



UNIVERSIDADE EDUARDO MONDLANE

FACULDADE DE AGRONOMIA E ENGENHARIA FLORESTAL

Mestrado em Maneio e Conservação da Biodiversidade

**MAPEAMENTO DA BIOMASSA LENHOSA DAS FLORESTAS
DE MIOMBO NA RESERVA NACIONAL DO NIASSA**

Autor:

Orlando Alexandre Macave

Supervisora:

Prof. Doutora Eng^a Natasha S. Ribeiro

Maputo, Abril de 2019

Mapeamento da Biomassa Lenhosa das Florestas de Miombo na Reserva Nacional do Niassa

Autor:

Orlando Alexandre Macave

Supervisora:

Prof. Doutora Eng^a Natasha S. Ribeiro

Dissertação apresentada à Universidade Eduardo Mondlane (UEM) - Faculdade de Agronomia e Engenharia Florestal (FAEF) como parte das exigências para obtenção do título de Mestre em Maneio e Conservação da Biodiversidade.

Maputo, Abril de 2019

DEDICATÓRIA

A

Toda

Minha

Família

Dedico

*"Quando a última árvore tiver caído,
Quando o último rio tiver secado,
Quando o último peixe for pescado,
Irão entender que dinheiro não se come".*

Greenpeace

AGRADECIMENTO

À força suprema, que cada religião designa por um nome diferente.

Este trabalho foi financiado pelo Fundo Nacional de Investigação (FNI) e pelo Fundo de Investigação Aplicada e Multisectorial (FIAM): Programa de cooperação Itália e Moçambique em coordenação com a Universidade Eduardo Mondlane (UEM). Por isso, aproveito este espaço para agradecer em especial as instituições supracitadas pelo apoio financeiro.

Agradeço a minha supervisora Prof. Doutora Natasha S. Ribeiro pelo trabalho prestado e pela paciência e disponibilidade imediata durante a elaboração deste trabalho. Agradeço também por incentivo e por todo apoio em fornecer material bibliográfico científico fundamental para a finalização deste projecto.

Agradeço ao dr Aniceto Chauque, Eng^o Sá Nogueira, Eng^o Arménio Cangela e a todos docentes do curso de Mestrado em Maneio e Conservação da Biodiversidade pelos ensinamentos transmitidos durante a formação.

O meu agradecimento vai também para os meus colegas do curso, meu brother Araújo, mana Julieta, cota Pires, brother Amadeu, a montante e jusante Angelina, Sean, Sara, Gildo, Natércia, Teófilo e Soto, por fazerem parte da minha formação académica.

Agradeço a todos meus amigos e pessoas próximas que me ajudaram a ultrapassar problemas durante a minha formação.

O meu agradecimento é extensivo para todos aqueles que directa ou indirectamente contribuíram para a realização deste trabalho.

A todos, o meu muito obrigado

O autor

ÍNDICE

<i>Conteúdos</i>	<i>páginas</i>
DEDICATÓRIA	I
AGRADECIMENTO	II
ÍNDICE DE TABELAS	V
ÍNDICE DE FIGURAS	VI
ÍNDICE DE FÓRMULAS	VII
LISTA DE ABREVIATURAS & ACRÓNIMOS	VIII
RESUMO	1
ABSTRACT	2
1. INTRODUÇÃO	3
1.1. Problema e Justificação do Estudo.....	5
1.2. Objectivos.....	6
1.2.1. Geral.....	6
1.2.2. Específicos:.....	6
2. REVISÃO BIBLIOGRÁFICA	7
2.1. Florestas de Miombo.....	7
2.1.1. Divisão do Miombo	8
2.1.2. Estrutura, composição e ecologia do Miombo.....	8
2.1.3. Floresta de Miombo em Moçambique	9
2.2. Biomassa florestal.....	10
2.3. Teledetecção	12
2.3.1. Fontes de energia	12
2.3.1.1. Espectro Eletromagnético.....	13
2.3.1.2. Energia Reflectida da Superfície Terrestre.....	14
2.3.2. Sistema óptico.....	14
2.3.3. Sistema radar.....	16
2.3.4. Satélites Landsat-8, ALOS PALSAR e Sentinel	18
2.3.4.1. Satélite Landsat-8	18
2.3.4.2. Satélite ALOS.....	20
2.3.4.2.1. ALOS 2/PALSAR 2	22
2.3.4.3. Sentinel	23
2.4. Teledetecção para estimativa de Biomassa e carbono florestal	25

3. DESCRIÇÃO DA ÁREA DE ESTUDO	27
3.1. Localização.....	27
3.2. Clima	28
3.3. Hidrologia.....	28
3.4. Relevo e solos.....	29
3.5. Vegetação e fauna	29
3.6. População humana dentro da Reserva Nacional do Niassa.....	31
3.7. Regime de queimadas.....	32
4. MATERIAIS E MÉTODOS	34
4.1. Aquisição de dados de satélite	34
4.2. Amostragem de campo e colheita de dados	36
4.3. Tratamento das imagens ópticas	38
4.4. Tratamento das imagens radar.....	39
4.5. Extracção de números digitais (ND)	40
4.6. Estimativa da biomassa lenhosa acima do solo (BLAS).....	41
4.7. Estimativa de estoque de carbono	43
4.8. Ajuste da equação espacial de biomassa	46
4.8.1. Combinação das variáveis.....	46
4.8.2. Selecção da melhor equação de biomassa	48
4.8.3. Comparação das melhores equações.....	50
5. RESULTADOS & DISCUSSÃO	54
5.1. Descrição estatística das variáveis espectrais.....	54
5.2. Biomassa e carbono florestal.....	57
5.2.1. Biomassa	57
5.2.2. Estoque de carbono florestal	62
5.3. Ajuste da equação de biomassa	64
5.3.1. Estatísticas de ajuste da equação espacial de biomassa	64
5.3.2. Comparação das equações	68
5.3.3. Distribuição gráfica dos resíduos.....	69
5.3.4. Equação seleccionada de biomassa.....	70
5.4. Mapa de densidade de biomassa e carbono florestal.....	72
6. CONCLUSÕES	74
7. RECOMENDAÇÕES	75
8. REFERÊNCIAS BIBLIOGRÁFICAS	76

ANEXOS	85
--------------	----

ÍNDICE DE TABELAS

<i>Conteúdos</i>	<i>Páginas</i>
Tabela 1: Comprimento de onda do sistema radar de abertura sintética	17
Tabela 2: Características do Landsat 8	19
Tabela 3: Características do sensor palsar	22
Tabela 4: Parâmetros dos modos de aquisição de Sentinel 1	24
Tabela 5: Aplicação dos modos de aquisição do Sentinel 1	24
Tabela 6: Descrição das bandas espectrais do Sentinel 2	25
Tabela 7: Descrição das imagens de satélites usadas no estudo	34
Tabela 8: Equações de regressão	42
Tabela 9: Estatística descritiva das variáveis espectrais	54
Tabela 10: Biomassa estimada em cada nível de cobertura florestal.....	59
Tabela 11: Carbono estimado em cada nível de cobertura florestal	62
Tabela 12: Estatísticas das equações.....	64
Tabela 13: Estatísticas da equação seleccionada	70

ÍNDICE DE FIGURAS

<i>Conteúdos</i>	<i>Páginas</i>
Figura 1: Distribuição do Miombo	7
Figura 2: Obtenção de imagens por sensoriamento remoto	12
Figura 3: Espectro das ondas eletromagnéticas segundo seu comprimento	13
Figura 4: Curva espectral da vegetação, da água e do solo	14
Figura 5: Satélite LANDSAT 8	18
Figura 6: Satélite ALOS com três sensores	20
Figura 7: Satellite Alos 2/Palsar 2	23
Figura 8: Mapa da Reserva Nacional do Niassa	27
Figura 9: Frequência de queimadas (2000-2012)	33
Figura 10: Mosaico das cenas	35
Figura 11: Mapa de índice de aridez na RNN	36
Figura 12: Localização dos pontos de amostragem	38
Figura 13: Cobertura de dossel da RNN.....	43
Figura 14: Diagrama de variáveis para o modelo para a biomassa	47
Figura 15: Fluxograma do trabalho e programas informáticos usados	52
Figura 16: índices de vegetação	55
Figura 17: Relação entre a intensidade de retroespalhamento e a biomassa estimada	56
Figura 18: Comparação da biomassa em diferentes áreas de estudo.....	60
Figura 19: Comparação gráfica das equações.....	68
Figura 20: Distribuição gráfica dos resíduos das equações	69
Figura 21: Diagrama de BLAS ao longo da linha de regressão	71
Figura 22: Mapa de densidade de BLAS e carbono florestal	73

ÍNDICE DE FÓRMULAS

<i>Conteúdos</i>	<i>Páginas</i>
Fórmula 1: Índice de aridez.....	36
Fórmula 2: NDVI	39
Fórmula 3: SAVI	39
Fórmula 4: SR	39
Fórmula 5 e 6: Filtro speckle	40
Fórmula 7: Intensidade de retroespalhamento.....	41
Fórmula 8: Peso seco total.....	42
Fórmula 9: Somatório do peso seco total.... ..	42
Fórmula 10: Cálculo de carbono.	43
Fórmula 11: Cálculo de carbono por classe de cobertura do dossel.....	43
Fórmula 12: Cálculo de carbono total.	43
Fórmula 13: Modelo linear	46
Fórmula 14: Coeficiente de determinação ajustado	48
Fórmula 15 e 16: Erro padrão da estimativa.....	49
Fórmula 17: Estatística F.....	49
Fórmula 18: Resíduos padronizados.....	50
Fórmula 19 e 20: Critério de informação de AIC.....	51

LISTA DE ABREVIATURAS & ACRÓNIMOS

AIC: Critério de Informação de Akaike

ALOS: Advanced Land Observing Satellite

AVNIR: Advanced Visible and Near Infrared Radiometer type

BLAS: Biomassa Lenhosa Acima do Solo

CEAGRE: Centro de Estudos de Agricultura e Gestão dos Recursos Naturais

CENACARTA: Centro Nacional de Cartografia e Teledeteccção

CO₂: Dióxido de Carbono

DAP: Diâmetro a Altura do Peito

ESA: Agência Espacial Europeia

FAO: Organização das Nações Unidas para Alimentação e Agricultura

FQ: Frequência de Queimadas

FUPEF: Fundação de Pesquisas Florestais

GIZ: German Society for Internacional Cooperation

GPS: Global Positioning System

GtC: Giga Toneladas de Carbono

ha: Hectares

IA: Índice de Aridez

IPCC: The Intergovernmental Panel on Climate Change

IR: Intensidade de Retroespalhamento

IV: Índice de Vegetação

JAXA: Japan Aerospace Exploration Agency

Km²: Quilómetro Quadrado

MRV: Monitoria Relatório e Verificação

MtCO₂: Megatoneladas de Carbono

NASA: National Aeronautics and Space Administration

NDVI: Índice de Vegetação por Diferença Normalizada

OLI: Operacional Terra Imager

PALSAR: Phased Array type L-band Synthetic Aperture Radar

PMA: Precipitação Média Anual

PRISM: Panchromatic Remote-Sensing Instrument for Stereo Mapping

PST: Peso Seco Total

REDD⁺: Redução de Emissões de Deflorestação e Degradação florestal

RNN: Reserva Nacional do Niassa

SADC: Comunidade de Desenvolvimento da África Austral

SAVI: Índice de Vegetação Ajustado ao Solo

SGDRN: Sociedade de Gestão e Desenvolvimento da Reserva de Niassa

SR: Índice de Vegetação da Razão Simples

tC/ha: Toneladas de Carbono por hectare

Tier 1: Dados Globais com Guião do IPCC

Tier 2: Dados Locais (Funções e Parâmetros Locais)

Tier 3: Modelos de Simulação (Parâmetros e Funções Nacionais)

USGS: United States Geological Survey

UEM: Universidade Eduardo Mondlane

UTM: Universal Transverse Mercator

VP: Valor Ponderado

WGS84: World Geodetic System 1984

WWF: Fundo Mundial para a Natureza

RESUMO

A estimativa de biomassa ao nível da paisagem é crucial para a monitorização do carbono florestal, principalmente para países com o objectivo de mitigar os efeitos das mudanças climáticas e que desejam abordar convenções internacionais e aceder a mecanismos financeiros baseados na redução da emissão de carbono. A Reserva Nacional de Niassa (RNN) é a maior área (42000 km²) de conservação de Miombo na África Austral com elevada diversidade biológica, tornando-a uma área chave de conservação candidata para o desenvolvimento iniciativas MRV REDD+. Este trabalho teve como objectivo estimar a biomassa lenhosa acima do solo (BLAS) e estimar o potencial do carbono armazenado na RNN usando dados de teledetecção calibrados com dados de campo. Para o alcance dos objectivos do trabalho, imagens ALOS 2/PALSAR 2 ($\sigma^{\circ}\text{HH}$ e $\sigma^{\circ}\text{HV}$ banda L-SAR ~23.6 cm), SENTINEL 1B ($\sigma^{\circ}\text{VV}$ e $\sigma^{\circ}\text{VH}$ banda C-SAR ~ 5.7 cm) e 2A (NDVI, SAVI e SR) e LANDSAT 8/OLI (NDVI, SAVI e SR) que cobrem a RNN foram adquiridas. Para aquisição dos dados de campo, 24 parcelas de 1ha (100 m x 100 m) foram estabelecidas em função do índice de aridez (IA) e frequência de queimadas (FQ) através da amostragem aleatória estratificada. Os dados de diâmetro a altura do peito (DAP) obtidos nas parcelas foram usados para estimar a BLAS (t·ha⁻¹) usando a seguinte equação de regressão $\text{PST}_{(\text{Kg/arv})} = \exp[-2.134 + 2.530 \cdot \ln(\text{DAP})]$, desenvolvida para as florestas de Miombo. O conteúdo de carbono foi obtido pela multiplicação da biomassa pelo *default* de 0.5. Os dados espectrais de radar e ópticos foram extraídos numa janela de 100 m x 100 m. Para desenvolver a equação linear múltipla com variáveis espectrais a técnica de regressão Stepwise (*forward*) a 95% de significância ($\alpha = 0.05$) foi utilizada. A selecção da melhor equação espacial baseou-se nas estatísticas de coeficiente de determinação ajustado ($R^2_{aj.}$), erro padrão da estimativa (S_{yx}), estatística F , critério de informação de Akaike (AIC), valor ponderado (VP) e distribuição gráfica dos resíduos. Os resultados obtidos mostram que os dados ópticos combinados com radar são bons previsores de BLAS. A melhor equação de regressão foi $\text{BLAS}_{(\text{t/ha})} = 126.5 - 151.4 \text{NDVI1} + 250.1 \text{NDVI2} + 6.63 \sigma^{\circ}\text{HV} + 2.83$, com $R^2_{aj.}$ de 0.88, $S_{yx\%}$ de 12%, F de 18.9, VP de 3 e AIC de 123. A BLAS média estimada em cada classe de cobertura de dossel foi de 25.5 t·ha⁻¹ (10% - 25%), 59.6 t·ha⁻¹ (25% - 50%), 71.0 t·ha⁻¹ (50% - 75%) e 84.0 t·ha⁻¹ (75% - 100%). O estoque de carbono médio nas mesmas classes de cobertura foi estimado em 12.7 tC·ha⁻¹, 29.8 tC·ha⁻¹, 35.5 tC·ha⁻¹ e 42.0 tC·ha⁻¹, respectivamente. A BLAS e estoque de carbono médio total para a toda área da RNN foi de 55 t·ha⁻¹ (11 t·ha⁻¹ e 95 t·ha⁻¹) e 27.5 tC·ha⁻¹, respectivamente. De modo geral os resultados deste estudo revelam que os dados ópticos e radar são melhores substitutos de dados primários ou dados de campo, por outro lado as estimativas obtidas mostram que a RNN é um grande reservatório do carbono florestal. Portanto recomenda-se que o sistema de manejo da RNN esteja também focado no manejo da vegetação, queimadas e actividades humanas e não apenas na vida selvagem. A implementação de iniciativas de REDD+ vai permitir uma melhor gestão dos recursos florestais e criação de renda para as comunidades locais, reduzindo a degradação florestal, permitindo com que maiores quantidades de BLAS e estoque de carbono sejam mantidos a longo prazo.

Palavras-chave: Teledetecção, Ajuste de equação espacial, Biomassa e Carbono.

ABSTRACT

Landscape biomass estimation is important for forest carbon monitoring, especially for developing countries wishing to address international conventions and access to carbon-based financial mechanisms associated with mitigation of climate change. The Niassa National Reserve (NNR ~ 42000 km²) is largest conservation area in Southern Africa, making it a key conservation area candidate for developing MRV REDD + initiatives. The main goal of this study was to estimate above-ground biomass (AGB) and carbon potential reserved in the RNN using field-calibrated remote sensing data. In order to achieve the objectives of the study, the images ALOS 2 / PALSAR 2 (σ° HH and σ° HV band L-SAR ~ 23.6 cm), SENTINEL 1B (σ° VV and σ° VH band C-SAR ~ 5.7 cm) and 2A (NDVI, SAVI and SR) and LANDSAT 8 / OLI (NDVI, SAVI and SR) which cover the RNN were acquired. For the acquisition of the field data, 24 plots of 1 ha (100 m x 100 m) were established according to the aridity index and fire frequency (FF). The DBH data was used to estimate the AGB (t·ha⁻¹) in each plot using an allometric equation ($WD_{(kg/tree)} = \exp[-2,134 + 2,530 \cdot \ln(DAP)]$) developed for Miombo woodlands. The carbon stock was estimate by multiplying AGB by 0.5 *default*. To select the best model of the spatial biomass were used the following criterion: adjusted R-squared (R²) Fisher statistic (F), Akaike information criterion (AIC), weighted value (WV) and graphical distribution of residues. The results show that the optical data combined with radar are good predictors of AGB. The best selected equation was $AGB_{(t/ha)} = 126.5 - 151.4 NDVI1 + 250.1 NDVI2 + 6.63 \sigma^{\circ}HV + 2.83$, with $R^2_{aj} = 0.88$, $S_{yx}\% = 12$, $F = 18.9$, $WV = 3$ and $AIC = 123$. The estimated AGB at each level of canopy cover was 25.5 t·ha⁻¹ (10% - 25%), 59.6 t·ha⁻¹ (25% - 50%), 71.0 t·ha⁻¹ (50% - 75%) and 84.0 t·ha⁻¹ (75% - 100%). The carbon stock in the same coverage classes was estimated at 12.7 tC·ha⁻¹, 29.8 tC·ha⁻¹, 35.5 tC·ha⁻¹ and 42.0 tC·ha⁻¹ respectively. The AGB and average carbon stock was 55 t·ha⁻¹ (11 t·ha⁻¹ and 95 t·ha⁻¹) and 27.5 tC·ha⁻¹ respectively. In general the results of this study reveal that optical data and radar are better substitutes for primary data or field data, on the other hand the estimates obtained show that the RNN is a great power in sequestering and storing carbon. Based on the results it is recommended that the RNN management system be also focused on the management of vegetation, fires and human activities, not just wildlife. On other hand implementing REDD + initiatives will enable better management of forest resources and income creation for local communities, reducing forest degradation, allowing for greater amounts of carbon stock and AGB to be maintained over the long term.

Keywords: Remote sensing, allometric equations, Biomass and Carbon.

1. INTRODUÇÃO

As florestas desempenham um papel importante no ciclo global de carbono pela capacidade de fixar o dióxido de carbono (CO₂) através do processo da fotossíntese, que mantêm grandes quantidades de carbono armazenado na biomassa em diferentes compartimentos da planta (Brown, 2002). Por isso, as florestas têm assumido cada vez mais importância nos esforços internacionais para a mitigação das mudanças climáticas (IPCC, 2007). Deste modo a Convenção-Quadro das Nações Unidas para as Mudanças Climáticas (UNFCCC) exige que os países assumam o compromisso de elaborar e actualizar periodicamente os inventários nacionais de biomassa e do carbono sequestrado pelas florestas (Fehrmann e Kleinn, 2005).

