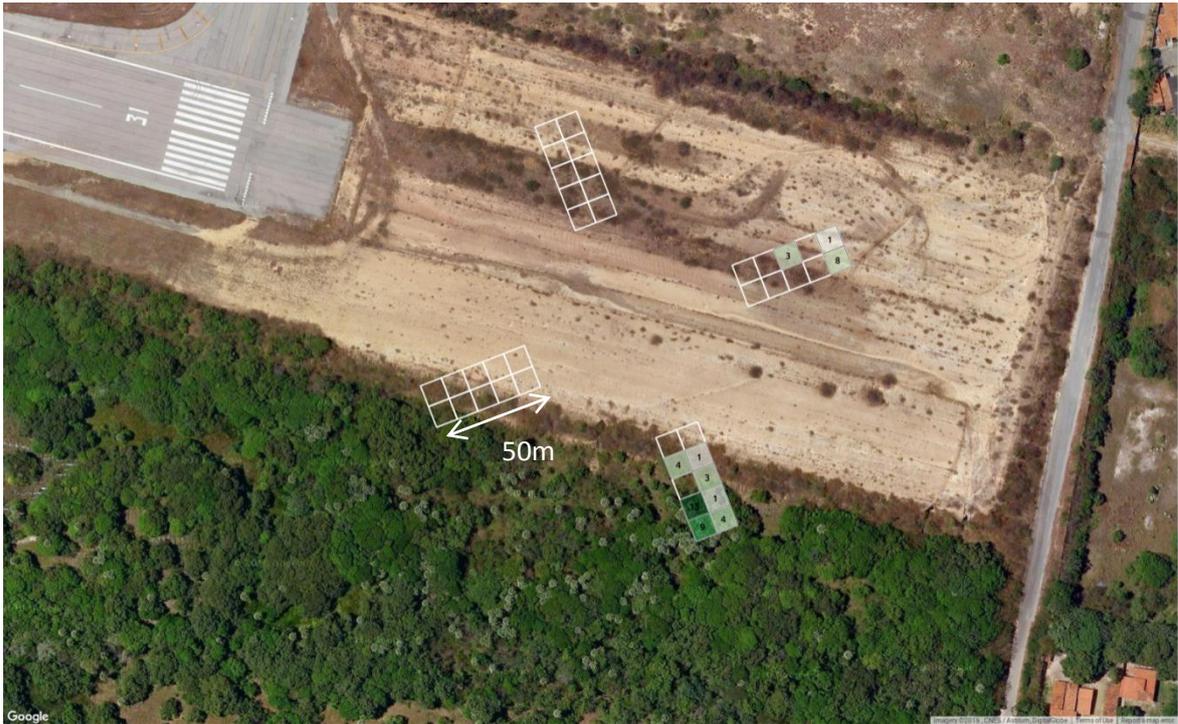


Figura 24 - Exemplo de análise visual do Conglomerado CE-70 com 10/40 subparcelas com uso florestal. Localizado no terreno de um aeroporto, com parte da área com solo exposto e parte com mais árvores e vegetação arbustiva, aparentemente uma pequena floresta de vegetação secundária.



Figura 25 - Exemplo de análise visual do Conglomerado CE-236 com 07/40 subparcelas com uso florestal. Área de agricultura com alguns grupos de árvores próximas a um rio e borda de um provável morro.

Em continuidade às avaliações visuais dos conglomerados, seu conteúdo e imagens de alta resolução foram comparados pontos do IFN com os dados que seriam utilizados para a modelagem de estoque florestal. Foram geradas imagens que exemplificam o detalhamento de comparação dos dados de inventário com imagens do PALSAR de 2010 (**Figuras 26 a 33**). A sequência se iniciou (Figura 27) com uma visão distante do conglomerado CE-101 ao centro, em escala 1:250.000 em que estavam presentes outros 14 conglomerados. Em seguida, foi feita uma aproximação gradativa com o ponto CE-101 ao centro para ilustrar o tipo de informação que pôde ser extraída do SR em relação a uma amostra do IFN. A imagem foi feita na mesma posição com uma parte de cena do PALSAR sobrepondo a área (Figura 28), seguindo-se na mesma configuração em escalas 1:50.000 (**Figuras 28 e 29**), 1:10.000 (**Figuras 30 e 31**) e 1:1.250 (**Figuras 32 e 33**).

As informações das figuras com imagem de satélite óptico (26, 28, 30 e 32) foram complementadas pelas características de resposta registradas pelo PALSAR nas outras imagens (27, 29, 31 e 33), facilitando a localização de áreas sem floresta, que no PALSAR composto, apareceram em tom roxo, devido ao RFDI maior que compôs a banda azul. Este complemento foi operacional nas escalas menos detalhadas (1:250.000 e 1:50.000) porém começou a perder qualidade na escala 1:10.000 com alguma distinção de características correlacionadas com a imagem óptica e não apresentou informação distinguível na escala 1:1.250, o que indicaria o limite de resolução deste dado que teve sua menor unidade de informação com tamanho de 22,5 m por 22,5 m, enquanto a imagem de fundo teve pixel de 1 m x 1 m. A partir de constatações desta natureza, foi determinado que a área amostral de sensoriamento que se pretendia correlacionar com o ponto de cada conglomerado seria de um raio de 100 a 200 metros a partir do ponto de grade do IFN ou de um quadrado com centro neste ponto e 200 a 400 metros de lado, amostrando assim uma quantidade significativa de pixels para realizar levantamentos estatísticos e mantendo uma cobertura de área em que as subparcelas do conglomerado estivessem contidas. As imagens visíveis de fundo foram geradas com o plugin OpenLayers do Qgis, utilizando a camada "Google Satellite", os conglomerados são dados vetoriais gerados no estudo e as imagens de RADAR foram criadas com os dados do PALSAR.

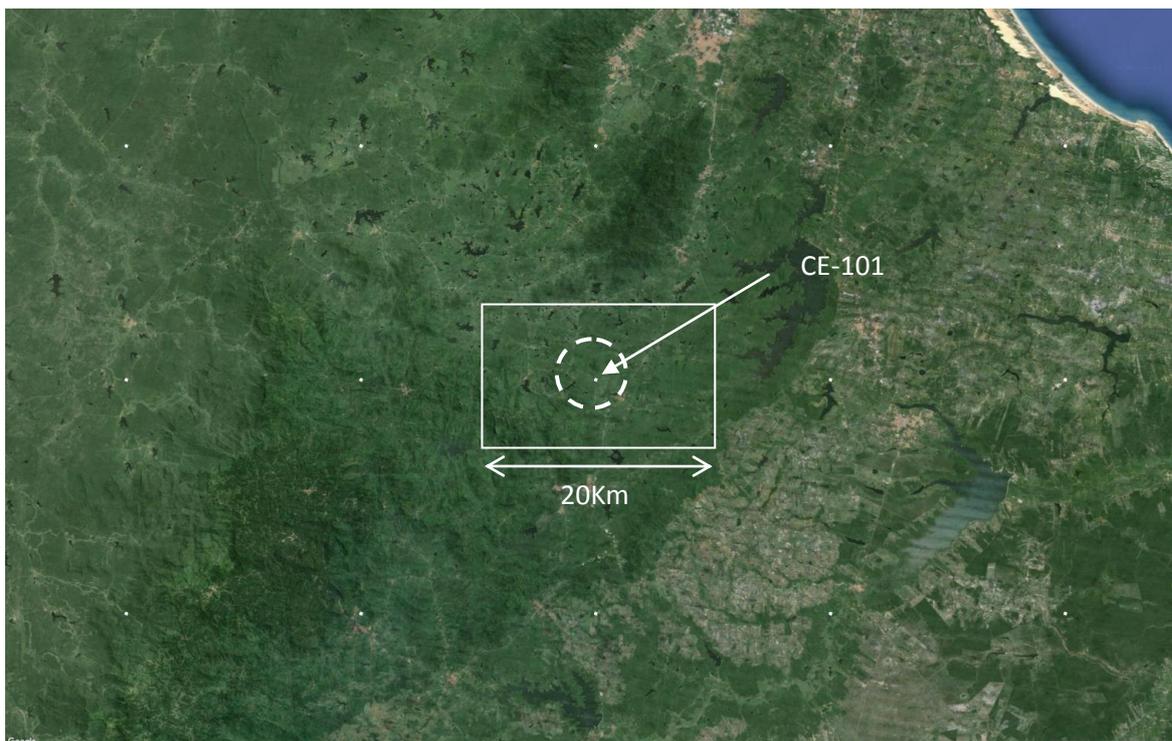


Figura 26 - Localização do Conglomerado CE-101 em escala 1:250.000 com as subparcelas em branco, posteriormente aproximada para a área em destaque. Percebeu-se variações de densidade de vegetação, áreas de uso de solo diferentes e algum relevo com prováveis rios e lagoas.

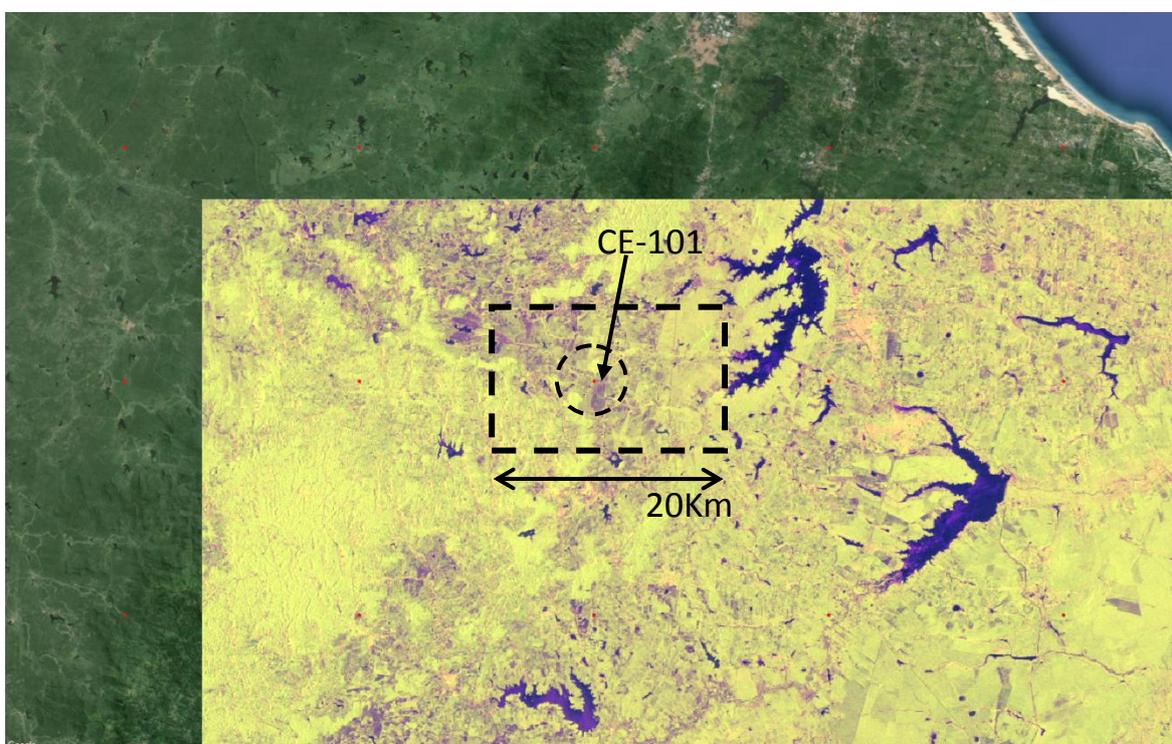


Figura 27 - Localização do Conglomerado CE-101 em escala 1:250.000 com as subparcelas em vermelho e os pixels de 22,5x22,5m do pulsar ao fundo, será aproximada a área em destaque. Ficaram mais evidentes as diferenças de densidade de vegetação e os grandes corpos com água.

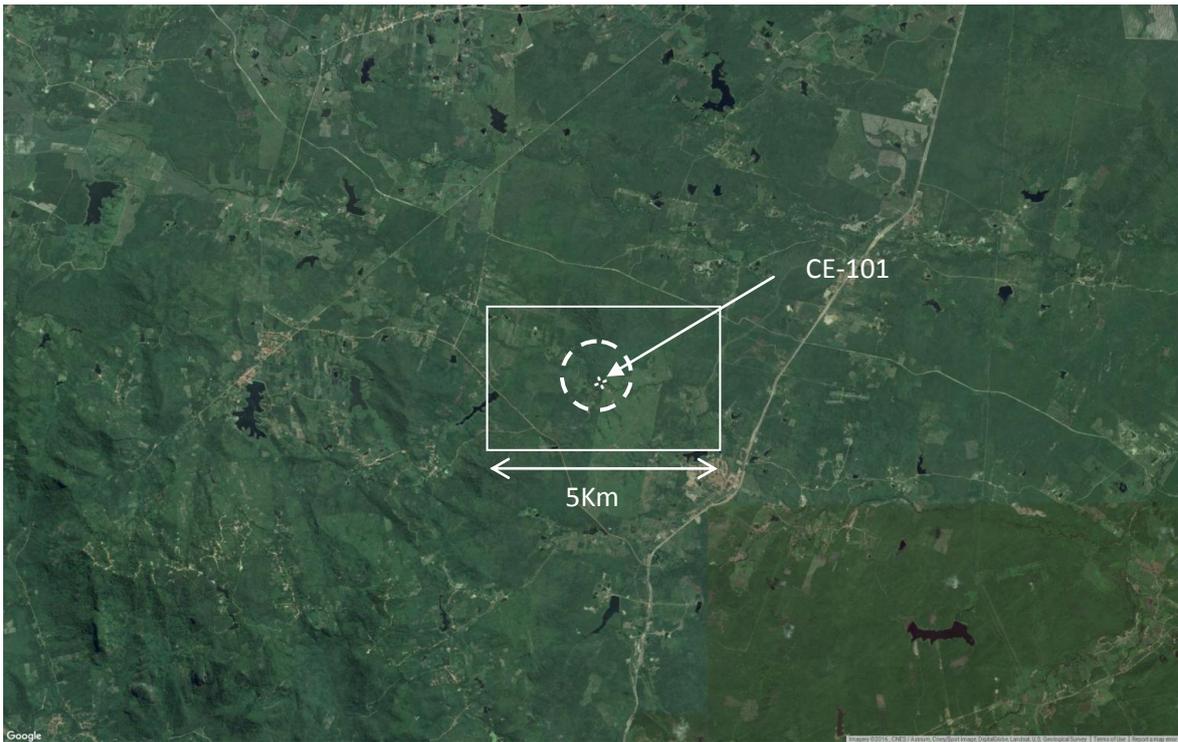


Figura 28 - Localização do Conglomerado CE-101 em escala 1:50.000 com as subparcelas em branco. Com a aproximação surgiram estradas e mais detalhes de relevo, diferenças de vegetação visíveis.

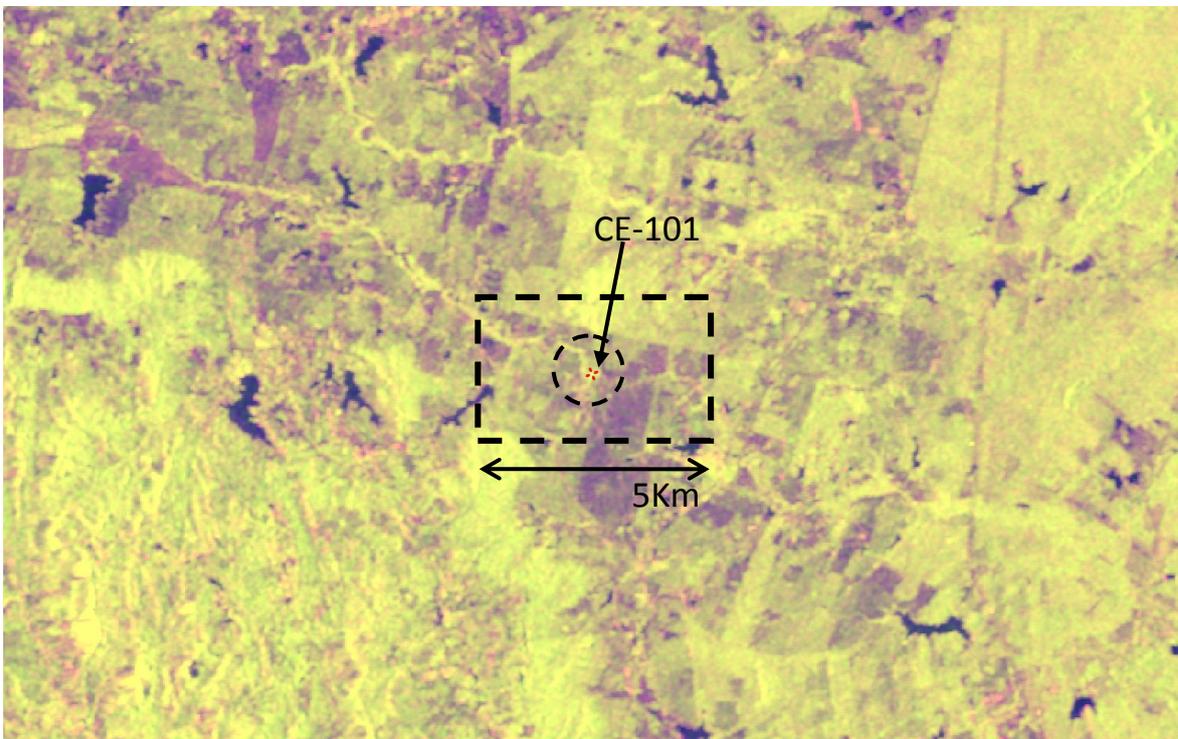


Figura 29 - Localização do Conglomerado CE-101 em escala 1:50.000 com as subparcelas em vermelho e os pixels de 22,5x22,5m do pulsar ao fundo. Mais contraste entre áreas com mais e menos vegetação.

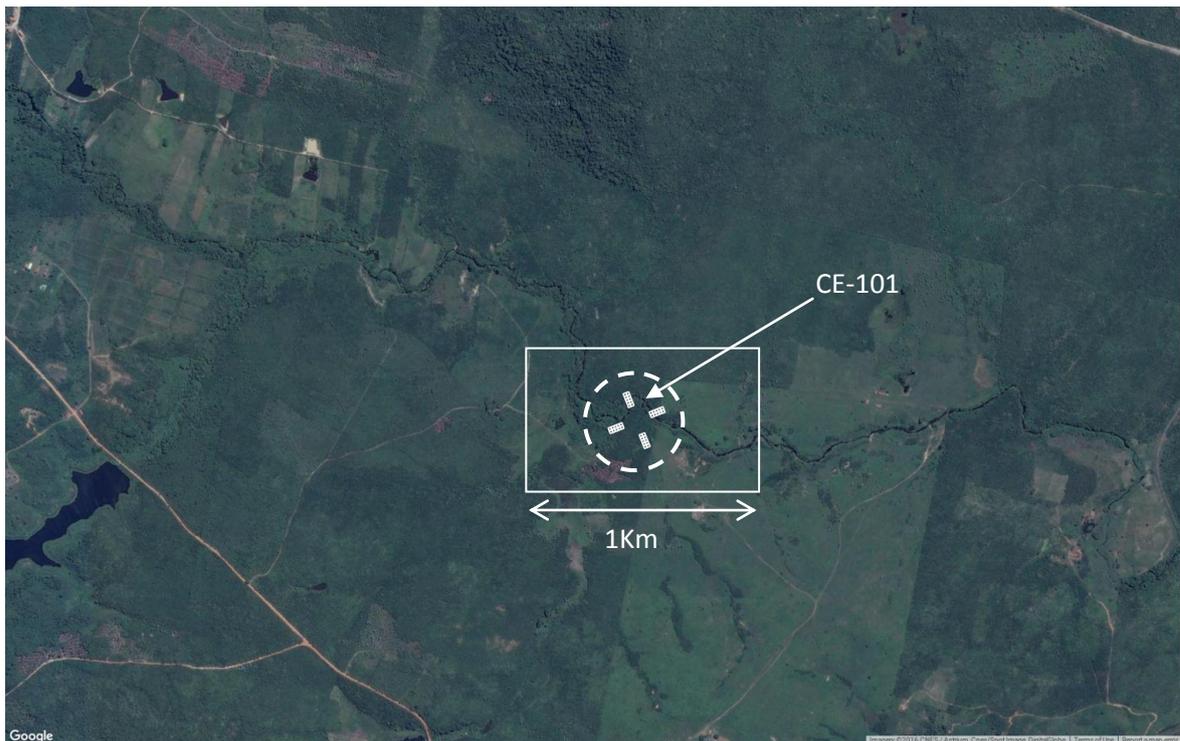


Figura 30 - Localização do Conglomerado CE-101 em escala 1:10.000 com as subparcelas em branco. Foi possível localizar um maciço florestal ao norte, uma lagoa ao oeste, além de um polígono com menos vegetação do que o restante da imagem a leste do conglomerado. Existência de limites de propriedades.

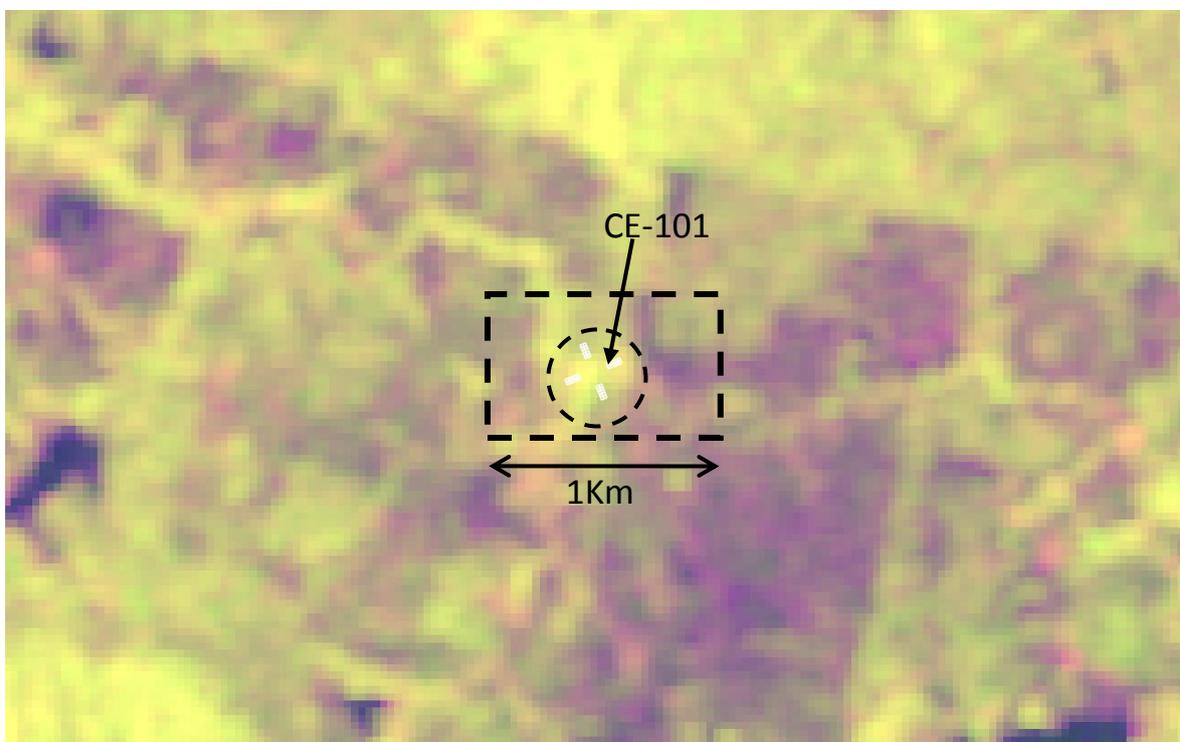


Figura 31 - Localização do Conglomerado CE-101 em escala 1:10.000 com as subparcelas em branco e os pixels de 22,5x22,5m do pulsar ao fundo. Foi possível identificar os elementos maiores da imagem óptica, o contraste continuou maior, mas começa a perder definição de contornos nas formas da imagem.



Figura 32 - Localização do CE-101 em escala 1:1.250 com as subparcelas coloridas de acordo com a classe de uso de solo e os números no centro com a quantidade de fustes contados naquele local. Houve relação entre o amostrado e o que pode ser visto na imagem, porém as subparcelas puderam estar deslocadas ou a área ter sido alterada entre a coleta e a aquisição da imagem. É possível identificar árvores individuais e o leito de um rio acompanhado por vegetação.

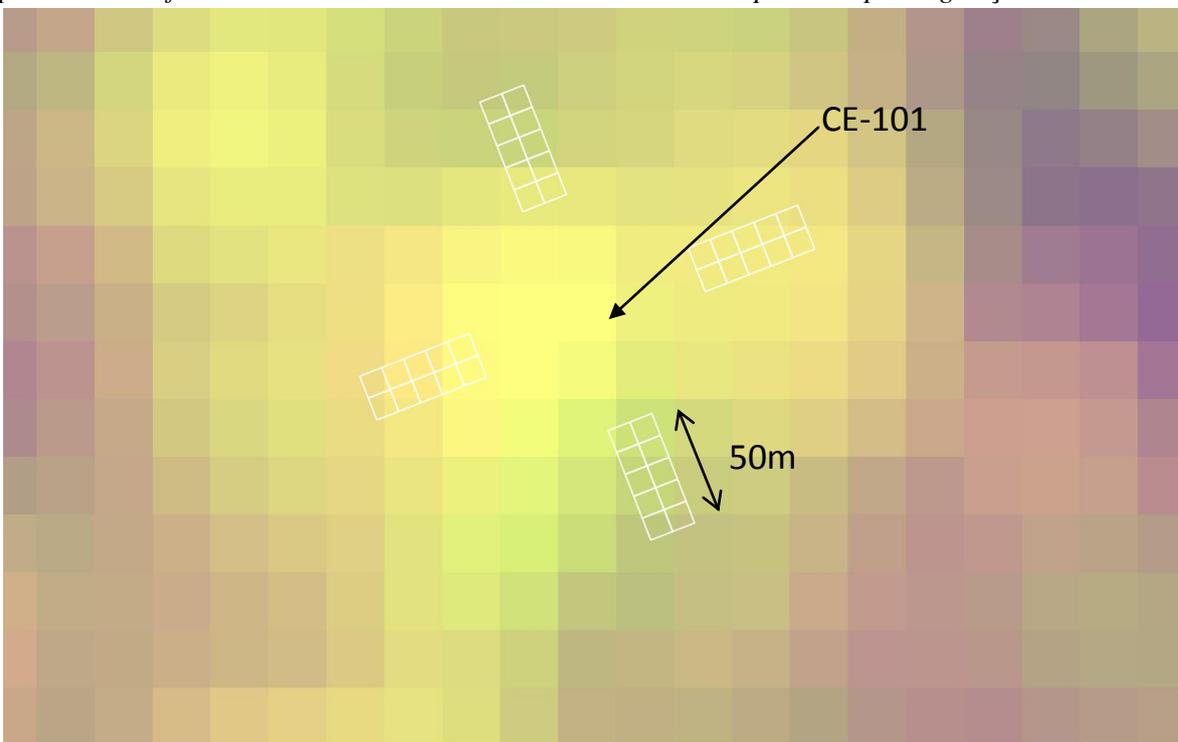


Figura 33 - Localização do CE-101 em escala 1:1.250 com as subparcelas em branco e os pixels de 22,5x22,5m do pulsar ao fundo. Perdeu-se informação de objetos identificáveis na imagem, as árvores não puderam ser identificadas, porém o tom amarelo indicou mais biomassa onde o conglomerado estava do que no canto direito da imagem, o que foi compatível com a **Figura 32**.

Com a avaliação visual de imagens em conjunto com os dados espacializados das subparcelas, pôde-se notar que apesar dos dados não terem sido exatamente coincidentes (o que não foi o objetivo do inventário e nem desta análise), eles representaram a região em torno da posição aproximada que o dado fora coletado. As quantidades de árvores por subunidade e subparcela foram adequadas à distribuição de vegetação que se pôde notar na maior parte das imagens avaliadas. Em uma amostragem aleatória de 40 pontos, dos 340 com indivíduos medidos, seis imagens (15%) não pareceram se relacionar com o que existiu nos dados do conglomerado associado.

Para uma comparação qualitativa de níveis de estoque florestal que poderiam ser extraídos dos dados, foram então criadas diferentes classificações discretizadas para os dados de uso do solo do IFN, nível de dB para polarização HH, valores de RFDI, valores de NDVI e as tipologias do PROBIO 2002. A seguir foram apresentados os níveis de estoque considerados e quais os limites dos dados para cada classe. Em todos os casos os níveis variaram de 0 a 5, sendo zero um potencial de estoque florestal nulo e cinco o maior potencial.

5.1.1. Uso de Solo da Subparcela do IFN

As classes de uso do solo foram organizadas em seis níveis de estoque florestal (*Tabela 6*). Cada conglomerado recebeu um identificador inteiro que determinava o nível de estoque florestal esperado de acordo com o uso de solo das subparcelas.

Tabela 6 - Categorias discretas de estoque florestal de acordo com o uso de solo classificado no IFN, sendo consideradas apenas aquelas que apareceram ao menos em um conglomerado do Ceará.

Nível	Estoque Florestal	Classes de Uso do Solo IFN
0	Nulo	Afr, Agu e Dun
1	Muito Baixo	Acc, Ap
2	Baixo	Acp
3	Médio	Vsb1, Vss1, Vsp1
4	Alto	Vsb2, Vss2, Vsp2
5	Muito Alto	Ou, Rg, Rm

Algoritmo para classificação no *Field Calculator* do Qgis no *Apêndice 1*.