As florestas de Miombo são o maior ecossistema florestal seco da África Subsaariana com uma extensão de aproximadamente 2.7 milhões de km² distribuídos em sete países (WWF, 2012), e constitui base de sustento para mais de 90% dos cerca de 690 milhões de habitantes desta região que vivem com menos de 1 dólar por dia (FAO, 2008). De facto, estas florestas contribuem para o desenvolvimento socioeconómico das comunidades rurais através da exploração e comercialização de produtos florestais não madeireiros, tais como lenha e carvão (Chidumayo, 2013).

De acordo com GIZ (2014) as perdas florestais registadas anualmente na floresta de Miombo da região da África Austral durante o período de 2005-2012 atingiram cerca de 0,46% por ano, dando origem a elevadas perdas de biomassa e às consequentes emissões de carbono. Estima-se que a região da SADC seja responsável por metade das perdas de carbono de biomassa em África, devido ao desmatamento (GIZ, 2014). Embora tanto a extensão da mudança de cobertura florestal como as causas do desmatamento variem entre os diferentes países, a mudança de cobertura florestal resulta sobretudo da expansão agrícola, da produção de energia de biomassa e de actividades de exploração madeireira (FAO, 2010).

Face a esta situação, os países da África Austral têm um elevado potencial para participarem no programa de Redução das Emissões por Desmatamento e Degradação florestal (REDD+) (GIZ, 2014), um mecanismo de financiamento que está a ser desenvolvido a nível internacional destinado a compensar os países em desenvolvimento por medidas tomadas para impedir o desmatamento e a degradação das florestas (Siteo *et al.*, 2013).

Moçambique é um dos países da África Austral que ainda apresenta uma área considerável de cobertura florestal, com cerca de 34 milhões de hectares (Wertz-Kanounnikoff *et al.*, 2011). Porém apresenta elevadas taxas de desmatamento e degradação florestal (Siteo *et al.*, 2012). CEAGRE e Winrock International (2016) utilizando a informação de mapas globais de Hansen *et al.* (2013) estimaram a taxa de desmatamento em 138 mil hectares por ano (0.23%).

Perante essa situação, o País viu a necessidade de desenvolver fortemente as estratégias do mecanismo REDD+ com objectivo de conservar as florestas e aumentar as reservas de carbono nos ecossistemas (Nhantumbo *et al.*, 2013). O objectivo final da estratégia é de promover um desenvolvimento sustentável, maior resiliência às mudanças climáticas, desenvolvimento rural integrado, através de um conjunto de acções com enfoque nos sectores de florestas, agricultura e energia (Winrock International, 2016).

Entretanto, para que o país participe no mecanismo REDD+, tem de cumprir uma série de requisitos. O pré-requisito para a configuração de um programa participativo REDD + é o monitoramento, reporte e verificação (MRV) da biomassa e estoques de carbono da linha de base e suas mudanças ao longo do tempo (Siteo *et al.*, 2013 e Ribeiro *et al.*, 2013).

Segundo Siteo *et al.* (2013), durante a fase de implementação de REDD+, o país deverá passar da utilização de dados globais, aplicando o guião do IPCC (*Tier 1*) para utilização de dados locais, funções e parâmetros nacionais de implementação de REDD+ (*Tier 2*) como um dos requisitos mínimos para quantificação da biomassa e monitoramento dos estoques de carbono. Contudo, a implementação de modelos de simulação e implementação dos mecanismos por desempenho de REDD+ (*Tier 3*) deve ser levado em conta para melhorar a MRV das actividades de REDD+ (IPCC, 2007).

Dada a importância de pesquisas de estimativa de biomassa ao nível da paisagem e necessidade de desenvolver funções e parâmetros nacionais e implementação de REDD+, optou-se em desenvolver este estudo na Reserva Nacional do Niassa (RNN) como forma de contribuir para a comunidade científica em fornecimento de dados locais e funções que permitam estimar a biomassa acima do solo (BLAS) e o carbono florestal, contribuindo assim para que o país passe dos parâmetros globais de estimativas (*Tier 1*) para parâmetros nacionais, na planificação de implementação das actividades de REDD+ (*Tier 2*), para além de fornecer informação relevante na gestão de ecossistemas florestais na RNN.

1.1. Problema e Justificação do Estudo

A RNN é a mais extensa área de conservação de Miombo no País, representando 36% da área de conservação no País (Ribeiro *et al.*, 2008). Possui elevada diversidade biológica que inclui mais de 800 espécies de plantas, metade das quais endémicas, várias espécies faunísticas e acima de 400 espécies de pássaros, algumas das quais em perigo de extinção. Dentro da RNN encontram-se distribuídas várias aldeias, formando no total cerca de 45.000 habitantes, sendo que todos dependem da agricultura de sequeiro, caça, pesca e exploração dos recursos florestais (Cunliffe, 2014).

O crescimento acelerado da população na RNN acompanhado pela expansão das áreas agrícolas e pelo uso descontrolado do fogo para a limpeza dos campos agrícolas, caça furtiva, extracção do mel e secagem do peixe (Cangela, 2014) ameaça a biodiversidade e integridade da Reserva, colocando em risco os objectivos da conservação (Ribeiro *et al.*, 2008). Por outro lado a RNN além de ser remota tem dados limitados, dificultando o entendimento do papel exacto da reserva na conservação da biodiversidade, implementação do mecanismo REDD+ e manejo de ecossistemas florestais.

A extinta Sociedade de Gestão da Reserva de Niassa (SGDRN) iniciou juntamente com a Universidade Eduardo Mondlane (UEM), em 2004, um programa de investigação com vista a apoiar as actividades de manejo e conservação dos ecossistemas florestais baseada na gestão e monitoria das queimadas e dos habitats a partir do mapeamento à escala da paisagem. Neste contexto foi elaborado o mapa de biomassa por Ribeiro *et al.* (2008), que apresentava as lacunas devido a saturação de *pixels*, e que para efeitos de determinação das potencialidades da RNN no âmbito do programa REDD+ deveria ser actualizado.

Conforme o recomendado por Ribeiro *et al.* (2008) e Ribeiro *et al.* (2013) este estudo pretende dar seguimento ao trabalho e actualizar o mapa de biomassa e carbono florestal a escala da paisagem através da integração das variáveis espectrais dos sensores ópticos e radares, uma vez que estudos do género são escassos e incipientes. Pretende-se também com este estudo fornecer uma equação alométrica de biomassa ajustada ao nível da paisagem com dados de teledeteccção.

A escolha da RNN deve-se ao facto de ser a maior área de conservação de Miombo na África Austral, com alta diversidade biológica e provavelmente com um grande repositório de carbono,

tornando-a como uma área chave de conservação candidata para desenvolver um sistema de monitoria, relatório e verificação (MRV) das actividades de REDD+.

1.2. Objectivos

1.2.1. Geral:

Mapear a biomassa lenhosa na Reserva Nacional do Niassa por forma a contribuir para o manejo da biodiversidade e para a implementação do mecanismo REDD+.

1.2.2. Específicos:

Para alcançar o objectivo geral, definiu-se os seguintes objectivos específicos:

- a) Estimar a biomassa lenhosa e estoque de carbono acima do solo das florestas de Miombo com base em equação alométrica;
- b) Ajustar a equação de regressão de biomassa a partir de variáveis espectrais de sensores ópticos e radar;

2. REVISÃO BIBLIOGRÁFICA

2.1. Florestas de Miombo

A palavra “Miombo” provém de várias línguas faladas no centro da África e denota uma ou mais espécies do género *Brachystegia*, *Julbernardia*, e *Isoberlinia* (Família Fabacea e Subfamília Caesalpinioideae) como sendo as mais abundantes da região. Existem 21 espécies de *Brachystegia* em Miombo e três espécies em cada um dos géneros relacionados (White 1983). A floresta de Miombo é a floresta tropical sazonal mais extensa em África, cobrindo cerca de 2,7 milhões de km² em regiões com mais de 700 mm de precipitação média anual e em solos pobres em nutrientes (Campbell *et al.*, 1995, Frost 1996). Segundo White (1983), o Miombo abrange sete países da África: Angola, Zimbábwe, Zâmbia, Malawi, Moçambique, Tanzânia e uma parte do Sul da República Democrática do Congo (RDC) (Figura 1).

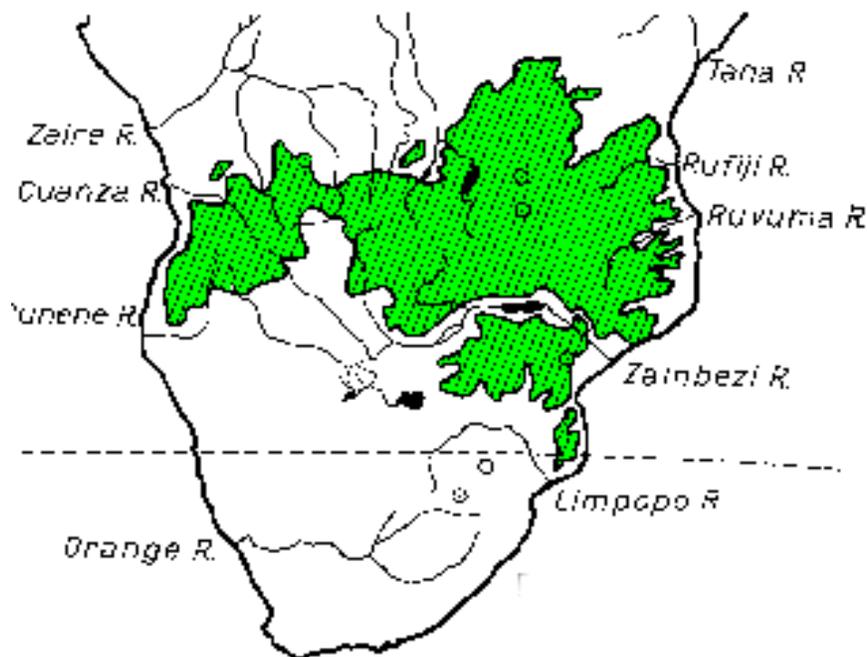


Figura 1: Distribuição de Miombo na África Austral

Fonte: Campbell *et al.* (1995) citado por GIZ (2014)

2.1.1. Divisão do Miombo

Para Ribeiro *et al.* (2002) de acordo com precipitação, o Miombo subdivide-se em húmido e seco. O Miombo húmido é mais frequente no oeste de Angola, norte de Zâmbia, sudoeste da Tanzânia e a zona central de Malawi, em áreas com precipitação média anual superior a 1000 mm. Esta subdivisão também ocorre em Moçambique, embora muito pouco frequente, pode ser encontrado em Gurué na província da Zambézia e em algumas províncias como Nampula e Cabo Delgado. Floristicamente é mais rico que o Miombo seco, e nele podem ser encontradas quase todas as espécies do Miombo. O Miombo seco ocorre no sul de Malawi, Zimbabwe e Moçambique, em áreas com uma precipitação média inferior a 1000 mm/ano, apresentando uma diversidade florística menor que o Miombo húmido.

2.1.2. Estrutura, composição e ecologia do Miombo

Apesar de ocorrer em regiões com poucos nutrientes, estação seca prolongada e baixa precipitação em algumas áreas, a floresta de Miombo é abrigo de muitas espécies, incluindo várias espécies de aves endémicas exclusivas do Miombo. Ela também fornece alimentação e abrigo a mamíferos como o elefante (*Loxodonta africana*), rinoceronte (*Diceros bicornis*) leão (*Panthera leo*) búfalo (*Syncerus caffer caffer*) leopardo (*Panthera pardus*) impala (*Aepyceros melampus johnstoni*) e zebra (*Equus burchelli boehmi*) (WWF, 2012).

Conforme as variações topográficas e fisiográficas, a estrutura e composição do Miombo são modificadas pelo clima, solo e altitude, distinguindo-se de uma região para outra. A vegetação é dominada por árvores de folha larga sem espinho, da subfamília *Caesalpinioideae*, mas a vegetação herbácea é dominada por espécies da família *Andropogoneae*. O estrato arbustivo é geralmente ausente e descontínuo. Uma das características principais de Miombo é a sua aparente uniformidade em vastas regiões, devido à fisionomia semelhante das espécies dominantes da subfamília *Caesalpinioideae* (Pereira, 2002).

O crescimento das árvores em geral é lento tornando-se mais significativo a partir dos 8 anos de idade. O incremento do diâmetro do tronco e da copa em povoamentos jovens é maior do que em povoamentos adultos. A produção primária líquida anual das florestas de Miombo ronda entre 900 a 1600 g/m² e o incremento médio anual da biomassa estimado em 3 a 4% (Campbell *et al.*, 1995).

Segundo White (1983) o clima do Miombo é marcado por duas estações separadas, onde mais de 95% das chuvas ocorrem de 5 a 7 meses, com um verão quente e húmido, o que resulta numa estação onde se concentram as actividades de produção lenhosa, crescimento, reprodução e decomposição, isto é, geralmente de Novembro a Abril. Cinco estações fenológicas podem ser distinguidas no Miombo: estação quente-seca antes das chuvas, início da estação chuvosa, meio da estação chuvosa, estação chuvosa tardia e estação fria e seca. A maioria das espécies são decíduas e produzem novas folhas antes das chuvas, usando substâncias de reservas internas. O aparecimento de novas folhas marca o início da estação de crescimento e ocorre geralmente 2 a 3 meses antes de início da estação chuvosa (Ribeiro *et al.*, 2002).

Em geral, as folhas caem entre Julho-Agosto no Miombo seco e entre Agosto-Setembro, no Miombo húmido fazendo com que 91% da produção da biomassa vegetal morta esteja concentrada durante a época seca, entre os meses de Maio a Outubro. O aparecimento das folhas regista-se 2-4 semanas após o início das primeiras chuvas. A floração tem lugar entre Setembro a Outubro, com a excepção do género *Julbernardia* que floresce entre Novembro a Abril (Ribeiro *et al.*, 2002).

2.1.3. Floresta de Miombo em Moçambique

Em Moçambique assim como nos outros Países, a estrutura e composição de Miombo são modificadas pelo clima, solo e altitude, distinguindo-se de uma região para outra. Em Moçambique o Miombo húmido é dominado por *Brachystegia spiciformis* com alturas de 15 a 22 m, ocorrendo em simultâneo com as florestas semi-decíduas mesoplanálticas de *Pteleopsis sp.*, *Erythrophleum sp.* e *Newtonia sp.* (Marzoli, 2007e Ribeiro *et al.*, 2013).

O Miombo húmido ocorre em regiões altas das províncias de Manica e Zambézia com altitude superior a 1000 m e precipitação média anual que varia de 1200 a 1800 mm (Ribeiro *et al.*, 2002). O Miombo semi-decíduo ocorre nas regiões de baixa altitude e precipitação entre 800-1200 mm. Ambos são dominados pela *Brachystegia spiciformis* e *Julbernardia globiflora* e várias espécies de valor económico tais como: *Pterocarpus angolensis*, *Swartzia madagascarensis* e *Millettia stuhlmanii*. O Miombo decíduo é típico das zonas de baixa altitude e precipitações médias anuais entre 600 a 800 mm, representando a vegetação mais dominante em Moçambique (Marzoli, 2007).

2.2. Biomassa florestal

O termo "biomassa" refere-se à matéria (massa) de organismos vivos (bio), incluindo plantas, animais e micro-organismos (ou de um ponto de vista bioquímico: celulose, lignina, açúcares, gorduras, proteínas) (Pereira, 2016). Segundo Brown *et al.* (1989) a biomassa quando é expressa por unidade de área é denominada por densidade de biomassa. O mesmo autor acrescenta a definição da biomassa dizendo que é a quantidade constituída por organismos no ecossistema florestal em termos de massa.

A biomassa de uma espécie vegetal, ou grupo de espécies, ou comunidade, é o conteúdo total de matéria orgânica viva presente em um dado local em determinado tempo (Pereira, 2016). Isto inclui tanto a biomassa que está acima da superfície do solo, como a que está abaixo. A biomassa acima do solo (AGB, do inglês *above-ground biomass*) é definida como toda a biomassa vegetal viva lenhosa e herbácea acima do solo incluindo o caule, troncos, galhos, cascas, sementes e folhagens (IPCC, 2007).

Os estudos de biomassa florestal tornaram-se hoje objecto de especial interesse público, sobretudo por causa das relações entre a biomassa florestal e o carbono atmosférico, e deste com as mudanças climáticas. Com efeito, a biomassa vegetal, incluindo as partes acima e abaixo do solo, é a principal via para remoção de CO₂ da atmosfera através dos processos da fotossíntese e respiração (IPCC, 2007).

No processo de fotossíntese, a vegetação absorve e armazena na matéria orgânica produzida grande parte do carbono atmosférico, contribuindo assim para atenuar o efeito estufa e retardar as mudanças climáticas em curso (IPCC, 2007). Porém, os estudos e estimativas de biomassa florestal não se limitam a este aspecto, nem possuem esta única finalidade. Pois os serviços gerados pelas florestas não se reduzem ao sequestro e armazenamento do CO₂ atmosférico (nem ao fornecimento de madeira e celulose para as indústrias). O estudo e o monitoramento das florestas com vistas à sua conservação e preservação, são necessários por outras razões também: desde a sobrevivência de inúmeras espécies vegetais e animais, até a sobrevivência de incontáveis comunidades humanas que vivem integradas aos ecossistemas florestais. As maiores incertezas sobre biomassa florestal e taxas de desflorestamento são relativas às florestas tropicais, indicando a necessidade de estudos mais detalhados nestas áreas (Pereira, 2016).

De acordo com IPCC (2014) a maior percentagem de biomassa em uma espécie florestal encontra-se na componente fuste (madeira e casca). Porque, durante a fase inicial de desenvolvimento de uma floresta, uma grande parte de carboidratos é canalizada para a produção de biomassa da copa. Posteriormente, quando as copas começam a competir entre si, a produção relativa de fuste aumenta e a de folhas e ramos diminui gradativamente (Pereira, 2016).

Para estimar a biomassa em florestas tropicais requer um amplo conjunto de dados provenientes de estudos ecológicos que mensuram a biomassa directamente (IPCC, 2014). Estas medições podem ser realizadas por diferentes métodos (directo e indirecto). O método directo, moroso e destrutivo, consiste em delimitar parcelas e efectuar o desbaste de todos os indivíduos pertencentes à parcela para posterior tratamento e pesagem, sendo feita em seguida a extrapolação destes resultados para a área total de interesse (Brown *et al.*, 1989). Ou então emprega-se o método por amostragem de indivíduos, seleccionados segundo a espécie e conforme o seu diâmetro a altura do peito (DAP), de modo a representarem todas as classes de diâmetro daquela espécie encontradas na área pesquisada. Os indivíduos assim seleccionados são medidos e coletados para posterior tratamento e pesagem (Siteo e Tchaúque, 2007).

Para o caso do método indirecto, os modelos de regressão são aplicados aos indivíduos estruturalmente mensurados dentro de parcelas representativas com tamanho delimitado. Para elaborar os modelos de regressão utilizados em estimativas da biomassa pode-se empregar diversas variáveis estruturais, tais como: DAP, altura, densidade da madeira, área basal, área da copa, diâmetro médio da copa, volume do cone ou combinações destas variáveis (Siteo e Tchaúque, 2007; Pereira, 2016).

Segundo a IPCC (2007) cerca de 50% de biomassa é constituída por carbono que se encontra armazenado em diferentes compartimentos da planta. As quantidades de carbono armazenado e as taxas entre biomassa viva e carbono no solo são determinadas pelo solo, clima e tipo de floresta (Campos, 2001). Contudo, em muitos casos, os estoques de carbono em florestas naturais pode mudar sem uma mudança na área florestal, causada pela perda de biomassa associada à colheita selectiva de madeira, fragmentação florestal, queimadas e agricultura itinerante.

2.3. Teledetecção

Teledetecção ou sensoriamento remoto é uma tecnologia que permite obter imagens e outros tipos de dados, da superfície terrestre, através da captação e do registo da energia refletida ou emitida pela superfície (Aronoff, 1989). O termo teledetecção refere-se à obtenção dos dados a uma distância, ou seja, sem o contacto físico entre o sensor e a superfície terrestre (Elachi, 1987). A figura 2 mostra o processo de obtenção de dados da superfície terrestre pelos sensores dos satélites.

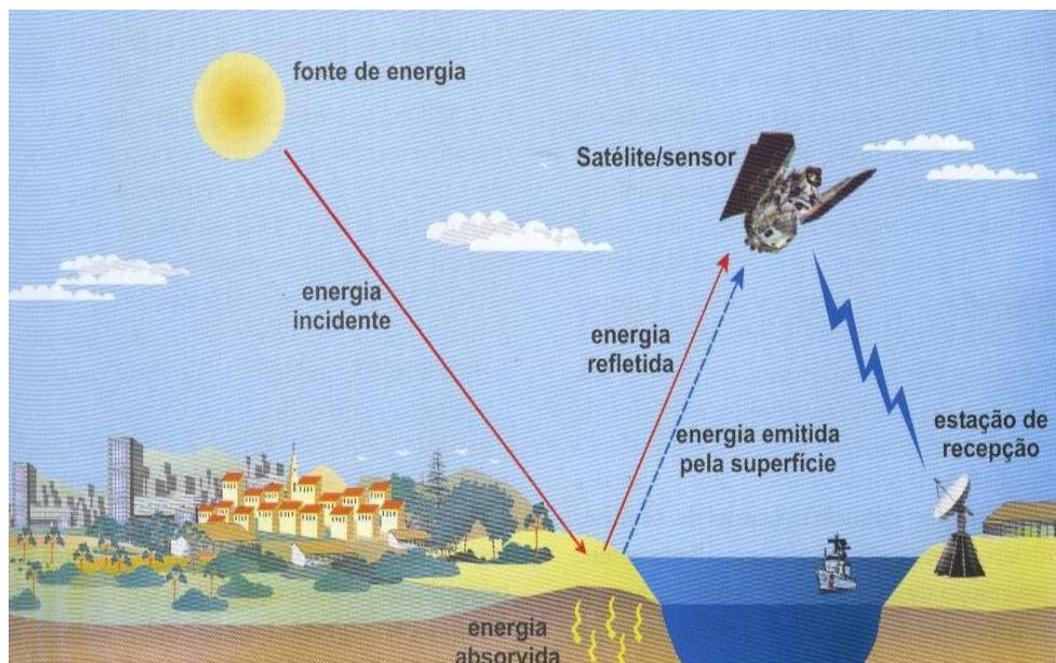


Figura 2: Obtenção de imagens por teledetecção

Fonte: Elachi (1987)

2.3.1. Fontes de energia

Qualquer actividade requer o uso de energia, assim como para a obtenção de dados por teledetecção. A energia com a qual operam os sensores remotos pode ser proveniente de uma fonte natural, como a luz do sol e o calor emitido pela superfície da Terra, e pode ser de uma fonte artificial como, por exemplo, a do *flash* utilizado em uma máquina fotográfica e o sinal produzido por um radar. A energia utilizada em teledetecção é a radiação eletromagnética, que propaga em forma de ondas eletromagnéticas com a velocidade da luz (300.000km/s) (Marques, 2015). Ela é medida em frequência (em unidades de hertz – Hz), e comprimento de onda (em unidades de

metro). A frequência de onda é o número de vezes que uma onda se repete por unidade de tempo. Dessa maneira, quanto maior for o número, maior será a frequência e, quanto menor, menor será a frequência de onda (Aronoff, 1989).

Segundo Congalton e Green (2009) o comprimento de onda é a distância entre dois picos de ondas sucessivos: quanto mais distante, maior é o comprimento e, quanto menos distantes, menor será o comprimento de onda. A frequência de onda é directamente proporcional à velocidade de propagação e inversamente proporcional ao comprimento de onda.

2.3.1.1. Espectro Eletromagnético

O espectro eletromagnético representa a distribuição da radiação eletromagnética, por regiões, segundo o comprimento de onda e a frequência. O espectro eletromagnético abrange desde curtos comprimentos de onda, como os raios cósmicos e os raios gama (γ), de alta frequência, até longos comprimentos de onda como as ondas de rádio e TV de baixa frequência. Na região do espectro visível, o olho humano enxerga a energia (luz) eletromagnética, sendo capaz de distinguir as cores do violeta ao vermelho. A radiação do infravermelho (aquela do calor) é subdividida em três regiões: infravermelho próximo (0,7-1,3 μm), médio (1,3-6,0 μm) e distante ou termal (6,0-1000 μm) (Aronoff, 1989).

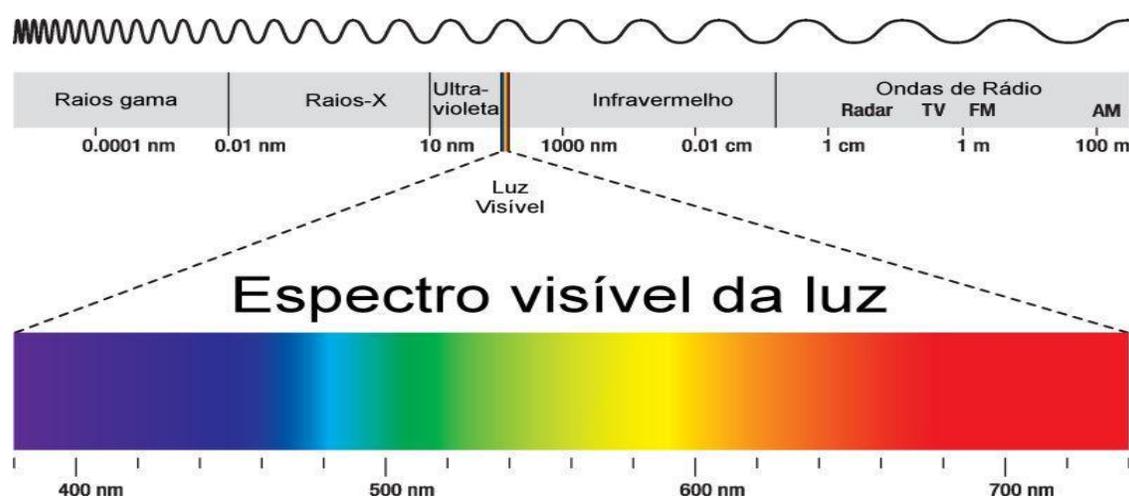


Figura 3: Espectro das ondas eletromagnéticas segundo seu comprimento

Fonte: Furian (2014)

2.3.1.2. Energia Refletida da Superfície Terrestre

De acordo com Aronoff (1989) os objectos da superfície terrestre como a vegetação, a água e o solo refletem, absorvem e transmitem radiação eletromagnética em proporções que variam com o comprimento de onda, de acordo com as suas características bio-físico-químicas. A variação da energia refletida pelos objectos pode ser representada através de curvas, como as mostradas na figura 4. Devido a essas variações, é possível distinguir os objectos da superfície terrestre nas imagens de sensores remotos. A representação dos objectos nessas imagens vai variar do branco (quando reflectem muita energia) ao preto (quando refletem pouca energia).

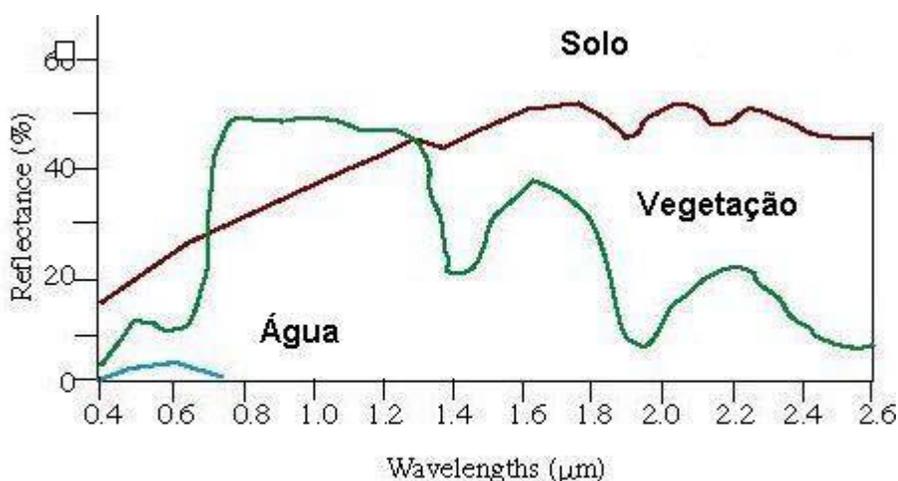


Figura 4: Curva espectral da vegetação, da água e do solo

Fonte: Coura (2007)

2.3.2. Sistema óptico

Sistemas ópticos funcionam nos comprimentos de onda do visível e infravermelho do espectro eletromagnético registrando a energia refletida pela vegetação. A energia refletida é igual à energia incidente menos a energia absorvida e transmitida pela superfície foliar da planta (Aronoff,1989). A interação da vegetação com a energia eletromagnética está relacionada, principalmente, com o processo de fotossíntese. Este processo é fundamentado na absorção da energia luminosa do sol, especificamente nos comprimentos de onda de 0,4 a 0,72 μm no visível, por parte dos pigmentos fotossintetizantes como as clorofilas. Já nos comprimentos de onda de 0,72 a 2,6 μm no infravermelho, a reflectância é controlada pelo mesófilo esponjoso e conteúdo de água foliar

(Pereira, 2016). Dessa forma, o estudo das características espectrais de um tipo vegetal pode ser útil na identificação do estresse vegetal, produtividade, fenologia e identificação de espécies (Shimada *et al.*, 2006).

Para estudos do Miombo, imagens de sensores ópticos são utilizadas em diversas abordagens, tais como: distribuição e mapeamento de áreas de Miombo (Campbell *et al.*, 1995), mapeamento e estimativa de parâmetros estruturais e biomassa (Coura, 2007), avaliação e estimativa de índice de área foliar (Ribeiro *et al.*, 2008), avaliação de mudanças e monitoramento (Aronoff, 1989).

Os dados dos sensores ópticos em muitos casos são transformados em índices de vegetação (IV). Os IV baseados em dados de reflectância espectral foram desenvolvidos para estimar propriedades biofísicas como a biomassa, índice de área foliar (IAF) e percentagem de cobertura de dosséis vegetais (Tucker, 1979). Os IV gerados a partir de dados oriundos de sensores remotos constituem uma importante ferramenta para o monitoramento de alterações naturais ou antrópicas na cobertura da terra. Vários índices de vegetação que são encontrados na literatura representam os esforços para medir parâmetros biofísicos da vegetação. Os índices são algoritmos que utilizam os valores de reflectância e resultam em uma medida radiométrica adimensional que indica a abundância relativa e a actividade da vegetação verde (Howard, 1991).

Um dos exemplos da aplicação dos IV é na determinação do índice de área foliar (Holben *et al.*, 1980), bem como na avaliação do uso e manejo do solo e da recuperação de áreas degradadas (Tucker, 1979). Um índice ideal deve maximizar a sensibilidade de parâmetros biofísicos, normalizar efeitos externos, como ângulo solar, ângulo de visada do sensor, efeitos atmosféricos e normalizar efeitos internos como topografia, solo e a diferença entre vegetação (Howard, 1991). Existem vários índices utilizados em estudos científicos de análise da variabilidade da vegetação, porém alguns índices de vegetação mais aplicados nos estudos científicos e que foram aplicados no presente estudo estão descritos abaixo, segundo (Holben *et al.*, 1980):

a) Índice de vegetação por diferença normalizada – NDVI

O índice de vegetação por diferença normalizada (NDVI) é uma relação entre medidas espectrais (reflectância - r) de duas bandas, a do infravermelho próximo (800-1100 nm) e a do vermelho (600-700 nm), e visa eliminar diferenças sazonais do ângulo do Sol e minimiza os efeitos da atenuação atmosférica (Holben *et al.*, 1980).

b) Índice de vegetação ajustado ao solo - SAVI

O SAVI foi um índice desenvolvido com o objetivo de melhorar os valores de NDVI sem necessidades de medições em campo para cada área de análise e elaborada uma constante L, que representa o factor de ajuste para o substrato do dossel. L é uma constante denominada de factor de ajuste do índice SAVI, podendo assumir valores de 0,25 a 1 dependendo da cobertura do solo. O valor para L de 0,25 é indicado para vegetação densa e de 0,5 para vegetação com densidade intermediária, quando o valor de L for 1 para vegetação com baixa densidade. Se o valor do SAVI for igual a 0, seus valores tornam-se iguais aos valores do NDVI. Portanto O valor de L mais utilizado é 0,5 (Haripriya, 2000).

c) Índice de vegetação da razão simples – SR

O índice de vegetação da razão simples é utilizado na teledetecção para avaliar e caracterizar a superfície terrestre (Jordan, 1969), esse índice é obtido a partir da divisão entre as bandas do infravermelho próximo e do vermelho, sendo que no infravermelho próximo os valores radiométricos aumentam com o aumento da vegetação enquanto no vermelho os valores radiométricos descem com o aumento da vegetação (Haripriya, 2000).

2.3.3. Sistema radar

Desde a década de 70, as imagens de radar vêm sendo utilizadas para o reconhecimento e mapeamento geológico e estimativa da biomassa, especialmente em regiões de difícil acesso. A principal vantagem de radar é a capacidade de adquirir imagens independentemente da presença de nuvens ou fumaça (JAXA, 2007). O termo *RADAR* é um acrónimo da expressão inglesa *Radio Detection and Ranging* e refere-se a um dispositivo sensor capaz de detectar alvos através da indicação da sua posição e distância (Elachi, 1987). Por definição é um sistema activo, isto é, o sensor emite energia electromagnética que é retroespalhada por um alvo e registada pelo mesmo sistema (JAXA, 2007).

Segundo Dobson *et al.* (1995) existem dois tipos de radar: os aerotransportados de visada lateral (*Side-looking airborne radar: SLAR*) e de abertura sintética (*Synthetic aperture radar: SAR*). No primeiro caso (SLAR) uma antena fixa é propagada por meio de uma plataforma móvel, isto é por

um avião. A direcção de visada é lateral em relação à direcção do vôo da aeronave (JAXA, 2007). Enquanto, no segundo caso (SAR), uma antena longa é sintetizada artificialmente através do registo sequencial de amplitudes e fases do sinal retroespalhado por uma antena de dimensão reduzida (Ferraz *et al.*, 2013).

Os radares SAR operam em comprimentos de onda (γ) que variam de 1mm a 1m. As principais bandas são: X, C, S, L e P mostradas na tabela 1. Essas denominações não possuem um significado lógico e foram definidas por militares nos estágios iniciais da pesquisa por razões de segurança (Chaves *et al.*, 2000).

Tabela 1: Principais comprimentos de onda e frequência, utilizados pelo sistema de abertura sintética (SAR).

Denominação da banda	Comprimento de onda (cm)	Frequência (GHz)
X	3.0	9.50
C	5.7	5.25
S	10.0	3.0
L	23.5	1.17
P	68.0	0.44

Fonte: JAXA (2007)

Segundo Chaves *et al.* (2000) os sistemas radares não dependem do sol ou das condições solares e podem operar durante o dia e à noite. Quando se pretende extrair informações em uma imagem SAR é importante considerar que a mesma possui dois tipos de propriedades. A primeira propriedade está relacionada com as características do alvo, nomeadamente: humidade do solo, rugosidade do terreno, relevo, estrutura da vegetação e quantidade de água presente nas folhas verdes (Dobson *et al.*, 1995). A segunda propriedade está relacionada com as características instrumentais do sistema, destacando-se frequência ou comprimento de onda, polarização, ângulo de incidência e direcção de visada (Chaves *et al.*, 2000).

Os sistemas radar constituem-se num complemento importante dos sensores ópticos, que operam nas faixas espectrais do visível e do infravermelho, cujos dados estão directamente relacionados com as características físico-químicas do alvo. Entretanto sugere-se o uso de ambas as informações dos sistemas (óptico e radar) criando dessa forma um procedimento denominado sinergismo.

2.3.4. Satélites Landsat-8, ALOS PALSAR e Sentinel

2.3.4.1. Satélite Landsat-8

O Landsat 8 foi lançado pela NASA em 11 de Fevereiro de 2013 e é o mais novo satélite de observação da terra. Começou oficialmente a sua missão em 30 de Maio, depois dos ajustes e calibrações realizadas pelos engenheiros e cientistas da NASA¹. A expectativa é que tenha uma vida útil de 40 anos de observação da superfície terrestre vista do espaço. Esse projecto é uma parceria feita entre a NASA e o USGS (*United States Geological Survey*) (USGS, 2013). A plataforma espacial do Landsat 8 fornece energia suficiente para o controle da órbita, altitude, comunicação e armazenamento de dados. O satélite é composto basicamente por um subsistema mecânico (estrutura primária e 5 mecanismos de implantação), um subsistema de gestão e controle de dados, um subsistema de controlo de altitude, um subsistema de energia eléctrica, um subsistema de frequência de rádio (RF), um sistema de propulsão e um subsistema de controlo térmico, como mostra a figura 5 (USGS, 2013).

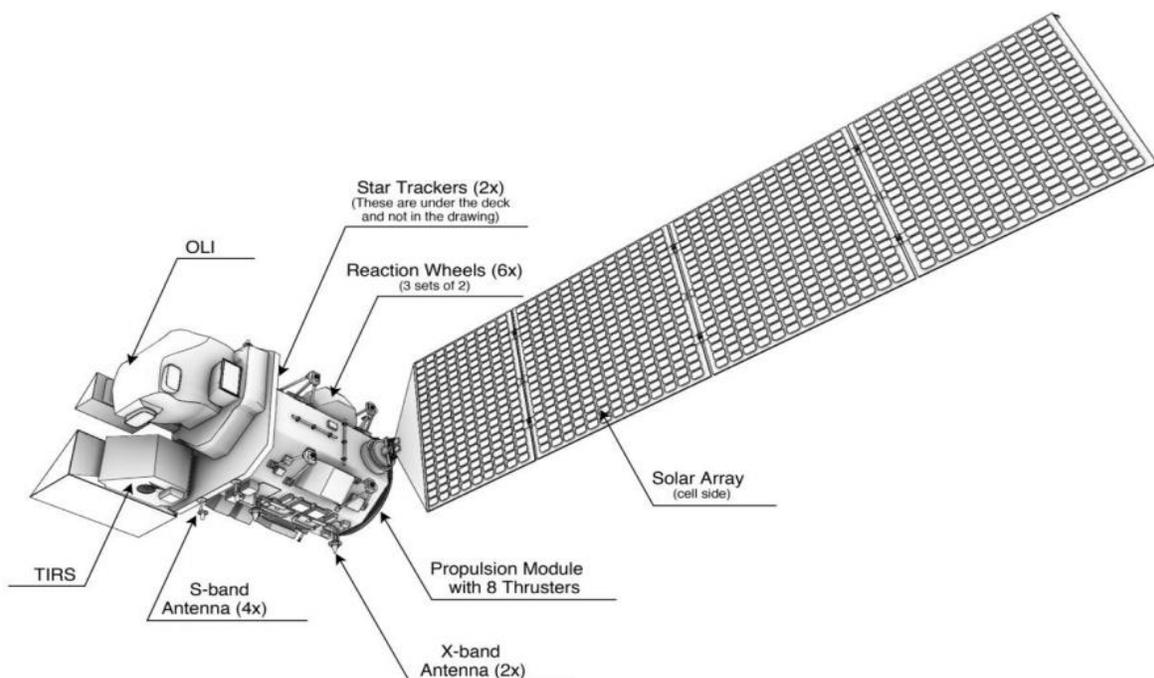


Figura 5: Satélite LANDSAT 8

Fonte: USGS (2013)

¹ National Aeronautics and Space Administration

A plataforma Landsat-8 opera com dois instrumentos: *Operational Terra Imager (OLI)* e *Thermal Infrared Sensor (TIRS)*. Os produtos OLI consistem de nove bandas multiespectrais com resolução espacial de 30 metros (bandas de 1 a 7 e 9). As faixas térmicas do instrumento TIRS são úteis no fornecimento de temperaturas de superfície mais precisas e os dados são colhidos no *pixel* de 100 metros. A banda 8 do instrumento OLI é a pancromática e possui uma resolução espacial de 15 metros como mostra a tabela 2. A banda 1 (ultra-azul) é útil para estudos costeiros. A banda 9 é útil para a detecção de nuvens (USGS, 2013). O tamanho aproximado da cena Landsat-8 é de 170 km ao norte-sul por 183 km a leste-oeste.