5.1.2. Resposta em dB da polarização HH do PALSAR

Para o histograma de dB calculado no buffer de 200 m em torno dos conglomerados a partir das imagens do PALSAR, foram consideradas diferentes combinações dos bins entre -6 (n06) e -12 (n12) que trouxeram a contagem dentre 192 pixels amostrados por conglomerado. Foram definidos parâmetros de identificação de Estoque Florestal Potencial, estimados por conglomerado nos níveis de 0 a 5 (*Tabela 7*).

Tabela 7 - Categorias discretas de estoque florestal do Ceará utilizando a resposta em dB nos pixels dentro de um raio de 200m em torno de cada conglomerado do IFN. Os conglomerados foram classificados do maior nível para o menor, de modo que um ponto é classificado apenas uma vez para cada variável.

Nível	Estoque Florestal	Contagem de pixels e limites de intensidade
0	Nulo	Não atende aos critérios dos níveis 1 a 5
1	Muito Baixo	Mais de 150 pixels com dB entre -6 e -12
2	Baixo	Mais de 50 pixels com dB entre -6 e -10
3	Médio	Mais de 100 pixels com dB entre -6 e -10
4	Alto	Mais de 150 pixels com dB entre -6 e -10
5	Muito Alto	Mais de 180 pixels com dB entre -6 e -10

Algoritmo para classificação no *Field Calculator* do Qgis no *Apêndice 1*.

5.1.3. NDVI do RapidEye

Para as classes de estoque florestal, utilizando as imagens do RapidEye, também foram consideradas diferentes combinações de bins, utilizando o NDVI (calculado com as bandas 3 e 5) para os 24.155 pixels amostrados por conglomerado. Foram obtidos e apresentados os níveis de contagem e os parâmetros de inclusão para os valores estimados (*Tabela 8*).

Tabela 8 - Categorias discretas de estoque florestal do Ceará utilizando o NDVI calculado nos pixels dentro de um raio de 200m em torno de cada conglomerado do IFN. Os conglomerados foram classificados do maior nível para o menor, de modo que um ponto é classificado apenas uma vez para cada variável.

Nível	Estoque Florestal	Classes de Uso do Solo IFN
0	Nulo	Não atende aos critérios dos níveis 1 a 5
1	Muito Baixo	Mais de 300 pixels com ndvi entre 0,2 e 0,6
2	Baixo	Mais de 300 pixels com ndvi entre 0,4 e 0,6
3	Médio	Mais de 600 pixels com ndvi entre 0,4 e 1,0
4	Alto	Mais de 1200 pixels com ndvi entre 0,4 e 1,0
5	Muito Alto	Mais de 1200 pixels com ndvi maior que 0,4

Algoritmo para classificação no *Field Calculator* do Qgis no **Apêndice 1**.

5.1.4. RFDI do PALSAR

Para a categorização do Estoque Florestal utilizando o RFDI, foram consideradas somas de pixels por faixas de RFDI calculado, realizadas para as categorias 5 para a 0 de forma a classificar cada conglomerado apenas uma vez em ordem decrescente de nível de estoque. O algoritmo para classificação no Field Calculator do Qgis foi apresentado (**Apêndice 1**). Os critérios desta variável de classificação foram também sumarizados de acordo com os níveis (**Tabela 9**).

Tabela 9 - Categorização dos conglomerados de acordo com o RFDI apurado em um raio de 200m por nível de estoque florestal esperado. Os conglomerados foram classificados do maior nível para o menor, de modo que um ponto é classificado apenas uma vez para cada variável.

Nível	Estoque Florestal	Classes de Uso do Solo IFN
0	Nulo	Não atende aos critérios dos níveis 1 a 5
1	Muito Baixo	Mais de 100 pixels com RFDI entre 0,1 e 0,6
2	Baixo	Mais de 20 pixels com RFDI entre 0,3 e 0,6
3	Médio	Mais de 50 pixels com RFDI entre 0,3 e 0,6
4	Alto	Mais de 100 pixels com RFDI entre 0,3 e 0,6
5	Muito Alto	Mais de 50 pixels com RFDI entre 0,4 e 0,6

Algoritmo para classificação no *Field Calculator* do Qgis no **Apêndice 1**.

5.1.5. Tipologias de vegetação do PROBIO 2002 (MMA)

Os conglomerados foram ainda classificados através de um cruzamento geográfico com as tipologias de vegetação do PROBIO 2002 (Discutido no item 5.2.1), em que foi verificado em qual polígono do PROBIO cada conglomerado se sobrepunha, e associada a ele a tipologia na tabela de atributos do vetor de pontos do IFN. Para as tipologias foram determinados níveis de estoque (*Tabela 10*), com qual sigla foi considerada em cada um dos seis níveis.

Tabela 10 - Categorização em níveis de estoque florestal de acordo com a tipologia do PROBIO 2002 a que cada conglomerado se sobrepôs.

Nível	Estoque Florestal	Tipologias IBGE – PROBIO/MMA
0	Nulo	Corpos D'água, Iu, Vazio
1	Muito Baixo	Pm
2	Baixo	Ag, Pf, Pmb, Sp
3	Médio	P, T, Tp
4	Alto	F, Fb, Fs, Pa, Sd, SN, Ta, TN
5	Muito Alto	A, As, Td

Algoritmo para classificação no *Field Calculator* do Qgis apresentados no **Apêndice 1**.

5.2. Regressão das Classes de Estoque Florestal

Todos os dados foram processados nos registros de subparcelas, pois as informações de uso do solo do conglomerado existiram neste nível de detalhamento. Deste modo, as 10 subparcelas de cada subunidade tiveram o mesmo valor de cobertura florestal (informado pela equipe de inventário apenas para as quatro subunidades). Ainda, as 40 subparcelas do conglomerado foram analisadas com o mesmo valor de estoque de biomassa, amostra de sensoriamento remoto e informação de tipologia do PROBIO, pois os dados de produtividade florestal potencial do IFN foram divulgados de forma resumida por conglomerado. Da mesma forma as amostragens de sensoriamento e tipologia foram feitas com o buffer representativo do mesmo ponto. Foram apresentadas as médias de Classes de Estoque Florestal derivadas dos algoritmos anteriores (*Tabela 11*).

Tabela 11 - Classes de estoque florestal determinadas a partir dos dados de inventário e sensoriamento, para estimativa de potencial florestal. Os valores médios foram calculados para todas as subparcelas classificadas para cada uso do solo do inventário.

Categoria e Contagem		Médias de Classe de Estoque Florestal Definido					
Uso do Solo	Sub parcelas	E.Uso Solo	E.Cob Florestal	Est. Probio	E.dB Palsar	Est. RFDI	Est. NDVI
Agricultura Cíclica	329	1	1.5	2.5	1.0	1.9	2.4
Agricultura Permanente	81	2	0.0	4.3	3.4	4.1	2.6
Afloramento Rochoso	97	0	3.1	3.9	2.5	1.4	2.2
Água	220	0	1.5	2.7	0.9	2.2	1.6
Área Indiscriminada	404	0	2.5	3.2	1.1	1.8	2.5
Pecuária	2014	1	1.4	3.0	0.5	1.9	2.2
Dunas	10	0	5.0	3.0	2.0	1.0	2.0
Urbano	116	0	2.0	2.7	1.7	3.4	3.3
Outros	367	5	3.7	2.2	2.2	2.5	2.8
Reflorestamento Algaroba	20	5	5.0	3.9	1.3	0.9	2.4
Reflorestamento Misto	65	5	3.5	3.8	3.8	3.7	4.3
Veg. Sec. Pioneira Só Palmeiras	27	3	4.6	3.7	1.6	3.4	1.6
Veg. Sec. Média Só Palmeira	40	4	5.0	3.0	2.0	1.8	2.8
Veg. Sec. Pioneira com Palmeira	125	3	5.0	3.4	2.8	4.2	3.9
Veg. Sec. Média com Palmeira	105	4	4.8	3.7	2.8	1.2	3.2
Veg. Sec. Pioneira sem Palmeira	4931	3	4.5	3.3	1.4	2.0	2.7
Veg. Sec. Média com Palmeira (vazio)	5136	0	4.9	3.6	2.9	1.7	2.6
	953	0	0.4	3.6	2.0	1.5	0.6
Total Geral	15040	1.4	3.7	3.4	1.9	1.9	2.4

Os dados de estoque estimado, reorganizados em ordem crescente das colunas de estoque florestal (classificação crescente pelas colunas da esquerda para a direita do que foi apresentado na tabela) tiveram seus resultados plotados (*Figura 34*). Foi possível descartar determinadas categorias de uso do solo baseado nos estoques estimados com as outras variáveis. Por exemplo, houve um vale nas curvas de estoque com cobertura, dB Palsar e Probio para a categoria 1 de uso do solo (Ap e Acc que são agropecuária) e um pico para as categorias 0 e 5. Estas respostas permitiram uma análise de frequência cruzada entre as estimativas de diferentes origens, na tentativa de explicar o dado de campo utilizando um conjunto de dados de mapeamentos e sensoriamento remoto.

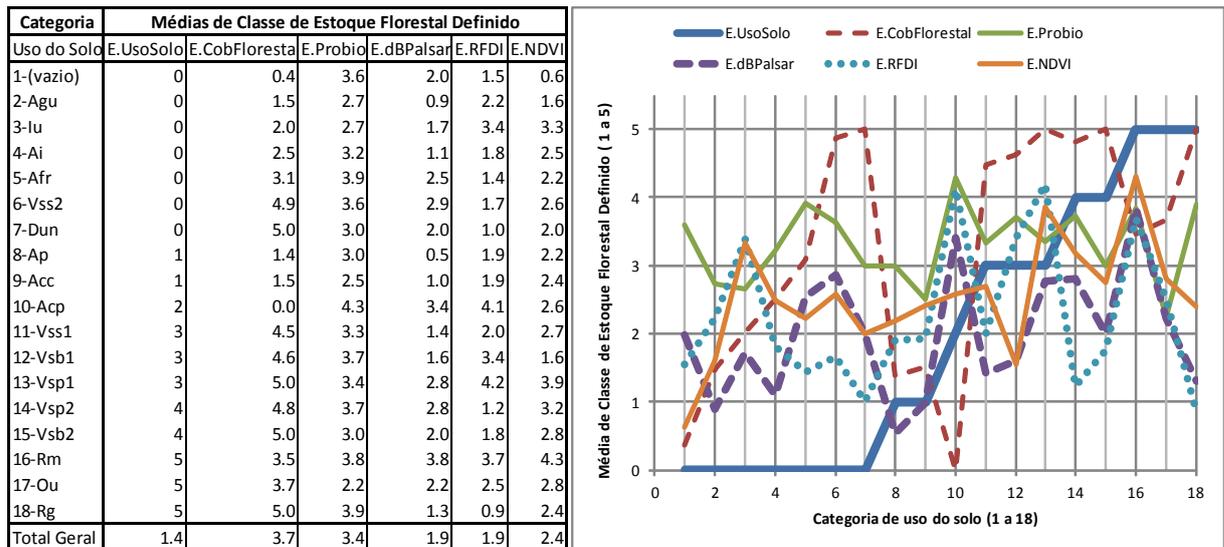


Figura 34 - Gráfico com as classes de Estoque Florestal definidos para as subunidades, com os diferentes dados disponíveis e distribuição por classe de uso do solo do IFN.

Foi possível observar que as diferentes classificações tiveram comportamentos distintos em relação às categorias de Uso do Solo (**Figura 34**), porém algumas características foram comuns a todas as ou parte das classificações, como um resultado alto (>3.4) na média de classe de estoque em todas as definições para o Rm (Reflorestamento Misto), valores médio-altos (>2.6) em pelo menos 3 definições para Vss1, Vsb1 e Vsp1 (Vegetação Pioneira com e sem palmeira) e valores baixos (<2.5) em pelo menos 3 definições para Vazio, Agu, Afr, Ai e Iu (áreas potencialmente sem vegetação).

Apesar deste comportamento aparentemente coerente, ao fazer regressões lineares e não lineares com os dados das 15.040 subparcelas o resultado foi insatisfatório para a predição dos próprios dados modelados, em parte porque a única variável que de fato estava detalhada em todas as amostras foi a classificação de uso do solo do IFN. Esta diferença de detalhamento dos conglomerados fez com que diversas subparcelas de uso diferente de solo localizadas em um mesmo conglomerado tivessem de ser relacionadas a mesmos valores das variáveis que se desejava serem preditores, pois estas foram calculadas para uma área em torno do conglomerado e um valor foi atribuído a todas as subparcelas que o formavam.

Ao avaliar esta relação, os valores esperados do sensoriamento em uma área que abrangue o conglomerado poderiam ser aparentemente estimados a partir da classificação de uso do solo das subparcelas porque elas foram de fato mais detalhadas do que a amostra de sensoriamento. O caminho oposto, que foi o interessante para a interpolação do inventário, não pôde ser feito com estes dados e a abordagem feita neste estudo. Com esta constatação, se considerou então duas opções para buscar correlação das amostras de campo e das amostras de imagens, de forma sistemática e abrangente. A primeira foi a de utilizar um detalhamento maior nas imagens, e a segunda de relacionar os valores médios por conglomerado da classificação de estoque florestal a partir do uso do solo, ou seja, um detalhamento menor do que se pretendeu prever.

A primeira opção foi descartada, pois mesmo que houvessem dados de satélite disponíveis em resolução de 22.5 e 5 metros, o que permitiria unidades amostrais de 50 m por 50 m ou menores, dados plenamente confiáveis e corrigidos de todas as subparcelas não estavam disponíveis. A informação espacial no nível de escala, que seria necessário para relacionar unidades pequenas (subparcela de 10m por 10m, por exemplo), não existiria no formato pensado para a execução do IFN, que exigia a marcação com GPS apenas do ponto central e dos quatro pontos iniciais de cada subunidade, a partir dos quais a localização espacial era feita com bússola e trena. O erro esperado para o GPS, em conjunto com os procedimentos de navegação posteriores, fugiram do escopo deste estudo e estavam sendo realizados pela própria equipe do IFN, para controle de qualidade e melhoria de coleta de dados. O erro aceito para o conglomerado, sendo da ordem de 10 metros, bem como da posição do início das subunidades, que junto com a imprecisão de direção das subparcelas, levou a incertezas suficientemente pequenas para os objetivos do inventário. Porém, estes dados necessitariam de diversas correções e processamentos para uso direto com SR de altíssima resolução.

Foi decidido então pela segunda opção, que reduziu a quantidade de registros por variável a 376 conglomerados (ao considerar as informações das subparcelas resumidas por ponto da grade do IFN), com valores somados de indivíduos e suas variáveis de estoque florestal, associados a valores médios por conglomerado de variáveis mensuradas da floresta e das variáveis originais divulgadas pelo IFN, e extraídas de imagens de sensores remotos. Foram confeccionados histogramas das variáveis resultantes para os conglomerados (*Figuras 35 a 44*), que posteriormente foram utilizadas em outras

regressões com o objetivo de modelar os dados de campo a partir do sensoriamento remoto.

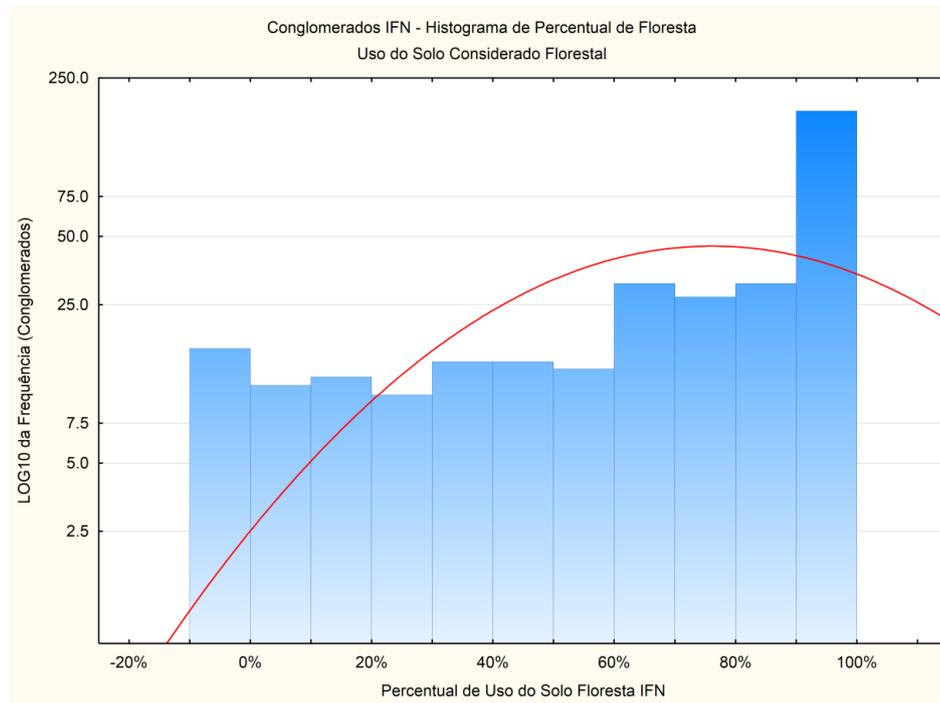


Figura 35 – Histograma em escala logarítmica do percentual de floresta de cada conglomerado estimado de acordo com o uso de solo cadastrado no IFN. A maior parte demonstrou percentuais de floresta acima de 60% conforme uso do solo das subparcelas.

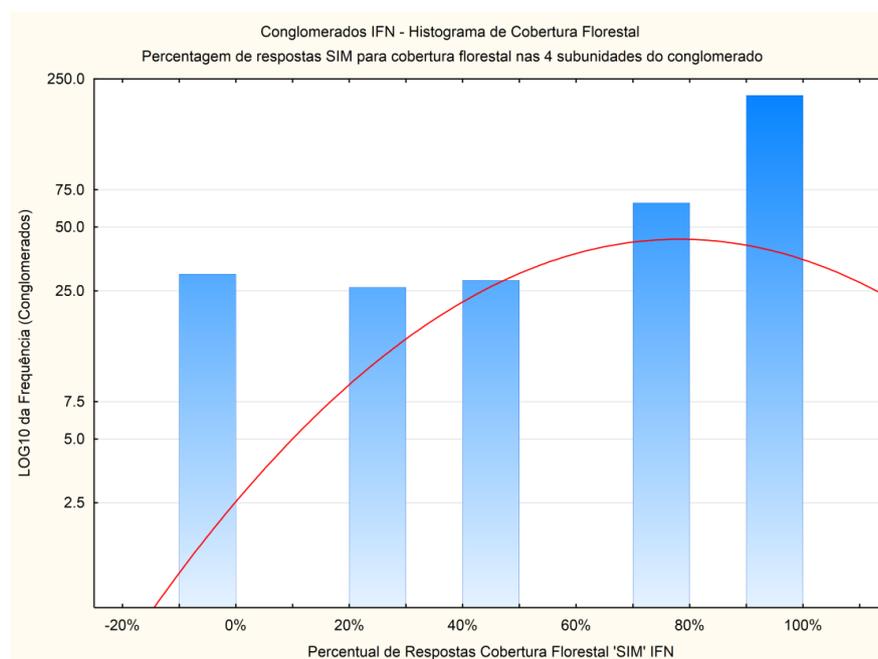


Figura 36 – Histograma em escala logarítmica do percentual de floresta de cada conglomerado estimado de acordo com a informação de cobertura florestal das quatro subunidades. O chefe de equipe informou SIM ou NÃO para cada subunidade, assim as possibilidades de percentuais de cobertura florestal ficaram restritas a 0, 25, 50, 75 e 100%.

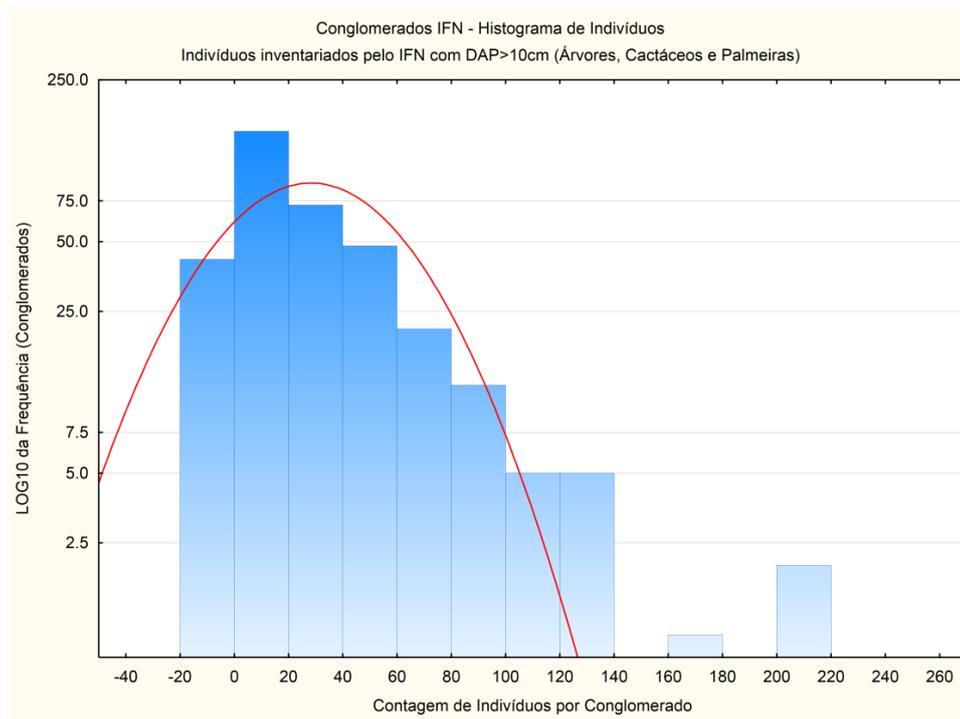


Figura 37 - Histograma em escala logarítmica do total de indivíduos entre os 13.248 com DAP maior ou igual a 10cm amostrados, em cada conglomerado do IFN. Podem ser Árvores, Cactáceos ou Palmeiras e a maior parte dos conglomerados teve entre 20 e 60 indivíduos inventariados.

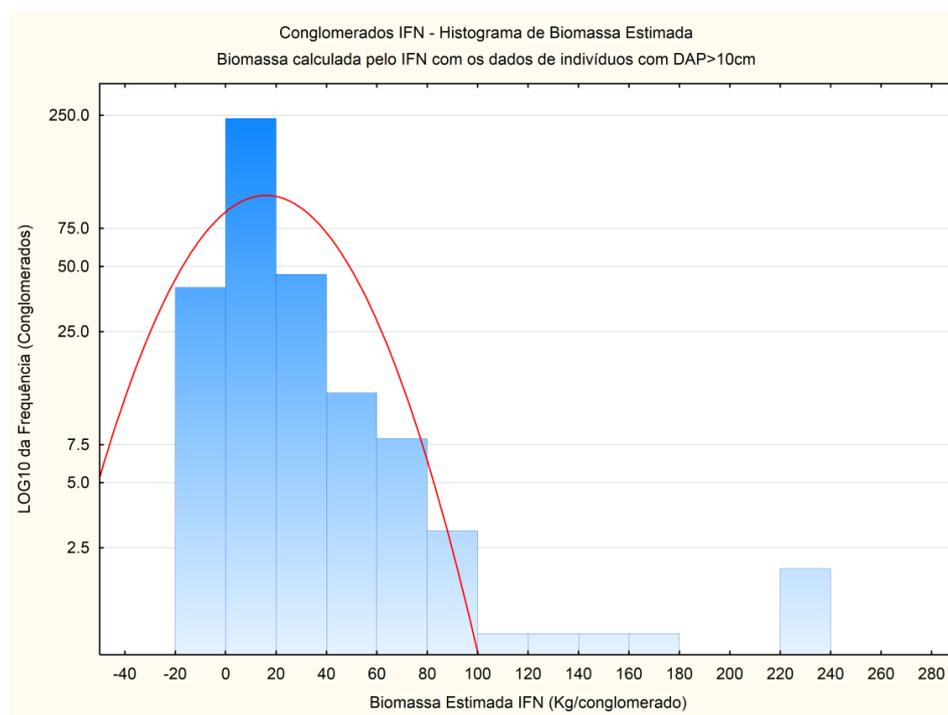


Figura 38 – Histograma em escala logarítmica da biomassa calculada a partir de indivíduos com DAP maior ou igual a 10cm amostrados em cada conglomerado do IFN. Podem ser Árvores, Cactáceos ou Palmeiras. A maior parte dos conglomerados com biomassa calculada apresentou valores até 100Kg, que para a caatinga representou um conteúdo de 49Kg de carbono em 0,4 hectares.

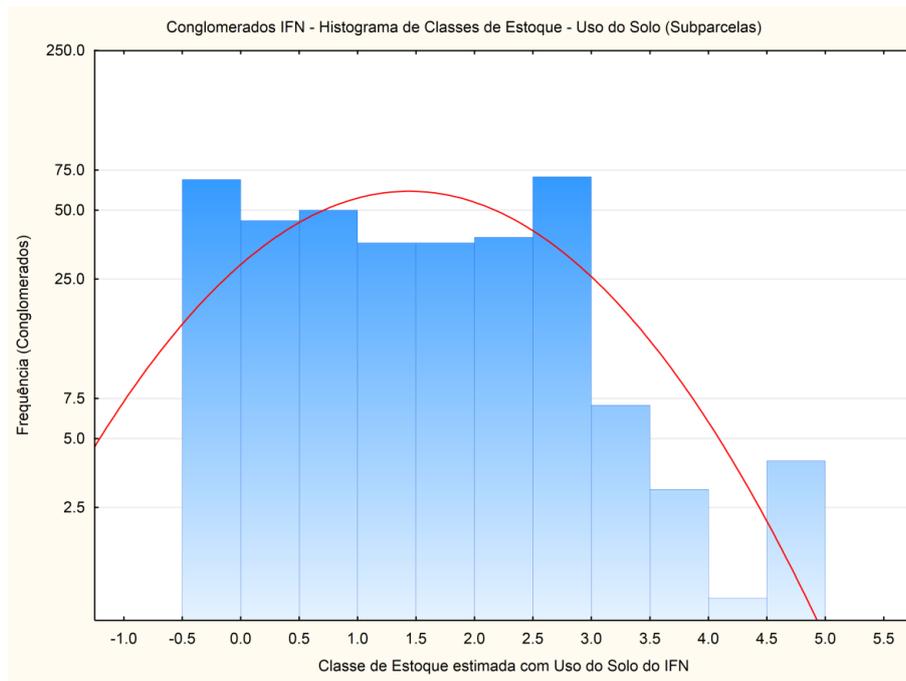


Figura 39 - Histograma em escala logarítmica das médias por conglomerado de classe de estoque florestal, estabelecida a partir das classes de uso do solo do IFN. Distribuição homogênea e quantidades semelhantes de valores inteiros e intermediários (que indicaram haver mais de uma classe no conglomerado) indicaram haver mistura de classes em uma parte considerável dos pontos.

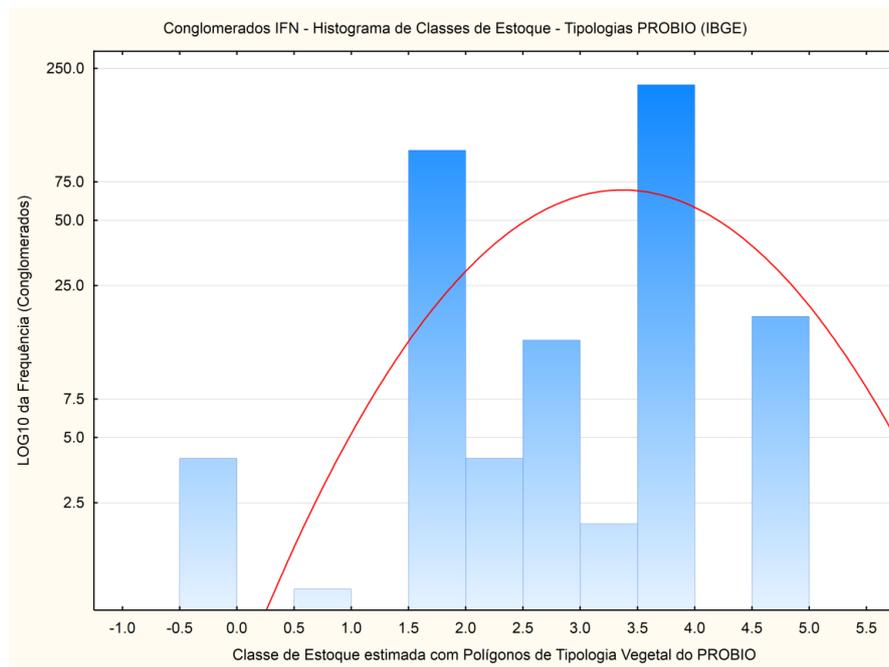


Figura 40 – Histograma em escala logarítmica das médias por conglomerado de classe de estoque florestal, estabelecida a partir das tipologias vegetais do IBGE publicadas do PROBIO 2002 do MMA. Destacaram-se os valores entre 1,5 e 2,0 e entre 3,5 e 4,0 que concentraram as tipologias com maior área de cobertura no estado, que incluíram as savanas e a agricultura.