Tabela 2: Características do satélite LANDSAT 8.

SATÉLITE LANDSAT 8	
Características	Operacional Land Imager (OLI) Banda 1 a 9 e Thermal Infrared Sensor (TIRS) Bandas 10 e 11
Largura de Faixa	170x185 km
Bandas Espectrais/Resolução espacial	Banda 1 Coastal aerosol (0.43 - 0.45 μm) - 30 m
	Banda 2 Blue (0.50 0.51 μm) - 30
	Banda 3 Green (0.53 - 0.59 μm) - 30 m
	Banda 4 Red (0.64 – 0.67 μm) – 30 m
	Banda 5 Near Infrared NIR (0.85 - 0.88 μm) - 30 m
	Banda 6 SWIR 1 (1.57 - 1.65 μm) - 30 m
	Banda 7 SWIR 2 (2.11 - 2.29 μm) - 30 m
	Banda 8 Panchromatic (PAN) (0.50 - 0.68 μm) - 15 m
	Banda 9 Cirrus (1.36 - 1.38 μm) - 30 m
	Banda 10 Thermal Infrared TIRS 1 (10.6 - 11.19 μm) - 100 m
Banda 11 Thermal Ifrared TIRS 2 (11.5 - 12.51 μm) - 100 m	
Resolução radiométrica	16 Bits
Projeção	Projeção UTM, DATUM WGS 1984
Revista	16 dias
Órbita	Heliossíncrona (Altitude de 705 km)

Fonte: USGS (2013)

2.3.4.2. Satélite ALOS

O satélite ALOS (*Advanced Land Observing Satellite*) foi lançado em 24 de janeiro de 2006, com a missão de observar e obter imagens de todo o planeta para fins de monitoramento de desastres ambientais, levantamento de recursos naturais (Ferraz *et al.*, 2013). Os objetivos da missão ALOS são principalmente o de promover pesquisa científica e utilização dos dados em amplas categorias que variam desde as ciências ambientais até as ciências computacionais (JAXA, 2007). O satélite está localizado em uma altitude de 691,65 km em relação à superfície terrestre com inclinação de 98,16°. Sua órbita é solar-síncrona com um ciclo completo de 46 dias e sub-ciclo de 2 dias. Está equipado com três sensores mostrados na figura 6:

- Panchromatic Remote-Sensing Instrument for Stereo Mapping* (PRISM), com uma banda pancromática; com 2,5 m de resolução espacial, e que compreende três sistemas ópticos, para medição precisa das elevações
- O *Advanced Visible and Near Infrared Radiometer type 2* (AVNIR-2), sensor multiespectral, que possui 4 bandas espectrais abrangendo a região espectral do visível e infra-vermelho próximo, possui 10 m de resolução que é responsável, juntamente com o PRISM pela observação da cobertura da Terra
- Phased Array type L-band Synthetic Aperture Radar* (PALSAR) que é o sensor radar para observação da Terra dia e noite e em qualquer condição de tempo.

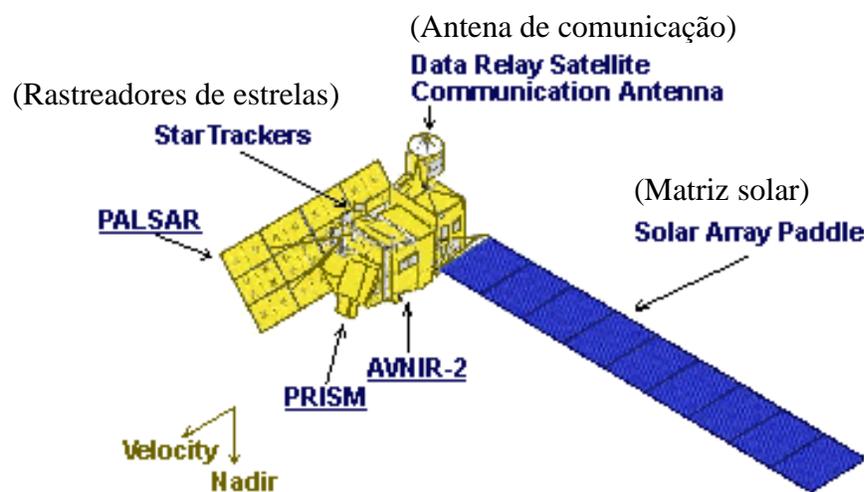


Figura 6: Satélite ALOS com três sensores

Fonte: JAXA (2007)

O *Phased Array type L-band Synthetic Aperture Radar* (PALSAR) é um sensor microondas activo que opera na banda L numa frequência de 1270 MHz (23,6 cm) e pode ser operado em diferentes modos: FBS (*Fine Beam Single polarization*), FBD (*Fine Beam Dual polarization*), POL (modo polarimétrico) e ScanSAR (tabela 3) (Shimada *et al.*, 2006). Por não sofrer influência da atmosfera, condições climáticas e não depender da luz, o PALSAR opera dia e noite e livre de nuvens. Sua resolução espacial varia de 7 a 100 m (Pereira, 2016). É o segundo radar de abertura sintética (SAR) japonês. Sua alta resolução é para o modo convencional, mas o PALSAR tem outro modo de observação vantajoso, o ScanSAR, no qual permite adquirir imagens de 250 a 350 km de largura, ou seja, de três a cinco vezes maior do que as imagens SAR convencionais e por isso é considerado útil para monitoramento de florestas tropicais e da extensão do gelo oceânico. O PALSAR foi desenvolvido juntamente pela JAXA² e *Japan Resources Observation System Organization* (JAROS) (JAXA, 2006a).

O PALSAR possui quatro polarizações (HH, VV, HV e VH). A polarização é um parâmetro importante que influencia o retroespalhamento de alvos na superfície da terra (JAXA, 2006a). A polarização refere-se à direção do campo elétrico na onda eletromagnética, que pode ser orientada horizontalmente (H) ou verticalmente (V). Existem quatro combinações lineares possíveis de polarização: HH, VV, HV e VH. As polarizações HH e VV são chamadas de polarizações lineares paralelas horizontal e vertical, respectivamente. Actualmente são as mais utilizadas em sistemas orbitais SAR. A primeira letra refere-se à polarização da radiação transmitida pela antena e a segunda à polarização recebida pela antena. As polarizações HV e VH são chamadas de polarizações cruzadas (JAXA, 2007).

Segundo JAXA (2007) as imagens podem ser processadas com diferentes níveis sendo que, as imagens do sensor PALSAR possuem os seguintes níveis de processamento: 1.0; 1.1 e 1.5. A diferença básica entre estes níveis de processamento é que no nível 1.0 o sinal é bruto, sem processamento; o nível 1.1 o dado é complexo com uma visada (*single-look complex*) e o nível 1.5 o dado é em amplitude e múltiplas visadas (*mult-look*). A tabela 3 mostra as características do sensor PALSAR abordado no satélite ALOS.

² Japan Aerospace Exploration Agency

Tabela 3: Características do sensor PALSAR da banda L (23.6 cm) nos modos Fino, ScanSar e Polarimétrico.

Frequência	1.270MHz (Banda L)			
	Fino (Fine)		ScanSAR	Polarimétrico
Modo				
Largura da banda	28 MHz	14 MHz	28 MHz e 14 MHz	14 MHz
Polarização	HH	HH + HV	HH	HH+HV+VH+VV
Angulo de Incidência	8° ~ 60°	8° ~ 60°	18° ~ 48°	8° ~ 60°
Resolução em alcance	7 ~ 44m	14 ~ 88m	100m (<i>multilook</i>)	24 ~ 89m
Largura da faixa	40 ~ 70 Km	40 ~ 70 Km	250 350	20 ~ 65 Km

Fonte: JAXA (2007)

2.3.4.2.1. ALOS 2/PALSAR 2

Depois do satélite Alos/Palsar ter atingido a sua vida útil foi lançada a versão mais avançada designada de Alos 2/Palsar2. O Satélite Avançado de Observação da Terra-2 (ALOS-2) é uma missão de continuação do ALOS. A ALOS contribuiu para a cartografia, observação regional, monitoramento de desastres e pesquisas de recursos, desde o seu lançamento em 2006 (JAXA, 2014).

A JAXA conduziu atividades de pesquisa e desenvolvimento para o ALOS-2 (figura 7) para melhorar as tecnologias de observação ampla e de alta resolução desenvolvidas para o ALOS, a fim de satisfazer as necessidades sociais. Essas necessidades sociais incluem: 1) Monitoramento de desastres de áreas danificadas, em detalhes consideráveis e quando essas áreas podem ser grandes 2) Actualização contínua de arquivos de dados relacionados a informações nacionais sobre terra e infraestrutura 3) Monitoramento eficaz de áreas cultivadas 4) Monitoramento global de florestas tropicais para identificar os sumidouros de carbono (JAXA, 2014).

O Radar de Abertura Sintética de banda L de última geração (PALSAR-2) a bordo do ALOS-2 terá um desempenho aprimorado em comparação com o ALOS / PALSAR. O PALSAR-2 é capaz de observar dia e noite e em todas as condições meteorológicas oferecendo as imagens com as seguintes polarizações HH, HV, VV e VH. O ALOS-2 foi lançado pelo veículo de lançamento H-IIA em 24 de maio de 2014 (JAXA, 2014).

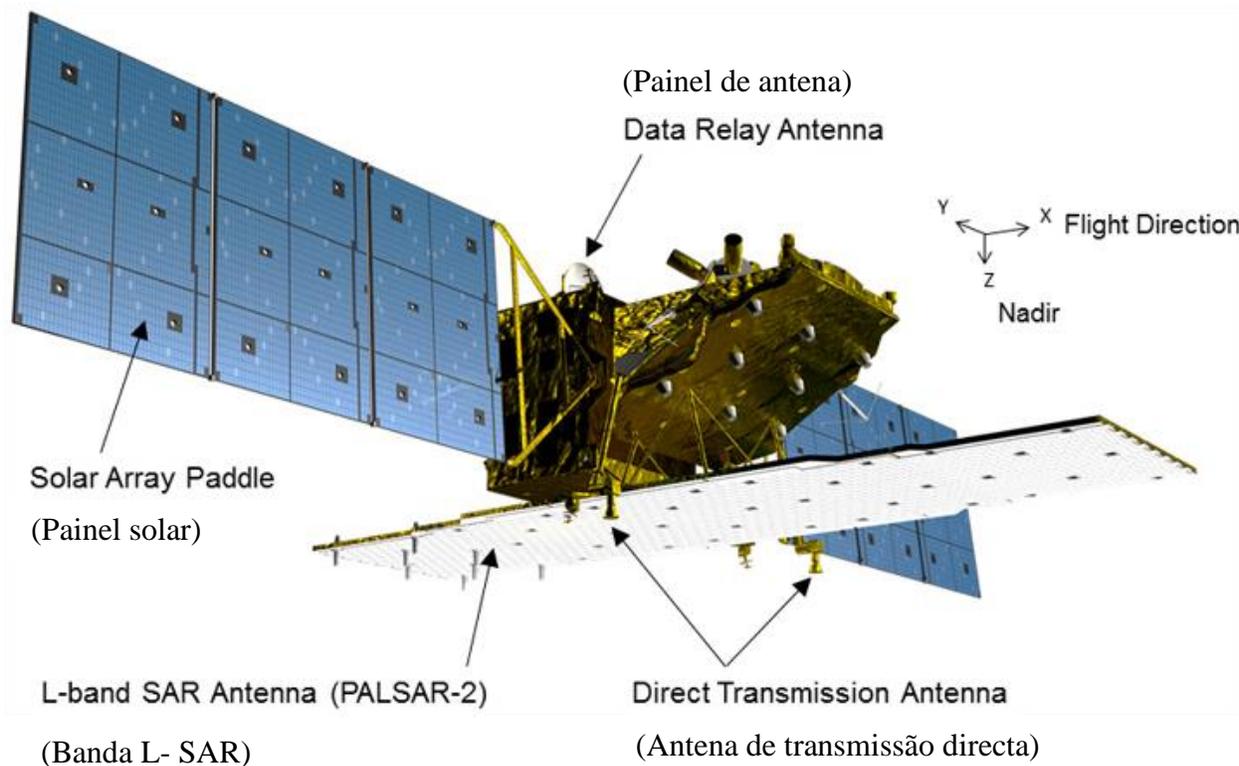


Figura 7: Satélite e sensor (Alos 2/Palsar 2)

Fonte: JAXA (2014)

2.3.4.3. Sentinel

Os sentinelas são um conjunto de família de satélites que foram concebidos no âmbito do programa da componente do espaço. A missão do Sentinel 1 funciona na região das micro-ondas e as missões Sentinel 2 e 3 nas regiões do visível e do infravermelho do espectro eletromagnético. As missões Sentinel 1 e 3 são dedicadas a monitorização dos meios terrestres e marinho, enquanto Sentinel 2 é essencialmente dedicada a monitorização do meio terrestre. Cada uma das missões Sentinel 1, 2 e 3 são constituídas por dois satélites que operam em conjunto com o objectivo e aumentar a frequência de aquisição de imagens (ESA, 2013).

Segundo ESA (2013) a missão Sentinel-1 apresenta uma órbita quase polar com um sensor C-SAR (*Synthetic Aperture Radar*) e capacidade de recolha de dados durante 24 horas, sob qualquer condição meteorológica. O sistema tem a capacidade de operar nos modos de dupla polarização (HH/HV ou VV/VH) e polarização única (HH ou VV) e possui quatro modos de aquisição distintos: SM (*Stripmap Mode*), IW (*Interferometric Wide Swath Mode*), EW (*Extra-Wide Swath*

Mode) e WV (*Wave Mode*). O modo SM adquire os dados com uma faixa de 80 km e uma resolução espacial de 5 m por 5 m. A faixa no terreno é iluminada por uma sequência contínua de pulsos enquanto o feixe da antena é direcionado para um ângulo de azimute fixo e um ângulo *off-nadir* aproximadamente fixo. Dado que os satélites Sentinel-1 estão equipados com o sensor C-SAR, é possível dar continuidade aos dados de observação da Terra obtidos pelos satélites da Agência Espacial Europeia (ESA): ERS-1, ERS-2 e ENVISAT e dos satélites RADARSAT-1 e RADARSAT-2 da agência espacial do Canadá. As aplicações dos modos de aquisição do Sentinel 1 são apresentadas na tabela 5 e a tabela 5 apresenta os modos de aquisição do Sentinel 1.

Tabela 4: Parâmetros dos modos de aquisição do Sentinel 1.

Modo	Ângulo de incidência	Largura da faixa	Polarização
SM	20° - 45°	80 Km	HH/HV, VV/VH, HH, VV
IW	29° - 46°	250 Km	HH/HV, VV/VH, HH, VV
EW	19° - 47°	400 Km	HH/HV, VV/VH, HH, VV
WV	22° - 35°	20 x 20 km	HH, VV

Fonte: ESA (2013)

Tabela 5: Aplicação dos modos de aquisição do Sentinel 1. SM (*Stripmap Mode*), IW (*Interferometric Wide Swath Mode*), EW (*Extra-Wide Swath Mode*) e WV (*Wave Mode*).

Aplicação	Modos			
	SM	IW	EW	VW
Ártico e gelo marinho		X	X	
Vigilância de navios em mar aberto		X	X	
Monitorização de poluição de óleo		X	X	
Ventos marítimos				X
Florestas		X		
Agricultura		X		
Cartografia de deformação urbana		X		
Monitorização de inundações	X	X		
Análise de sismos	X	X		
Monitorização de deslizamento de terras e vulcões	X	X		

Fonte: ESA (2013)

A missão sentinel-2 tem uma órbita quase polar e dispõe de um sensor MSI (*MultiSpectral Instrument*) com 13 bandas espectrais (tabela 6), com grande resolução espacial (10, 20, 60 m, dependendo da banda) e uma resolução temporal de 10 dias com um satélite e de 5 dias apenas com dois satélites operacionais (ESA, 2013).

Tabela 6: Descrição das bandas espectrais do Sentinel 2. Comprimento de onda (μm) e resolução espacial (m)

Nome das bandas	Comprimento de onda (μm)	Resolução espacial (m)
Banda 1 Aerossol	0.443	60
Banda 2 - Azul	0.490	10
Banda 3 - Verde	0.560	10
Banda 4 - Vermelho	0.665	10
Banda 5 - Vegetação	0.705	20
Banda 6 - Vegetação	0.740	20
Banda 7 - Vegetação	0.783	20
Banda 8 - NIR	0.842	10
Banda 8A - Vegetação	0.865	20
Banda 9 - Vapor de água	0.945	60
Banda 10 - SWIR - Crus	1.375	60
Banda 11 - SWIR	1.610	20
Banda 12 - SWIR	2.190	20

Fonte: ESA (2013)

2.4. Teledetecção para estimativa de Biomassa e carbono florestal

Segundo Siteo e Tchaúque (2007) a teledetecção ou sensoriamento remoto é usada para determinar a biomassa viva (acima do solo) e é baseado no estudo de cobertura de florestas com recurso a imagens de satélite e fotografias aéreas, sendo que alguns satélites (IKONOS, QUICKBIRD, LIDAR e ALOS/PALSAR) apresentam elevada resolução espacial, tornando-se uma grande oportunidade para aprofundar as informações sobre a biomassa/carbono nos ecossistemas florestais. Estas técnicas, são bastante importantes principalmente em áreas com escassez de informação detalhada, como é o caso dos ecossistemas de Miombo que cobrem maior parte de Moçambique (Ribeiro *et al.*, 2008).

O uso da teledetecção tem grande vantagem pois permite fazer inferências de biomassa e de carbono a larga escala (Haripriya, 2000), ou seja, ao nível da paisagem como é o caso da RNN (Ribeiro *et al.*, 2008) mas para o seu funcionamento requer conhecimentos sobre interpretação de imagens de satélite em classes de cobertura florestal ou algumas características particulares das

bandas espectrais das imagens e de funções que relacionam estas características com a biomassa (IPCC, 2006; Pereira 2016).

De acordo com Holben *et al.* (1980) através das técnicas de teledetecção, a biomassa é estimada a partir de relações directas entre a resposta espectral das características da floresta e a biomassa usando análise de regressão, onde as bandas espectrais (índices de vegetação) são consideradas como variáveis independentes (x) e o valor estimado da biomassa como variável dependente (y). Depois da estimativa da biomassa a partir do modelo, ela é convertida em carbono a partir do factor de conversão (0.47 ou 0.5) dependendo da tipologia florestal (IPCC, 2007)

Ribeiro *et al.* (2008) afirmam que a aplicação da teledetecção para estimativa da biomassa também requer dados da superfície de campo para calibração e verificação de seus dados porque estas técnicas não medem directamente a biomassa. Elachi (1987) recomenda que a função que relaciona as características da floresta captadas pelos sensores com biomassa seja calibrada utilizando método directo com amostragem em parcelas ou funções alométricas.

3. DESCRIÇÃO DA ÁREA DE ESTUDO

3.1. Localização

A Reserva Nacional de Niassa (RNN) está localizada na Província do Niassa e Cabo Delgado entre $12^{\circ}38'48.67''S$ e $11^{\circ}27'05.83''S$ e $36^{\circ}25'21.16''E$ e $38^{\circ}30'23.74''E$ (Ribeiro *et al.*, 2013). O seu limite Norte é o rio Rovuma, na zona Este ocupa os distritos de Mueda e Montepuez, os distritos de Marrupa e Majune fazem limite Sul e os distritos de Sanga e Muembe a Oeste. A reserva tem uma superfície total de 42000 Km^2 , ocupando no total cerca de 1/3 da província do Niassa e 1/15 da Província de Cabo Delgado. A parte central da reserva faz limites a Norte com o rio Rovuma, Sudeste: Rio Lugenda, Sudoeste: Rio Lutize, Oeste: Rio Lussanhando (SGDRN, 2005).

A RNN encontra-se dividida em 15 unidades de gestão: R1, R3, R4, R6, L1, L2, L4, L5, L6, L7 e L9 (áreas de conservação de recursos), R2, R5, L3 e L8 (áreas de conservação de selva virgem) e montes Jao e Mecula (áreas especiais de conservação) (SGDRN, 2007) (figura 8).

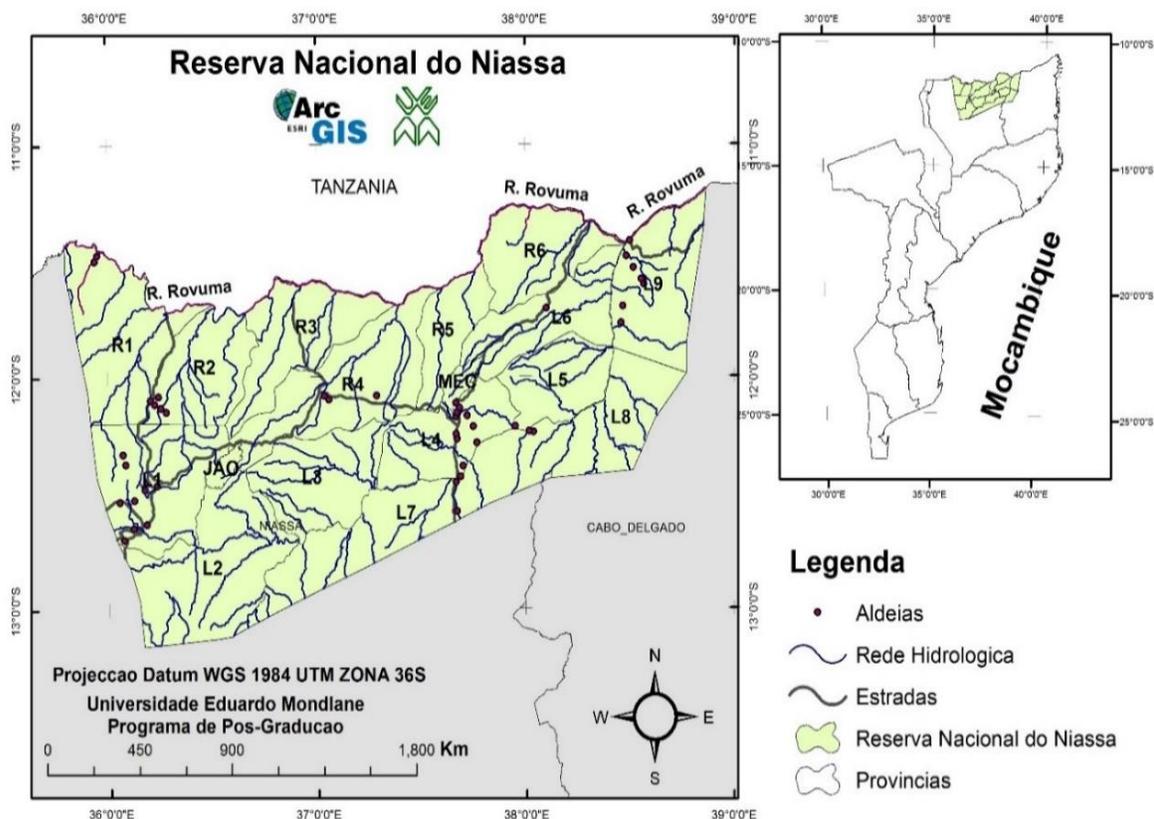


Figura 8: Mapa da área de estudo

Fonte de dados espaciais: Centro Nacional de Cartografia e Teledetecção (CENACARTA).

3.2. Clima

De acordo com SGDRN (2007) o clima é tropical húmido, com precipitações durante a estação quente (Novembro-Abril) sob a forte influência das correntes quentes das Agulhas, no Indico. Prevalecem os ventos costeiros que transportam ar carregado de humidade com as consequentes chuvas características das tempestades do tipo convectivo. Este fenómeno é acentuado pela presença de inúmeros *inselbergs* na paisagem circundante que estimulam a humidade.

A precipitação média anual na RNN varia de 900 mm a 1200 mm (Timberlake, 2004) podendo atingir 1400 mm ou mais na montanha de Mecula, nos vales dos rios Rovuma e Lugenda (SGDRN, 2007). A montanha de Mecula é suficientemente alta para causar um aumento de precipitação nas suas imediações (SRN, 2006).

As temperaturas médias mensais podem atingir 30° C em Outubro e Novembro (estação quente e húmido), enquanto a média dos meses mais frescos da estação seca (Maio – Agosto), varia entre 20° C e 26°C (Ribeiro *et al.*, 2008).

3.3. Hidrologia

A RNN possui um sistema hidrológico extenso, projecta-se para Norte e para Sul, a partir de uma linha divisória central ao longo da Reserva, até à confluência dos rios Rovuma-Lugenda. Este sistema alimenta um grande número de rios e cursos de água permanentes ou sazonais, assim como uma rede de dambos bem desenvolvida e que inunda sazonalmente. Os rios principais são o rio Rovuma, com os seus afluentes Lucheringo, Messinge e Chiulezi; e o rio Lugenda com os seus rios afluentes: Luatise, Luambala, Luchimua e Lureco (SGDRN, 2007).

Na RNN existe um conjunto de pequenas zonas de captação, das quais as maiores foram identificadas. A montanha de Mecula é importante na hidrologia da Reserva. A montanha de Mecula é um *inselberg* isolado no centro da Reserva erguendo-se a mais de 1 000 m acima da planície circundante, sendo suficientemente alta para gerar chuvas orográficas nas áreas circunvizinhas (Ribeiro *et al.*, 2013). Isto quer dizer que representa também água permanente alimentando cursos de água que escorrem ao longo das suas encostas. Os dois cursos mais importantes são o Ncuti e o Licombe (SRN, 2006).

O sistema de drenagem da Reserva pode ser subdividido num número de importantes zonas de captação de água ou bacias hidrográficas. Cada uma destas bacias, forma o coração das “unidades ecológicas” que foram utilizadas na definição de unidades de gestão conforme delineadas no Plano de Zoneamento (SRN, 2006).

3.4. Relevo e solos

A reserva tem uma paisagem suavemente ondulada em um planalto com altitude variando de 300 a 600 metros acima do nível do mar (Ribeiro *et al.*, 2008). A reserva tem dois picos principais, a montanha de Jao no oeste com uma elevação de 1200 m acima do nível do mar e a montanha de Mecula no leste, com 2000 m de altura. O relevo da RNN é muito acidentado e com muitas elevações, para além dos montes Jao e Mecula, ao longo da reserva encontram-se distribuídas montanhas como Missinginge com 1002 m, o Mbamba com 1105 m, o Matondovela com 1180 m e outras montanhas com altitudes variando entre os 500 a 1000 metros constituídos pelos montes Messiringe, Lukwisi e Nopocuro (Fonseca, 1998).

As características dos solos variam de areno-argilosos, profundos e permeáveis de pouca fertilidade a solos inférteis de camadas superficiais e finas de areia, frequentemente vulneráveis à erosão. Nos dambos encontram-se solos hidromórficos de textura variada, desde arenoso de cores cinzentas, arenoso sobre argila a solos argilosos estratificados de cor escura (MAE, 2005).

3.5. Vegetação e fauna

Segundo Timberlake (2004), Ribeiro *et al.* (2008) e Ribeiro *et al.* (2013) a vegetação da RNN pode ser dividida em seguintes grupos principais: floresta decídua (aberta e densa/fechada), bosques ribeirinhos e matagal; floresta sempre verde, vegetação dos *Inselbergs*; vegetação da Serra de Mecula, *dambos* (pradaria inundada) e floresta com agricultura itinerante. Ribeiro *et al.* (2008) descreveu principais aspectos estruturais da vegetação da seguinte maneira:

a) Floresta densa

A cobertura da copa do estrato superior cobre mais de 75% e a camada herbácea está pouco desenvolvida ou totalmente ausente.

b) Floresta sempre verde

A cobertura da copa da camada dominante varia de 50 a 75%. Uma camada de arbusto denso moderado está normalmente presente com um estrato no solo normalmente esparso.

c) Floresta aberta

A cobertura da copa da camada superior está entre 25 e 50% e um estrato herbáceo bem estabelecido e normalmente presente.

d) Floresta ribeirinha

Mosaico de capim e outras ervas com plantas e árvores lenhosas dispersas ou agrupadas (cobertura da copa de 10 a 20%). Ocorrem ao longo dos rios.

e) Florestas de montanha

Floresta com mais de 80% de cobertura de árvores, que ocorrem no topo e encostas das Montanhas Mecula e Jao.

f) Dambos

Mosaico de capim e outras plantas herbáceas com árvores dispersas ou agrupadas (cobertura da copa de 10 a 20%), normalmente inundadas periodicamente.

g) Vegetação dos Inselbergs

Formação da rocha granítica com vegetação pequena. Onde os solos se apresentam uma capacidade muito fraca de absorção de humidade e cujas condições são quase comparáveis às encontradas em desertos.

A floresta decídua cobre cerca de 95% da RNN. Na sua maioria são constituídas por florestas de Miombo, dominado por três (3) espécies de *Brachystegia* ou *Julbernardia* com uma camada de gramíneas bem desenvolvida. No lado oeste da reserva, a floresta de Miombo é significativamente mais densa e as árvores possuem uma altura maior em relação ao este. Esta é provavelmente uma indicação de maior pluviosidade, ou de solos com alto teor de argila na parte ocidental (Ribeiro *et al.*, 2008).

A floresta de Miombo é mais comum em solos mais arenosos, e é particularmente bem desenvolvida ao longo da bacia Mecula-Mbatamila (Timberlake, 2004). Em áreas relativamente mais secas (com solos rasos ou com menos capacidade de armazenamento de humidade do solo), a floresta cobre menor área e é mais aberta. Espécies de *Combretum* e outras são comuns, com menor abundância de espécies típicas de Miombo como *Brachystegia* e *Julbernardia* (Ribeiro *et al.*, 2013).

Nas proximidades do rio Lugenda ocorre um tipo mais seco de floresta dominada por *Millettia Stuhlmannii*. Esta floresta de *Millettia* é intercalada com vegetação do tipo mais seco - *Acacia Welwitschii*, em áreas arborizadas constituídas essencialmente por argila, e manchas muito pequenas de *Euphorbia* (Timberlake, 2004). Existem pequenas comunidades florestais isoladas que ocorrem nas montanhas, especialmente na montanha de Mecula, e *inselbergs* encontrados em toda a reserva (Ribeiro, 2007).

A RNN possui larga diversidade faunística que inclui cerca de 5000 elefantes, 14.000 pala-palas, 800 leões, 350 cães selvagens africanos, leopardos, búfalos e mais de 400 espécies de pássaros alguns em perigo de extinção (Craig, 2009 e SGDRN, 2010).

3.6. População humana dentro da Reserva Nacional do Niassa

Ao longo de décadas a reserva foi ocupada por famílias locais que vivem em grupos relativamente isolados e, actualmente conta com cerca de 45.000 habitantes distribuídos em 50 aldeias incluindo duas sedes distritais, nomeadamente, Mecula e Mavago (Cunliffe, 2014). A densidade populacional é baixa e varia de 0.8 habitantes/km² em Mecula até 1.9 habitantes/Km² no distrito de Mavago (MAE, 2005).

Grande parte da população vive dedicando-se à prática de agricultura de subsistência incluindo outras actividades como extracção do mel, lenha, caça e comércio de pequena escala e vivem com menos de 1 dólar por dia (Cunliffe *et al.*, 2009).

3.7. Regime de queimadas

Quanto ao regime de queimadas na RNN, dois trabalhos já foram realizados em coordenação com a Universidade Eduardo Mondlane. O primeiro trabalho foi realizado por Ribeiro (2007) com intuito de compreender o regime de queimadas no período de 5 anos (2001-2005). Os resultados mostram que o fogo é um factor ecológico importante na dinâmica da floresta de Miombo. A estação das queimadas é de Maio a Outubro, com um pico no fim da estação seca (Agosto a Outubro). A frequência de queimadas é maior na porção oriental da reserva (quatro a cinco vezes em cinco anos) do que no oeste (duas a três vezes em cinco anos).

Como forma de dar continuidade ao trabalho iniciado por Ribeiro (2007), foi realizado o segundo trabalho por Ribeiro *et al.* (2017) com objectivo de analisar o regime de queimadas a longo prazo (2000-2012). Os resultados obtidos mostram que em média o fogo retorna a um sítio particular em cada 3.29 anos numa frequência de 0.36 vezes/ano com pico na época seca (figura 9). Aproximadamente 43% da área total da RNN queimou em cada 1-2 anos e as regiões Central-Norte e Este registaram queimadas mais frequentes, sendo mais intensas nas zonas de baixa frequência e densidade de queimadas. O mesmo estudo observou que a ocorrência de queimadas é favorecida pelo tipo de cobertura da terra e densidade de elefantes.

As queimadas são principalmente antrópicas e causadas por caça de subsistência, rotas comerciais, pedestres à Tanzânia, recolha de mel, limpeza e abertura de campos principalmente em torno das duas principais aldeias de Mecula e Mavago (Ribeiro, 2007 e Cangela, 2014).

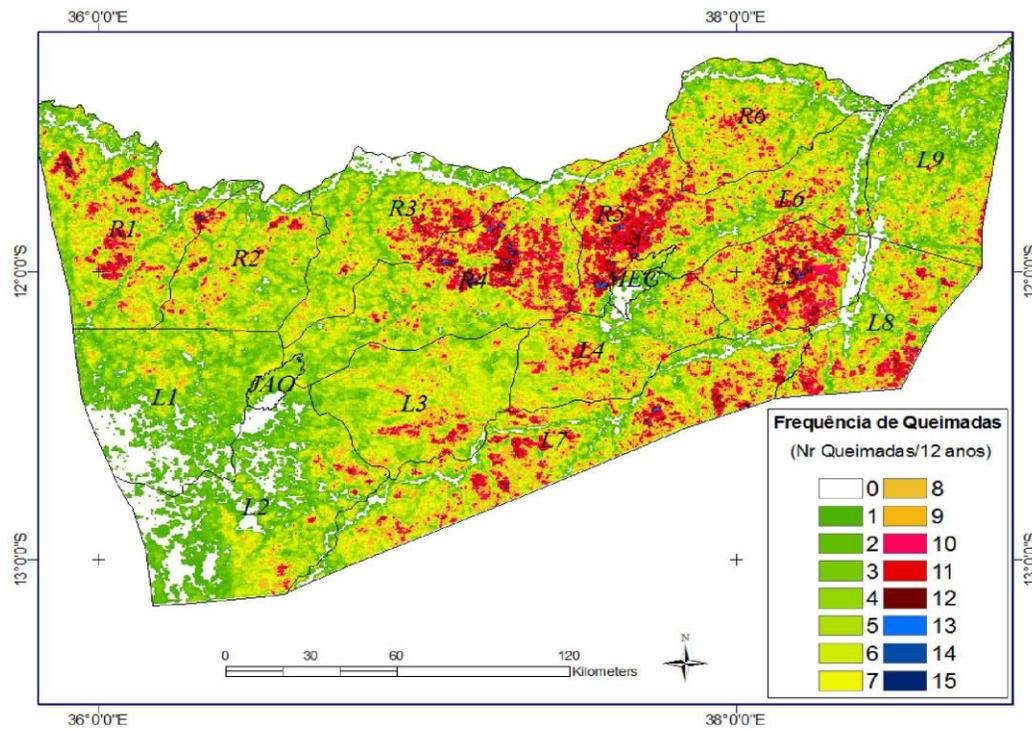


Figura 9: Frequência de queimadas na Reserva Nacional do Niassa (2000-2012)

Fonte: Ribeiro *et al.* (2017)

4. MATERIAIS E MÉTODOS

4.1. Aquisição de dados de satélite

As imagens de satélite correspondentes a quatro sensores (ópticos e radares) que cobrem a RNN (~ 42000 km²) foram adquiridas no presente trabalho, sendo que as ópticas correspondem aos sensores Landsat 8/OLI e Sentinel 2A/MSI, enquanto as imagens radar correspondem aos sensores Sentinel 1B e Alos 2/Palsar 2.

As imagens Landsat 8/OLI e Sentinel 2A/MSI foram adquiridas a partir do site: *earthexplorer.usgs.gov*. Por outro lado, a imagem Sentinel 1B do sensor radar foi adquirida a partir do seguinte site: *Vertex.daac.asf.alaska.edu*. Por último, as cenas que correspondem ao Alos/Palsar foram adquiridas no *www.eorc.JAXA.jp*, onde estão disponíveis dados de Alos 2/Palsar. Durante aquisição de dados ópticos (Landsat 8 e Sentinel 2A) foram seleccionadas imagens com uma cobertura de nuvens abaixo de 10%. A tabela 7 mostra a descrição de cada imagem adquirida e a figura 10 visualiza o mosaico das cenas dos sensores ópticos e radar usados no presente estudo.

Tabela 7: Descrição das imagens Landsat 8/OLI, Sentinel 2A/MSI e 1B e Alos 2/Palsar 2, data de aquisição, referência da imagem, tipo de banda, comprimento de onda e resolução espacial.

Satélites	Tipo de sensor	Data de aquisição	Referência de imagem	Tipos de Bandas	Comprimento de Onda /Polarizações*	Resolução espacial
LANDSAT 8/OLI	Óptico	20/05/2017	166/68, 167/68, 166/69 e 167/69	Banda 2	0.45 - 0.51	30 m
				Banda 3	0.53 - 0.59	
				Banda 4	0.64 - 0.67	
				Banda 5	0.85 - 0.88	
Sentinel 2A/MSI	Óptico	29/04/2017	T36LZL, T36LZM, T36LZN, T37LBF, T37LBG, T37LCF, T37LCH, T37LDG e T37LDH	Banda 2	0.45 - 0.51	10 m
				Banda 3	0.53 - 0.59	
				Banda 4	0.64 - 0.67	
				Banda 8	0.78 - 0.82	
Sentinel 1B	Radar	18/02/2017	155253/009606, 160043/009679 e 160108/009679	Banda C (5.7 cm)	Polarizações: VH, VV	10 m
Alos 2/Palsar 2	Radar	05/03/2016	11E035, 11E036, 11E037, 11E038, 12E035, 12E036, 12E037, 12E038 e 13E035	Banda L (23.6 cm)	Polarizações: HH, HV	10 m

* HH: transmissão horizontal de comprimento de onda (CO) e recepção horizontal do sinal, HV: transmissão horizontal de CO e recepção vertical do sinal, VV: transmissão vertical de CO e recepção vertical do sinal e VH: transmissão vertical de CO e recepção horizontal do sinal.