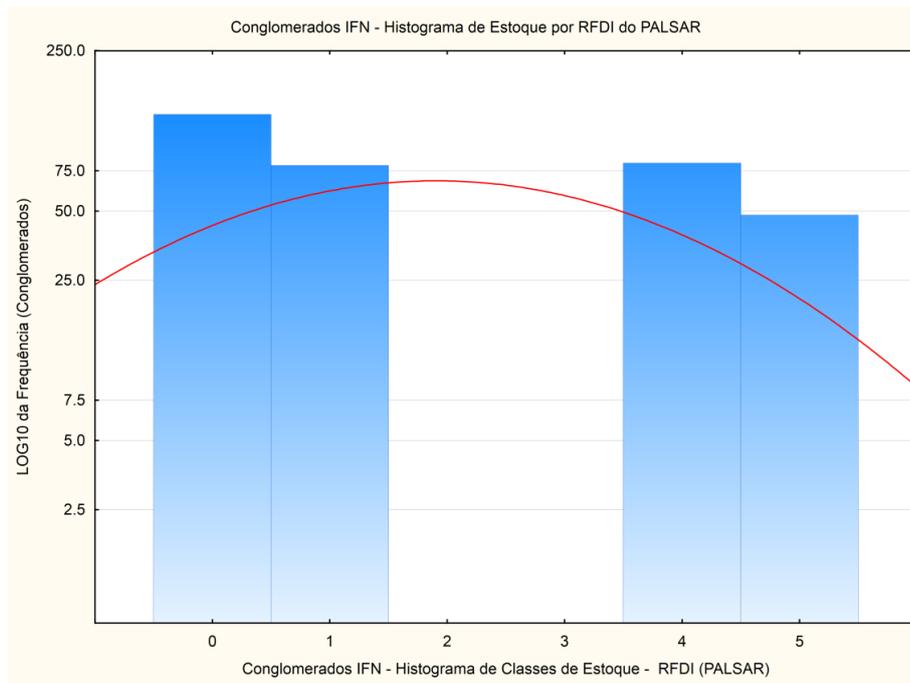


Figura 41 – Histograma em escala logarítmica das médias por conglomerado de classe de estoque florestal, estabelecida a partir do RFDI derivado dos dados do PALSAR. Os níveis escolhidos tornaram a classificação dos conglomerados abrupta, não foram identificados pontos nos níveis dois e três de estoque com este classificador, o que não foi revisado, pois posteriormente o RFDI foi usado individualmente para mapear as áreas de maior e menor estoque no estado.

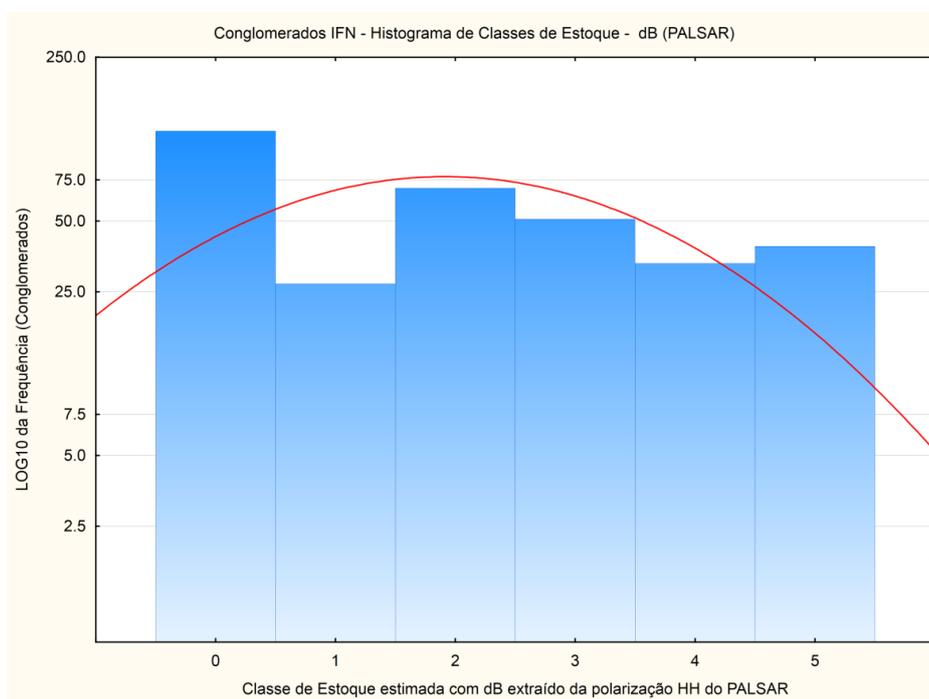


Figura 42 – Histograma em escala logarítmica das médias por conglomerado de classe de estoque florestal, estabelecida a partir do nível de dB da polarização HH do PALSAR. Quantidade de conglomerados com cada nível de estoque esteve distribuída de forma mais homogênea do que a do RFDI, indicação de que os limites de HH escolhidos separaram características existentes no Estado do Ceará.

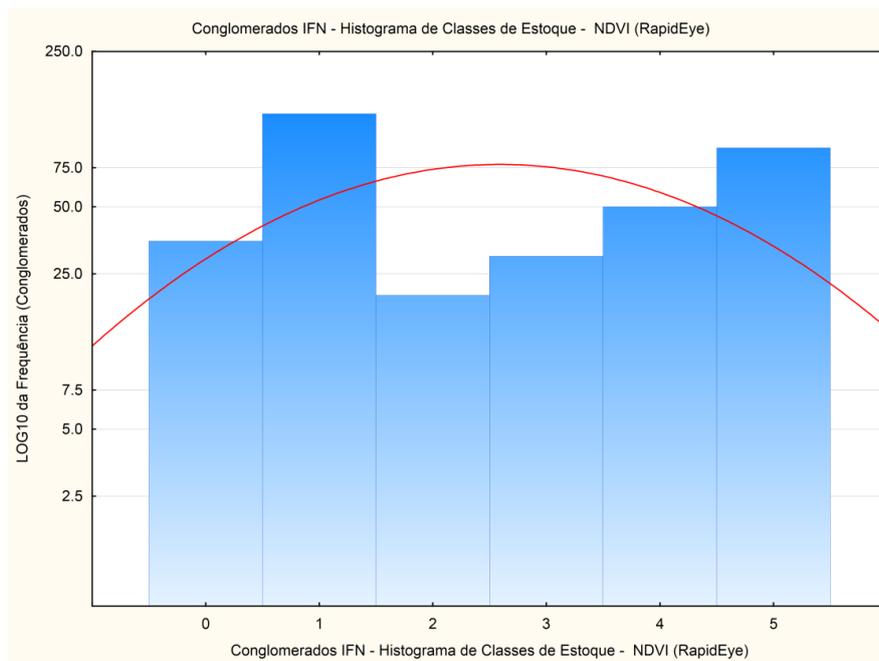


Figura 43 – Histograma em escala logarítmica das médias por conglomerado de classe de estoque florestal, estabelecida a partir do NDVI calculado com as imagens RapidEye. Distribuição homogênea, com a maior parte dos conglomerados sendo classificada nos níveis um e cinco de estoque florestal.

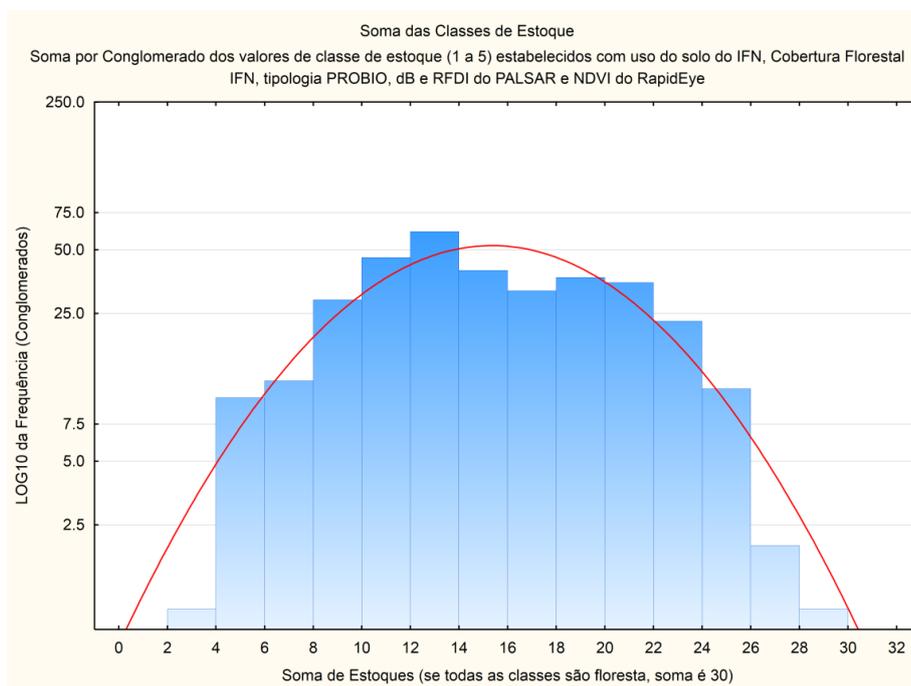


Figura 44 – Histograma em escala logarítmica das somatórias das médias por conglomerado de todas as classes de estoque florestal, estabelecidas a partir dos dados descritos nos histogramas anteriores. Neste gráfico esteve concentrada a maioria dos conglomerados em valores somados de 10 a 22. O valor máximo possível foi 30 e o menor valor observado é dois. Conseguiu-se distinguir casos em que todos os índices de estoque foram concordantes para soma até oito (23 registros) e a partir de 22 (18 registros), que são 9,2% dos registros.

A regressão não linear da quantidade de indivíduos com dados de rfdi, dB e ndvi foi obtida e apresentada (**Figura 45**). A função apresentou coeficiente de determinação 0.6, respondendo por 45% da variabilidade dos dados. Porém, mesmo com o melhor ajuste conseguido por mínimos quadrados, o modelo não foi eficiente para a previsão, o que pôde ser observado em sequência dos valores preditos pelo modelo (**Figura 46**).

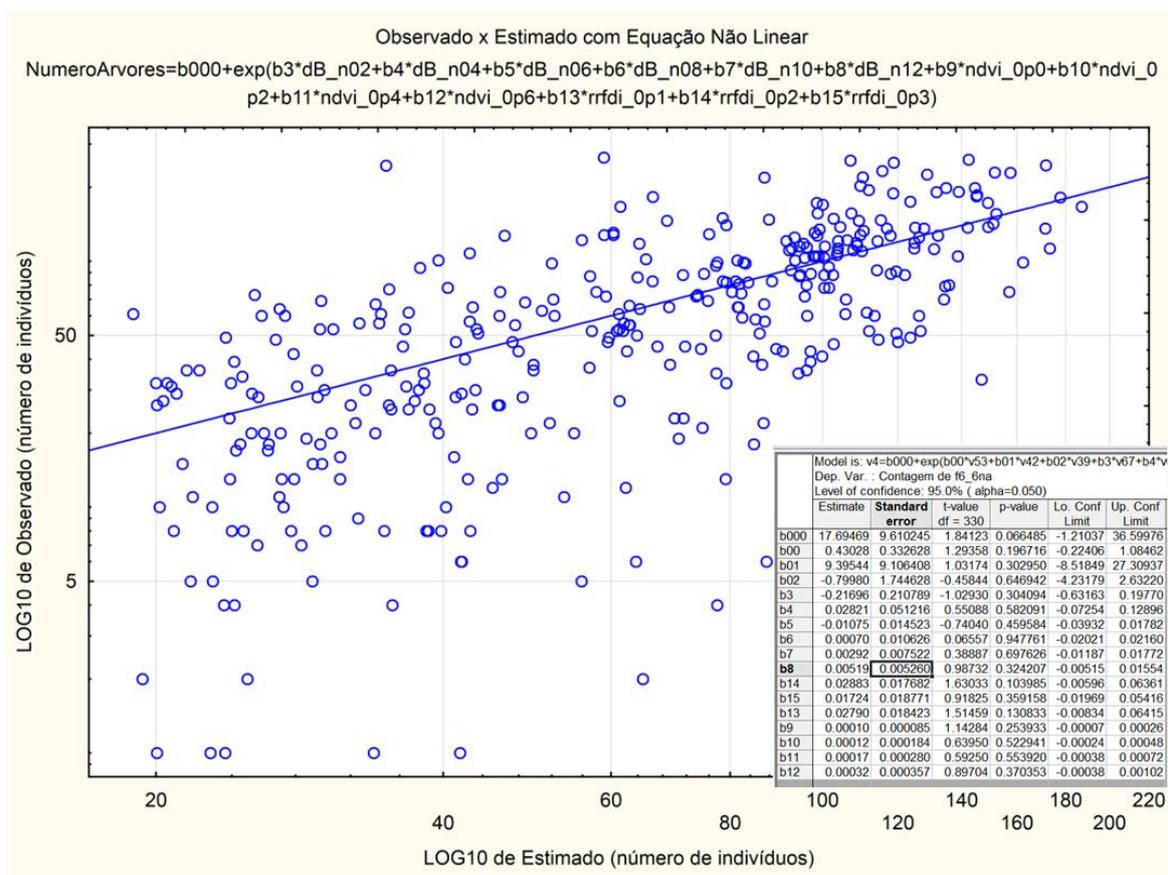


Figura 45 - Gráfico com os valores estimados com o modelo e os dados originais observados, apesar do ajuste aparentar ser representativo, a função resultante não descreveu os dados observados. Foram apresentados de forma ilustrativa os resultados com número de indivíduos por sido obtido o melhor ajuste para esta variável utilizando os estimadores descritos anteriormente. Os resultados na estimativa de biomassa e outras variáveis foram equivalentes.

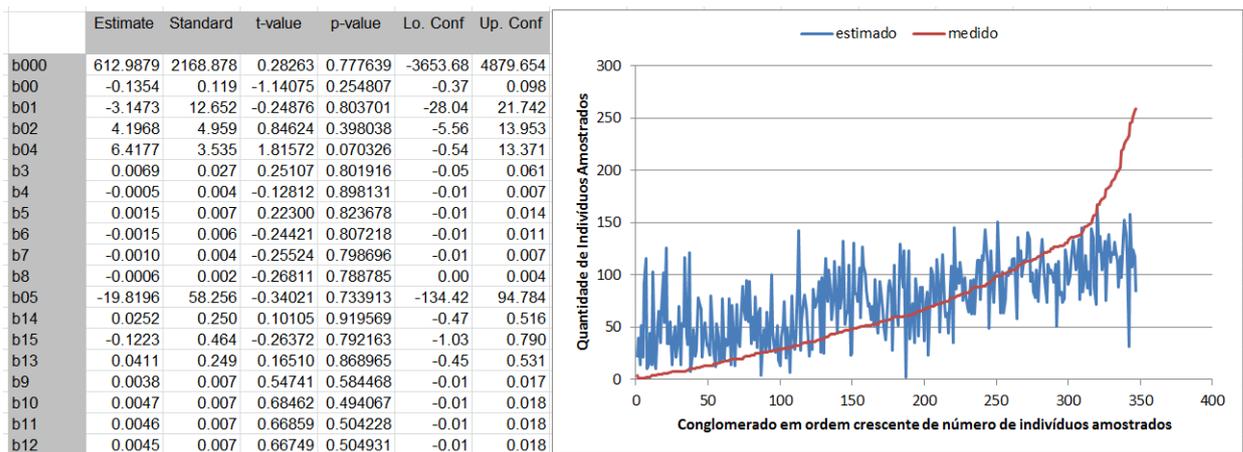


Figura 46 - Parâmetros estimados na regressão com modelo exponencial das variáveis que apresentaram maior correlação com a quantidade de indivíduos de cada ponto do IFN. O comportamento do modelo apresentou uma tendência positiva, mas que não teve uma coerência com o comportamento dos dados amostrados, estes de fato distribuídos em uma curva exponencial. A linha azul indica que apesar da diferença de erros quadrados terem sido minimizadas, a função encontrada não representou o dado que se queria explicar.

Estudos anteriores foram realizados em áreas de caatinga, em Petrolina – PE (LIMA, 2014), sendo encontradas relações lineares entre variáveis de inventário florestal e índices de vegetação como o NDVI. No caso, a área estudada se encontrava em uma região experimental da EMBRAPA de aproximadamente 6 km por 16 Km, com a coleta em 20 pontos desta região e apenas uma imagem de satélite. A escala de cobertura do estudo de todo o Ceará foi diferente, sendo necessário buscar relações entre 376 pontos que apresentavam distâncias entre si que acomodariam toda a região experimental do exemplo da Embrapa. Esta diferença foi um indicativo de que apesar do método de regressão linear direto ter sido adequado para determinados casos, foram necessárias outras correções e ajustes para uma análise em território mais amplo e descontínuo. A abordagem realizada para o Ceará pôde ser alterada para o cálculo de áreas menores em torno de pontos determinados de forma mais precisa e corrigida, porém foi necessário um tempo maior de análise e processamento sem garantias de que os resultados seriam satisfatórios.

Dado o resultado insatisfatório utilizando a regressão, procedeu-se a aplicação de técnicas de geoestatística para processar e interpretar o estoque florestal do Ceará. Foi utilizada a krigagem com máscaras e associação dos índices de vegetação apenas para filtrar os dados e reclassificá-los. A abordagem com krigagem apresentou dados que responderam parte das dúvidas relacionadas à distribuição espacial de estoque no estado.

5.3. Interpolação do IFN por Krigagem Ordinária

Como os resultados de correlação entre os dados do IFN e o das imagens seriam os construtores de funções para a co-krigagem de dados de estoque florestal para os pontos da grade regular do IFN, foi feita uma krigagem ordinária com os dados para avaliar a viabilidade da técnica e qual tipo de informação poderia ser obtida com a interpolação dos dados amostrais por meio da geoestatística. A geoestatística tem sido uma das técnicas difundidas para a estimativa de biomassa em grandes áreas a partir de inventários e imagens de sensoriamento remoto (WULDER, 2008). Optou-se por realizar a krigagem com um modelo de distribuição, utilizando o script “R” de krigagem com seleção de modelos, alterado para que fosse obrigatoriamente utilizado apenas o “LIN” (linear) conforme apresentado em código fonte (**Apêndice 1**). O modelo foi aplicado diretamente no ambiente do Qgis e a resposta da krigagem gerou um arquivo Raster em formato GeoTIFF que posteriormente foi ajustada com uma função exponencial para compor mapas e cruzar informações com dados vetoriais relacionados ao Ceará.

Nesta seção foram apresentados os resultados desta krigagem com os dados originais de biomassa do IFN do Ceará. Optou-se por exibir os dados em mapas de todo o estado para propiciar uma visualização geral do Estoque Florestal estimado. A projeção dos dados em um mapa permitiu a comparação das informações detectáveis em escala estadual com características físicas conhecidas do estado, como a divisão de bacias hidrográficas, as sub-regiões políticas e os dados de imóveis rurais disponíveis no CAR do estado.

Esperou-se que as técnicas utilizadas neste estado, uma vez que ofereceram resultados satisfatórios, pudessem ser diretamente aplicadas em outras regiões do Brasil, necessitando de calibragem em uma escala bem menor do que o desenvolvimento realizado para o Ceará. Como o IFN provavelmente procederá com a amostragem de todos os estados brasileiros, foram priorizados processos e análises automatizados e passíveis de replicação em outros conjuntos de dados.

O mapa de densidade de biomassa em toneladas por hectare demonstrou uma resolução final de 500 m, o que significou ter uma estimativa de biomassa para cada 25 hectares do estado como refinamento dos valores estimados pelo SFB para a grade de pontos distantes 20K m uns dos outros, com uma área delimitada por pontos de grade de 40mil hectares. A rasterização do resultado da krigagem em pixels de 25 hectares foi escolhida por facilitar o

processamento, ser suficientemente detalhada para a apresentação no mapa, ser compatível com a abordagem de regressão (cada área processada com 200m de raio está contida em um pixel do raster), além de permitir o processamento do estado com todos os dados do Ceará em menos de 1 hora com os recursos computacionais disponíveis.

O primeiro mapa (*Mapa 1*) apresenta os dados de biomassa calculados pelo SFB para os pontos do IFN, utilizados como entrada de dados. A modelagem foi feita com os dados exibidos no mapa com 223 dos 376 conglomerados do IFN em um arquivo vetorial de pontos. Foi utilizado o valor de biomassa calculado como sendo a representação do estoque florestal do conglomerado, lembrando que a intenção do processo era poder comparar quais regiões do estado tinham mais ou menos estoque florestal potencial, sem estimar o valor exato do estoque em cada local no resultado. A biomassa informada no IFN (para um conglomerado de 0,4ha) foi normalizada para 1ha, passando a ser uma informação de biomassa por hectare e o valor armazenado também no arquivo vetorial de pontos. Os dados de radar apresentados no *Mapa 2* foram utilizados na etapa do *Item 5.4* para a criação de máscara de filtragem com o RFDI.

O arquivo de pontos era então passado para o software estatístico R como uma tabela de dados com 223 registros e três colunas, sendo elas o valor de biomassa, a coordenada X e a coordenada Y de cada ponto. Depois foram calculadas as coordenadas do envelope do arquivo, definindo as dimensões do arquivo raster em que eram armazenados os resultados. Por fim, foi feito o ajuste automático de variograma com modelo linear de distribuição, e o variograma com menor erro (*Figura 47*) foi passado para o método “krige” que gerou a predição por krigagem com pixels de 500x500 metros, armazenada em um arquivo raster com as dimensões e sistema de referência do envelope dos pontos.

O raster resultante foi transformado em um mapa (*Mapa 3*) com valores redistribuídos por relação linear dos limites do resultado da krigagem para representar os limites existentes nos dados do inventário. Foram redistribuídos para valores entre zero e 200. A maior parte dos dados era menor do que 60, portanto foi realizado um corte neste nível para facilitar a visualização e análise.

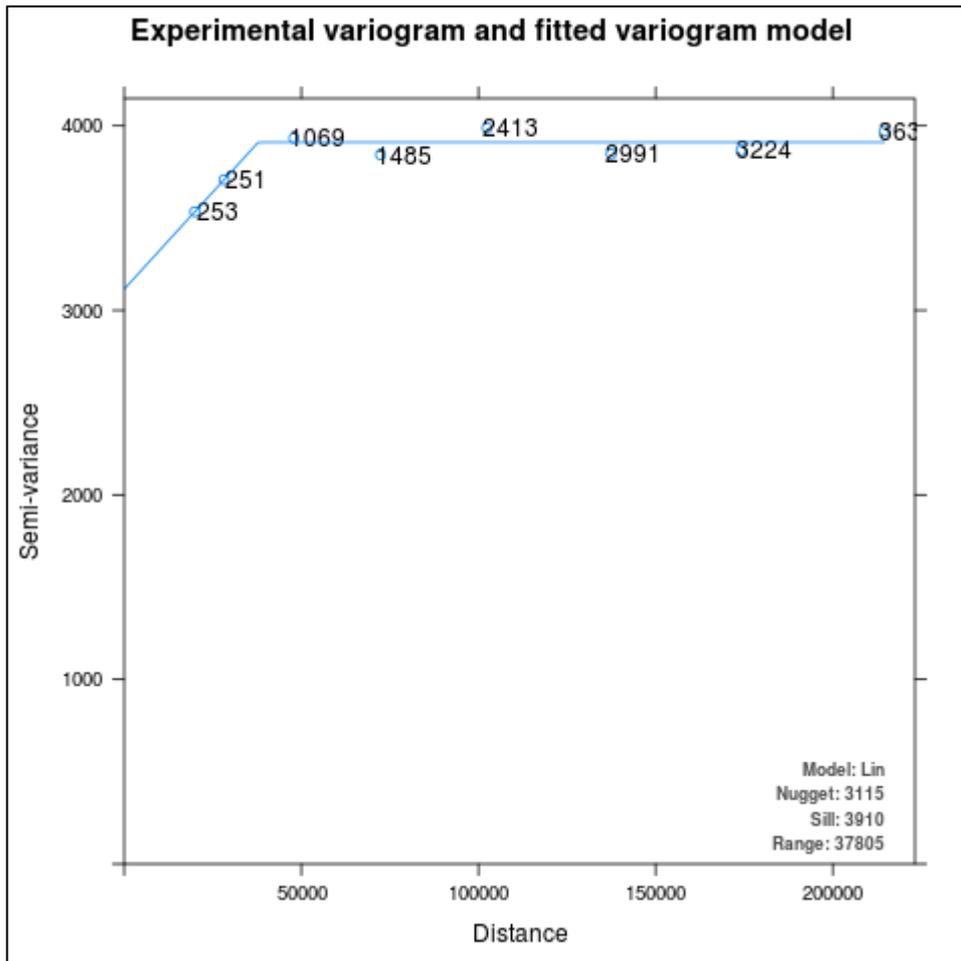
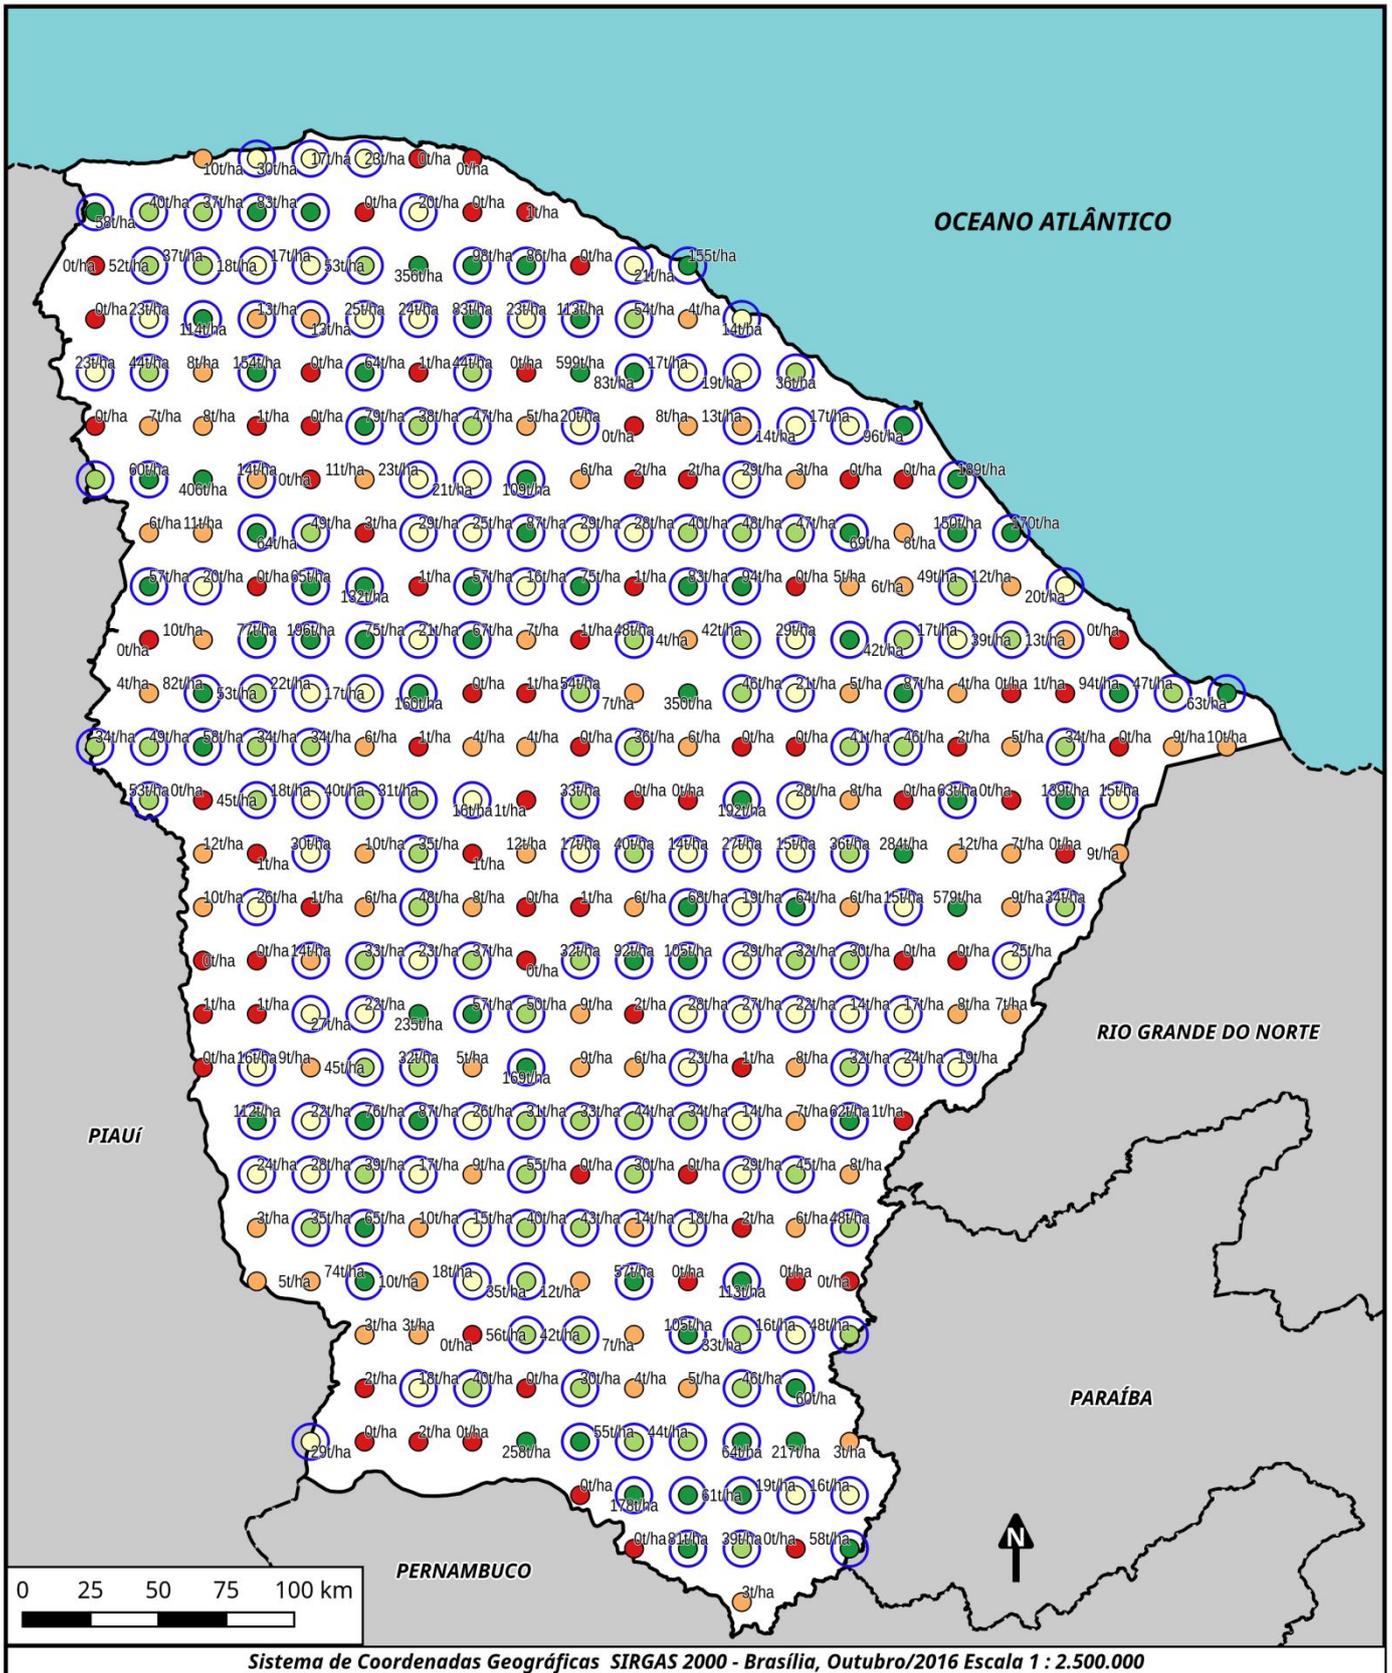


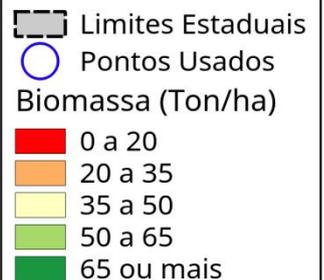
Figura 47 – Variograma com melhor ajuste no R com algoritmo *AutoFitVariogram*, utilizado para a krigagem ordinária com modelo Linear para interpolação da biomassa do IFN.