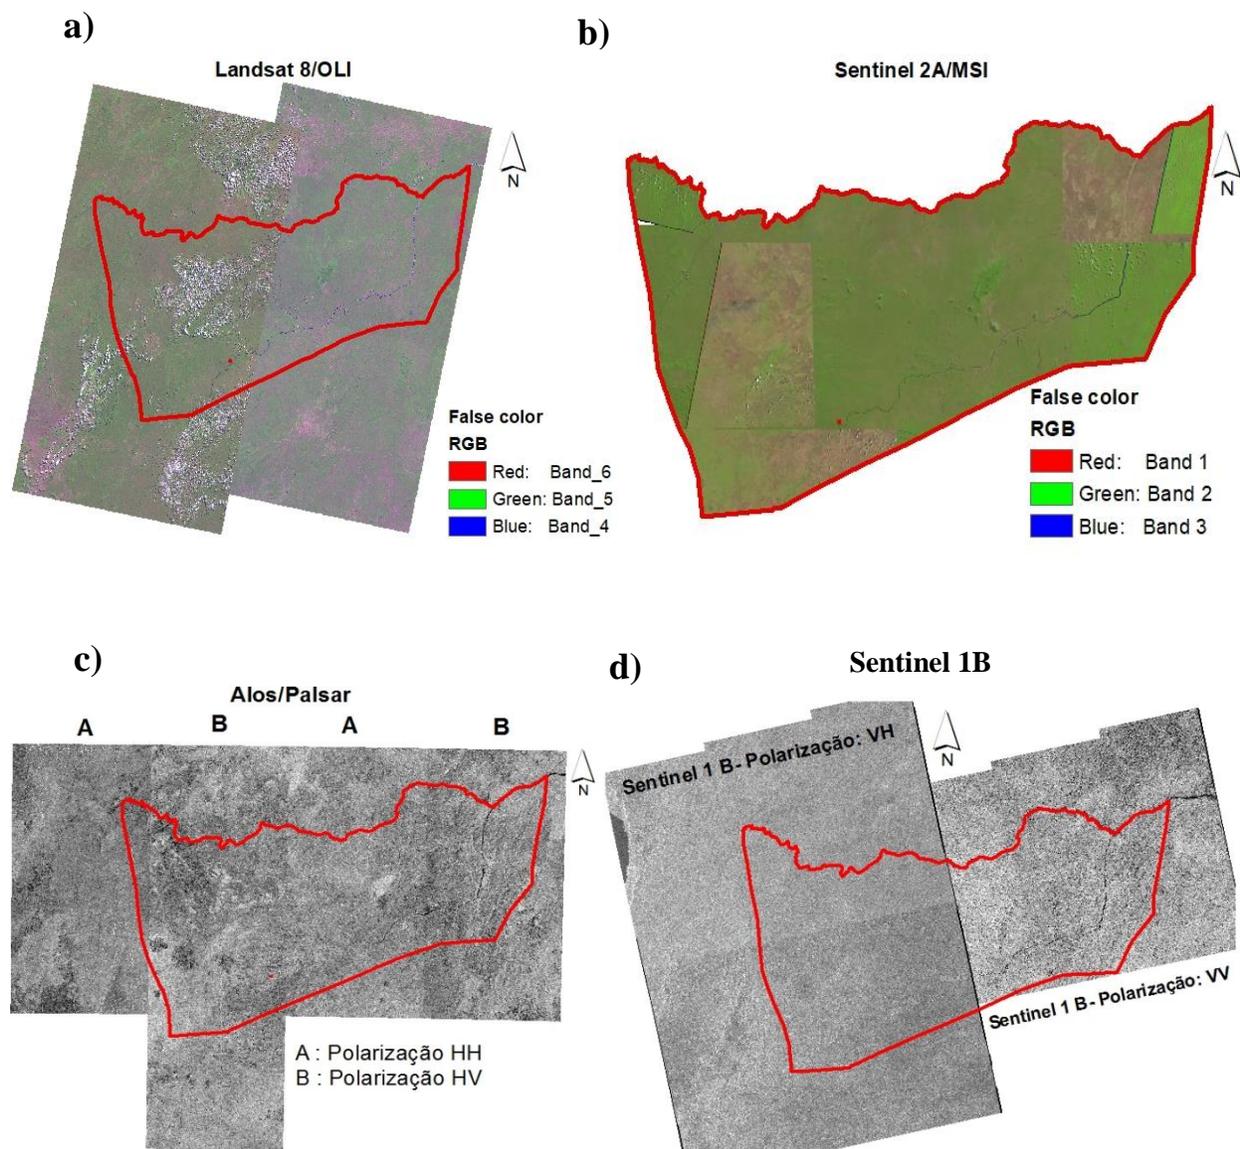


Figura 10: (a) mosaico das cenas do Landsat 8/OLI em falsa cor; (b) mosaico das cenas do Sentinel 2A/MSI e recorte ao nível da RNN~ 42000 km² em falsa cor; (c) mosaico das cenas de Alos/Palsar 2 com polarizações HH e HV (L-SAR adquiridas no modo *Strip Map Mode*); (d) mosaico das cenas do Sentinel 1B com polarizações VH e VV (C-SAR adquiridas no modo *Interferometric wide swath*).

4.2. Amostragem de campo e colheita de dados

O tipo de amostragem escolhida para este estudo, foi amostragem aleatória estratificada. Para definição dos estratos, usou-se dados de frequência de queimadas (FQ) extraídos do trabalho de Ribeiro *et al.* (2017) e de índice de aridez (dados climáticos da *WorldClim*). O índice de aridez (IA) foi elaborado por Thornthwaite (1948) e ajustado posteriormente por Penman em 1953 (UNEP, 1997). Este índice calcula a diferença entre a quantidade de chuva e a perda de água para atmosfera, ou seja, a evapotranspiração (Freitas, 2005). Segundo UNEP (1997) o IA pode ser usado para quantificar a disponibilidade de precipitação na atmosfera e no estabelecimento das classes climáticas. Três níveis de susceptibilidade foram estabelecidos a partir de valores do índice de aridez: muito alta de 0.05 até 0.20, alta de 0.21 até 0.50 e moderada de 0.51 até 0.65 e maior que 0.65 é considerado IA baixo (Freitas, 2005). O mapeamento do IA entre 1950-2000 na RNN (figura 11) usado para o presente estudo, foi calculado usando a seguinte fórmula:

$$IA = PMA/EMA \quad (1)$$

Onde:

IA: índice de aridez;

PMA: Precipitação média anual (mm);

EMA: Evapotranspiração média anual (mm).

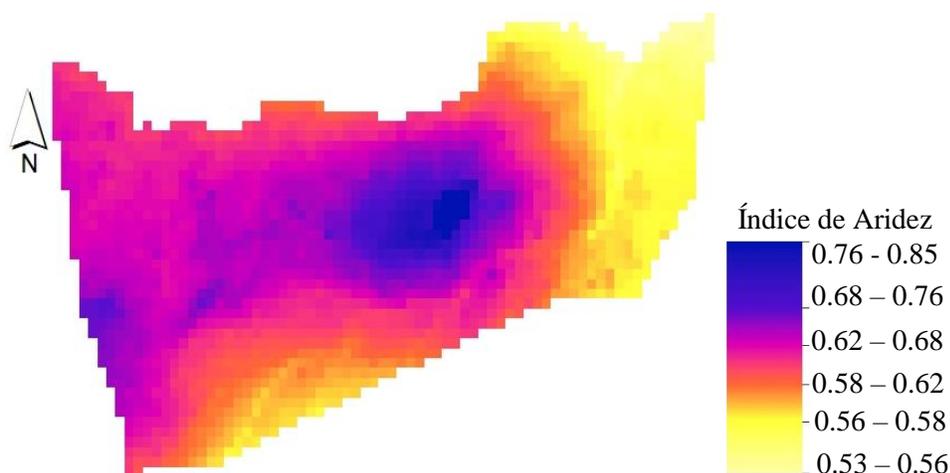


Figura 11: Mapa de índice de aridez na Reserva Nacional do Niassa, calculado com dados da *Worldclim* no período de 1950 – 2000.

A estratificação do IA resultou em seis classes nomeadamente: 0.53 a 0.56 (A); 0.56 a 0.58 (B); 0.58 a 0.62 (C); 0.62 a 0.68 (D); 0.68 a 0.76 (E) e 0.76 a 0.85 (F). Os dados do IA foram combinados com as quatro classes de FQ nomeadamente: 0 a 1 (P), 1 a 3 (Q), 3 a 7 (R) e 7 a 13 (S) a partir de uma matriz cruzada (Anexo 1). O cruzamento das variáveis (IA e FQ) resultou em 24 pontos, que posteriormente foram alocados como parcelas de amostragem ao longo da RNN permitindo desse modo a captura de toda variação da estrutural da floresta. Todas parcelas foram codificadas para facilitar a recolha de dados nos próximos anos, tendo sido criado a seguinte codificação: AP, BP, CP, DP, EP, FP, AQ, BQ, CQ, DQ, EQ, FQ, AR, BR, CR, DR, ER, FR, AS, BS, CS, DS, ES e FS.

A alocação dos pontos foi feita no *ArcGis* 10.2 obedecendo os critérios como distância em relação à estrada em não mais de 5 km devido ao difícil acesso; a não ocorrência de rochas ou *inserlbegs*, rios e Dambos (vegetação inundada). Também foram consideradas as áreas de manejo, ou seja, os pontos estão representativos das unidades de manejo nomeadamente R1, R3, R4, R6, L1, L2, L4, L5, L6, L7 e L9 (áreas de conservação de recursos) e R2, R5, L3 e L8 (áreas de conservação de selva virgem). As coordenadas dos 24 pontos potenciais para amostragem foram registados no GPS (*Garmin*) para facilitar a sua localização no campo (figura 12).

A aquisição de dados do campo referente a este trabalho, foi realizada por um grupo de pesquisadores e estudantes da Faculdade de Agronomia e Engenharia Florestal (FAEF) da Universidade Eduardo Mondlane (UEM) no mês de Abril de 2017. No campo foram marcadas parcelas com uma dimensão de 100 m x 100 m ($10000 \text{ m}^2 = 1\text{ha}$) com orientação para o norte (Sanquetta *et al.*, 2006). Também marcou-se os cinco pontos das coordenadas, sendo quatro pontos para os vértices e o quinto ponto retirado no centro da parcela. Dentro das parcelas variáveis biofísicas foram medidas, sendo que para o presente estudo interessa apenas descrever o diâmetro a altura do peito (DAP em cm). Em todas parcelas mediu-se o DAP de todos os indivíduos (árvores com $\text{DAP} \geq 5 \text{ cm}$) usando uma suta. Em árvores com bifurcação acima do DAP, apenas registou-se uma medida a 1.3m, e no caso de árvores bifurcadas abaixo do DAP, foram registadas as duas medidas Sanquetta *et al.* (2006). Para além do DAP, anotou-se também o nome da espécie com ajuda de um técnico de botânica da UEM, estado sanitário e tipo de vegetação que ocorre dentro da parcela. Toda a informação colhida no campo foi registada numa folha de campo especialmente preparada para este efeito, podendo ser visualizada no Anexo 2 deste estudo.

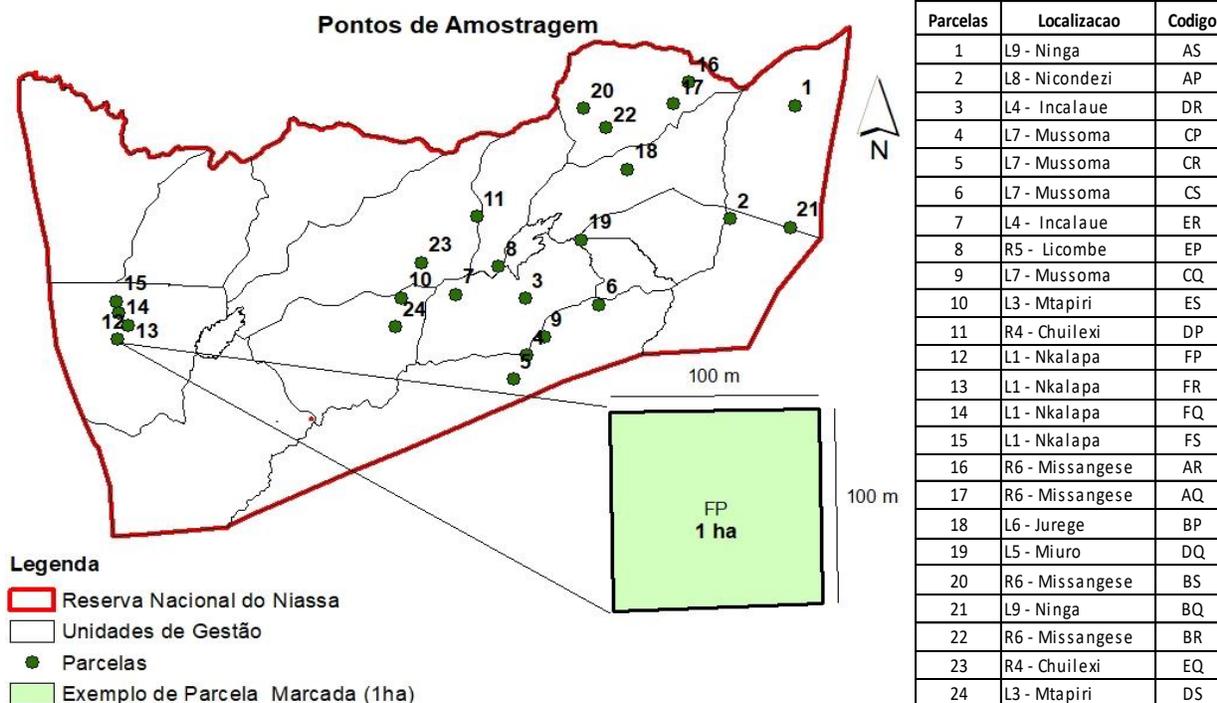


Figura 12: Localização dos pontos de amostragem, unidades de gestão e códigos atribuídos à cada parcela (tabela ao lado do mapa) ao longo da Reserva Nacional do Niassa.

4.3. Tratamento das imagens ópticas

Após a aquisição das imagens ópticas do Landsat 8 e Sentinel 2A seguiu-se a fase do tratamento das mesmas, o tratamento inclui o pré-processamento e o processamento digital. O pré-processamento é feito devido às imperfeições obtidas durante a aquisição da imagem (Colwell, 1983). Nesta fase as cenas foram recortadas e feitas as devidas correções geométricas, isto é projectar a imagem para o Datum WGS84 UTM zona 36S usando alguns pontos de controlo já conhecidos dentro da RNN. Uma vez que as imagens apresentavam bandas separadas, fez-se a composição de bandas através do *software* ERDAS 2014 numa operação chamada “*composite bands*” para que todas estivessem numa única imagem em formato *GeoTIFF* (Eastman e Andes, 2006). As correcções atmosféricas foram feitas para atenuar a influência dos constituintes atmosféricos, tais como vapor d’água e aerossóis. Este processo foi feito na ferramenta *ACTOR/workstation* encontrado *toolbox* do ERDAS 2014, onde as imagens no formato *GeoTIFF* foram submetidas ao *workstation*, indicando as datas em que as imagens foram capturadas pelo sensor e o valor da elevação solar (Furian, 2014).

O processamento também foi desenvolvido no ERDAS 2014, onde calculou-se três índices de vegetação nomeadamente: índice de vegetação de diferença normalizada (NDVI), índice de vegetação do solo ajustado (SAVI) e índice de vegetação da razão simples (SR). Para o cálculo dos índices foram usadas bandas espectrais da região do infra vermelho próximo (NIR) e região do vermelho (RED) (Holben *et al.*, 1980). Depois dos cálculos dos índices de vegetação na ferramenta *Raster* do ERDAS 2014, os mesmos dados no formato *GeoTIFF* (Marques, 2015) foram importados para *ArcGis* 10.2 para extração de valores espectrais. Segundo Viganó *et al.* (2011) as fórmulas usadas para calcular os índices são apresentadas abaixo:

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED}) \quad (2)$$

$$\text{SAVI} = (1 + 0.5) * (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED} * 0.5) \quad (3)$$

$$\text{SR} = \text{RED} / \text{NIR} \quad (4)$$

4.4. Tratamento das imagens radar

O pré-processamento das imagens radar (Alos 2/Palsar 2 e Sentinel 1B) consistiu no recorte, mosaico e correcção das distorções geométricas a partir dos pontos de controlo obtidos durante a marcação das parcelas, também foram usados quatro pontos das extremidades da RNN retirados do *shapefile* da reserva no *ArcGis* 10.2. Para a extração da imagem ao nível da RNN, combinada e projectada para Datum WGS84 UTM zona 36S foram usadas ferramentas da extensão do *ArcToolbox* designadas: *extract by mask*, *mosaic to new raster* e *define projection*, respectivamente.

O processamento foi efectuado no ERDAS 2014, nesta fase eliminou-se o ruído *Speckle*. Segundo JAXA (2006a) o ruído *Speckle* é a principal causa das distorções radiométricas que prejudica a interpretação das imagens de radar, tornando-se um ruído multiplicativo que é proporcional à intensidade do sinal recebido (Shimada *et al.*, 2006). O efeito visual deste ruído proporciona uma textura granulosa que pode dificultar a interpretação das imagens de radar (JAXA, 2006a). Sendo assim, para diminuir o ruído *Speckle* é necessário fazer a filtragem, esses filtros devem manter o valor médio do retorno do radar (*backscatter*), preservar as bordas presentes na imagem e as informações de textura (JAXA, 2007).

No presente trabalho o ruído *Speckle* foi reduzido através do Filtro de *Frost*, sendo este um filtro linear, derivado da minimização do erro médio quadrático sobre o modelo multiplicativo do ruído (JAXA, 2007). Neste filtro incorpora-se a dependência estatística do sinal original, uma vez que se supõe uma função de correlação espacial exponencial entre *pixels* (Howard, 1991). A razão da escolha do filtro é por este apresentar um modelo adaptativo que preserva a estrutura de bordas e mantém os valores da intensidade de retroespalhamento (IR) (JAXA, 2007).

No filtro de Frost o valor \hat{I} associado ao *pixel* corrente é dado pela equação (5), onde x e y determinam a posição do *pixel* corrente e i e j são determinados pelos limites da janela do filtro. O coeficiente $m(x+i, y+i)$ é dado pela equação (6).

$$\hat{I}(x,y) = \sum_{ij} \sum m(x+i,y+i) I(x+i,y+i) \quad (5)$$

$$m(x+i,y+i) = K_0 \alpha \exp(-\alpha t) \quad (6)$$

Em que, α é o coeficiente adaptativo determinado por estatísticas locais da janela; K_0 é a constante normalizadora; t é a distância entre *pixel* corrente (x, y) ao *pixel* na posição $(x+i, y+i)$.

4.5. Extração de números digitais (ND)

Antes da extração dos valores digitais houve necessidade de uniformizar tamanhos de resolução espacial das imagens, sendo 30 m para imagens do sensor OLI e 10 m para imagens radar e Sentinel 2A/MSI. As imagens com 30 m de resolução espacial foram transformadas para 10 m, para permitir a extração de dados digitais numa janela de 100 m x 100 m. A transformação da resolução espacial nas imagens ópticas foi realizada no ambiente do *ArcGis* 10.2 com a ferramenta *resample* do *arc toolbox*, essa ferramenta permite importar imagens no formato *GeoTIFF* e escolher o tamanho da nova resolução espacial do novo *raster* a ser criado (Congalton e Green, 2009).

Cada parcela no campo tinha uma área de 1ha com o seu centro e extremidades marcado. Ao marcar os dados com GPS, sempre há erros de posicionamento, especialmente quando as correções diferenciais não estão disponíveis (erros de até 3-5 m são comuns) (Kasischke *et al.*, 1997). Para não aumentar os erros de posição não foram usadas as coordenadas das extremidades, mas sim foi criado um *buffer* em torno de cada centro marcado com um raio de 50 m. Com o círculo criado foi possível criar linhas rectas paralelas nas quatro extremidades do mesmo, formando um quadrado

de 1ha. Todos os *pixels* dentro das parcelas foram extraídos com a ferramenta *Extract by mask* do *ArcGis* 10.2. Uma vez que os valores dos *pixels* apresentavam uma distribuição normal ($N = 2400$ *pixels*, $Shapiro\ wilk = 0.9607$, $P_{\text{calculado}} = 0.4517$ e $\alpha = 0.05$) optou-se em retirar apenas o valor médio dos *pixels* dentro de cada parcela, o mesmo recomendado por (JAXA, 2007). Para as imagens ópticas foram extraídos valores médios dos índices de vegetação NDVI, SAVI e SR enquanto para as imagens de abertura sintética da banda L (SAR ~23.6 cm) e C (SAR ~ 5.7 cm) de Alos 2/Palsar 2 e Sentinel 1B respectivamente foram extraídos valores digitais médios (brutos sem nenhuma transformação) e posteriormente calculou-se a intensidade de retroespalhamento (IR).

Segundo Ryan *et al.* (2012) a IR mais conhecida por radar *backscatter* é a quantidade de energia espalhada pelo alvo em direcção ao sensor em relação à quantidade de energia que foi emitida pelo sensor (pulso de micro-ondas). É expressa em σ^0 (sigma-zero), que é o retroespalhamento do radar por unidade de área. A unidade de σ é [m^2 / m^2], expressa em decibel (dB) (JAXA, 2007). A fórmula padrão para calcular é dada por equação 7:

$$\gamma^0 = 10 * \log_{10}(ND^2) - K \text{ [dB]} \quad (7)$$

Onde ND é o número digital de *pixels* de imagem medido na imagem SAR (ou, mais precisamente, o valor médio de pixel em um grupo de pixels). K é um factor de calibração que varia dependendo do sensor de SAR e do sistema do processador usado. Para os dados ALOS / PALSAR e Sentinel 1B, o factor de calibração é -83.0 db (JAXA, 2014). O valor da IR (γ^0) normalmente pode variar de cerca de -35 dB (ND ~ 500) em áreas com baixo brilho de retroespalhamento, até cerca de -5 dB (ND ~ 8000) para retrodifusão extremamente alta. γ^0 é geralmente negativo e raramente atinge 0 dB (JAXA, 2006a).