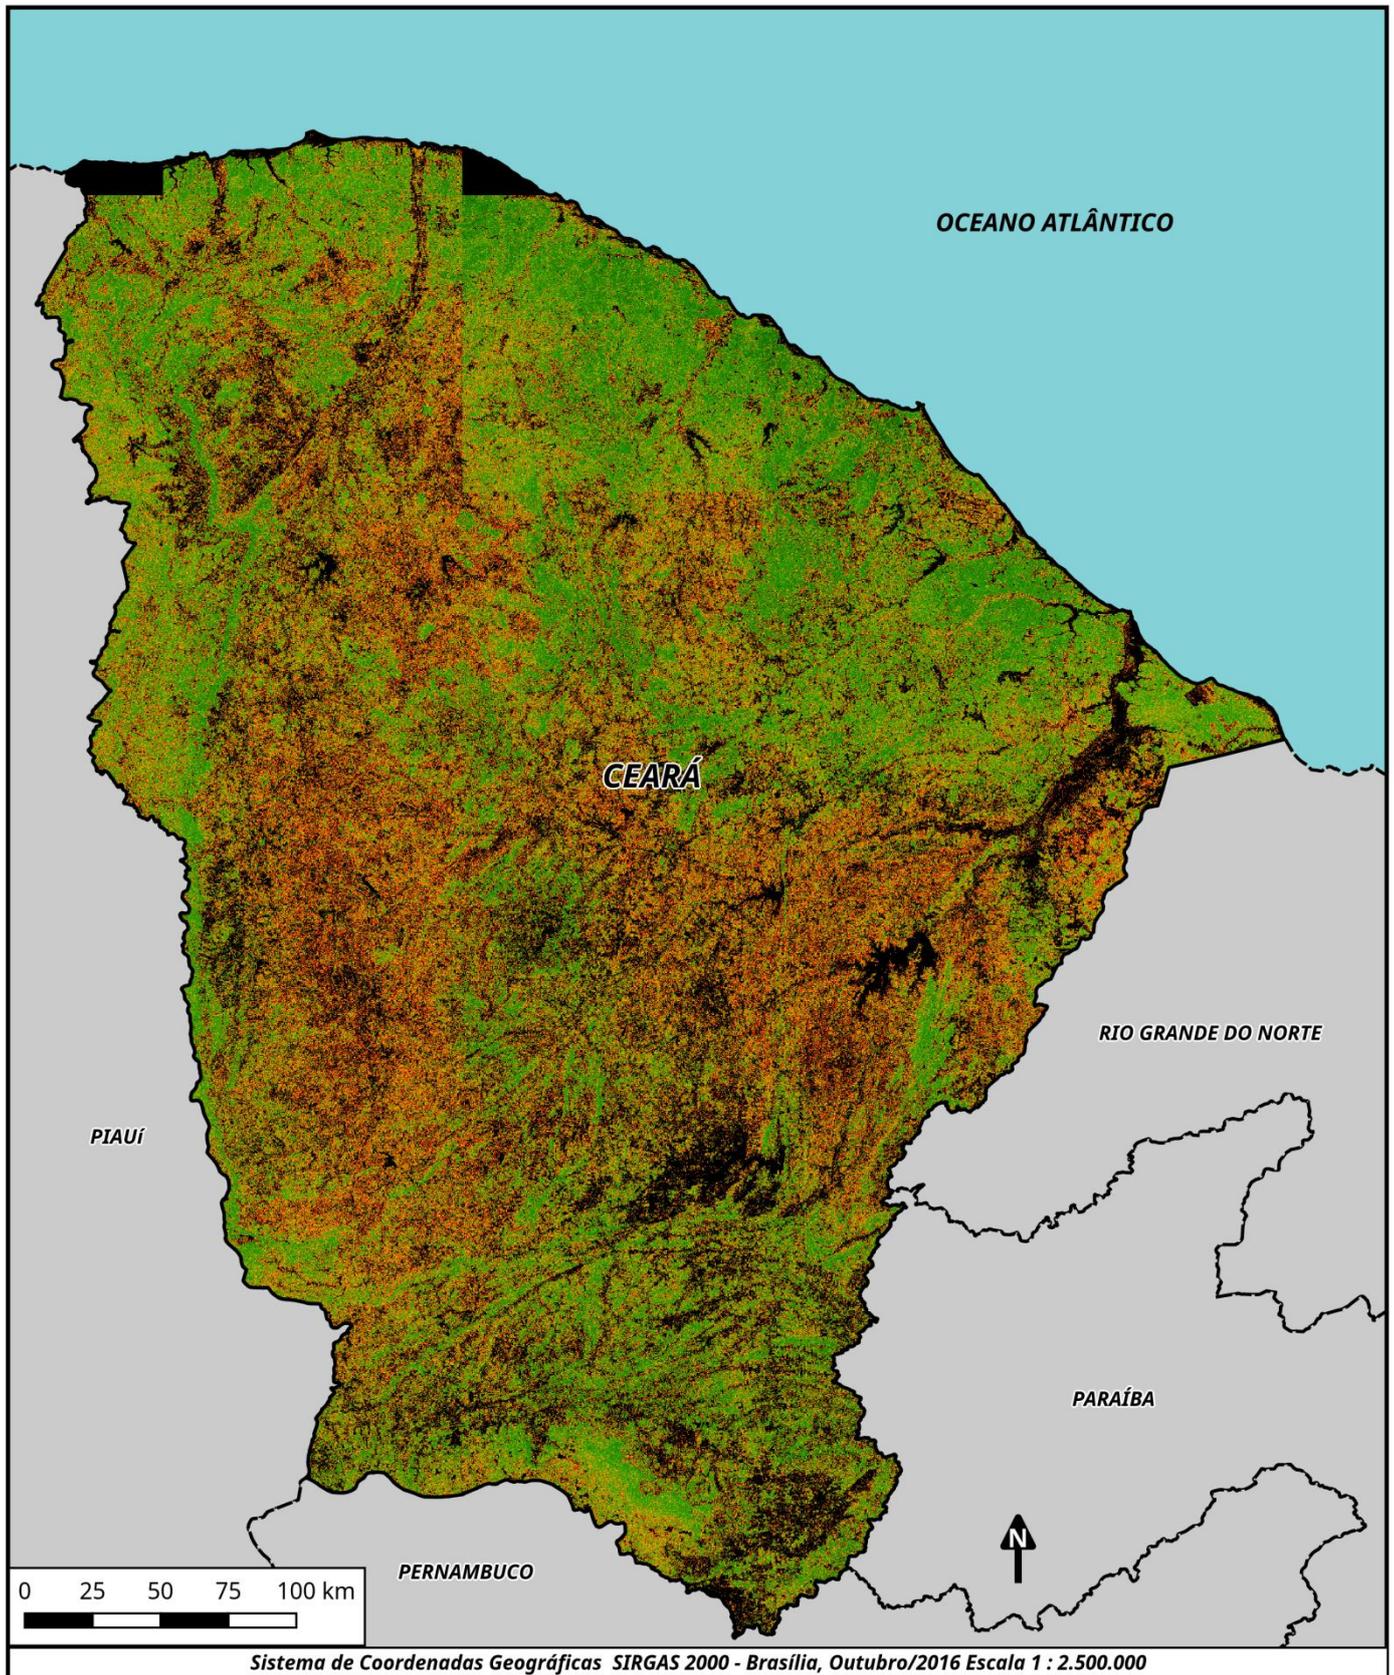
Ressalta-se que os valores de biomassa encontrados representavam uma interpolação espacial da biomassa estimada pelo IFN, portanto esperava-se uma coerência entre grandezas estatísticas da krigagem e do inventário como a média estadual de biomassa. A estimativa variaria de acordo com o modelo usado na krigagem, os limites no reajuste e os próprios cálculos utilizados no inventário. Com os dados brutos do inventário é possível realizar novas estimativas de potencial florestal com equações diferentes da utilizada para a caatinga no IFN e então realizar uma nova krigagem. O resultado pode então ser cruzado com outras informações que auxiliem a aplicação para o fim que se deseja. Considerou-se neste estudo o interesse em relacionar a distribuição de estoque florestal com o mapeamento de vegetação PROBIO, com os limites de bacias hidrográficas do Ceará, com as sub-regiões administrativas e os imóveis rurais do estado.



Mapa 1 - Biomassa calculada por Conglomerado do IFN

As cores representam os níveis de biomassa calculada pelo SFB em cada conglomerado a partir da altura e diâmetro das plantas da família *Arecaceae* (palmeiras) e árvores (tronco lenhoso) que apresentaram mais de 10cm de DAP. Foram encontrado valores entre zero e 239 toneladas por ponto. Como o ponto tem 4000 m² (0,4 hectare), a biomassa por área ficou entre zero e 600ton/ha. Os pontos destacados em azul são dos 223 conglomerados utilizados para interpolação da biomassa em todo o Ceará.

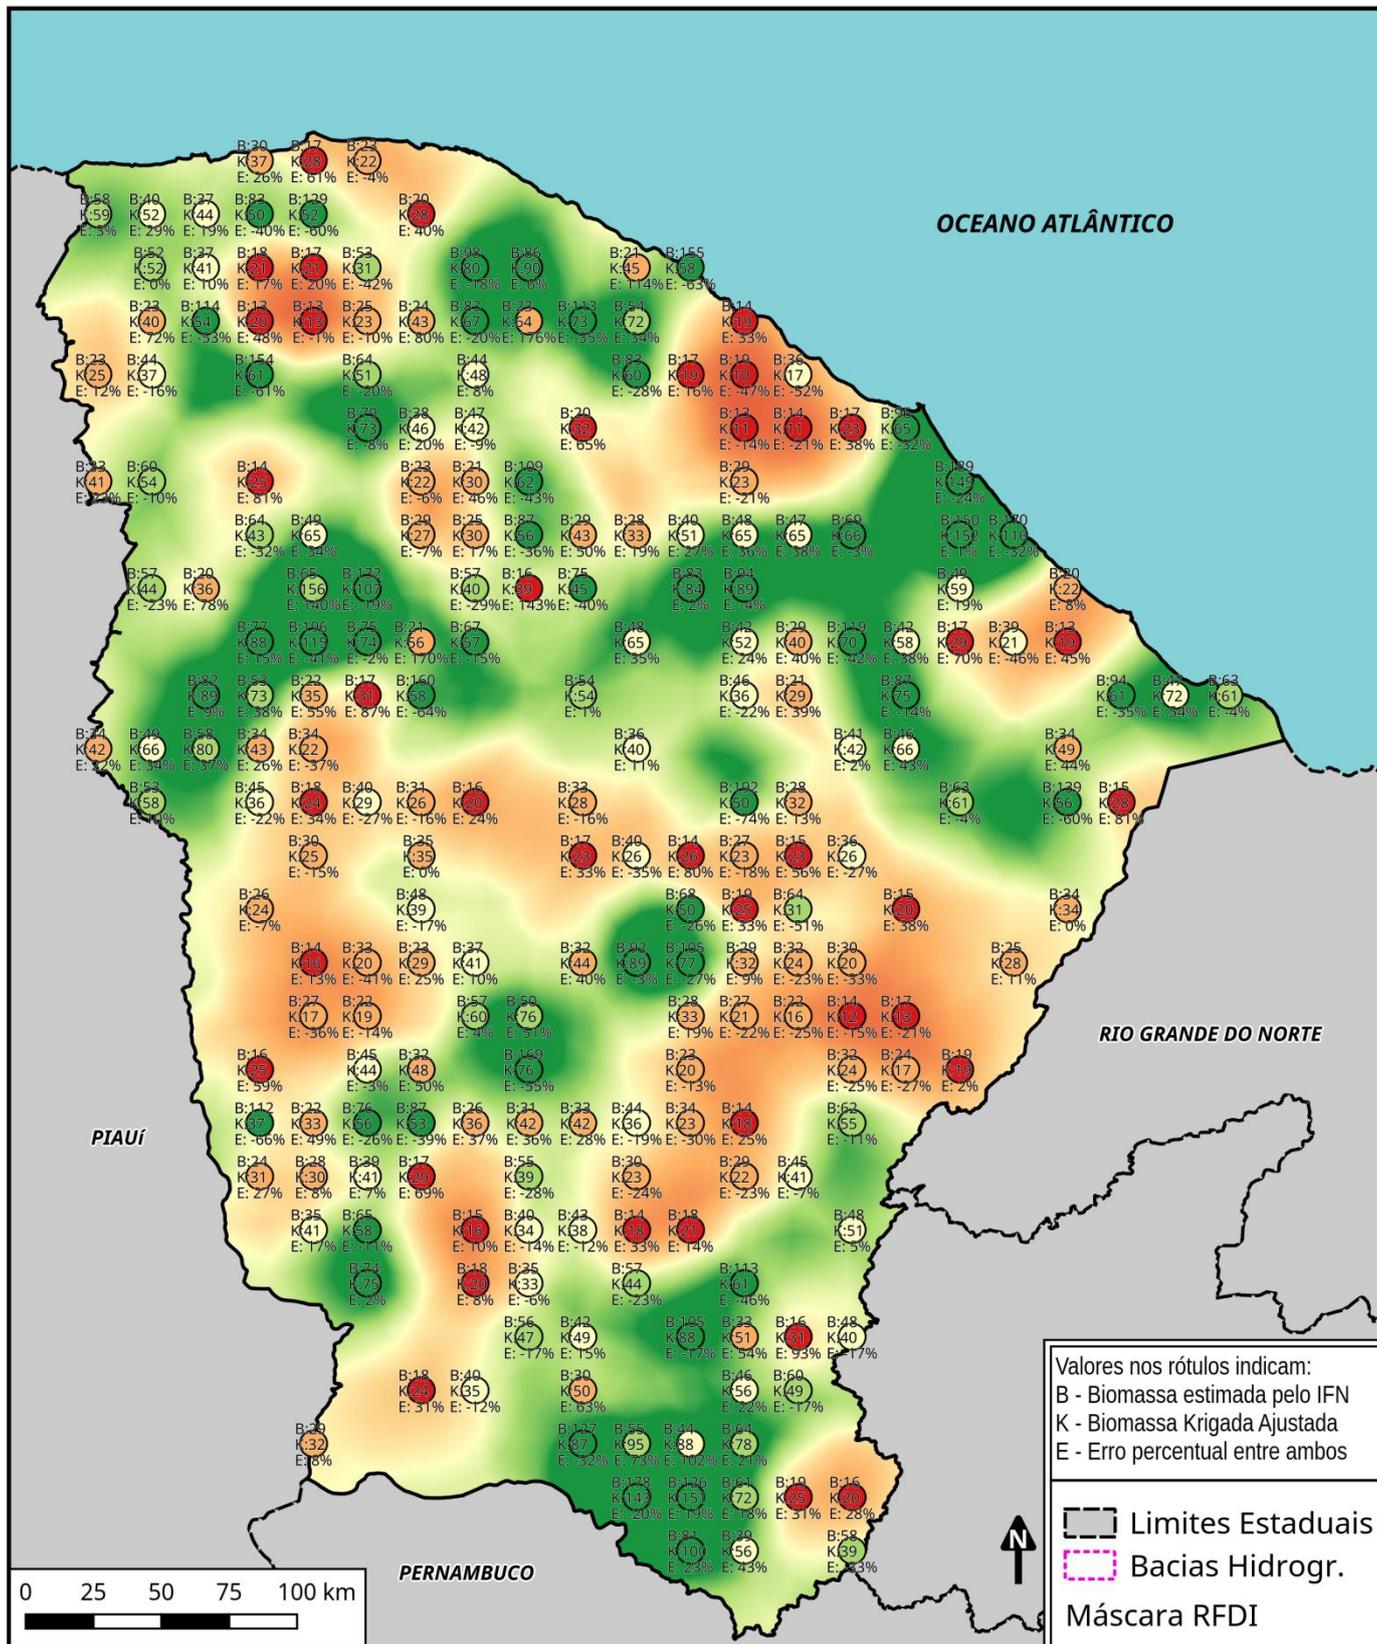




Mapa 2 - RFDI calculado do PALSAR, estimativa de áreas com pouca estrutura vegetal

Índice de degradação florestal (RFDI) calculado com o PALSAR, utilizado para retirar áreas degradadas da estimativa de biomassa, estas áreas incluem água e campo. Devido à natureza da resposta de RADAR, foram considerados sem vegetação os pixels com maiores valores de RFDI e os com valores muito baixos (maior que 135 e menor do que 110 no raster normalizado).

- ▭ Limites Estaduais
- RFDI - Degradação
- 110 (corte inferior)
- 127 (menos degrad.)
- 130
- 134 (mais degradado)
- 135 (corte superior)



Mapa 3 - Krigagem Ordinária da Biomassa do IFN no Ceará

Estimativa de biomassa florestal em indivíduos com 10 ou mais centímetros de DAP com krigagem à partir dos conglomerados com biomassa entre 5 e 80 toneladas por hectare de acordo com o IFN. Krigagem ordinária com modelo linear e posterior ajuste exponencial ($0.2686 \cdot \text{EXP}(0.037987 \cdot \text{Krig})$). Erro médio mínimo de 4,57ton/ha em buffer de 5Km, erro quadrático de 77,57 ton/ha. Foram utilizados 226 de 347 conglomerados.

Resultado Krigagem Linear

Dados iniciais da interpolação, resultantes da krigagem de 223 pontos do IFN.
A equação exponencial ajustada destes dados foi utilizada para ajustar a interpolação.

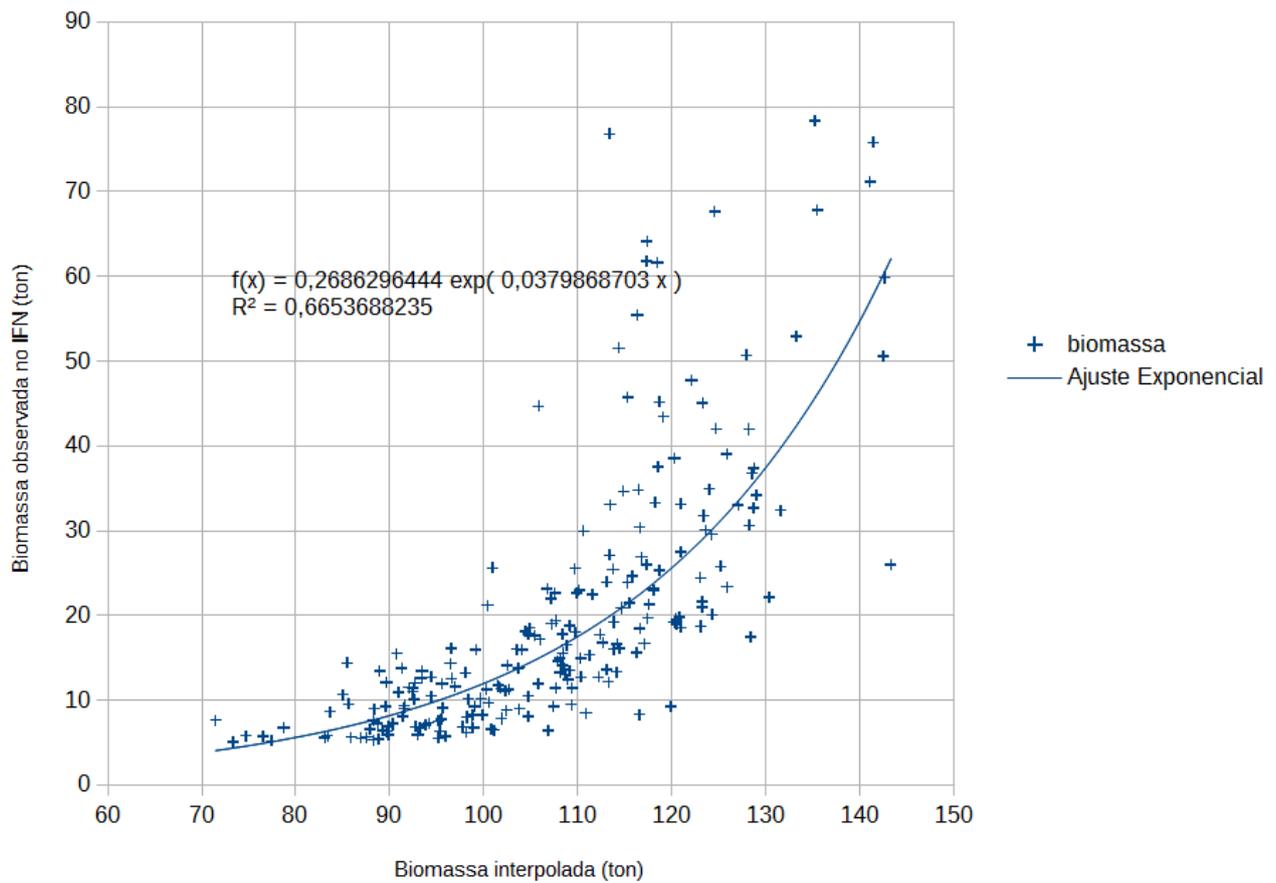


Figura 48 – Resultado da krigagem dos 223 pontos selecionados, em relação à biomassa observada nos conglomerados. Estes dados foram posteriormente ajustados com a equação indicada no gráfico, de modo a redistribuir os pixels da interpolação.

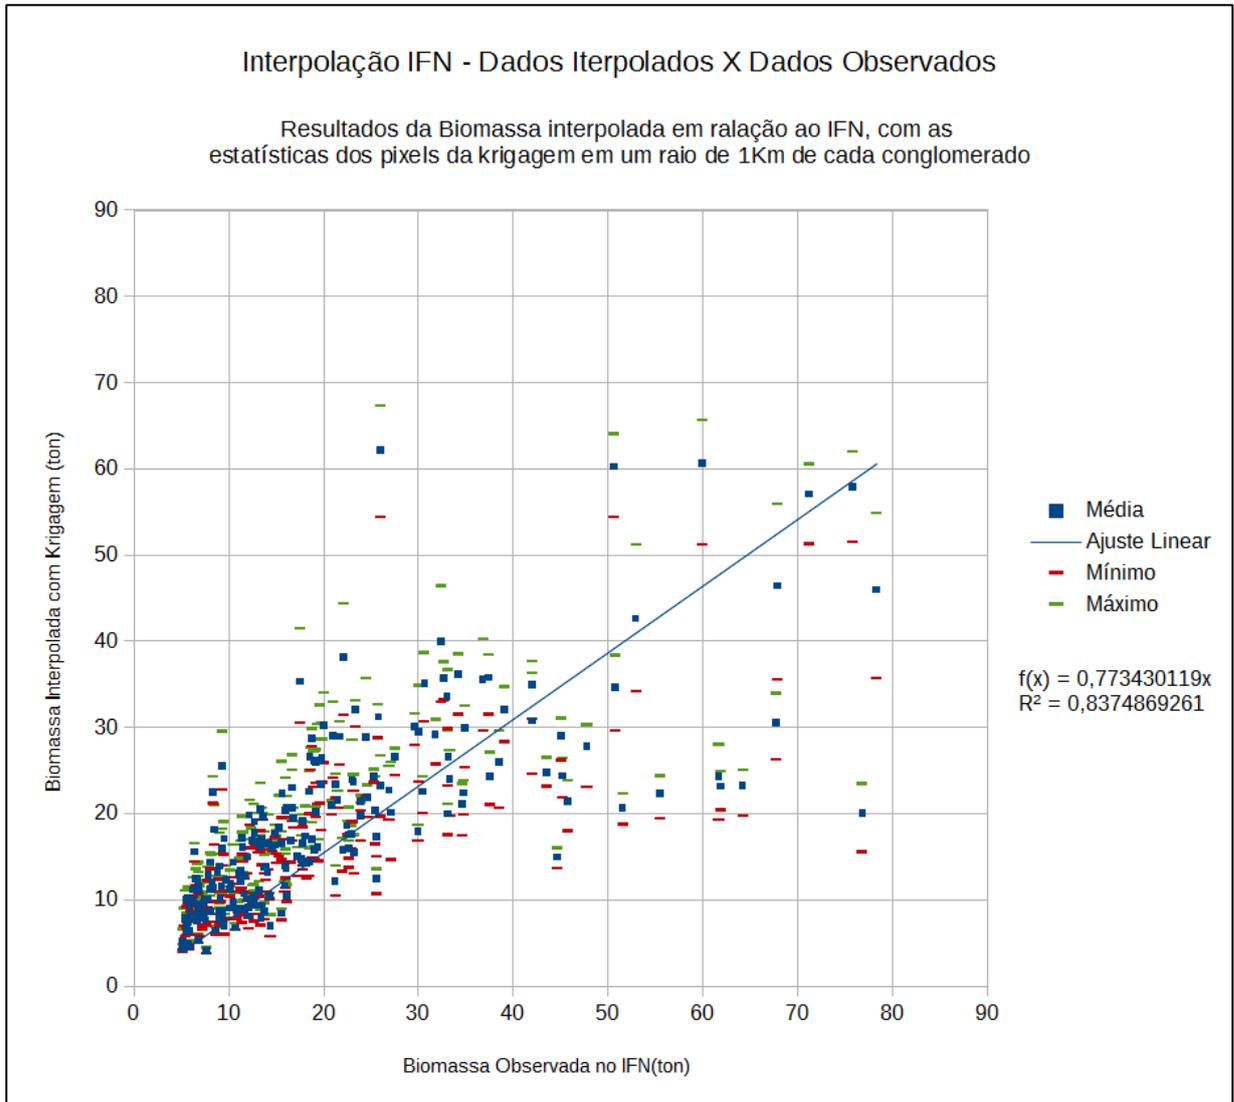


Figura 49 – Resultado da interpolação dos 223 pontos selecionados para a krigagem, em relação à biomassa observada nos conglomerados. Os valores no gráfico referiam-se à média, mínimo e máximo obtidos pela interpolação para cada conglomerado, de todos os pixels inseridos em um buffer de 1Km em torno do ponto de coleta de campo.

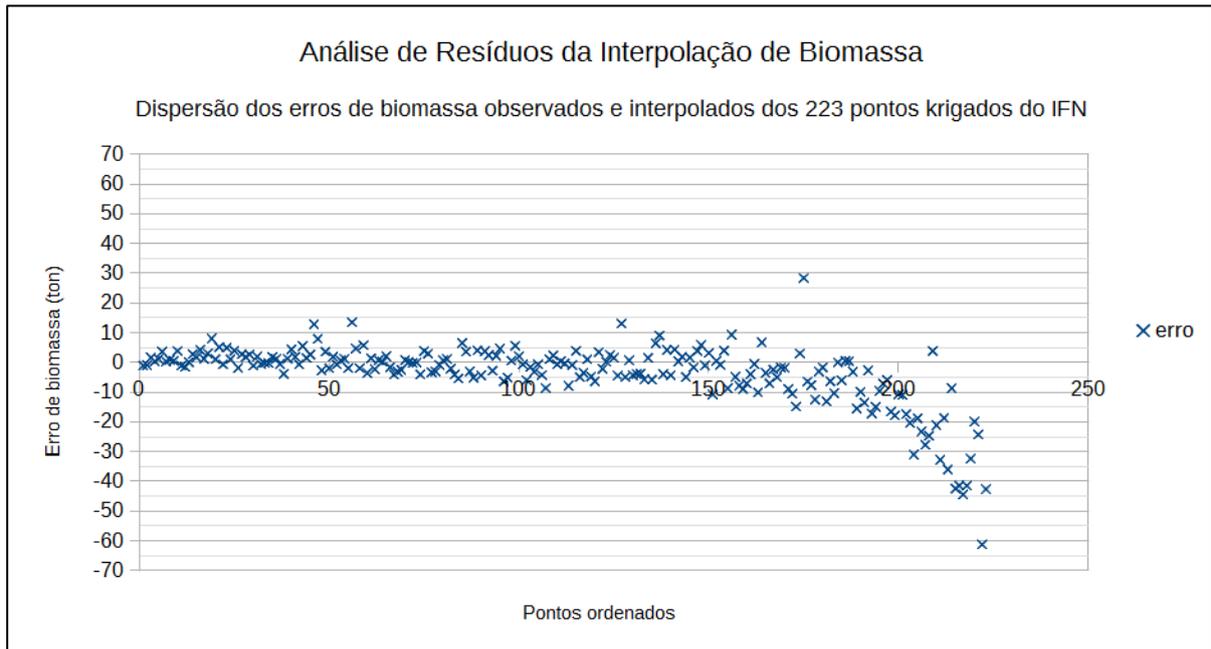


Figura 50 – Erros encontrados na interpolação final da biomassa do IFN. O erro médio encontrado foi de -3,81 toneladas, sendo 184 pontos (82% dos 223 utilizados) com erro menor ou igual a 10 toneladas e destes, 147 (66%) com erro menor ou igual a 5 toneladas.