4.6. Estimativa da biomassa lenhosa acima do solo (BLAS)

Uma vez tratando-se de uma área de conservação, o método destrutivo não constitui o meio apropriado para a quantificação de biomassa e carbono florestal, por isso recorreu-se ao método indirecto de estimativa (Siteo e Tchaúque, 2007). O peso seco total (PST) por árvore foi estimado usando uma equação alométrica desenvolvida para a floresta de Miombo. A selecção da equação foi feita mediante a avaliação de quatro equações alométricas encontradas na literatura (tabela 8).

No processo de selecção da melhor equação, para além da análise dos avaliadores estatísticos como maior coeficiente de determinação ajustado (R^2_{aj}) e menor erro padrão da estimativa em percentagem ($S_{yx}\%$) (Floriano *et al.*, 2006), também foram analisadas medidas estatísticas de precisão tais como coeficiente de variação (CV), desvio padrão (SD), intervalo de confiança (95% de probabilidade) e distribuição da biomassa ao longo da linha de regressão (Kennedy, 2008). A ideia principal por detrás dessa análise foi a de encontrar uma equação que se adequa melhor aos dados colhidos no presente estudo e que os valores obtidos apresentem menores erros evitando desse modo a sub ou sobrestimativa de biomassa. Os avaliadores estatísticos estão apresentados no Anexo 3.

Tabela 8: Equações alométricas seleccionadas na literatura e seus respectivos autores, região e tipo de floresta onde cada equação foi desenvolvida.

Equação alométrica	Região	Tipo de Floresta	Autor
$PST = \exp [(-2.134 + 2.530*\ln(DAP))]$	Global	Florestas Tropicais Secas	Brown <i>et al.</i> (1989)
$PST = 0.0625*DAP^{2.553}$	Sul da Tanzânia	Floresta de Miombo	Mugasha e Chamshama (2002)
$PST = 0.171*DAP^{2.347}$	Niassa- Muembe	Floresta de Miombo	Macia (2016)
$PST = 0.1754*DAP^{2.3238}$	Corredor da Beira	Floresta de Miombo	Guedes <i>et al.</i> (2018)

Depois das análises estatísticas supracitadas constatou-se que a equação da função exponencial de Brown *et al.* (1989) apresenta melhor estimativa de BLAS para a área de estudo e condiz com o intervalo de estimativa encontrada na literatura desenvolvida na floresta de Miombo. Sendo assim, para o cálculo de PST por árvore foi usada equação 8 (Brown *et al.*, 1989) e PST por parcela foi usada a fórmula 9 apresentada abaixo:

$$PST = \exp [-2.134+2.530*\ln (DAP)] \quad (8)$$

$$BLAS_i = \sum_{i=n}^1 PST \quad (9)$$

Onde:

PST: Peso seco total (Kg/árvore)

DAP: Diâmetro a altura do peito (cm)

\ln : Logaritmo na base natural

BLAS_i: Biomassa lenhosa total acima do solo (t·ha⁻¹).

4.7. Estimativa de estoque de carbono

O estoque de carbono foi estimado a partir da multiplicação do valor médio da BLAS pelo coeficiente de 0.5 como mostra a fórmula 10. O factor ou *default* de 0.5 corresponde ao teor de carbono presente na biomassa das florestas tropicais (IPCC, 2007). Depois de calcular o carbono ao nível da árvore individual a partir da fórmula 10, foi calculado também o carbono total dentro da parcela ($t \cdot ha^{-1}$) aplicando a fórmula 11. Por último, foi calculado o carbono total dentro de todas parcelas de amostragem a partir da fórmula 12, apresentada abaixo. Os resultados de BLAS e estoque de carbono foram determinados em função do nível de cobertura das árvores dentro dos limites da RNN ($\sim 42000 \text{ km}^2$).

$$C_i = PST * 0.5 \quad (10)$$

$$CT_p = \sum_{i=n}^1 PST * 0.5 \quad (11)$$

$$CT = CT_p(10\% - 25\%) + CT_p(25\% - 50\%) + CT_p(50\% - 75\%) + CT_p(75\% - 100\%) \quad (12)$$

Onde:

C_i : Carbono total em cada árvore (tC/árvore);

i : Árvores medidas dentro da parcela;

0.5: Coeficiente de conversão de biomassa em carbono;

CT_p : Carbono total por parcela (toneladas de carbono~ tC);

CT: Carbono total dentro das áreas de amostragem por nível de cobertura florestal (toneladas de carbono~ tC).

De acordo com Hansen *et al.* (2013) estimar a biomassa por nível de cobertura florestal é crucial pois fornece estimativas em diferentes variações florestais. Os dados de nível de cobertura foram extraídos na plataforma da *Global Forest* (GF) (ver figura 13) no seguinte endereço eletrónico <http://earthenginepartners.appspot.com/science-2013-global-forest>. Esses dados são obtidos a partir de análises temporais de imagens Landsat que caracterizam a extensão e a mudança da floresta ao longo do tempo (mais detalhes sobre dados de nível de cobertura florestal estão disponíveis no endereço eletrónico da GF) (Hansen *et al.*, 2013).

Depois da aquisição dos dados de cobertura florestal, os mesmos foram importados no ambiente *ArcGis* 10.2 onde foram recortadas ao nível da RNN e georreferenciadas para o Datum WGS 1984 Zona 36S. O *raster* de cobertura de dossel florestal no formato *GeoTIFF* foi transformado para *shapefile* (*raster to shapefile*) com objectivo de obter a tabela de atributos. O procedimento *dissolve* no *ArcGis* 10.2 foi usado para poder unir os dados e calcular a área total por cada nível de cobertura florestal. Depois do processamento dos mesmos dados, foram criadas quatro classes de cobertura florestal, nomeadamente: (10% - 25%), (25% - 50%), (50% - 75%) e (75% - 100%), como mostra o mapa da figura 13 abaixo.

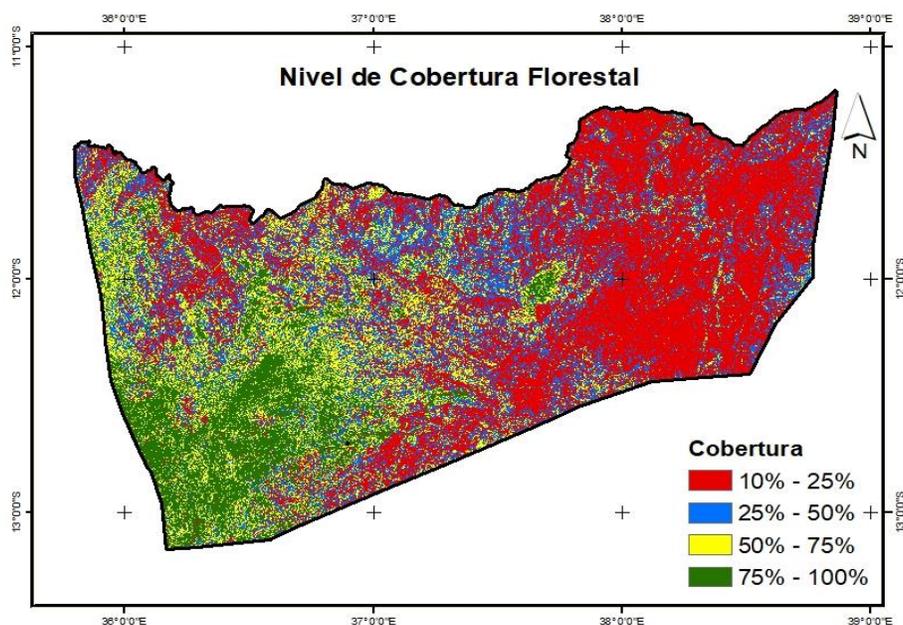


Figura 13: Cobertura do dossel da RNN (Fonte: <http://earthenginepartners.appspot.com/science-2013-global-forest>).

Essas classes foram criadas de modo a permitir a distinção dos dados no mapa, e que o intervalo entre elas seja de fácil interpretação e ao mesmo tempo que representam informação útil para a gestão de biomassa (Siteo e Tchaúque, 2007), ou seja, intervalos de classes cobertura do dossel florestal que possam descrever melhor Miombo aberto, médio e denso dentro da RNN (Ribeiro *et al.*, 2008).

As análises estatísticas das médias de BLAS por cada nível de cobertura florestal foram feitas através de análise da variância (ANOVA) de factor único, com finalidade de saber se as médias de BLAS encontradas em diferentes classes de cobertura são estatisticamente diferentes (95% de

nível de significância). Este tipo de análise constitui uma técnica estatística geralmente empregada na análise de dados experimentais quantitativos (Friedman, 2002). Verificou-se que as variâncias são homogêneas, portanto não existe um fundamento lógico para formação de blocos (Kennedy, 2008).

Nesse caso nenhuma restrição é imposta quanto a casualização, ou seja a atribuição dos tratamentos às unidades experimentais (classes de cobertura florestal) é feita considerando o conjunto completo das unidades experimentais (Friedman, 2002).

Duas hipóteses foram formuladas: hipótese nula (H_0) e hipótese alternativa (H_1), descritos da seguinte forma:

- H_0 : A média de BLAS é igual em todas classes de cobertura do dossel florestal
- H_1 : A média de BLAS é diferente em todas classes de cobertura do dossel florestal

Conclusão do teste de variância (ANOVA): se o $F_{\text{calculado}} > F_{\text{critico}}$, rejeita-se H_0 e conclui-se que existe diferenças significativas de BLAS dentro das classes de cobertura do dossel florestal.

No presente estudo todas as áreas com cobertura das árvores a partir de 10%, foram consideradas áreas florestais de acordo com a definição da FAO (2003) e definição 2 de Moçambique (Falcão e Noa, 2016), embora em Moçambique são considerados áreas florestais a partir dos 30% de cobertura florestal (definição 1) (Falcão e Noa, 2016). A escolha dos 10% neste estudo foi para garantir a maior abrangência da estimativa de biomassa; uma vez que os *dambos* e a vegetação dos *inselbergs* seriam excluídos pois apresentam área com uma cobertura de copa abaixo dos 30% (Ribeiro *et al.*, 2008).

4.8. Ajuste da equação espacial de biomassa

Para o ajuste da equação de biomassa foi utilizado modelo de regressão do tipo linear múltiplo. Segundo Allison (1999) regressão linear múltipla é uma colecção de técnicas estatísticas para construir equações que descrevam de maneira razoável relações entre várias variáveis explicativas de um determinado processo. O modelo de regressão múltipla neste estudo foi usado para prever a BLAS, usando um procedimento *Stepwise* no pacote estatístico Minitab® versão 18.0, esse procedimento remove aleatoriamente uma observação de cada vez para produzir a equação de regressão com o melhor coeficiente de determinação e o menor erro (Friedman, 2002).

A escolha deste tipo de modelo está extremamente ligado ao segundo objectivo do presente trabalho, que consiste em combinar as variáveis dos sensores ópticos e radar na previsão de BLAS. Este modelo permite incorporar mais de uma variável, pois em alguns casos uma variável independente não é capaz de explicar a variável de resposta (Zanette, 2017). A regressão linear múltipla é dada pelo seguinte modelo:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (13)$$

Onde:

Y : Variável dependente: biomassa ($t \cdot ha^{-1}$);

X : Variáveis independentes: NDVI1, SAVI1, SR1, NDVI2, SAVI2, SR2, σ^{HH} , σ^{HV} , σ^{VV} e σ^{VH} ;

β_i : Coeficientes ou parâmetros do modelo;

ε : Erro aleatório;

4.8.1. Combinação das variáveis

Depois de determinar o modelo a ser usado para o ajuste da equação de biomassa, houve necessidade de determinar as fases de integração das variáveis espectrais (mostradas na figura 14) e a biomassa. A combinação das variáveis consistiu em criar várias possibilidades de integração das variáveis ópticas e radar para serem inseridas no procedimento *Stepwise*. Essa integração consistiu em quatro fases, sendo que a primeira fase (1) as variáveis espectrais do sensor OLI foram integradas com variáveis dos sensores Palsar 2, Sentinel 1B e MSI. A segunda fase (2) consistiu em integrar variáveis espectrais do sensor Palsar 2 e variáveis dos sensores OLI, MSI e

Sentinel 1B. A terceira fase consistiu em integrar variáveis espectrais do sensor Sentinel 1B com as variáveis do sensor MSI. A quarta combinação e a última integrou-se variáveis de todos os sensores (Palsar 2, Sentinel 1B, OLI e MSI).

Em cada fase de procedimento *Stepwise* foi selecionada a equação que apresentou melhor estatísticas de regressão, essas equações foram comparadas entre elas. A figura 14 apresentada em forma de diagrama mostra todas as fases de integração das variáveis espectrais.

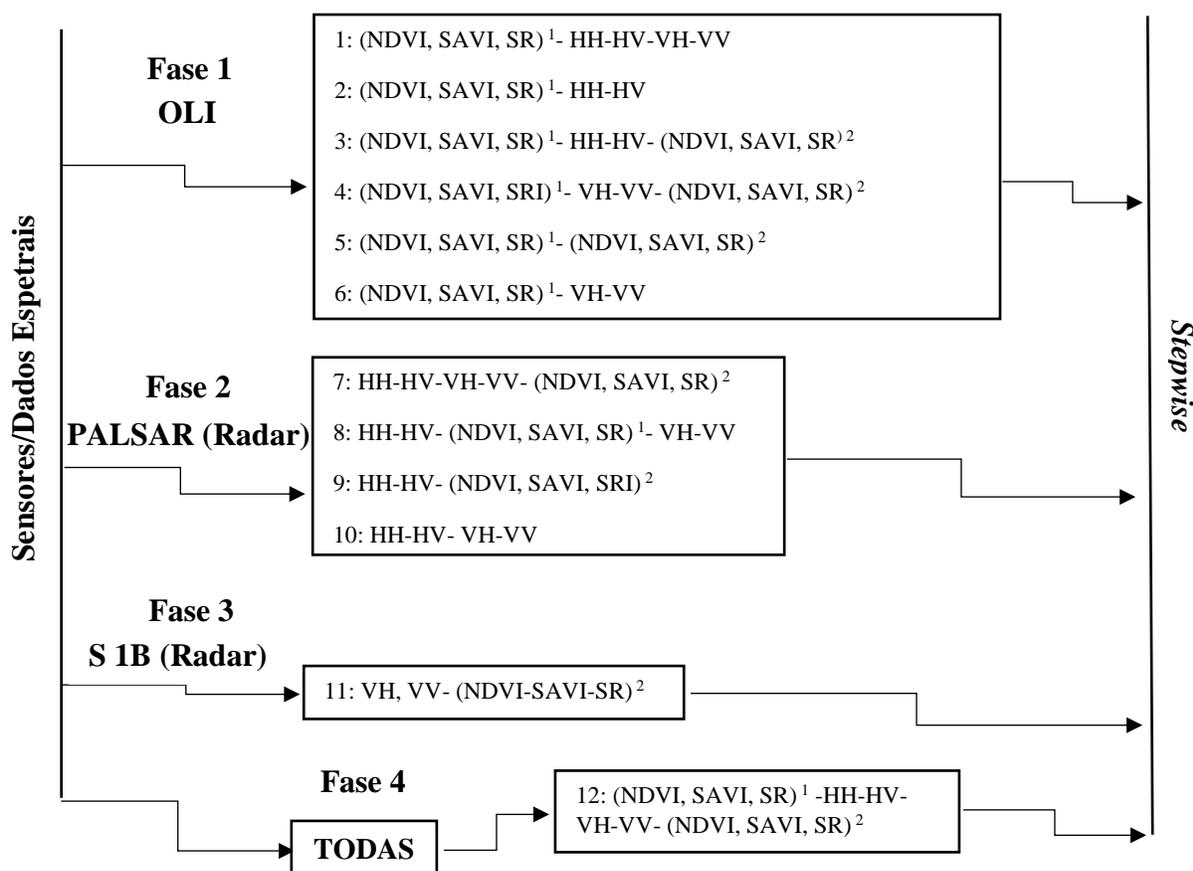


Figura 14: Diagrama de integração das variáveis espectrais para o modelo de biomassa.

Legenda:

- $(NDVI, SAVI, SR)^1$: índices de vegetação obtidos com imagem Landsat 8/OLI
- $(NDVI, SAVI, SR)^2$: índices de vegetação obtidos com imagem Sentinel 2B/MSI
- σ^{HH}, σ^{HV} : IR das polarizações do sensor Palsar 2
- σ^{VH}, σ^{VV} : IR das polarizações do Sentinel 1B

4.8.2. Selecção da melhor equação de biomassa

Para a selecção da melhor equação de biomassa usou-se avaliadores estatísticos mais usados na ciência florestal para medir a qualidade das variáveis submetidas ao modelo de regressão. Sendo assim, cinco avaliadores estatísticos foram aplicadas neste estudo, nomeadamente: maior coeficiente de determinação ajustado (R^2_{aj}), seguido do menor erro padrão da estimativa em percentagem ($S_{yx}\%$), maior estatística F , menor critério de informação de Akaike (AIC) (AIC foi usando também para comparar as melhores equações), análise gráfica da distribuição dos resíduos padronizados e menor valor ponderado dos escores (Zanette, 2017).

a) Coeficiente de determinação ajustado

Segundo Kennedy (2008), a integração de inúmeras variáveis no modelo de regressão, mesmo quando estas têm pouco poder explicativo na variável dependente (Y) aumentarão o valor de coeficiente de determinação (R^2) aumentando desse modo a inclusão indiscriminada de variáveis. Entretanto como forma de minimizar esse efeito aplica-se uma medida alternativa de coeficiente de determinação, que penaliza a inclusão de variáveis pouco explicativos. Desse modo trata-se de coeficiente de determinação ajustado, dado pela seguinte fórmula matemática:

$$R^2_{aj} = \left[\frac{\left(\sum_{i=1}^n (\gamma - \theta)^2 \right)}{\left(\sum_{i=1}^n (\gamma - \mu)^2 \right)} \times \left(\frac{n-1}{n-p} \right) \right] \quad (14)$$

Onde

γ : Valor da variável dependente (Biomassa);

θ : Valor da variável independente (NDVI1, SAVI1, SR1, NDVI2, SAVI2, SR2, $\sigma^{\circ}HH$, $\sigma^{\circ}HV$, $\sigma^{\circ}VV$ e $\sigma^{\circ}VH$);

μ : Média dos valores observados da variável dependente (BLAS);

n : Número de observações ($n = 24$)

p : Número de coeficientes do modelo.

b) Erro padrão de estimativa

O erro padrao da estimativa (S_{yx}) é uma medida estatística que mede a dispersão média entre os valores observados e estimados ao longo da linha de regressão, sendo que quanto maior for o valor

de S_{yx} menor terá sido o ajuste da equação (Machado *et al.*, 2002). A expressão para o cálculo é dada pela seguinte fórmula:

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^n (\gamma - \mu)^2}{n-p}} \quad (15)$$

$$S_{yx}\% = \frac{S_{yx}}{\mu} \times 100 \quad (16)$$

Onde:

S_{yx} : Erro padrao da estimativa;

$S_{yx}\%$: Erro padrao da estimativa em percentagem;

γ, μ, n, p : descritos na fórmula 14.

c) Estatística F

A distribuição F de Fisher, mede a razão entre os quadrados da regressão e a soma dos resíduos, com graus de liberdade p e $n-p$ respectivamente (Zanette, 2017). A expressão para o seu cálculo é apresentado pela seguinte fórmula:

$$F = \frac{SQR/p}{SQRe/(n-p)} \quad (17)$$

Onde:

SQR : Soma dos quadrados da regressão;

$SQRe$: Soma dos quadrados de residuo;

n, p : descritos nas fórmulas anteriores.

d) Análise dos resíduos padronizados

Segundo Kennedy (2008) a análise gráfica dos resíduos padronizados é indispensável na selecção da melhor equação alométrica, mesmo quando os estimadores dos ajustes sejam considerados bons. Essa análise é crucial porque mostra se existe tendenciosidade nas estimativas da variável

dependente ao longo da curva de regressão, independência dos resíduos e homogeneidade das variâncias. De acordo com Zanette (2017) também é importante determinar a amplitude de resíduo através da diferença do maior e menor resíduo, principalmente quando duas ou mais equações apresentam um comportamento similar ao longo da curva de regressão, sendo assim, será melhor equação, aquela que apresentar menor amplitude de resíduos. A análise dos resíduos sempre deve ser acompanhada com estatísticas de regressão já citadas anteriormente (Kennedy, 2008). A expressão para o seu cálculo em percentagem é dada pela seguinte fórmula:

$$Re (\%) = \left(\frac{\gamma - \theta}{\mu} \right) \times 100 \quad (18)$$

Onde:

$Re (\%)$: Resíduos em percentagem

γ, θ, μ : descritos nas fórmulas anteriores.

e) Valores ponderados dos padrões estatísticos

O método de análise das equações a partir do valor ponderado (VP) também foi aplicado por Zanette (2017). Esse critério de selecção considera todas variáveis estatísticas e sintetiza os resultados facilitando dessa forma a escolha da melhor equação. O valor ponderado é determinado atribuindo valores ou pesos aos parâmetros estatísticos. As estatísticas são ordenadas de acordo com sua eficiência, sendo atribuído 1 para equações mais eficientes, 2 para a segunda equação eficiente e assim sucessivamente. Depois faz-se o somatório dos pesos e a melhor equação é a que apresentar menor valor ponderado (Floriano *et al.*, 2006).