5.4. Estimativa de Estoque Florestal com o RFDI

O RFDI (índice de degradação florestal) foi também utilizado em estimativas espaciais de estoque florestal potencial. Como o resultado de krigagem do IFN foi um mapa de densidade em formato raster espacializado, a abordagem utilizada foi gerar um raster único para toda a região do estado do Ceará para sobrepor e cruzar informações de estimativa de existência de vegetação por meio do PALSAR com a estimativa de estoque florestal potencial a partir do IFN. As áreas com vegetação homogênea de acordo com o PALSAR puderam ter seu estoque potencial estimado com maior precisão a partir da krigagem do que áreas em que foi observada maior variação de estrutura vegetal.

O RFDI das cenas de 2009/2010 do PALSAR que sobrepuseram o Ceará foi aglomerado em um arquivo virtual (**Mapa 2**). A imagem foi gerada com cores que representaram maior e menor densidade de vegetação aferida com o índice, indicativos de existência de estoque florestal. Em seguida foram separados apenas os valores mais baixos de estoque potencial com os quais foi feita uma máscara a ser aplicada como filtro de áreas sem biomassa provável. Este dado de sensoriamento foi associado à informação interpolada do IFN, de modo a estimar apenas a biomassa dos locais em que há probabilidade de o RFDI indicar existência de floresta, mesmo que esparsa.

O uso de ambos os dados em conjunto levou a uma informação robusta tanto para a estimativa de quantidade de estoque florestal com base nos dados de campo do IFN, quanto no detalhamento espacial das áreas com menos estrutura florestal feito pelo índice do PALSAR. Os dois resultados formaram uma ferramenta a ser utilizada no Estado, principalmente pelas dificuldades que a Caatinga ofereceu no levantamento de dados dendrométricos por sensoriamento remoto.

5.5. Resultado da Krigagem e o mapeamento de vegetação (PROBIO)

Para uma comparação dos resultados da krigagem com outras informações de vegetação existente do Ceará, foram utilizados dados de mapeamento de vegetação do PROBIO (Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira) do MMA em conjunto com o IBGE, principalmente os dados vetoriais de tipologias vegetais gerados pelo projeto. De acordo com o material de referência do projeto, a vegetação pode ser definida como um dos componentes mais importantes da biota, uma vez que seu estado de conservação e de continuidade que estabelecem a existência ou não de habitats adequados para as espécies, sendo a manutenção de serviços ambientais ou mesmo o provimento de bens essenciais à existência de populações humanas e é essencial que haja um bom conhecimento acerca do atual estado da cobertura vegetal brasileira (MMA, 2004).

Nesta abordagem, por determinação do MMA, tem sido ressaltado que áreas com predomínio de vegetação nativa, ainda que com algum grau de uso antrópico, deveriam ser contabilizadas e mapeadas no rol das tipologias de vegetação nativa. Outra premissa determinada pelo MMA foi de que a vegetação secundária, em estágio avançado de desenvolvimento, deveria ser contabilizada e mapeada como vegetação nativa (MMA, 2004). Esta característica se assemelhou ao que foi feito para a classificação dos conglomerados do IFN, em que áreas de vegetação secundária foram consideradas florestas.

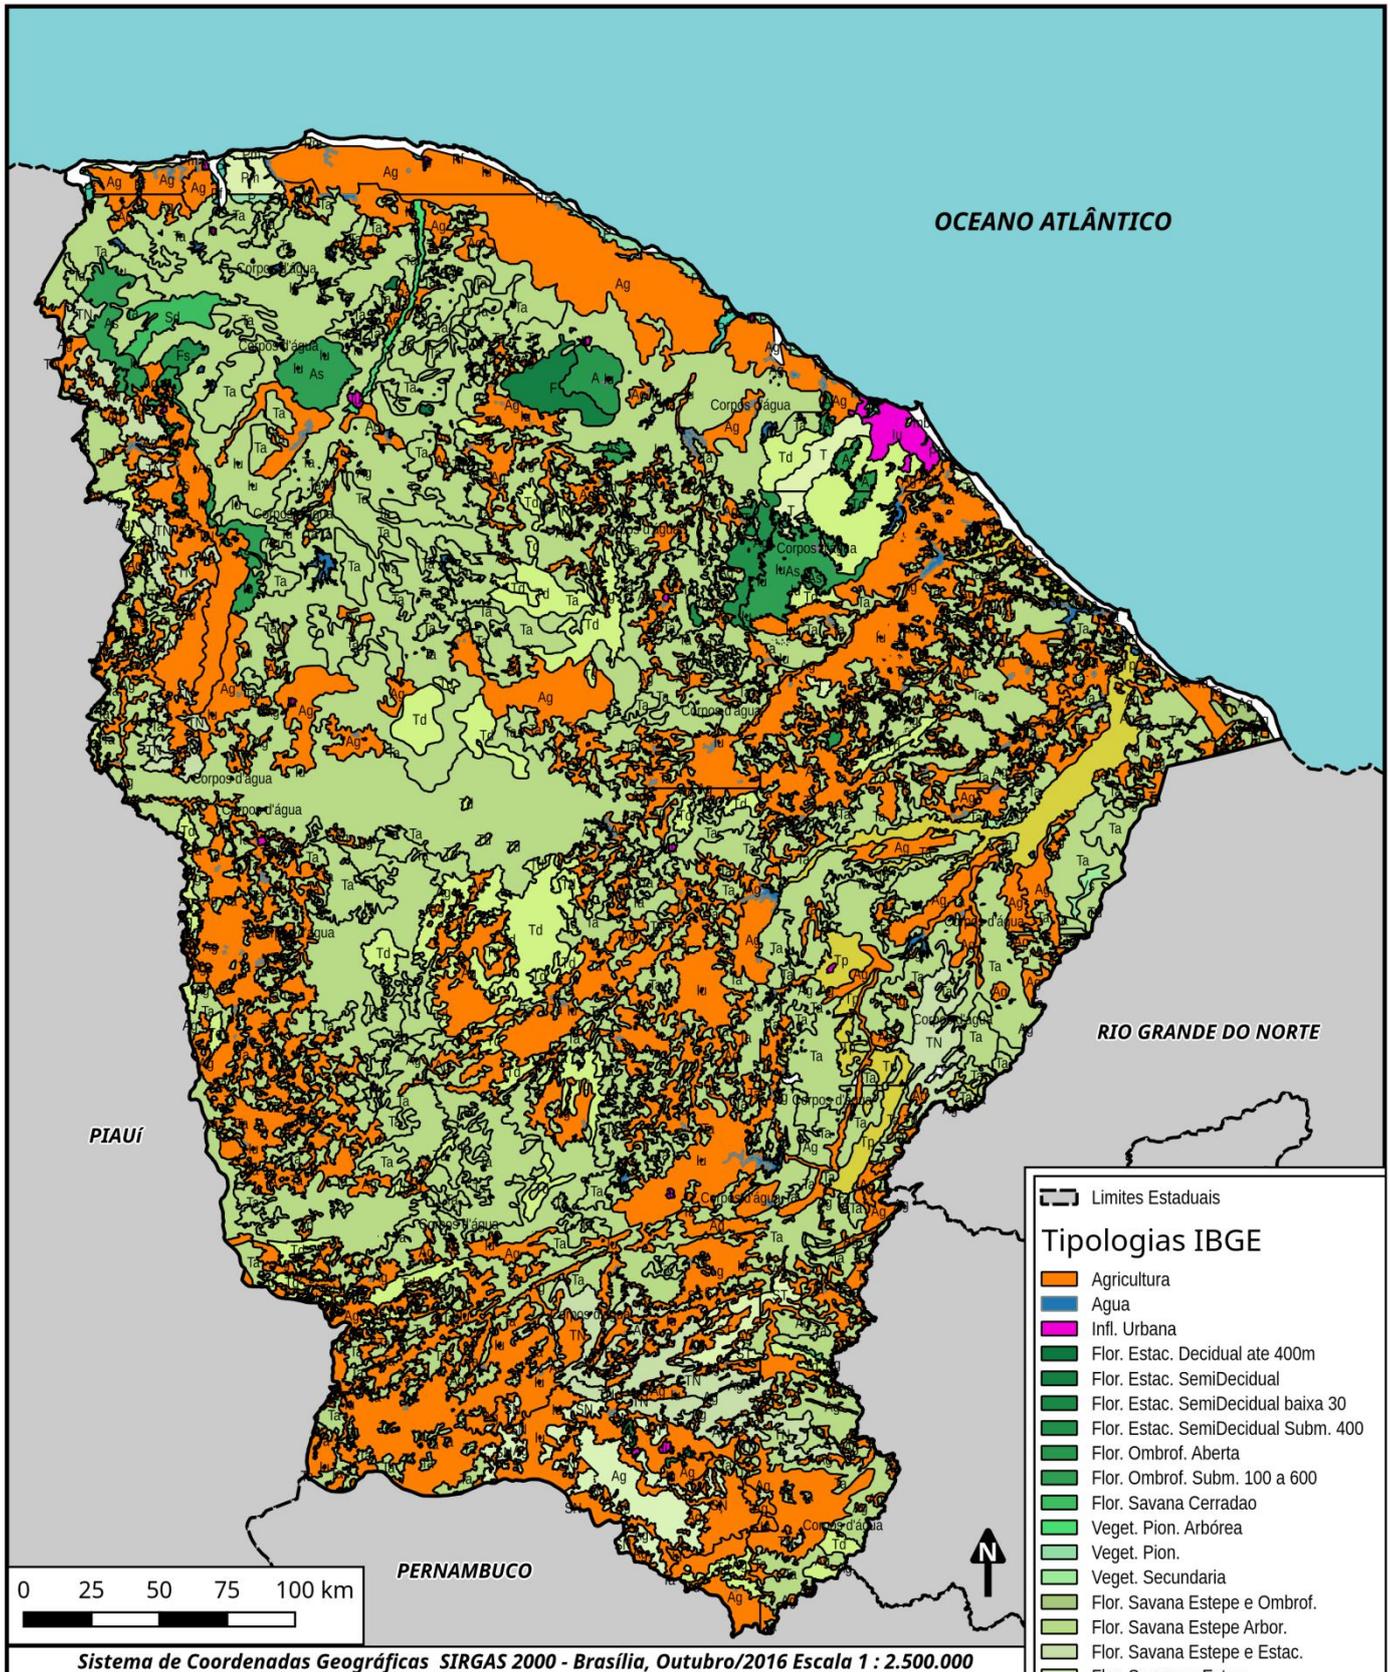
Para as estimativas de biomassa em regiões de mesma tipologia, foi aplicada uma máscara de eliminação de pixels em que o PALSAR indica haver pouca ou nenhuma estrutura florestal. Esta máscara filtrou 43.335.805 dos 61.498.225 pixels analisados dentro dos limites estaduais, o que equivale à remoção de 29,53% dos pontos. Estes pontos com valor zero de biomassa foram incluídos junto aos pixels krigados no *Mapa 4*.

Como o mapeamento PROBIO de 2004 com dados de 2002 tem sido o mais atual e completo disponível para vegetação oficial do Brasil, foi utilizado como referência de cobertura vegetal de solo e em análises de distribuição espacial de resultados deste estudo. A principal aplicação apresentada foi o cruzamento dos polígonos do PROBIO com as estimativas de biomassa feitas com a *krigagem* do IFN.

Ao comparar o resultado desta interpolação com o mapa de tipologias de vegetação do PROBIO e com os dados degradados dos índices de vegetação já processados, encontrou-se uma coerência do que foi esperado na variação dos dados de sensoriamento já analisado e com outras informações geográficas do Ceará. Os polígonos de tipologia de vegetação mais densa estavam posicionados próximos ou sobrepostos às áreas com índices de vegetação, que indicaram mais atividade fotossintética e estrutura florestal mais densa, ambos estando na sua maioria sobre áreas do resultado da krigagem, que indicaram uma biomassa maior estimada a partir do inventário florestal.

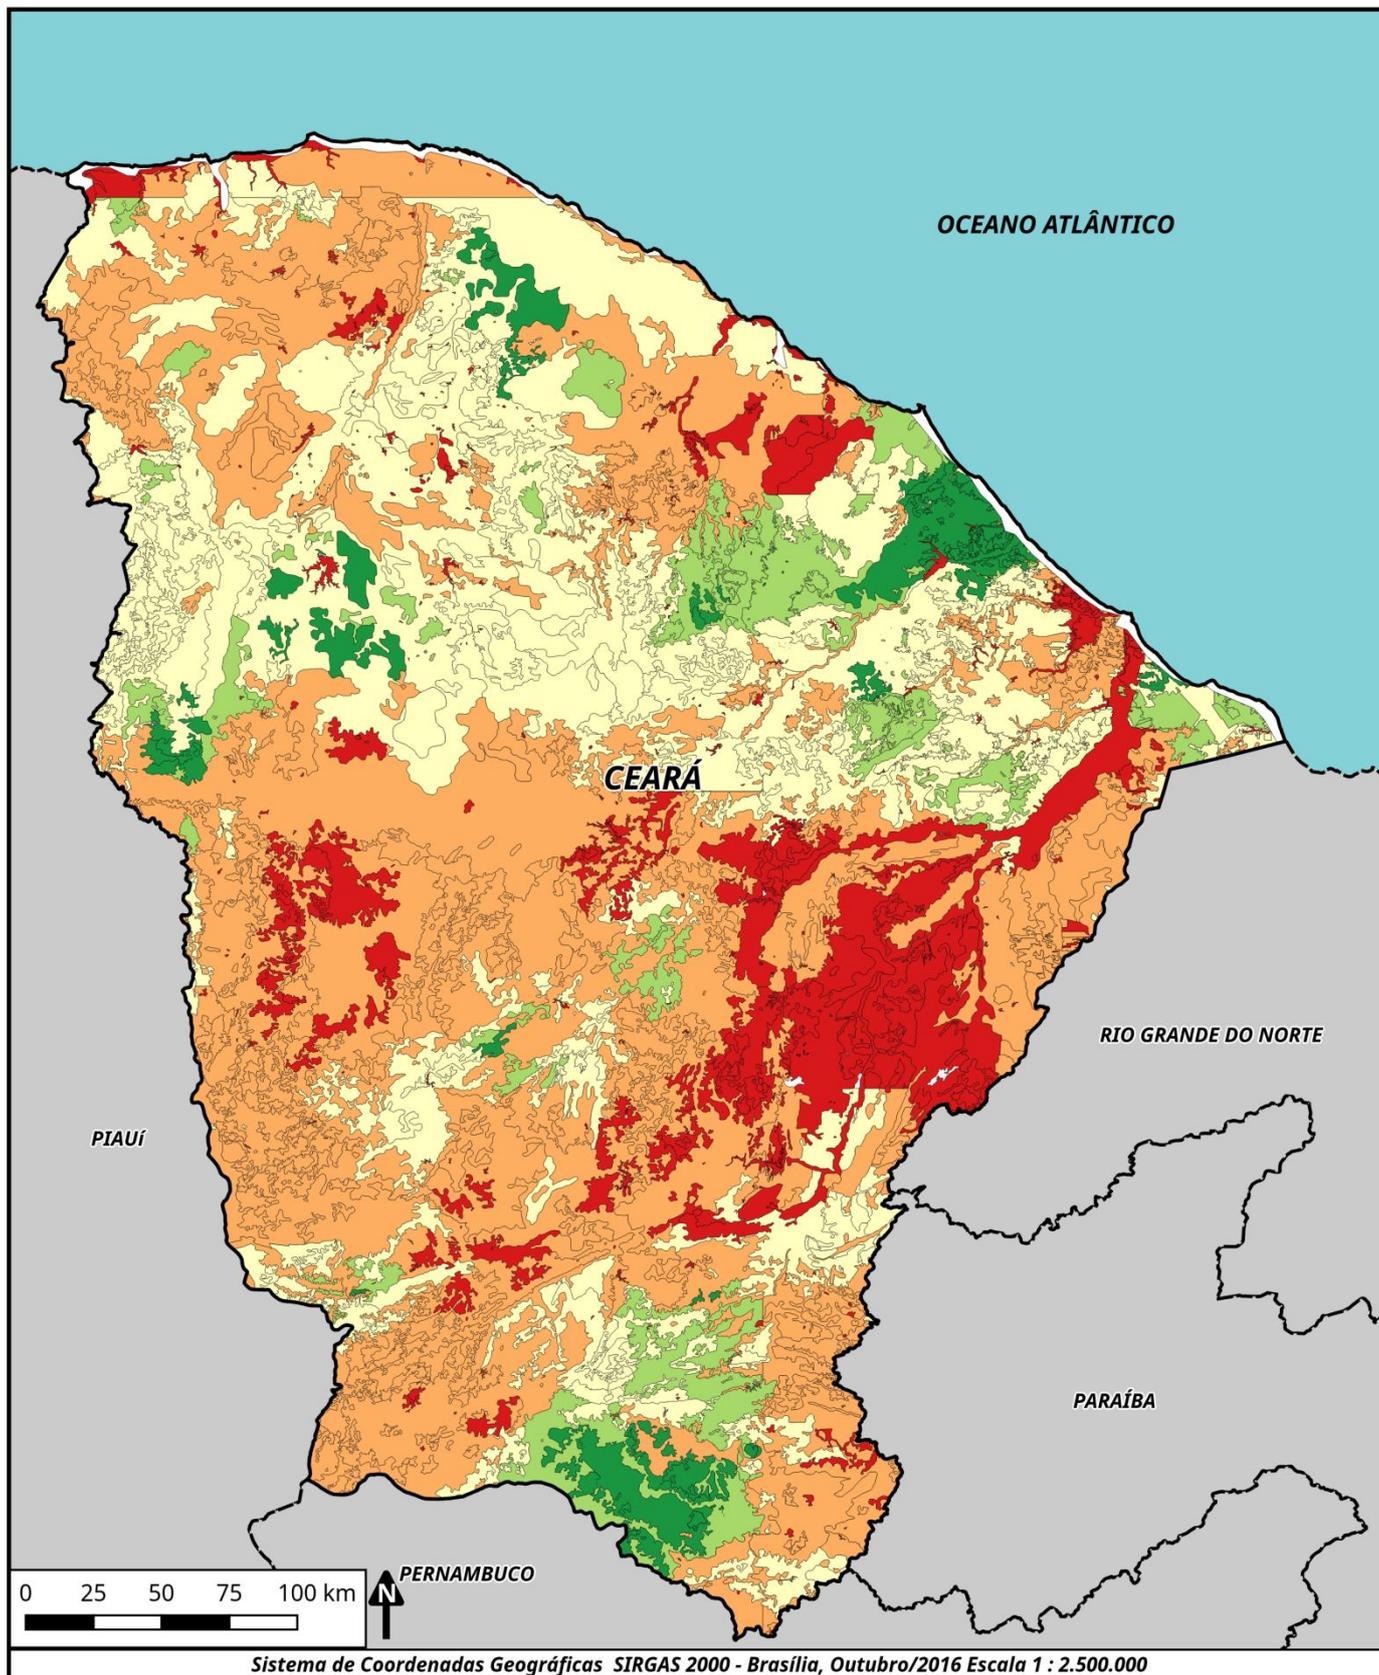
O quinto mapa (**Mapa 5**) apresenta as tipologias de vegetação do IBGE no mapeamento PROBIO do MMA, feito em 2002. Este foi um mapeamento completo de vegetação de todo o estado, com feições geométricas que continham vegetação de características semelhantes 14 anos antes. Neste período houve mudanças de uso e cobertura do solo que foram lembradas ao se comparar os dados do IFN, podendo existir polígonos que tiveram parte de sua área desmatada ou vegetação recuperada e conseqüentemente os polígonos se produzidos recentemente mostrariam formas diferentes. Ainda assim foi o melhor ponto de partida encontrado para ensaiar o uso do resultado interpolado de biomassa do IFN para mapear a variação de estoque florestal do Ceará.

O ensaio consistiu em utilizar estas feições do mapeamento de 2002 como fronteiras divisórias do território e estimar o estoque florestal total de cada figura geométrica com o raster da krigagem do IFN. Para extrair as informações em um mapeamento adequado à distribuição de vegetação existente no estado, foi calculada a média dos pixels resultantes da krigagem em cada polígono de tipologia de vegetação e armazenado o resultado na tabela de atributos que foi usada para gerar o resumo de dados por tipologia. O sexto mapa (**Mapa 6**) apresenta os mesmos polígonos do PROBIO, mas com valores médios dos pixels da krigagem dentro de cada polígono, descontada a máscara de locais com maior degradação florestal indicada pelo PALSAR.



Mapa 5 - Tipologias do PROBIO 2002 do Ceará

Polígonos do PROBIO 2002 (MMA) classificados de acordo com as tipologias de vegetação. As feições alaranjadas representam áreas de agricultura enquanto os tons verdes mais claros são de vegetação menos densa, tons mais escuros indicam vegetação adensada dentre as encontradas no Ceará.



Mapa 6 - Biomassa dos Polígonos do PROBIO do Ceará

Polígonos do PROBIO 2002 (MMA) classificados com a biomassa média do resultado da krigagem dos dados do IFN, filtrada pelas áreas com menos floresta de acordo com o RFDI do PALSAR.

Biomassa Média

▬ Limites Estaduais (ton/ha)

- 0-20
- 20-35
- 35-50
- 50-65
- 65 ou mais

A classificação do PROBIO (2002) foi feita 12 anos antes da coleta dos dados do IFN (2014) e resultado da krigagem nos polígonos não foi condizente com a relação esperada de biomassa com as tipologias associadas. O sumário dos dados encontrados por tipologia foi apresentado (*Tabela 12*) e puderam-se observar categorias com maiores concentrações de biomassa por área, valores acima da média de 33,8 ton./ha da Caatinga mais comum (“Savana Estepe Arborizada”), enquanto tipologias de menor densidade de vegetação estiveram abaixo desta média. Por exemplo, as áreas com vegetação menos densa de “Savana Estepe Parque” e “Savana Estepe” (não arborizada) apresentaram biomassa média de 27,5 e 25,9 ton./ha enquanto áreas de “Floresta Estacionária SemiDecidual baixa 30” ou “Floresta Savana e Estacionária” indicaram ter vegetação densa, com mais de 70 ton./ha.

Foi verificado um total de biomassa para o Ceará de 340 milhões de toneladas, já descontada a máscara de floresta do PALSAR. A biomassa do Estado foi estimada pela equipe do IFN, utilizando métodos estatísticos sobre os dados tabulares do inventário com um resultado de aproximadamente 410 milhões de toneladas, diferença de 18% em relação ao estimado neste estudo. A proximidade dos resultados se deveu provavelmente à dependência do resultado da krigagem com a própria estimativa do inventário.

A proximidade com o resultado estimado pelo IFN foi suficiente para ser utilizada a interpolação espacializada para as análises de distribuição de biomassa, já que o resultado do IFN pretendeu ser apenas geral para o estado e detalhado por conglomerado. Assim, foi possível um detalhamento utilizando o resultado espacial interpolado, inicialmente com as tipologias mapeadas pelo PROBIO (*Tabela 12*) e posteriormente em áreas privadas com auxílio do banco de dados do CAR. Estas informações talvez possam ser futuramente cruzadas com o déficit de reserva legal declarada do CAR e às vegetações ocorrentes no IFN para planejamento de recuperação ambiental, além da estimativa de estoque florestal ser útil nas avaliações de PRA e CRA do código florestal de 2012.

Tabela 12 – Área, biomassa média e biomassa total estimada por tipologia do PROBIO para o Ceará com a krigagem do IFN.

Tipologia	Área (ha)	Biom. (ton/ha)	Biomassa (ton)
Flor. Estac. Decidual ate 400m	3.317	34,4	114.208
Flor. Estac. SemiDecidual	53.756	30,9	1.662.037
Flor. Estac. SemiDecidual baixa 30	2.856	71,6	204.589
Flor. Estac. SemiDecidual Subm. 400	56.825	55,7	3.166.485
Flor. Ombrof. Aberta	63.354	26,9	1.702.957
Flor. Ombrof. Subm. 100 a 600	243.262	34,7	8.441.802
Flor. Savana Cerradão	38.013	35,1	1.335.053
Flor. Savana e Estacionária	157.790	73,1	11.540.881
Flor. Savana e Estepe	46.096	47,2	2.177.378
Flor. Savana e Pion.	573	27,3	15.636
Flor. Savana Estepe	49.532	25,9	1.284.628
Flor. Savana Estepe Arbor.	7.464.161	33,8	251.982.729
Flor. Savana Estepe e Estac.	446.726	39,6	17.712.036
Flor. Savana Estepe e Ombrof.	10.564	57,8	610.856
Flor. Savana Estepe Flor.	803.289	34,8	27.916.458
Flor. Savana Estepe Parque	256.639	27,5	7.059.498
Savana Parque	11.128	46,1	512.832
Veget. Pion.	28.902	20,8	600.617
Veget. Pion. Arbórea	21.423	26,4	564.844
Veget. Pion. Fluviom.	15.071	15,8	238.867
Veget. Pion. Fluviom. Herb.	63	11,4	725
Veget. Pion. Mangeuzal	2.162	38,1	82.363
Veget. Pion. Mar. Restinga	34.470	9,5	326.735
Veget. Pion. Mar. Restinga Arbus. duna	3.018	63,8	192.575
Veget. Pion. Mar. Restinga Herb. Praia	1.175	19,1	22.443
Veget. Secundaria	11.929	46,1	550.448
Total Geral	9.826.091	34,6	340.019.680

5.5.1. Resultado da Krigagem e propriedades rurais (CAR)

Em continuidade à análise, foi realizado outro ensaio de aplicação de resultados no formato raster atingido por este estudo, tendo por objetivo a distribuição da krigagem com dados geopolíticos e propriedades privadas. Foi primeiramente feito o cruzamento com as microrregiões administrativas do Ceará, para obtenção do perfil de biomassa média das áreas delimitadas por características econômicas e sociais similares, de acordo com o levantamento censitário de 2010 do IBGE. Os valores médios dos pixels que formaram estas regiões foram apresentados em formato gráfico (*Figura 51*) que equivale às regiões sobrepostas ao raster da krigagem (*Mapa 4*).

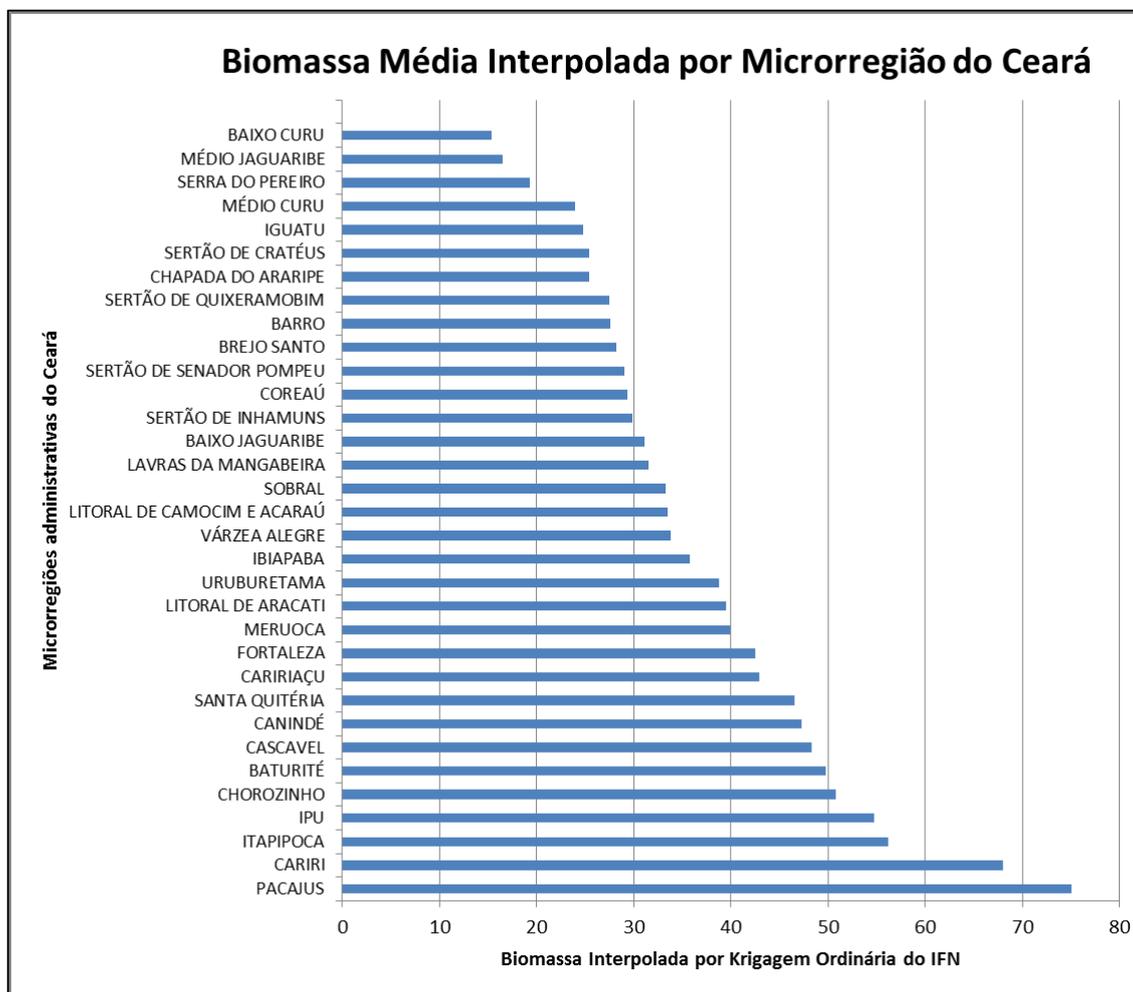


Figura 51 - Valores médios em ordem crescente de biomassa em Microrregiões administrativas censitárias do Ceará, estimados utilizando a krigagem de dados do IFN. A distribuição de biomassa pôde ser relacionada com as divisões administrativas do Ceará. As menores médias de estoque florestal por hectare (biomassa menor que 24ton/ha) foram encontradas nas regiões Serra do Pereiro, Chapada do Araripe, Iguatu, Baixo e Médio Jaguaribe, Sertões de Quixeramobim e Cratêus. As regiões com maior média de estoque florestal (biomassa maiores que 40ton/ha) foram Itapipoca, Sobral, Ipu, Caririação, Barro, Brejo Santo e Cariri.

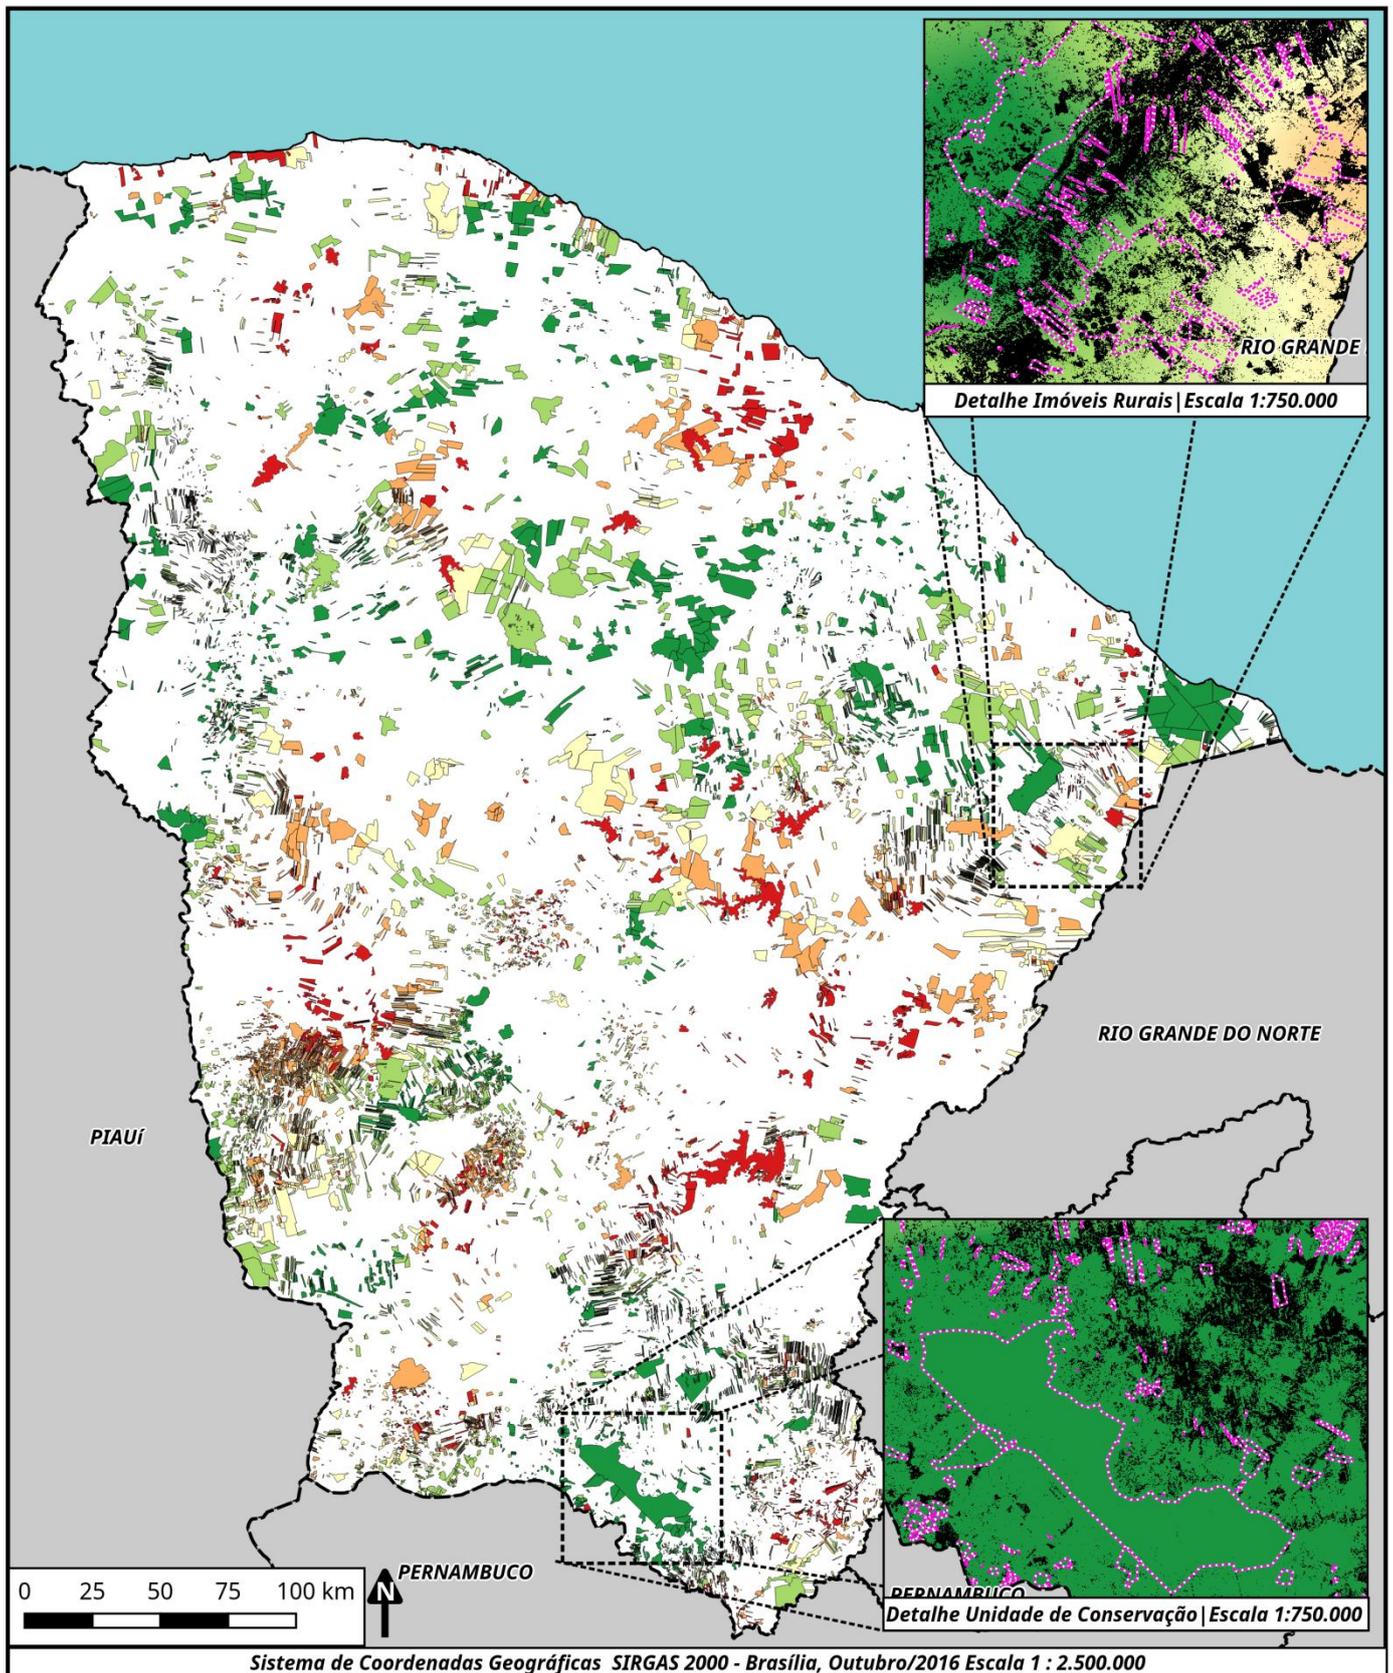
A biomassa média destas regiões pode ser associada ao clima e a disponibilidade de água das mesmas, particularmente pela precipitação anual registrada em cada uma e a existência de rios de maior vazão no território. Os municípios da Serra do Pereiro, por exemplo, demonstraram a menor biomassa média estimada (15ton/ha), com precipitação que não ultrapassou 915mm anuais na climatologia de 1960 a 1990 (INMET/2016), enquanto os municípios do Cariri apresentaram biomassa média acima de 45ton/ha e precipitação em torno de 1.100mm anuais para o mesmo período. Em seguida foi realizado o cruzamento do dado interpolado com krigagem e as áreas declaradas de imóveis rurais do CAR apresentados em mapa (*Mapa 7*).

Foram analisados 21.784 imóveis no total, com 72 dos 376 pontos de conglomerados do IFN sobrepostos a base de maio de 2016 do CAR nacional no estado do Ceará, ou seja, 19,1% dos conglomerados. A área total destes imóveis foi de 2,8 milhões de hectares, que representaram 19,0% dos 14,88 milhões de hectares do estado. O resumo dos dados interpolados nas propriedades foi detalhado por tipo e área de imóvel (*Tabela 13*).

Tabela 13 - Resumo de dados calculados para os imóveis rurais cadastrados no Ceará. Os dados foram separados por tipo (assentamento, imóvel rural e povos/comunidades tradicionais) e por classes de área em hectares. O tipo, classe, quantidade e área dos imóveis foi declarado no SICAR até Maio de 2016, a coluna "Pixel" foi a quantidade de pixels total dentro dos imóveis e a coluna "Pixel 0" foram os pixels eliminados pelo RFDI do PALSAR. A coluna "Não Flor." resultou da relação entre pixels eliminados e o total de cada imóvel, e o restante dos pixels com os valores da interpolação foram usados para estimar a Biomassa de cada propriedade.

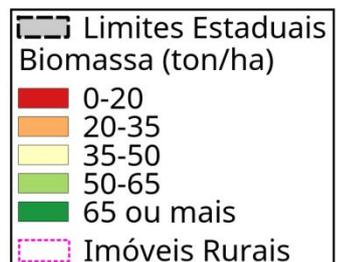
	Dados declarados			RFDI do PALSAR			Biomassa	
	Tipo/Classe	Imóveis	Área (ha)	Pixel	Pixel 0	Não Flor.	Toneladas	Ton/ha
Assentamentos	1 - até 50	3	98	420	55	13,1%	5.863	60,0
	2 - 50 a 100	1	53	226	32	14,2%	1.302	24,5
	3 -100 a 500	38	12.005	51.469	14.240	27,7%	455.655	38,0
	4 - 500 a 1000	119	92.179	395.033	85.858	21,7%	3.094.678	33,6
	5 - Maior 1000	346	1.098.151	4.703.111	1.134.712	24,1%	37.027.654	33,7
	Total Assent.	507	1.202.487	5.150.259	1.234.897	24,0%	40.585.153	33,8
Imóveis Rurais	1 - até 50	15.597	224.604	960.975	316.276	32,9%	6.610.242	29,4
	2 - 50 a 100	2.460	175.341	750.257	201.908	26,9%	5.453.123	31,1
	3 -100 a 500	2.761	557.724	2.383.925	573.946	24,1%	17.953.773	32,2
	4 - 500 a 1000	305	211.530	899.963	200.701	22,3%	7.440.481	35,2
	5 - Maior 1000	152	398.343	1.699.368	292.294	17,2%	14.456.585	36,3
	Total Im. Rur.	21.275	1.567.543	6.694.488	1.585.125	23,7%	51.914.203	33,1
PCT*	3 -100 a 500	1	335	1.436	210	14,6%	8.621	25,8
	5 - Maior 1000	1	38.890	166.745	326	0,2%	4.857.381	124,9
	Total PCT*	2	39.225	168.181	536	0,3%	4.866.003	124,1
Total geral	21.784	2.809.254	12.012.928	2.820.558	23,5%	97.365.358	34,7	

*PCT: Povos e Comunidades Tradicionais, tipo de registro distinto no SICAR.



Mapa 7 - Biomassa de Polígonos de Imóveis do CAR

Polígonos de imóveis rurais declarados no CAR, classificados com a biomassa média do resultado da krigagem dos dados do IFN, filtrada pelas áreas com menos floresta de acordo com o RFDI do PALSAR. Foram destacados exemplos de unidade de conservação (detalhe inferior) em que poucos pontos foram eliminados pelo RFDI e imóveis rurais (detalhe superior) em que há casos com mais pontos eliminados e variação da biomassa interpolada.



Pela estimativa com krigagem, dos 340 milhões de toneladas de biomassa acima do solo estimados para o Ceará, 28,6% estavam dentro de imóveis rurais cadastrados no CAR. A concentração de biomassa estimada em registros do SICAR pôde ser separada de acordo com o tipo de imóvel rural informado, distribuídas com 53,3% em 21.275 propriedades rurais (1,6 milhões de hectares ou 55,8% da área), 41,7% nos 507 assentamentos (1,2 milhões de hectares, 42,8% da área) e os 5,0% restantes em 2 áreas de povos e comunidades tradicionais (39 mil hectares, 1,4%). A desproporção na representação de cada tipo de imóvel em relação à biomassa e à área se deve a uma das áreas de comunidade tradicional estar em uma unidade de conservação, conforme destaque no *Mapa 7*.

Foram cruzados dados de biomassa nas tipologias do PROBIO com os imóveis analisados (**Figura 52**) em que foi possível identificar uma concentração de biomassa em propriedades maiores, pois nelas está a maior parte da área privada do Ceará. O módulo fiscal tem sido definido como uma unidade agrária medida em hectares, que varia de município para município, de acordo com as explorações feitas do solo e demais variáveis (LANDAU, 2012). No estado do Ceará esta unidade variou entre cinco e 90 hectares e os dados expressos utilizando esta medida mostraram um diferente ponto de vista sobre a distribuição de terra existente, uma vez que representaram um parâmetro legalmente importante para a regularização ambiental das propriedades rurais do país. Os dados classificados por módulo fiscal (**Figura 53**) estiveram ainda mais concentrados na classe de maior área, no caso mais de 100 módulos fiscais, com cerca de 92% da biomassa e da área do total levantado.

Foi observado que para os dados de Maio de 2016 os imóveis rurais menores tinham proporcionalmente mais áreas classificadas como não floresta (32,9% dos pixels) pelo RFDI do que os imóveis maiores (17,2% dos pixels). Ainda, a densidade de biomassa por área dos imóveis menores foi maior (29,4ton/ha) do que os maiores (36,3ton/ha) em todas as relações de classe avaliadas. Ambas as constatações podem estar relacionada, uma vez que mais áreas de não floresta em uma região levam a uma menor estimativa de biomassa no método desenvolvido.

Biomassa em Imóveis Rurais do Ceará por Tipologia de Vegetação e Classe Fundiária

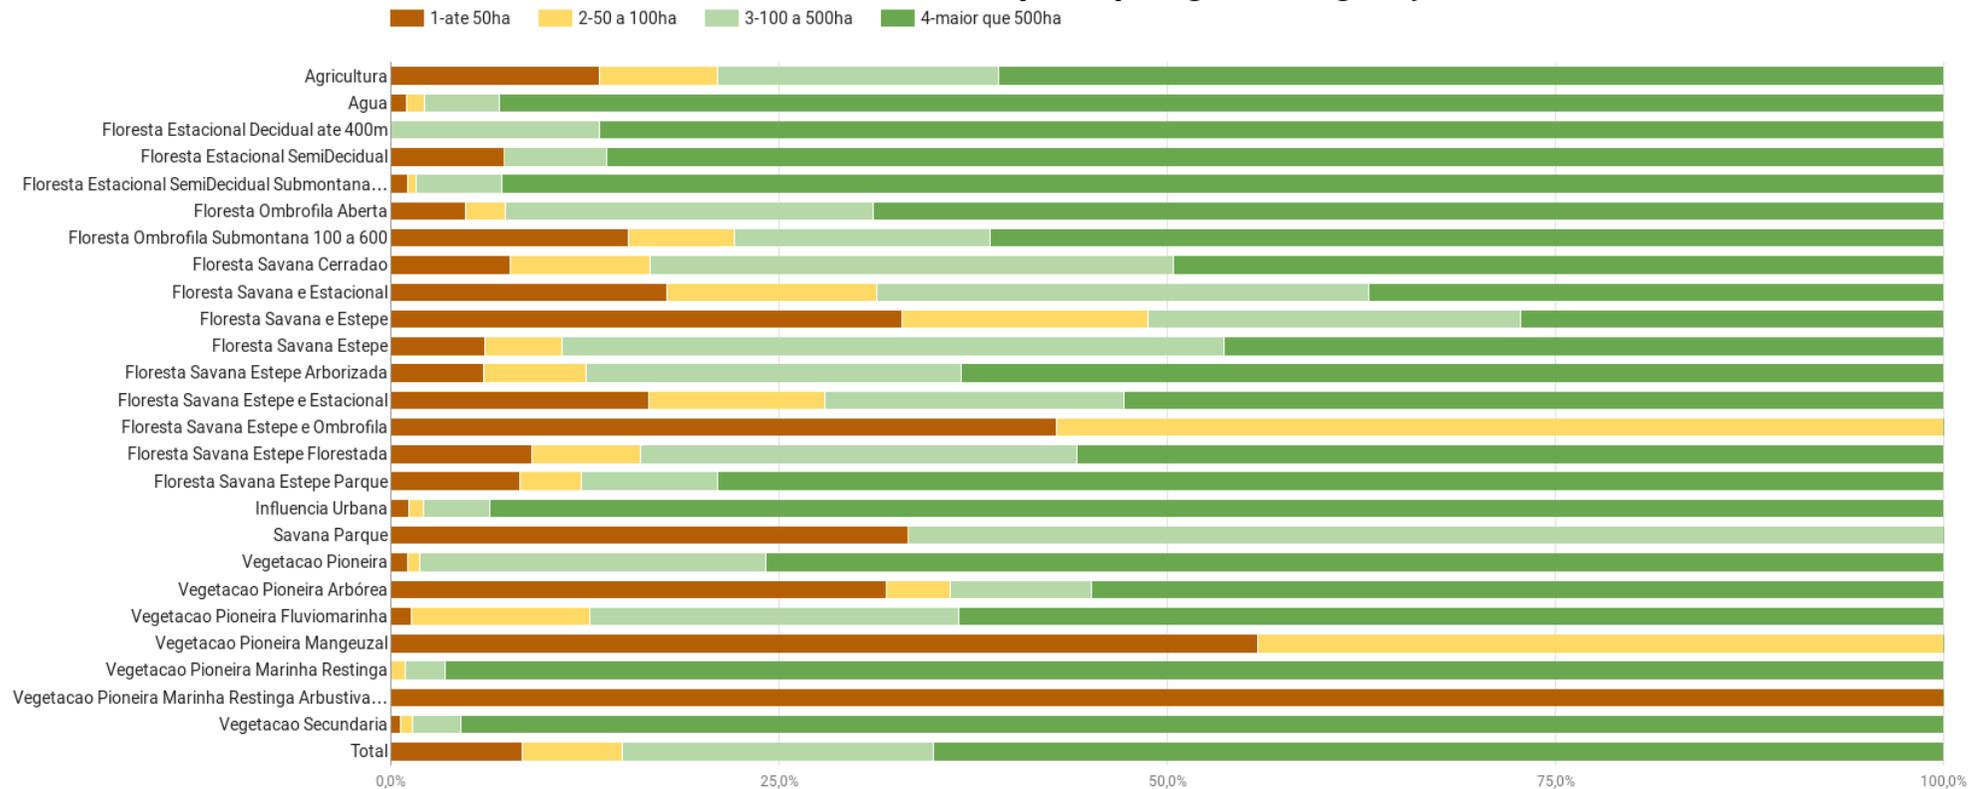


Figura 52 - Resumo de biomassa estimada por krigagem em imóveis rurais por classe fundiária em hectares. Os dados foram agrupados por tipologia do mapeamento PROBIO 2002. Do total considerado, 65,1% da biomassa foi encontrada em imóveis maiores do que 500ha, 20,1% em imóveis de 100 a 500ha, 6,4% em imóveis de 50 a 100ha e 8,4% em imóveis com menos de 50ha. Dentre as distribuições por tipologia, foi encontrada “Vegetação Pioneira Marinha Restinga Arbustiva duna” apenas em imóveis menores do que 50ha, “Vegetação Pioneira Manguezal” e “Floresta Savana Estepe e Ombrófila” apenas em imóveis menores do que 100ha.

Biomassa em Imóveis Rurais do Ceará por Tipologia de Vegetação e Módulos Fiscais

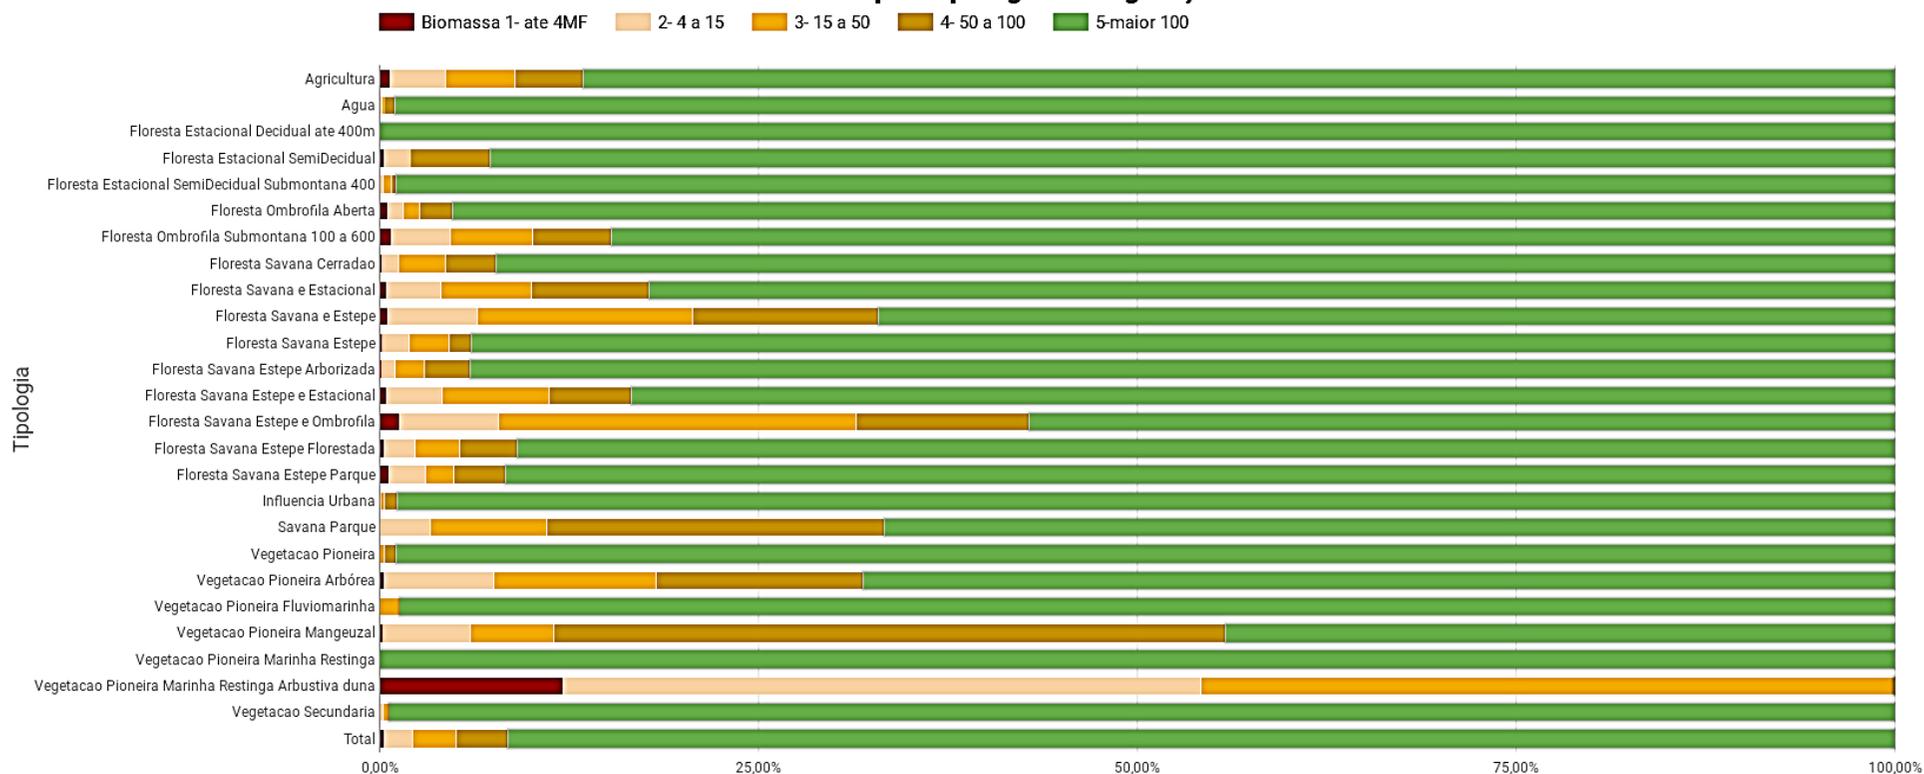


Figura 53 - Resumo de biomassa estimada por krigagem em imóveis rurais por classe fundiária em Módulos Fiscais (MF). Os módulos fiscais dos municípios do Ceará variaram de 5ha (Fortaleza) a 90ha (Aiuaba, Catarina, Saboeiro, entre outras). Do total de imóveis, 0,3% da biomassa foi encontrada na classe de até 4MF; 1,9% para 4MF a 15MF; 2,8% para 15MF a 50MF; 3,4% para 50MF a 100MF; 91,6% para maior do que 100MF. Propriedades com mais de 15MF foram consideradas grandes para fins de regularização ambiental.

5.5.2. Validação de krigagem em estimativa na escala do IFN

Os resultados da krigagem não puderam ser verificados com os próprios dados do IFN, pois todos os pontos foram utilizados. Para fazer uma avaliação de qualidade da técnica utilizada para estimar as variáveis, foram feitas duas novas krigagens com apenas parte dos dados, visando validar o método, apesar de o resultado ter sido um modelo diferente. Os resultados foram apresentados nas *Figuras 51 e 52*.

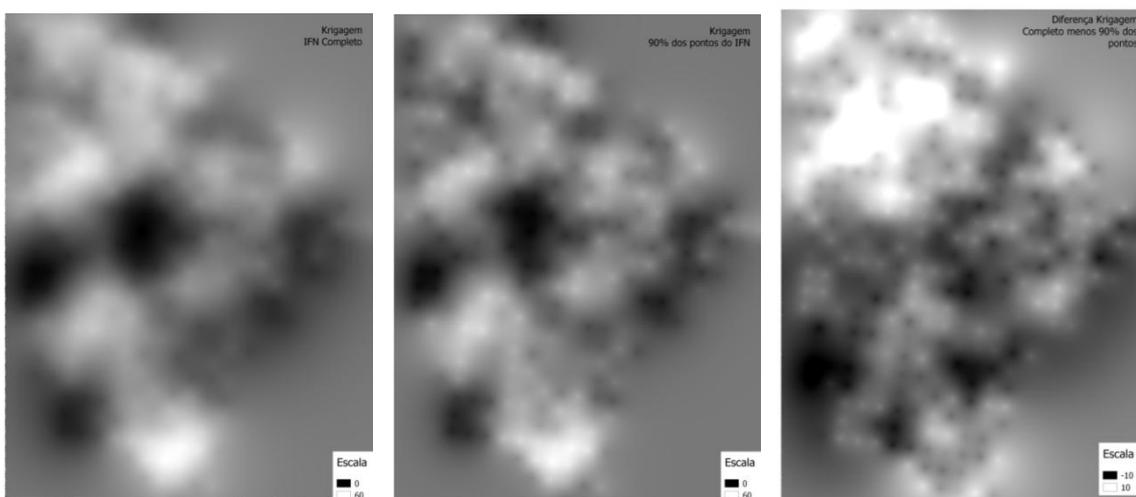


Figura 54 - Imagem dos pontos do IFN. À esquerda o resultado da krigagem feita com os 376 pontos do IFN, no centro o resultado do mesmo método aplicado em 90% dos pontos, com 37 removidos aleatoriamente. Na imagem à direita foi apresentada a diferença pixel a pixel das duas imagens, 84,24% dos pixels com diferença menor ou igual a 8 ton./ha de estimativa.

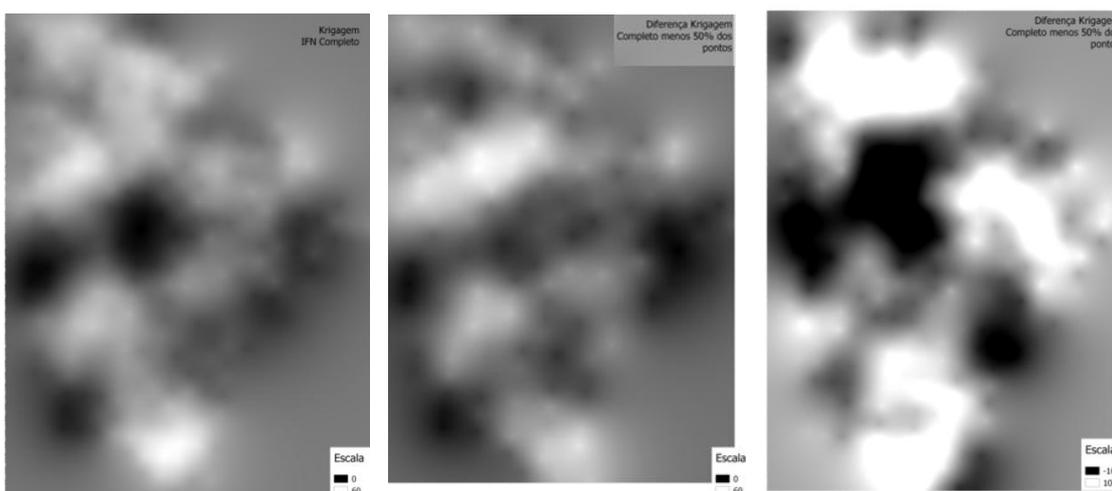


Figura 55 - Imagem dos pontos do IFN. À esquerda o resultado da krigagem feita com os 376 pontos do IFN, no centro o resultado do mesmo método aplicado em 50% dos pontos, com 188 removidos aleatoriamente. Na imagem à direita, a diferença pixel a pixel das duas imagens, 59,56% dos pixels com diferença menor ou igual a 8 ton./ha de estimativa.

Conforme dados dos comparativos quando 10% dos dados foram retirados, o resultado obtido foi 84,24% dos pixels com valores menores do que metade da diferença entre as classes de estoque florestal consideradas, assim com 90% dos dados foi possível chegar a um resultado compatível com o encontrado pela krigagem dos 376 pontos do IFN. Ao remover 50% dos conglomerados, conseguiu-se ainda atingir 59,56% dos pixels classificados com diferença que mantiveram a classe encontrada com a modelagem original.

Este resultado foi considerado satisfatório para o uso do modelo linear na krigagem ordinária. As diferenças indicaram ainda que o adensamento de pontos de coleta de inventário mostrou-se mais eficiente quando feito em áreas com informações heterogêneas, pois regiões com dados semelhantes na krigagem completa sofreram menos impacto quando parte dos pontos próximos foram removidos, do que regiões com pontos vizinhos com maior variação de biomassa registrada. Pôde-se concluir ainda que a krigagem completa do IFN foi um estimador com precisão maior para áreas com vegetação homogênea que foram amostradas e usadas na modelagem.

6. CONCLUSÃO

Foram estabelecidas etapas de análise e processamento de dados gerados pelo IFN que permitiram estimar estoque florestal potencial de áreas em que não havia conglomerados de inventário. As etapas utilizaram dados de sensores remotos ativos e passivos cruzados com resultados de krigagem de variáveis inventariadas ou estimadas.

A modelagem linear de variáveis de sensoriamento foi utilizada como auxiliar à abordagem com geoestatística, que apresentou resultados mais diretos devido à espacialização intrínseca dos métodos. A operacionalização das estimativas de estoque florestal potencial dependeu de um formato que facilitasse o uso em estimativas e estudos territoriais; os resultados espacializados facilitaram estas aplicações.

Foi possível interpolar os dados discretizados do IFN com o uso de Krigagem para uma estimativa espacialmente correlacionada de biomassa. Esta abordagem deve ser considerada em futuros estudos de distribuição territorial e planejamento de recuperação ambiental. O resultado espacial da interpolação de estoque florestal estimado pelo IFN foi complementado com a distribuição encontrada com dados derivados do PALSAR, e ambos podendo ser detalhados por sub-bacias hidrográficas, que se mostraram delimitadoras dos diferentes níveis de Estoque Florestal. A subdivisão em bacias hidrográficas pode ser importante principalmente para estudos de recuperação ambiental, pois oferecem limites naturais que influenciam a vegetação.

Com os resultados obtidos, foi possível classificar regiões do Ceará de acordo com o potencial de estoque florestal. O uso dos dados de RADAR foi determinante na aplicação de filtros de índice de vegetação, por ser menos influenciado pelas variações sazonais de conteúdo de água e coloração típicas da vegetação da Caatinga.

As etapas apresentadas puderam ser executadas em qualquer subconjunto de dados do IFN, a aplicação do método em outros locais dependerá da calibração dos índices, de acordo com a vegetação predominante e dos dados de sensoriamento disponíveis. Os processos generalistas auxiliaram automatizar o processamento de imagens e dados vetoriais, possibilitando a análise de todo o estado do Ceará como um objeto único.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abdikan, Saygin and SANLI, Fusun Balik. **Comparison of different fusion algorithms in urban and agricultural areas using sar (palsar and radarsat) and optical (spot) images.** Bol. Ciênc. Geod. vol.18, n.4, pp. 509-531. 2012.
- Antropov, O.; Rauste, Y.; Hame, T., **"Volume Scattering Modeling in PolSAR Decompositions: Study of ALOS PALSAR Data Over Boreal Forest,"** Geoscience and Remote Sensing, IEEE Transactions on , vol.49, no.10. pp.3838,3848. Out. 2011.
- Asner, G. P.; Knapp, D. E.; Cooper, A. N.; Bustamante, M. C.; Orlander, L. P. **Ecosystem structure throughout the Brazilian Amazon from Landsat observations and automated spectral unmixing.** Earth Interactions, v. 9, Paper 7, 2005. 31 p.
- Bacelar, Manuel J. Coimbra, **SAR Presentation** , Portugal, 2004.
- Biondo, L. M., Mesquita JR, H.N. , **Potencial Do Uso De Dados Palsar Na Identificação De Florestas Em Áreas Sem Visibilidade A Sensores Ópticos,** In: XI SENGEF, Curitiba, Brasil, 2014.
- BlackBridge, **RapidEye Red Edge White Paper,** Documentação descritiva da empresa responsável pela constelação RapidEye e seus produtos, Disponível em: https://resa.blackbridge.com/files/2014-06/Red_Edge_White_Paper.pdf , 2012
- Blue, Carbon Initiative, The, Howard J., Hoyt S., Pidgeon, E, Telszewski, M(eds.), **Coastal Blue Carbon: methods for assessing carbon stocks and emissions factors in mangroves, tidal salt marshes, and seagrass meadows,** Pag. 129-132, Conservation International, Intergovernmental Oceanographic Commission of UNESCO, International Union for Conservation of Nature. Arlington, Virginia, USA, 2014.
- Bohling , Geoff, **Introduction To Geostatistics And Variogram Analysis,** UK University of Kansas, Disponível em: <http://people.ku.edu/~gbohling/cpe940/Variograms.pdf>, Acessado em: Janeiro/2016.
- Lima, Camila Aparecida, Eristelma Teixeira de Jesus Barbosa Silva, Edson Eyji Sano, **Uso de imagens Landsat para a discriminação de Cerrado Rupestre na Área de Proteção Ambiental Pouso Alto e no Parque Nacional da Chapada dos Veadeiros,** Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil. 2009.
- Campos, J. C. C.; LEITE, H. G. **Mensuração Florestal: perguntas e respostas.** Viçosa: Editora UFV, 542 p, 2009.
- Dutra, Luciano Vieira, **Apresentação Proc. De Imagens de Radar de Abertura Sintética – Principios e Aplicações** , DPI (INPE). NPDI/DCC/ICEx/UFMG, IVWorkshop em Tratamento de Imagens, p. 4-13, 2003.
- Felix, Iara Musse , **RapidEye: a nova geração de satélites de Observação da Terra** , Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, INPE, pp. 25-30, Abr. 2009.

- Figueiredo Filho, A. Machado, S.A, Miranda, R.O.V. & Retslaff, F. **Compêndio de equações de volume e de afilamento de espécies florestais plantadas e nativas para as regiões geográficas do Brasil**. Curitiba, PR. Set. 2014.
- FAO, Food and Agriculture Organization of the United Nations, **Global Forest Resources Assesment 2015, How are the world's forests changing?** , Roma, Itália 54p, 2016.
- Freeman, Elizabeth A. , **Evaluating Kriging as a Tool to Improve Moderate Resolution Maps of Forest Biomass**, Environmental Monitoring and Assessment. 128(1-3), EUA, pp. 395-410, 2007.
- Freitas, Joberto Veloso de, **Inventário Florestal Nacional do Brasil: Implementando um Sistema Nacional de Monitoramento e Avaliação Florestal**, Apresentação no IV Simpósio Nacional de Invetário Florestal, Goiânia.
- Furuie, S.S., **PROCESSAMENTO DE IMAGENS MÉDICAS.**, Apresentação da disciplina PTC 5892 , Instituto do Coração, USP, São Paulo, SP, 2010.
- Ginciene, Bruno Rodrigues, **Utilização do EVI (Enhanced Vegetation Index) para maior sensibilidade na detecção de mudanças temporais em fragmentos de floresta estacional semidecidual**, Anais XV Simpósio Brasileiro de Sensoriamento Remoto, Curitiba, PR, Brasil, INPE, www.dsr.inpe.br/sbsr2011/files/p0984.pdf, p.1620, 2011.
- Gunnarsson, Fredrik, **On the potential of Kriging for forest management planning**, Relatório 13, Institutionen for skoglig resurshushalling och geomatik, UMEA University, Suécia, 36p. 1996.
- Hagen, Stephen, **Operational multi-sensor design for forest carbon monitoring to support REDD+ in Kalimantan, Indonesia**, Presentation To CMS Science Team, University of Maryland, College Park, EUA , 12p., Nov. 2014
- Hangsung, Jun Ji, **Satellite Imaging Information System**, Apresentação para ISE0042, Disponível em: <http://jun.hansung.ac.kr/SIIS/lectures.html>, Korea, 2015.
- Hong, Min-Gee, In-Kyu Jeong , Joonsoo-Choi , and Choen Kim³,**Mapping Of Alos Palsar H0 –Based Forest Stem Volume Classification Map** , IEEE, 2012.
- Huete, Alberto R., **Semi-Annual Report, January to June**, University of Arizona, Arizona, EUA. 14p., 1997.
- ICMBIO, **Portal do Instituto Chico Mendes de Conservação da Biodiversidade**. Disponível em: <http://www.icmbio.gov.br/portal/unidadesdeconservacao/biomas-brasileiros/caatinga>, Acessado em Jun., 2016.
- INMET, **BDMEP Banco de Dados Meteorológicos para Ensino e Pesquisa**. Disponível em <http://www.inmet.gov.br/projetos/rede/pesquisa/> . Acessado em: Maio/2016.

- INPE, DPI, **Documentação do CURSO DE TREINAMENTO SPRING-2.0**, Disponível em: <http://www.dpi.inpe.br/spring/teoria/aula6.pdf> , Acessado em: Jul., 2016.
- JAXA, **ALOS/PALSAR 25m Mosaic Product Format Description**. Jaxa Earth Observation Research Center, Tokio, Japão, 2012.
- Jensen, J.R., **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 604 p., 2009.
- Kuntschik, Gerardo, **Estimativa de biomassa vegetal lenhosa em cerrado por meio de sensoriamento remoto óptico e de radar**, 22 de março de 2004, Tese (Doutorado em Biociências), Instituto de Biociências, Universidade de São Paulo, São Paulo. 165p. , 2004.
- Landau, Elena C., **Variação Geográfica do Tamanho dos Módulos Fiscais no Brasil**, EMBRAPA, Brasília, DF, Novembro 2012, disponível em <http://aiba.org.br/wp-content/uploads/2013/11/variacao-Geografica-do-Tamanho-dos-Modulos-Fiscais-no-Brasil-Embrapa.pdf> , Nov. 2012.
- Lee, J-S. "Speckle Suppression And Analysis For Synthetic Aperture Radar Images", Opt. Eng. 25(5),255636, Maio, 1986.
- Lei 12.561 de 25 de maio de 2012, **Dispõe sobre a proteção de vegetação nativa**. Brasília, DF. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm . 2012.
- Lima Junior, Claudemiro de, **Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índice de vegetação**, Scientia Forestalis, Piracicaba, v. 42, n. 102, p. 289-298, jun. 2014.
- Mesquita Junior, Humberto Navarro. **ALOS PALSAR to Complement an Operational Amazonian Deforestation Monitoring Systems**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, INPE, pp. 7339-7346. Abril 2009.
- Mitchard, E. T. A., **Mapping tropical forest biomass with radar and spaceborne LiDAR in Lope National Park, Gabon: overcoming problems of high biomass and persistent cloud**, Biogeosciences, 9, pp. 179–191, 2012.
- Ministério do Meio Ambiente, **Documento de referência dos mapas de cobertura vegetal da execução do Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira**, MMA, Brasília, 2004.
- Ministério do Meio Ambiente, **Catálogo de Imagens de Satélite RapidEye do Ministério do Meio Ambiente**, Disponível em: <http://geocatalogo.mma.gov.br>, Acessado em Agosto, 2016.
- NASA, **Landsat 7 HandBook**, Disponível em: <http://landsathandbook.gsfc.nasa.gov/>, Acessado em Abril de 2016.

- Olea, Ricardo A., **A Practical Primer on Geostatistics** , U.S. Department of the Interior U.S. Geological Survey , Relatório aberto 2009-1103, Virginia, EUA, 348p, 2009.
- PHY-ASTR department, **hyperphysics database website**, Disponível em: <http://hyperphysics.phy-astr.gsu.edu/hbase>. Acessado em Julho, 2014
- Rouse, J. W. , **Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation. Progress Report - Number 4**, Remote Sensing Center, Texas A&M University, Texas, USA. 11p., 1973.
- Sales, Marcio H. , **Improving spatial distribution estimation of forest biomass with geostatistics: A case study for Rondonia, Brazil** , Ecological Modeling 205, Elsevier, pp. 221-230, 2007.
- Sampaio, E.V.S.B. & Silva, G.C., **Biomass equations for Brazilian semiarid caatinga plants**. Acta bot. Bras. 19(4): 935-943. 2005.
- SFB-A, Serviço Florestal Brasileiro, **Sistema Nacional de Informações Florestais**, disponível em: <http://www.florestal.gov.br/snif/> , acessado em Out., 2015.
- SFB-B, Serviço Florestal Brasileiro, **Cadastro Ambiental Rural**, Disponível em: www.florestal.gov.br/cadastro-ambiental-rural/ , acessado em Maio/2016.
- SFB-C, Serviço Florestal Brasileiro, **Documentação do Inventário Florestal Nacional**. Disponível em: <http://ifn.florestal.gov.br/>. Acessado em Jun., 2016.
- SFB-D, Serviço Florestal Brasileiro, **MANUAL DE CAMPO, Procedimentos para coleta de dados Biofísicos e Socioambientais**. Ministério do Meio Ambiente, Brasília - DF. 196p, Jun. 2014.
- Sian Lewis , **Mapping Forest Parameters Using Geostatistics and Remote Sensing Data**, Tese de Doutorado em Filosofia, Remote Sensing Unit, Department of Geography, University College London. Londres, Inglaterra. 392p., 2005.
- Trovao, Bernardo de Araújo Morais, **Uso de Máscaras Binárias Para Comparação da Acurácia Entre Classificações de Uso do Solo Feitas com Imagens Landsat e Rapideye, para as Classes de Vegetação Nativa**, Monografia em Recuperação de Áreas Degradadas, Viçosa, 43p., 2016.
- Wulder, Michael A. , **Spatially Explicit Large Area Biomass Estimation: Three Approaches Using Forest Inventory and Remotely Sensed Imagery in a GIS**, Sensors 2008, 8(1), pp. 529-560, 2008.
- Yamamoto, Jorge Kazuo ; P.M.B. Landim . **Geoestatística: conceitos e aplicações**. 1. ed. São Paulo: Editora Oficina de Textos,. v. 1., 215p., 2013.

7. APÊNDICE 1 – ALGORITMOS E COMENTÁRIOS

Neste apêndice estão os principais algoritmos desenvolvidos que levaram ao processo e resultados desta dissertação, com o intuito de facilitar e incentivar o uso dos programas e dos métodos de análise de informações geoespaciais, imagens e bancos de dados. Foram incluídos comentários nos códigos e instruções de uso mínimas aos interessados. As ferramentas utilizadas são de acesso livre e são mantidas por comunidades de desenvolvimento de software que permitem uma evolução constante.

Os códigos e equações desenvolvidos foram disponibilizados em repositório público (<https://github.com/leandromet>), juntamente com os resultados obtidos. As imagens e dados originais utilizados durante o estudo foram solicitados ao SFB, para disponibilização mediante autorização do fornecedor original dos dados, uma vez que o seu uso poderia estar restrito aos fins governamentais, acadêmicos e de pesquisa. Os dados processados do Ceará, como imagens RGB utilizando o PALSAR, imagens geradas com os índices de vegetação e clorofila de todo o estado, os resultados de análise do inventário e as entradas e saídas das interpolações por krigagem foram disponibilizados ao SFB e ao laboratório de Manejo Florestal da EFL/UnB, onde foi também disponibilizada uma cópia de todo o material.

Entre os recursos livres utilizados e recomendados estão o Python, que é uma linguagem de alto nível, fácil utilização para automação e processamento rápido. O Qgis que é um sistema de geoinformações completo, o R-cran que é um conjunto de softwares estatísticos, o Linux (Kubuntu e Opensuse) como sistema operacional, que facilita e acelera o processamento e a organização de arquivos e dados, o PostgreSQL com PostGIS que formam um banco de dados geoespacial robusto e completo. Também outros componentes menos diretos do OSGeo (<http://www.osgeo.org/>) foram amplamente utilizados como a GDAL/OGR/OSR, biblioteca de acesso e uso de dados espaciais vetoriais e rasterizados (imagens).

Com estas ferramentas foi possível que se pudesse aprender e controlar totalmente o que foi analisado e produzido. Assim compartilho os resultados com o objetivo de que outros possam se beneficiar da mesma forma do livre acesso e uso a este material em licença Creative Commons.

Licença de Uso dos Algoritmos

Esta dissertação é de direito autoral da Universidade de Brasília, os softwares estão publicados em <http://github.com/leandromet> e serão atualizados conforme necessário, sua reprodução em conjunto com esta dissertação tem função informativa e facilitadora do acesso a estas ferramentas. Todas as dissertações e teses da UnB são publicadas em licença Creative Commons (CC), que é uma entidade, sem fins lucrativos, criada para permitir maior flexibilidade na utilização de obras protegidas por direitos autorais. O objetivo é fazer com que um autor/criador possa permitir o uso mais amplo de seus materiais por terceiros, sem que estes infrinjam as leis de proteção à propriedade intelectual.

7.1.Script SQL – Extração de dados do banco do IFN

Os dados do IFN são recebidos em planilhas e outros arquivos em formato padrão, posteriormente são inseridos em um banco de dados PostgreSQL que tem cartucho espacial com a extensão PostGIS. Este formato é amplamente utilizado para armazenagem e uso de dados espaciais de todos os tipos. O SFB o utiliza também para os dados do Sistema Cadastro Ambiental Rural (SICAR), o MMA utiliza para dados do Sistema Nacional de Unidades de Conservação (SNUC), o IBAMA utiliza em diferentes sistemas e assim por diante. A consulta a seguir é aplicável no banco de dados concebido para o IFN do Ceará, que é o atual modelo de dados que será utilizado com todos os dados do inventário no futuro. São selecionados 38 valores de cinco tabelas relacionadas por chaves múltiplas para formar uma única tabela com todas as informações inicialmente avaliadas de cada fuste de cada indivíduo de todas as subparcelas que depois foram reespecializadas.

O único método diferente necessário é o condicional para o uso do solo da tabela `tb_form5`, que contém os dados de conglomerados do Formulário cinco de campo do IFN, em que estão armazenadas as siglas de uso do solo em 10 colunas diferentes. Foi feita uma condicional que utiliza a informação de subparcela originária do fuste alvo da tabela `form6_q5a20` (dados individuais de fustes) de acordo com a tabela `f6_5sp` (dados de subparcelas) para que o resultado contenha apenas a sigla que se deseja. As consultas SQL foram realizadas utilizando o software PGAdminIII em conjunto com o SQL console do Qgis, que pode ser acessado com a ferramenta Banco de Dados da caixa de ferramentas padrão do software. Os resultados de consultas realizadas no Qgis podem ser

imediatamente abertos no projeto em que se está trabalhando, como uma nova camada de dados ou como uma tabela, o que torna mais simples o uso de dados provenientes de banco de dados espacial.

```

SELECT #LISTA DE CAMPOS INICIALMENTE CONSULTADOS PARA REESPAIALIZAÇÃO
  grid.objectid as id_grid,
  grid_results.objectid as id_result,
  tb_form5.f5_segunico as id_form5,
  tb_form6.f6_segunico as id_form6,
  tb_form6_q5a20.f6_segunico as id_form6q5,
  grid.nome_alternativo as ncong,
  grid.shape as geom,
  grid_results.arvo_dap_10 as arv_10,
  grid_results.arvo_dap_5e10 as arv_5a10,
  grid_results.area_flores as area_fl,
  grid_results.perc_flores as perc_fl,
  grid_results.num_esp,
  grid_results.area_basa10 as basal10,
  grid_results.area_basal5e10 as basal5a10,
  grid_results.volume_dap10 as vol10,
  grid_results.volume_dap5e10 as vol5a10,
  grid_results.biomassa10 as biom10,
  grid_results.biomassa5e10 as biom5a10,
  grid_results.carbono10 as carb10,
  grid_results.carbono5e10 as carb5a10,
  tb_form5.f5_13cobflorestal as cobflor,
CASE #CONDICIONAL PARA SELEÇÃO DO USO DO SOLO RELACIONADO AO FUSTE
  WHEN f6_5sp = 1 then tb_form5.f5_19subparcela1
  WHEN f6_5sp = 2 then tb_form5.f5_19subparcela2
  WHEN f6_5sp = 3 then tb_form5.f5_19subparcela3
  WHEN f6_5sp = 4 then tb_form5.f5_19subparcela4
  WHEN f6_5sp = 5 then tb_form5.f5_19subparcela5
  WHEN f6_5sp = 6 then tb_form5.f5_19subparcela6
  WHEN f6_5sp = 7 then tb_form5.f5_19subparcela7
  WHEN f6_5sp = 8 then tb_form5.f5_19subparcela8
  WHEN f6_5sp = 9 then tb_form5.f5_19subparcela9
  WHEN f6_5sp = 10 then tb_form5.f5_19subparcela10
  ELSE NULL
END as uso_solo,
  extract(year from tb_form6.f6_3data) as f6_ano,
  tb_form6.f6_21qdtocos as qdtocos,
  tb_form5.f5_2subunidade as subuni,
  tb_form6_q5a20.f6_5sp as subp,
  tb_form6_q5a20.f6_6na as n_arv,
  tb_form6_q5a20.f6_9nf as n_fuste,
  tb_form6_q5a20.f6_7especie as especie,
  tb_form6_q5a20.f6_8mb as matbot,
  tb_form6_q5a20.f6_10dap as dap,
  tb_form6_q5a20.f6_11sa as sanidade,
  tb_form6_q5a20.f6_12qf as qldfust,
  tb_form6_q5a20.f6_13ps as posoci,
  tb_form6_q5a20.f6_14aff as arvff,
  tb_form6_q5a20.f6_15ht as h_total,
  tb_form6_q5a20.f6_16hf as h_fuste,
  tb_form6_q5a20.f6_18hm as h_medida
FROM #LISTA DE TABELAS DO BANCO DE DADOS DO IFN DO CEARÁ NO SFB
  ifn_ce.tb_form5, #TABELA COM DADOS DO FORMULÁRIO 5, DE CONGLOMERADOS
  ifn.grid, #TABELA ESPACIAL COM GEOMETRIA DE PONTOS E INFORMAÇÕES DAS DIFERENTES
  GRADES DO IFN
  ifn.grid_results, #TABELA COM RESULTADOS SECUNDÁRIOS DO IFN, PUBLICADOS NO SITE
  ifn_ce.tb_form6, #TABELA COM INFORMAÇÕES DO FORMULÁRIO 6, SOMENTE DAS SUBPARCELAS
  ifn_ce.tb_form6_q5a20 #TABELA COM INFORMAÇÕES DO FORMULÁRIO 6, FUSTES E INDIVÍDUOS
WHERE #CONDIÇÕES DE RELACIONAMENTO ENTRE AS 5 TABELAS
  grid.nome_alternativo = tb_form5.f5_ncong AND

```

```
grid_results.nome_alternativo = grid.nome_alternativo AND  
tb_form6.f6_ncong = tb_form5.f5_ncong AND  
tb_form6.f6_subuni = tb_form5.f5_2subunidade AND  
tb_form6_q5a20.f6_ncong = tb_form6.f6_ncong AND  
tb_form6_q5a20.f6_numsubuni=tb_form6.f6_subuni;
```

7.2. Operações no Qgis Field Calculator

7.2.1. Estoque Florestal com Uso do solo do IFN

A ferramenta “Calculadora de Campo” do Qgis é simples e prática, tem equivalente em todos os softwares de informações geoespaciais e foi amplamente aplicado para extração e classificação de dados. O uso de condicionais por vezes torna o código a ser executado extenso, mas é mais direto e simples do que a execução de um script ou ferramenta específica. Recomendo o uso para os casos em que a operação será realizada poucas vezes e o processo seja relativamente simples, como o cruzamento condicional de colunas ou operações espaciais e matemáticas que envolvem poucas variáveis. Aqui foram utilizados os valores de classe de uso de solo do IFN (coluna “tipologia” da tabela de atributos do arquivo vetorial) para aplicar os níveis de estoque florestal de 1 a 5 de acordo com os parâmetros listados na seção 5.3.1 da dissertação, criando um novo campo na tabela de atributos com valores inteiros de 0 a 5. São 16 condições em ordem, no caso de uma ser atendida o campo de resposta é preenchido, se não atendido as condições seguintes são testadas.

```
case when "tipologia" = 'Afr' then 0 else  
case when "tipologia" = 'Agu' then 0 else  
case when "tipologia" = 'Ai' then 0 else  
case when "tipologia" = 'Dun' then 0 else  
case when "tipologia" = 'lu' then 0 else  
case when "tipologia" = 'Ap' then 1 else  
case when "tipologia" = 'Acc' then 1 else  
case when "tipologia" = 'Acp' then 2 else  
case when "tipologia" = 'Vsb1' then 3 else  
case when "tipologia" = 'Vss1' then 3 else  
case when "tipologia" = 'Vsp1' then 3 else  
case when "tipologia" = 'Vsb2' then 4 else  
case when "tipologia" = 'Vsp2' then 4 else  
case when "tipologia" = 'Ou' then 5 else  
case when "tipologia" = 'Rg' then 5 else  
case when "tipologia" = 'Rm' then 5 else 0  
end end
```

7.2.2. Estoque Florestal com HH Palsar

Processo semelhante ao item 7.5, foram utilizadas 5 condições ordenadas para classificar cada conglomerado de acordo com o item 5.3.2 da dissertação. Desta forma quando a primeira condição é atendida as seguintes não são testadas, no caso da resposta média de HH um ponto que atende a categoria 5 também atende a categoria 4 e assim por diante, neste caso são testadas primeiro as condições mais restritivas e preenchido o novo campo de estoque classificado.

```
case when (( "dB_n10" + "dB_n08" + "dB_n06" ) > 180) then 5 else  
  
CASE WHEN  
(( "dB_n10" + "dB_n08" + "dB_n06" ) > 150) THEN 4 else  
CASE WHEN  
(( "dB_n10" + "dB_n08" + "dB_n06" ) > 100) THEN 3 else  
CASE WHEN  
(( "dB_n10" + "dB_n08" + "dB_n06" ) > 50) THEN 2 else  
CASE WHEN  
(( "dB_n10" + "dB_n08" + "dB_n06" + "dB_n12" ) > 150) THEN 1 else  
0 END end end end end
```

7.2.3. Estoque Florestal com NDVI Rapideye

Lógica semelhante ao item 7.4, atende o descrito no item 5.3.3 com quatro condicionais em sequência para valores médios calculados de ndvi para cada conglomerado.

```
CASE WHEN  
(("ndvi_0p4"+"ndvi_0p6" + "ndvi_0p8" ) > 1200) THEN 4 else  
CASE WHEN  
(("ndvi_0p4"+"ndvi_0p6") > 600) THEN 3 else  
CASE WHEN  
(("ndvi_0p4") > 300) THEN 2 else  
CASE WHEN  
(("ndvi_0p2"+"ndvi_0p4" ) > 300) THEN 1 else 0  
end end end end
```

7.2.4. Estoque Florestal com RFDI Palsar

```
case when (( "rrfdi_0p4" + "rrfdi_0p5" ) > 50) then 5 else
CASE WHEN
(( "rrfdi_0p3" + "rrfdi_0p4" + "rrfdi_0p5" ) > 100) THEN 4 else
CASE WHEN
(( "rrfdi_0p3" + "rrfdi_0p4" + "rrfdi_0p5" ) > 50) THEN 3 else
CASE WHEN
(( "rrfdi_0p3" + "rrfdi_0p4" + "rrfdi_0p5" ) > 20) THEN 2 else
CASE WHEN
(( "rrfdi_0p2" + "rrfdi_0p3" + "rrfdi_0p4" + "rrfdi_0p5" ) > 100) THEN 1 else
0 END end end end end
```

7.2.5. Tipologias PROBIO/MMA

```
case when "CLASSE_2" = 'A' then 'Floresta Ombrofila Aberta' else
case when "CLASSE_2" = 'Ag' then 'Agua' else
case when "CLASSE_2" = 'As' then 'Floresta Ombrofila Submontana 100 a 600' else
case when "CLASSE_2" = 'Corpos d'água' then 'Agua' else
case when "CLASSE_2" = 'Cs' then 'Floresta Estacional Decidual ate 400m' else
case when "CLASSE_2" = 'F' then 'Floresta Estacional SemiDecidual' else
case when "CLASSE_2" = 'Fb' then 'Floresta Estacional SemiDecidual baixa 30' else
case when "CLASSE_2" = 'Fs' then 'Floresta Estacional SemiDecidual Submontana 400' else
case when "CLASSE_2" = 'lu' then 'Influencia Urbana' else
case when "CLASSE_2" = 'P' then 'Vegetacao Pioneira' else
case when "CLASSE_2" = 'Pa' then 'Vegetacao Pioneira Arbórea' else
case when "CLASSE_2" = 'Pf' then 'Vegetacao Pioneira Fluviomarinha' else
case when "CLASSE_2" = 'Pfh' then 'Vegetacao Pioneira Fluviomarinha Herbacea' else
case when "CLASSE_2" = 'Pfm' then 'Vegetacao Pioneira Mangeuzal' else
case when "CLASSE_2" = 'Pm' then 'Vegetacao Pioneira Marinha Restinga' else
case when "CLASSE_2" = 'Pmb' then 'Vegetacao Pioneira Marinha Restinga Arbustiva duna' else
case when "CLASSE_2" = 'Pmh' then 'Vegetacao Pioneira Marinha Restinga Herbacea Praia' else
case when "CLASSE_2" = 'SN' then 'Floresta Savana e Estacional' else
case when "CLASSE_2" = 'SP' then 'Floresta Savana e Pioneira' else
case when "CLASSE_2" = 'ST' then 'Floresta Savana e Estepe' else
case when "CLASSE_2" = 'Sd' then 'Floresta Savana Cerradao' else
case when "CLASSE_2" = 'Sp' then 'Savana Parque' else
case when "CLASSE_2" = 'T' then 'Floresta Savana Estepe' else
case when "CLASSE_2" = 'TN' then 'Floresta Savana Estepe e Estacional' else
case when "CLASSE_2" = 'TP' then 'Floresta Savana Estepe e Ombrofila' else
case when "CLASSE_2" = 'Ta' then 'Floresta Savana Estepe Arborizada' else
case when "CLASSE_2" = 'Td' then 'Floresta Savana Estepe Florestada' else
case when "CLASSE_2" = 'Tp' then 'Floresta Savana Estepe Parque' else
case when "CLASSE_2" = 'Vs' then 'Vegetacao Secundaria' else
case when "CLASSE_2" = 'agua' then 'Agua' else 0
end end end end end end
```

7.3. Scripts Python

O Python é uma linguagem interpretada popularmente utilizada para executar operações de forma direta, simplificada e com menor formalidade estrutural. A linguagem é gerenciada de forma comunitária e permite o desenvolvimento de código de uma forma parecida com um texto descritivo comum, o que a torna mais intuitiva. Existem bibliotecas de geoprocessamento e de uso de imagens e dados vetoriais portadas para Python, que são utilizadas nas ferramentas da maior parte dos softwares de GIS (ArcGis, Qgis, SAGA, etc.). Estas bibliotecas em conjunto com a facilidade de programar em Python permitem que sejam criadas ferramentas específicas para o que se desejar. Elas foram utilizadas para acessar, decodificar, processar e extrair informações e estatísticas das imagens visíveis do RapidEye e dos dados de RADAR do PALSAR.

Os scripts podem ser associados à plugins do Qgis, por exemplo, o que permite o uso comunitário das ferramentas de forma mais ampla. Entre as vantagens de processar os dados desta forma está o entendimento mais completo do que é realizado pelo software, com as mesmas bibliotecas dos softwares GIS citados, o que permite atingir resultados compatíveis com outros estudos. Ao executar os processos em scripts encurta-se o caminho para automatizar e executar as operações em uma quantidade grande de dados, bastando que eles estejam armazenados em um padrão conhecido.

Os códigos a seguir foram elaborados para o processamento de imagens de todo o Brasil, o que foi realizado no SFB para uso no planejamento de missões do IFN, gerenciamento de concessões florestais e outras atividades. Foram necessárias pequenas alterações para atender os objetivos do estudo desta dissertação e o mesmo pode ser feito para qualquer outra aplicação semelhante.

7.3.1. Decodificação PALSAR em imagem R-G-B

Script Python para uso de imagens PALSAR, que foram fornecidas pela JAXA ao SFB em formato distinto de outros produtos do satélite ALOS, o que impede o uso direto de bibliotecas de interpretação de dados de RADAR. É necessária decodificação simples, porém para que não seja realizada manualmente cena a cena, optou-se por executar em um

processo cíclico para um banco de dados em disco. São informados o caminho e o formato dos arquivos, que posteriormente são abertos, decodificados e utilizados para gerar uma imagem colorida que é facilmente interpretada por usuários familiarizados com imagens visíveis. As imagens são geradas com três bandas com contraste ampliado, a primeira com os dados de resposta HH, a segunda com HV e a terceira com o RFDI calculado.

```
"""
```

```
#-----  
# Name:          ALOS HH, HV and RFDI on RGB 16signedint GEOTIFF  
# Purpose:       Calculates the RFDI , saves geotiff with HH, HV and RFDI layers  
#                in 8bit unsigned format, with values stretched for contrast  
#                enhancement.  
# Author:        leandro.biondo@florestal.gov.br  
#  
# Created:       06/07/2015  
# Copyright:     (c) leandro.biondo 2015  
# Licence:       GPL  
#-----  
"""  
  
import glob  
import gdal  
from gdalconst import *  
import osr  
import numpy as np  
from struct import *  
import array  
from scipy import ndimage  
import math  
import os  
  
def exporta_alos_geoTIFF(arquivo, destino, refer):  
    pos = arquivo.find(refer)-1  
    lat = -1*int(arquivo[pos+6:pos+8])  
    lon = -1*int(arquivo[pos+9:pos+12])  
    f = open(arquivo, "rb")  
    print f  
    count = 0  
    print os.stat(arquivo).st_size  
    npa = np.fromfile(f, dtype=np.dtype('<H'))  
    f.close()  
    npa = npa.astype(np.float32)  
    npa = npa**2  
    npr = npa.reshape(4500,4500)  
    med9 = np.array([  
        [0.11,0.11,0.11],  
        [0.11,0.12,0.11],  
        [0.11,0.11,0.11],  
    ])
```

```

#convolucao = ndimage.convolve(npr,med81)
#convolucao = ndimage.convolve(npr,med25)
convolucao = ndimage.convolve(npr,med9)
npalog = 10*np.log10(convolucao)-83
np.putmask(npalog, npalog<-500, -500)
npalog = npalog.reshape(4500,4500)
fv = open(arquivo.replace("HH","HV"), "rb")
print fv
count = 0

npav = np.fromfile(fv, dtype=np.dtype('<H'))
fv.close()
npav = npav.astype(np.float32)
npav = npav**2
nprv = npav.reshape(4500,4500)
#convolucao = ndimage.convolve(npr,med81)
#convolucao = ndimage.convolve(npr,med25)
convolucao = ndimage.convolve(nprv,med9)
npalogv = 10*np.log10(convolucao)-83
np.putmask(npalogv, npalogv<-500, -500)
npalogv = npalogv.reshape(4500,4500)
passer = True
rfdi = np.where ( passer, ( 1.*npalog - 1.*npalogv ) / ( 1.*npalog +
1.*npalogv ), -999 )
format = "GTiff"
driver = gdal.GetDriverByName( format )
metadata = driver.GetMetadata()
if metadata.has_key(gdal.DCAP_CREATE) \
and metadata[gdal.DCAP_CREATE] == 'YES':
    print 'Driver %s supports Create() method.' % format
if metadata.has_key(gdal.DCAP_CREATECOPY) \
and metadata[gdal.DCAP_CREATECOPY] == 'YES':
    print 'Driver %s supports CreateCopy() method.' % format
dst_ds = driver.Create( destino, 4500, 4500, 3, gdal.GDT_Byte,
['COMPRESS=LZW'] )
dst_ds.SetMetadataItem("DateTime", "2009:00:00")
dst_ds.SetGeoTransform( [ lon-0.000111111, 0.000222222, 0, lat-0.000111111,
0, -0.000222222 ] )
srs = osr.SpatialReference()
srs.SetWellKnownGeogCS( 'WGS84' )
dst_ds.SetProjection( srs.ExportToWkt() )

print "min", np.amin(npalog)
print np.amin(npalogv)
print np.amin(rfdi)

print "max", np.amax(npalog)
print np.amax(npalogv)
print np.amax(rfdi)
#new range

```

```

npalog=npalog+np.abs(np.amin(npalog))
npalogv=npalogv+np.abs(np.amin(npalogv))
rfdi=rfdi+np.abs(np.amin(rfdi))
npalog=(npalog-np.amin(npalog))*(255/((np.amax(npalog)-np.amin(npalog))))
npalogv=(npalogv-np.amin(npalogv))*(255/((np.amax(npalogv)-
np.amin(npalogv))))
rfdi=(rfdi-np.amin(rfdi))*(255/((np.amax(rfdi)-np.amin(rfdi))))

print "minpos", np.amin(npalog)
print np.amin(npalogv)
print np.amin(rfdi)

print "maxpos", np.amax(npalog)
print np.amax(npalogv)
print np.amax(rfdi)

print "meanpos", np.mean(npalog, dtype=np.float64)
print np.mean(npalogv, dtype=np.float64)
print np.mean(rfdi, dtype=np.float64)
dst_ds.GetRasterBand(1).WriteArray(npalog.astype(int))
dst_ds.GetRasterBand(2).WriteArray(npalogv.astype(int))
dst_ds.GetRasterBand(3).WriteArray(rfdi.astype(int))

# Once we're done, close properly the dataset
dst_ds = None
print "Gerada imagem %s" %destino
c=0
for files in glob.glob("C:\\Biondo\\PALSAR_Catalogo\\2009\\RGB\\*s1_HH"):
    entrada = files
    saida = files+"_img.tif"
    referencia = "RGB"
    print entrada, ">>>",saida
    exporta_alos_geoTIFF(entrada,saida,referencia)
    c+=1
    print c
    #if c >= 1:
    #    break
print "end"

```

7.3.2. Índices de Vegetação com RapidEye

Script Python para cálculo de diversos índices de vegetação a partir de pastas que contenham imagens RapidEye no formato padrão fornecido pela BlackBridge (com cinco bandas). O programa extrai os dados de irradiância das bandas 2, 3, 4 e 5 para então

calcular os índices NDVI, NDVI com RedEdge, Vari-RedEdge, Clorofila com Verde, Clorofila com RedEdge e MTCI.

```
#!/usr/bin/e
nv python

# -*- coding: utf-8 -*-
"""
#-----
-----
# Name:      RaidEye Vegetation Indexes
# Purpose:   Calculate ndvi, ndvi_redege, vari_redege,
#            chlorophyl green, chlorophyl redege and MTCI
# Author:    leandro.biondo@florestal.gov.br
#
# Created:   09/05/2016
# Copyright: (c) leandro.biondo 2016
# Licence:   GPL
#-----
-----
"""
import os
import sys
import numpy as np
from osgeo import gdal
from osgeo import ogr
import glob

def calculate_ndvi ( rapideye_filename ):
    """
    A function to calculate the Normalised Difference Vegetation Index
    from red and near infrared reflectances. The reflectance data ought
    to
    be present on two different files, specified by the varaibles
    `red_filename` and `nir_filename`. The file format ought to be
    recognised by GDAL
    """
    rapideyer = gdal.Open ( rapideye_filename )
    g_green = rapideyer.GetRasterBand(2)
    g_red = rapideyer.GetRasterBand(3)
    g_edge = rapideyer.GetRasterBand(4)
    g_nir = rapideyer.GetRasterBand(5)

    green= g_green.ReadAsArray()
    red = g_red.ReadAsArray()
    edge= g_edge.ReadAsArray()
    nir = g_nir.ReadAsArray()

    #NDVI - Normalized Difference Vegetation Index
    passer = np.logical_and ( red > 1, nir > 1 )
    ndvi = np.where ( passer, (1.*nir - 1.*red) / ( 1.*nir + 1.*red ),
```

```

-999 )

#NDVI_Red Edge
passer = np.logical_and ( nir > 1, edge > 1 )
ndviedge = np.where ( passer, (1.*nir - 1.*edge) / ( 1.*nir +
1.*edge ), -999 )

#VARI Red Edge - Visible Atmospherically Resistant Indices

passer = np.logical_and ( red > 1, edge > 1 )
variedge = np.where ( passer, (1.*edge - 1.*red) / ( 1.*edge +
1.*red ), -999 )

#CI - Chlorophyll Indices - green
passer = np.logical_and ( nir > 1, green > 1 )
clgreen = np.where ( passer, ((1.*nir / 1.*green)-1), -999 )

#CI - Chlorophyll Indices - rededge
passer = np.logical_and ( nir > 1, edge > 1 )
cledge = np.where ( passer, ((1.*nir / 1.*edge)-1), -999 )

#MTCI - MERIS terrestrial - chlorophyll index
passer = np.logical_and ( red > 1, edge > 1 )
mtci = np.where ( passer, (1.*nir - 1.*edge) / ( 1.*edge - 1.*red
), -999 )

return ndvi, ndviedge, variedge, clgreen, cledge, mtci
def save_raster ( output_name, raster_data, dataset, driver="GTiff" ):
    """
    A function to save a 1-band raster using GDAL to the file indicated
    by ``output_name``. It requires a GDAL-accessible dataset to collect
    the projection and geotransform.
    """
    # Open the reference dataset
    g_input = gdal.Open ( dataset )
    # Get the Geotransform vector
    geo_transform = g_input.GetGeoTransform ()
    x_size = g_input.RasterXSize # Raster xsize
    y_size = g_input.RasterYSize # Raster ysize
    srs = g_input.GetProjectionRef () # Projection
    # Need a driver object. By default, we use GeoTIFF
    if driver == "GTiff":
        driver = gdal.GetDriverByName ( driver )
        dataset_out = driver.Create ( output_name, x_size, y_size, 1, \
            gdal.GDT_Float32, ['TFW=YES', \
                'COMPRESS=LZW', 'TILED=YES'] )
    else:
        driver = gdal.GetDriverByName ( driver )
        dataset_out = driver.Create ( output_name, x_size, y_size, 1, \

```

```

        gdal.GDT_Float32 )
dataset_out.SetGeoTransform ( geo_transform )
dataset_out.SetProjection ( srs )
dataset_out.GetRasterBand ( 1 ).WriteArray ( \
        raster_data.astype(np.float32) )
dataset_out.GetRasterBand ( 1 ).SetNoDataValue ( float(-999) )
dataset_out = None
if __name__ == "__main__":
    caminho = "//media//leandro//back//EFL_UNB//2016//rapideye//"
c5=0
for infile in
glob.glob(r'/media/leandro/back/EFL_UNB/2016/rapideye/*.tif'):
    print "c5=",c5
    imagetif = infile
    c_ndvi, c_ndviedge, c_variedge, c_clgreen,
c_cledge, c_mtci = calculate_ndvi (imagetif)
    save_raster ( infile.replace('.tif','_ndvi.tif'),
c_ndvi,infile , "GTiff" )
    save_raster ( infile.replace('.tif','_edge.tif'),
c_ndviedge,infile , "GTiff" )
    save_raster (
infile.replace('.tif','_variedge.tif'), c_variedge,infile , "GTiff" )
    save_raster (
infile.replace('.tif','_clgreen.tif'), c_clgreen,infile , "GTiff" )
    save_raster (
infile.replace('.tif','_cledge.tif'), c_cledge,infile , "GTiff" )
    save_raster (
infile.replace('.tif','_clmtci.tif'), c_mtci,infile , "GTiff" )

    c5+=1
    # if c5==3:
    #     break

```

7.3.3. Decodificação de arquivo HH ou HV do PALSAR

Script para decodificação de uma banda do PALSAR no formato disponibilizado pela JAXA.

```

#!/usr/bin
n python
# -*- coding: utf-8 -*-
# Gets a PALSAR unsigned int 16bit dataset and returns
# a 32bit float GeoTIFF image in DB values normalized
# with the image global MAX and MIN DB values then filters
# the result with a 9 average convolution matrix with a
# center weight of 2 (8 neighbor pixels weight 1)
import glob
import gdal

```

```

from gdalconst import *
import osr
import numpy as np
from struct import *
import array
from scipy import ndimage
#safely calculates the log10 of a number, avoid problems with zero division
def safe_ln(x, minval=0.000000001):
    return np.log(x.clip(min=minval))
#exports an 32bit image geoTIFF from a binary 16bit unsigned integer ALOS
dataset
def exporta_alos_geoTIFF(arquivo, destino, refer):
# gets the geographic coordinates from the file name
    pos = arquivo.find(refer)
    print arquivo, refer, pos
    lat = -1*int(arquivo[pos+6:pos+8])
    lon = -1*int(arquivo[pos+9:pos+12])
    print lat, lon

#opens source file (ALOS - PALSAR binary data)
    f = open(arquivo, "rb")
    print f
    count = 0
# Creates and populate an array with the 16bit data from opened file
    a =array.array("H")
    print len(a)
    a.fromfile(f, 4500*4500)
    print a[25], a[3000], a[4500*4500-1], len(a)
#set geotiff metadata
    format = "GTiff"
    driver = gdal.GetDriverByName( format )
    metadata = driver.GetMetadata()
    if metadata.has_key(gdal.DCAP_CREATE) \
        and metadata[gdal.DCAP_CREATE] == 'YES':
        print 'Driver %s supports Create() method.' % format
    if metadata.has_key(gdal.DCAP_CREATECOPY) \
        and metadata[gdal.DCAP_CREATECOPY] == 'YES':
        print 'Driver %s supports CreateCopy() method.' % format
#create desired destination file
    dst_ds = driver.Create( destino, 4500, 4500, 1, gdal.GDT_Float32 )
    dst_ds.SetGeoTransform( [ lon-0.000111111, 0.000222222, 0, lat-
0.000111111, 0, -0.000222222 ] )
# georeferencing the image
    srs = osr.SpatialReference()
    srs.SetWellKnownGeogCS( 'WGS84' )
    dst_ds.SetProjection( srs.ExportToWkt() )
# creates a numpy array from the data array, for calculations
    npa = np.array(a, dtype = 'f32')
# extracting Normalised Radar Cross Section (NRCS)
# http://earth.eo.esa.int/pcs/alos/palsar/userinfo/ALOS-PALSAR-FAQ-

```

```

001.3.pdf
    npa = (10*safe_ln((npa)**2))-83
#normalizing NRCS values and creating the raster matrix with destination
resolution
    minval = np.min(npa[np.nonzero(npa)])
    maxval = np.max(npa[np.nonzero(npa)])
    print "maxmin", maxval, minval
    npa = (npa-minval)*((minval-maxval)/65536)+minval
    npr = npa.reshape(4500,4500)
# convolution of a 9x9 matrix with center wight 2 for attenuation of noise
med25 =
np.array([[0.0625,0.0625,0.0625],[0.0625,0.5,0.0625],[0.0625,0.0625,0.0625]
])
    convolucao = ndimage.convolve(npr,med25)
    dst_ds.GetRasterBand(1).WriteArray(convolucao)
# Once we're done, close properly the dataset
    dst_ds = None
    return "Gerado imagem %s" %destino
# running the function on a group of files inside some folder (changes
needed for MAIN module)
for files in glob.glob("/home//leandro//ALOS_PRODES//ALOS_Cenas//alpr//*"):
    entrada = files
    saida = files+".tif"
    referencia = "alpr"
    print entrada, ">>>",saida
    exporta_alos_geoTIFF(entrada,saida,referencia)

```

7.3.4. Cálculo de estatísticas de imagem em torno de pontos espaciais.

Script Python exemplificando o cálculo de estatísticas de um índice de vegetação (NDVI) em torno de pontos espacializados. Os processamentos são feitos em recortes das imagens com limites definidos por um raio fixo em torno de um ponto, que é o centroide de um arquivo qualquer de polígonos. Para este estudo foram utilizados os conglomerados do IFN como entrada vetorial de polígonos e foram calculados os índices em um raio de 200 metros de cada ponto.

```

#!/usr/bin/e
nv python
# -*- coding: utf-8 -*-
"""
#-----
-----
# Name:          RapidEyeNDVIfromCutRegions
# Purpose:       Calculates the NDVI of a defined region based on centroid
of features from a shapefile.

```

```

#
# Author:      leandro.biondo@florestal.gov.br
#
# Created:     29/11/2013
# Copyright:   (c) leandro.biondo 2013
# Licence:     GPL
#-----
-----
"""
import os
import sys
import numpy as np
from osgeo import gdal
from osgeo import ogr
import glob
#Funcao para calculo do NDVI, externa
def calculate_ndvi ( red_filename, nir_filename ):
    """
    A function to calculate the Normalised Difference Vegetation Index
    from red and near infrared reflectances. The reflectance data ought
to
to
be present on two different files, specified by the variables
`red_filename` and `nir_filename`. The file format ought to be
recognised by GDAL
    """
    g_red = gdal.Open ( red_filename )
    red = g_red.ReadAsArray()
    g_nir = gdal.Open ( nir_filename )
    nir = g_nir.ReadAsArray()
    if ( g_red.RasterXSize != g_nir.RasterXSize ) or \
        ( g_red.RasterYSize != g_nir.RasterYSize ):
        print "ERROR: Input datasets do't match!"
        print "\t Red data shape is %dx%d" % ( red.shape )
        print "\t NIR data shape is %dx%d" % ( nir.shape )
        sys.exit ( -1 )
    passer = np.logical_and ( red > 1, nir > 1 )
    ndvi = np.where ( passer, ( 1.*nir - 1.*red ) / ( 1.*nir + 1.*red ),
-999 )
    return ndvi
#Funcao para salvar um raster em formato de imagem
def save_raster ( output_name, raster_data, dataset, driver="GTiff" ):
    """
    A function to save a 1-band raster using GDAL to the file indicated
by ``output_name``. It requires a GDAL-accesible dataset to collect
the projection and geotransform.
    """
    # Open the reference dataset
    g_input = gdal.Open ( dataset )
    # Get the Geotransform vector
    geo_transform = g_input.GetGeoTransform ()

```

```

x_size = g_input.RasterXSize # Raster xsize
y_size = g_input.RasterYSize # Raster ysize
srs = g_input.GetProjectionRef () # Projection
# Need a driver object. By default, we use GeoTIFF
if driver == "GTiff":
    driver = gdal.GetDriverByName ( driver )
    dataset_out = driver.Create ( output_name, x_size, y_size, 1, \
        gdal.GDT_Float32, ['TFW=YES', \
            'COMPRESS=LZW', 'TILED=YES'] )
else:
    driver = gdal.GetDriverByName ( driver )
    dataset_out = driver.Create ( output_name, x_size, y_size, 1, \
        gdal.GDT_Float32 )
dataset_out.SetGeoTransform ( geo_transform )
dataset_out.SetProjection ( srs )
dataset_out.GetRasterBand ( 1 ).WriteArray ( \
    raster_data.astype(np.float32) )
dataset_out.GetRasterBand ( 1 ).SetNoDataValue ( float(-999) )
dataset_out = None

# Funcao que prepara um TIF e calcula o NDVI para uma area relacionada
um ponto central
# Entradas: caminho = caminho da pasta de trabalho, imagemtif = imagem
que sera processada
#         ptcenter = Ponto central da area a ser considerada, TileId =
Identificador do Grid RapidEye
#         distamost = distancia a ser considerada para amostragem,
metade do comprimento de amostragem
def prep_cut_call (caminhoi, imagemtif, ptcenter, TileId, distamost):
#Ponto para corte, utilizando o ponto informado.
    redcorte = (map(sum,zip(ptcenter,(-1*distamost,-1*distamost))),
map(sum,zip(ptcenter,(distamost,distamost))))
#Corte imagem com comprimento e altura 2 vezes a variável distamost
    os.system("gdalwarp -overwrite -te "+str(redcorte[0][0])+
"+str(redcorte[0][1])+" "\
    +str(redcorte[1][0])+" "+str(redcorte[1][1])+
    " %s %sRD_cut.tif"%(imagemtif, caminhoi))
#criadas 2 imagens temporárias com as bandas NIR e RED separadas, para
calculo do NDVI
    os.system("gdal_translate -b 3 %sRD_cut.tif %sred2_cut.tif"
%(caminhoi, caminhoi))
    os.system("gdal_translate -b 5 %sRD_cut.tif %snir2_cut.tif"
%(caminhoi, caminhoi))
#Calculo NDVI do corte RED/NIR, criada imagem com dados de NDVI
calculados
    c_ndvi = calculate_ndvi ( "%sred2_cut.tif"%caminhoi,
"%snir2_cut.tif"%caminhoi)
    save_raster ( "%sndvi2_cutdes%s.tif"%(caminhoi,TileId), c_ndvi,\
        "%sred2_cut.tif"%caminhoi, "GTiff" )
#Estatisticas do resultado, devolvidas estatisticas básicas para a
funcao.

```

```

src_ds = gdal.Open("%sndvi2_cutdes%s.tif"%(caminhoi,TileId))
srcband = src_ds.GetRasterBand(1)
stats = srcband.GetStatistics(0,1)
return (stats[0], stats[1], stats[2], stats[3] )

if __name__ == "__main__":
    caminhoi="//home//leandro//GINF//"
#Arquivo de feicoes que se deseja usar os centroides
shapefile = "//home//leandro//GINF//pr_300_wgs84b.shp"
driver = ogr.GetDriverByName("ESRI Shapefile")
dataSource = driver.Open(shapefile, 0)
layer = dataSource.GetLayer()
#Arquivo de feicoes que representam o grid de imagens
shapefile2 = "//home//leandro//GINF//pr_RapidEye_wgs84b.shp"
dataSource2 = driver.Open(shapefile2, 0)
layer2 = dataSource2.GetLayer()
c5 = 0
# Laco para percorrer as imagens do Grid RapidEye
for feature2 in layer2:
    c = 0
    dentro = 0
    geom2 = feature2.GetGeometryRef()
    TileId = int(feature2.GetField("TILE_ID"))
# Laco para percorrer os pontos de amostragem, usa os centroides como
ponto de comparacao
    for feature in layer:
        geom = feature.GetGeometryRef()
        pt = geom.Centroid()
        ptcenter = (pt.GetX(), pt.GetY())
# Teste para verificar se cada ponto central do shape de amostragens
intercepta o shape do mosaico RapidEye
        if pt.Intersects(geom2):
            dentro+=1
#Laco que encontra todos os arquivos TIF a serem processados conforme a
identificacao no mosico RapidEye
            for infile in
glob.glob(r'/mnt/hgfs/Biondo/GINF/Florestas_Parana/Imagens_RapidEye/*%s*.
tif'%TileId):
                #Ignora arquivos "browse."
                if infile.find("browse.") == -1:
                    #Ignora arquivos "udm."
                    if infile.find("udm.") == -1:
#Imagem TIF que sera cortada, ter as bandas NIR e RED separadas e
calculado o seu NDVI
                        imagemtif = infile
                        #Execucao das funcoes tomando como entrada os dados
resultantes da filtragem pelos pontos.
                        Statistica = prep_cut_call (caminhoi, imagemtif,
ptcenter, TileId, 150)
                        # Estatísticas simples do arquivo NDVI do corte em torno do
ponto de amostragem

```

```

print TileId, "(Min, Max, Mean, StDv)",
Statistica
# Limite para evitar que todos os pontos e imagens sejam processados,
comentar para processar todos os dados
c5+=1
if c5>5:
    exit(0)
c+=1
#Importante, resta a leitura do shape de amostragem para que ele possa
ser percorrido novamente no próximo Tile do R-E
layer.ResetReading()
print "Pontos: %i sendo %i contidas e %i nao" %( c, dentro, (c-
dentro))
#Apenas indica quais feições do RapidEye Grid continham pontos de
amostragem.
if dentro > 0:
    print TileId

```

7.4.Script R-CRAN no QGIS

Script R usado no Qgis para execução da Krigagem Ordinária com o modelo Exponencial com o auto variograma do R como plugin do Qgis. O resultado é o mesmo obtido com a krigagem utilizando apenas o R, porém o seu uso é facilitado por incluir camadas espaciais do Qgis diretamente no processamento. O resultado é um gráfico com o melhor variograma encontrado para o modelo escolhido (no caso modelo linear“LIN”) e um arquivo raster (imagem matricial) com os dados interpolados.

```

##Basic
statistics=group
##Layer=vector
##Field=Field Layer
## by= number 0.1
##Output=output raster
##Bibliotecas utilizadas para a krigagem
library(gstat)
library(rgl)
library("spatstat")
library("maptools")
install.packages("pls")
library (pls)
library(automap)
library(raster)

```

```

##Abertura de dados e alocação de variáveis
Y<-as.factor(Layer[[Field]])
attribut<-as.data.frame(Y)
A<-as.numeric(Y)
for(j in (1:length(levels(Y))))
for(i in 1:dim(attribut)[1]){
if (attribut[i,1]==levels(Y)[j]){
A[i]=j } }
##Carregamento das informações espaciais
coords<-coordinates(Layer)
Measure<- data.frame(LON=coords[,1], LAT=coords[,2], A)
coordinates(Measure)<-c("LON","LAT")
MinX<-min(coords[,1])
MinY<-min(coords[,2])
MaxX<-max(coords[,1])
MaxY<-max(coords[,2])
Seqx<-seq(MinX, MaxX, by=by)
Seqy<-seq(MinY, MaxY, by=by)
MSeqx<-rep(Seqx, length(Seqy))
MSeqy<-rep(Seqy, length(Seqx))
MSeqy <- sort(MSeqy, decreasing=F)
##Criação da planilha para execução no R
Grille <- data.frame(X=MSeqx, Y=MSeqy)
coordinates(Grille)=c("X","Y")
gridded(Grille)<-TRUE
##Extração do variograma com regressão automática para modelagem com
modelo de crescimento exponencial
v<-autofitVariogram(A~1,Measure,model = "Lin")
##Krigagem simples com R
prediction <-krige(formula=A~1, Measure, Grille, model="Lin")
##Saída de dados para o Qgis
result<-raster(prediction)
proj4string(Layer)->crs
proj4string(result)<-crs
Output<-result

```