4.8.3. Comparação das melhores equações

A comparação dos melhores modelos foi feita usando o Critério de Informação de Akaike (AIC). Segundo Floriano *et al.* (2006) A lógica do teste pelo AIC é que não há hipótese sendo testada como no teste F. Ao contrário, o teste permite determinar equação mais correcta em relação ao outro. Este teste pode ser utilizado para comparar qualquer tipo de modelo: lineares e não-lineares. De acordo com o mesmo autor somente devem ser comparadas equações que se ajustam bem aos dados, devendo-se antes eliminar todas as equações que não apresentam bons resultados, ficando-

se com os dois ou três melhores para a comparação final por meio de ferramentas estatísticas como o AIC.

De acordo com Akaike (1985) quanto menor for o valor de AIC obtido pelo modelo, melhor é a sua qualidade para realizar previsões de biomassa. A sequência para escolher a equação pelo AIC deve respeitar os seguintes passos: ajustar as equações; anotar a soma de quadrados do erro de cada equação, determinar o número de observações (n), calcular o AIC (se o $n > 100$ indivíduos), ou se necessário calcular o AICc (corrigido); se forem usados populações pequenas ($n < 100$ indivíduos). Segundo Akaike (1985) a comparação entre dois modelos é feita pela variação do AIC dos mesmos modelos. De referir que essa variação ou diferença (ΔAIC) é que permite a escolha do melhor modelo num conjunto de modelos, principalmente quando apresentam valores estatísticos muito aproximados. Quando esta diferença se encontra entre 0 – 4, existem evidências suficientes para afirmar que os modelos são iguais, entre 4 -10 indica menor suporte enquanto uma diferença acima de 10 pode indicar que os modelos são diferentes (Floriano *et al.*, 2006). Para o cálculo de AIC e a sua diferença (ΔAIC) são dadas pelas seguintes fórmulas:

$$AIC = n * \ln (SQ/n) + 2K \quad (19)$$

$$\Delta AIC = AIC_2 - AIC_1 = n * \ln (SQ_2 / SQ_1) + 2(K_2 - K_1) \quad (20)$$

Onde:

SQ: Soma de quadrados do erro;

SQ_1 e SQ_2 : Soma de quadrados do erro da equação 1 e 2;

K_1 e K_2 : Número de parâmetros da equação 1 e 2;

n : Número de observações e \ln = logaritmo de base natural.

Para finalizar esta secção de ajuste de equações é importante realçar que os cálculos das estatísticas e elaboração dos gráficos para este estudo, foram usados programas estatísticos como Statistic® versão 9.0, Minitab® versão 18.0 e Microsoft Excel 2016®. Para o processamento de imagens foi usado ArcGIS 10.2 e ERDAS 2014, como já havia sido referido anteriormente. A função de cada programa informático (**b**) e os passos de processamento (**a**) podem ser visualizadas no fluxograma da figura 15 mostrado abaixo.

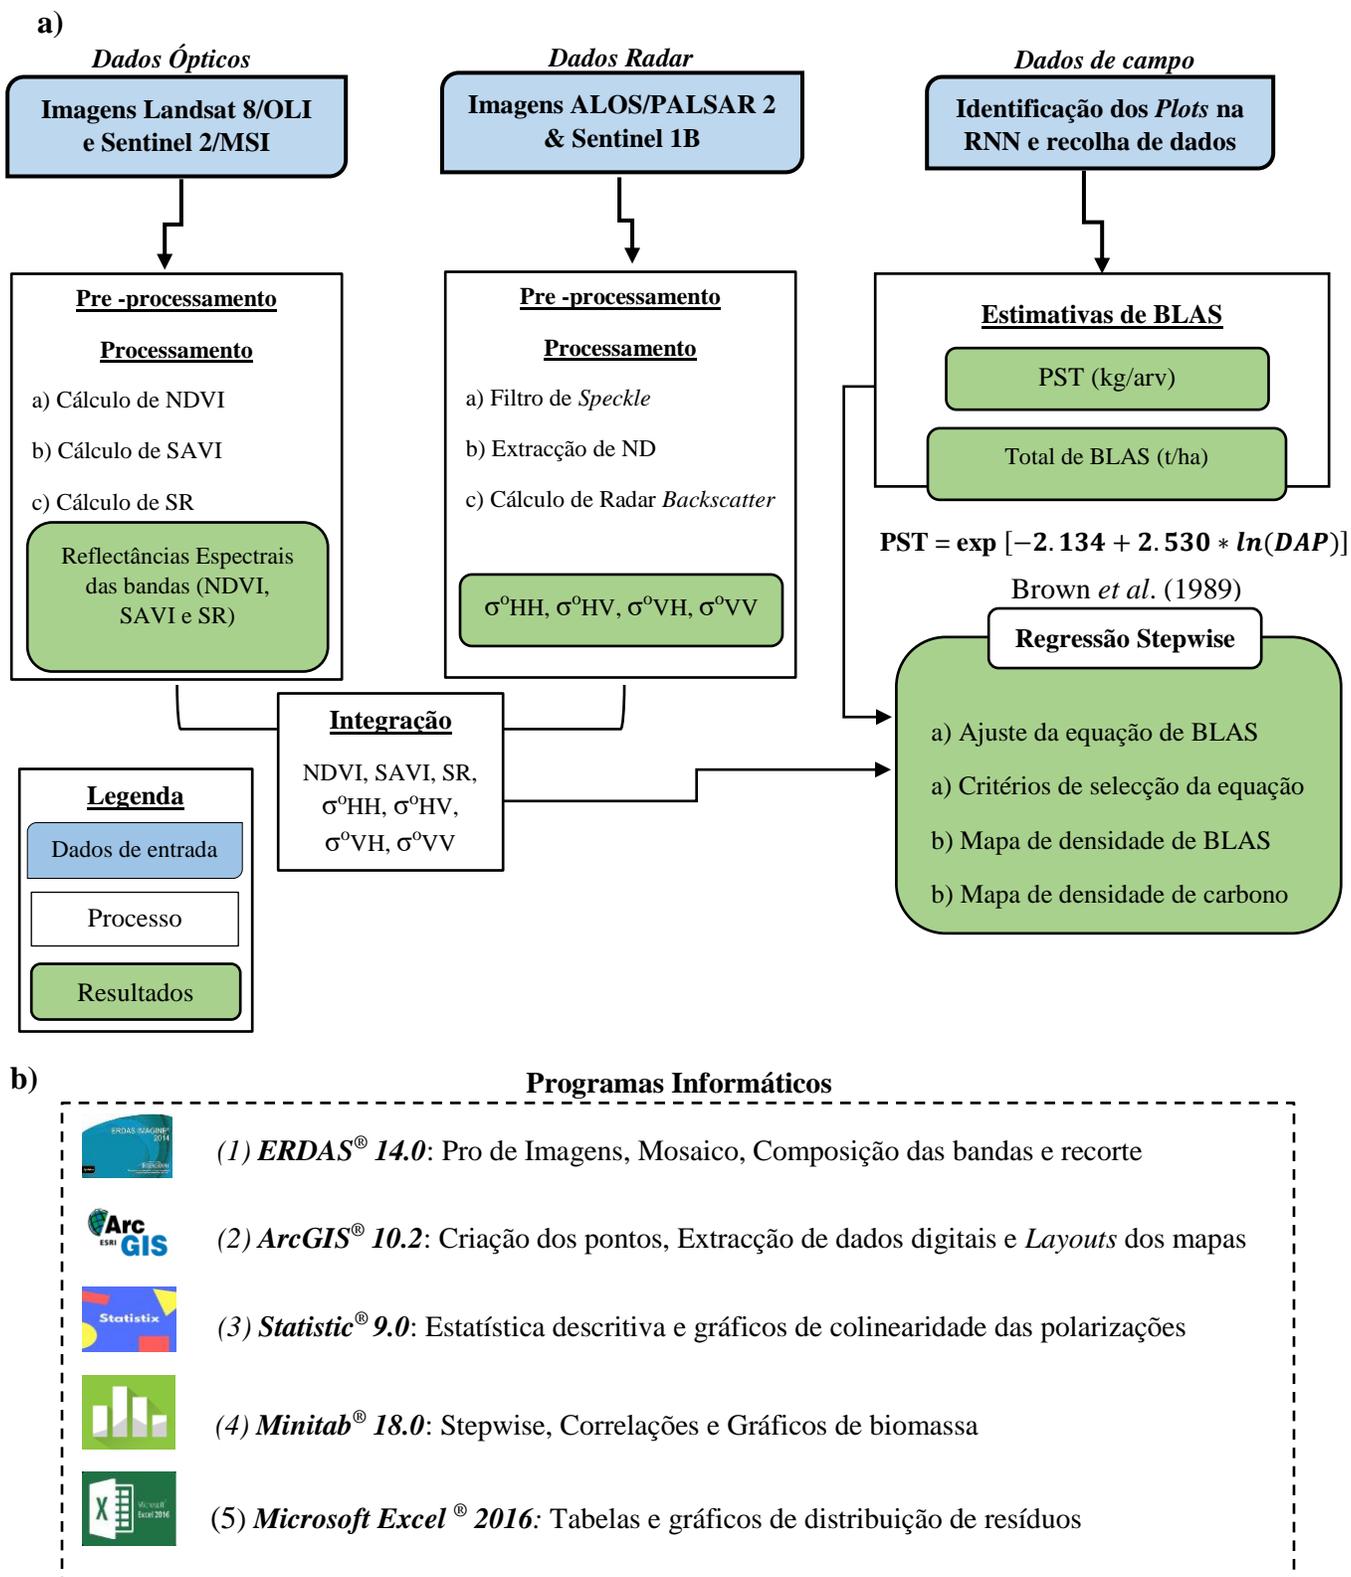


Figura 15: Fluxograma do trabalho (a) e programas informáticos usados no processamento (b)

Limitações do estudo

A extensão da RNN não permite a aquisição de uma única cena através do sensor que cobre toda área devido a largura da faixa dos satélites. Portanto as cenas que cobrem toda área foram capturadas em datas diferentes, principalmente para imagens ópticas (Landsat 8/OLI e Sentinel 2/MSI). As imagens Landsat 8/OLI apresentaram a seguinte diferença de datas: cena 1: LC08-L1TP-166068-data-2017/05/20, cena 2: LC08-L1TP-166069-data-2017/05/20, cena 3: LC08-L1TP-167068-data-2017/05/27 e cena 4: LC08-L1TP-167069-data-2017/05/27. As imagens Sentinel 2A/MSI apresentam a seguinte descrição: cena 1: L1C-T36LZL-A009627-data-2017/04/26, cena 2: L1C-T36LZM-A009670-data-2017/04/29, cena 3: L1C-T36LZN-A004980-data-2017/04/18, cena 4: L1C-T36LZN-A009670-data-2017/04/29, cena 5: L1C-T37LBG-A009627-data-2017/04/26, cena 6: L1C-T37LCG-A010056-data-2017/04/26, cena 7: L1C-T37LCH-A009627-data-2017/04/26 e cena 8: L1C-T37LDG-A009913-data-2017/05/16. Essa pequena diferença de datas de captura de imagens pode ter constituído fonte de erro devido à diferença da reflectância nas imagens, como resultado da diferença da insolação entre as datas de aquisição das imagens pelos sensores ópticos.

5. RESULTADOS & DISCUSSÃO

5.1. Descrição estatística das variáveis espectrais

As variáveis espectrais (NDVI1, SAVI1, SR1, NDVI2, SAVI2, SR2, $\sigma^{\circ}HH$, $\sigma^{\circ}HV$, $\sigma^{\circ}VV$ e $\sigma^{\circ}VH$) analisadas são apresentadas na tabela 9 em função dos sensores (OLI, MSI, Palsar 2 e S1B) e com seus respectivos valores estatísticos de média (μ), desvio padrão (SD), coeficiente de variação (CV), Mínimo e Máximo. Esses valores foram obtidos a partir dos dados de Anexo 4.

Tabela 9: Estatística descritiva das variáveis espectrais dos sensores OLI de Landsat 8, MSI de Sentinel 2A, Palsar 2 de Alos 2 e Sentinel 1 da família Sentinel B.

Sensores	Variáveis	Média	Desvio Padrão	CV (%)	Mínimo	Máximo
OLI	NDVI1	0.26	0.12	48.70	0.18	0.76
	SAVI1	0.24	0.09	38.13	0.10	0.40
	SR1	3.80	1.40	36.93	2.00	7.50
MSI	NDVI2	0.22	0.11	48.10	0.35	0.58
	SAVI2	0.22	0.10	43.12	0.08	0.40
	SR2	3.23	1.21	37.43	1.20	6.00
PALSAR 2	$\sigma^{\circ}HH$	-8.71	3.03	34.78	-14.0	-3.00
	$\sigma^{\circ}HV$	-13.25	2.52	19.05	-19.0	-9.00
S1B	$\sigma^{\circ}VV$	-23.21	3.65	15.72	-29.0	-17.0
	$\sigma^{\circ}VH$	-24.75	3.85	7.930	-29.0	-22.0

Os resultados da análise estatística mostram que no sensor OLI a variável NDVI1 tem um valor mínimo e máximo de 0.18 e 0.76 respectivamente, apresentando um CV igual a 48.7%, seguida de SAVI1 e SR1 com 38.13% e 36.93% de CV, respectivamente. Ainda analisando o sensor OLI, a variável SAVI1 apresentou valores que variam entre 0.10 a 0.40, com uma média 0.24 ± 0.09 . Para as variáveis do sensor MSI o valor de CV variou em 48%, 43% e 37% para NDVI2, SAVI2 e SR2, respectivamente. O CV (%) em cada variável, mostra que a amplitude da mesma pode ser explicada pela variação de densidade das florestas de Miombo, sendo que parcelas com maior cobertura florestal apresentaram maiores valores, seguidas de parcelas médias e por último de baixa densidade (Carreiras *et al.*, 2013). A figura 16 mostra com detalhes a distribuição espacial de todos índices de vegetação (IV) testados no presente trabalho.

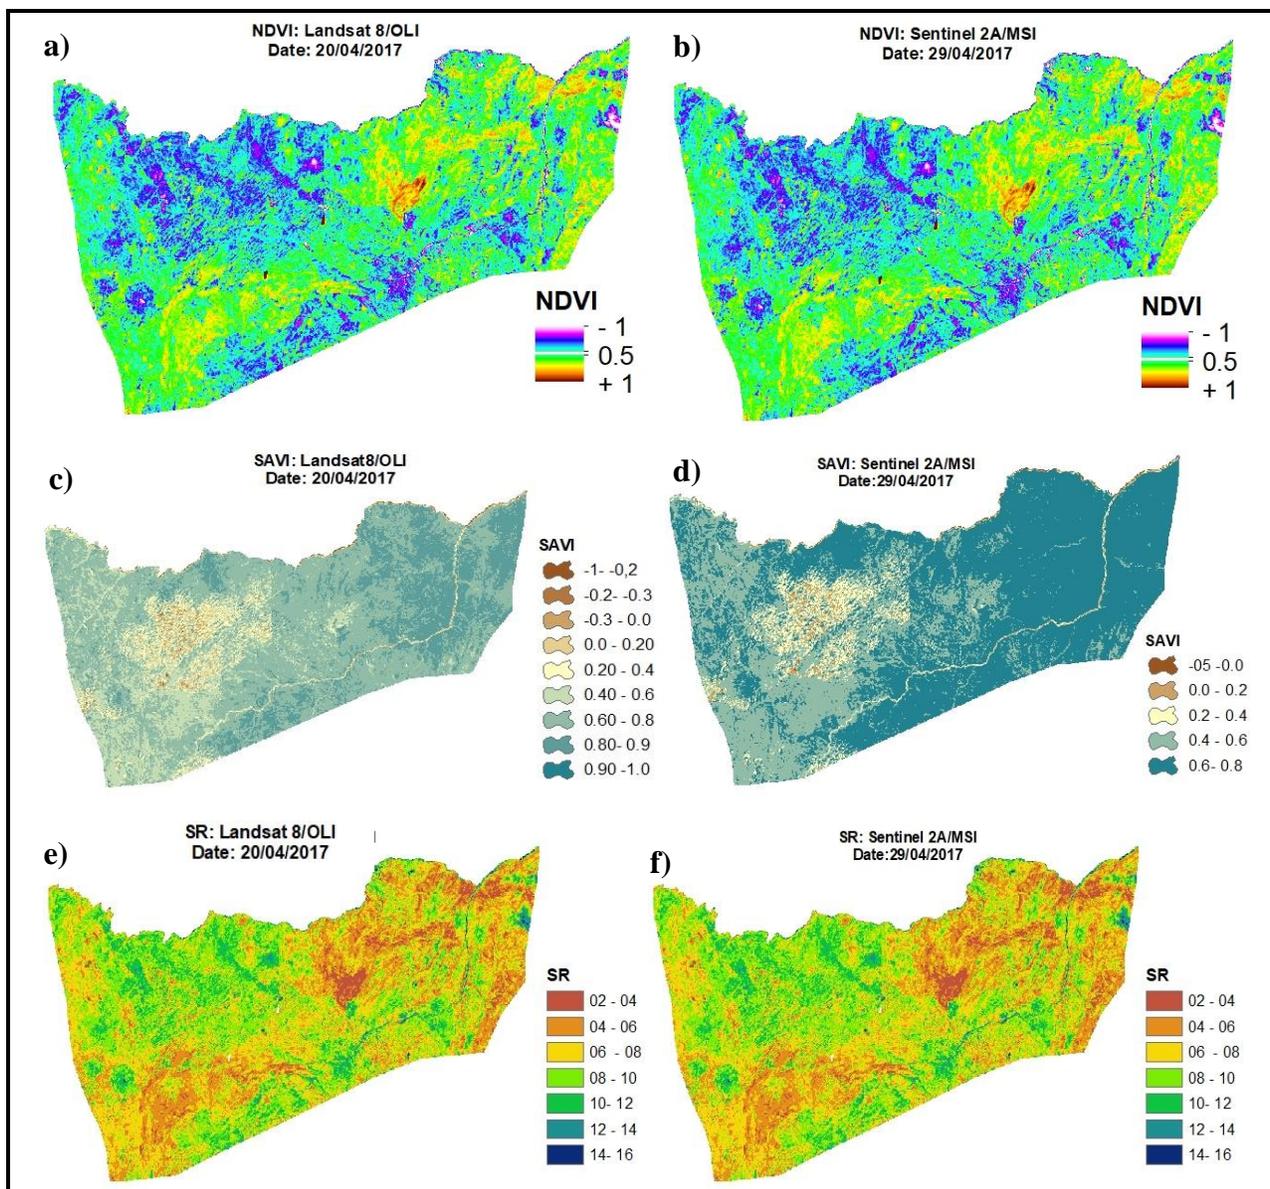


Figura 16: Índices de vegetação obtidos na RNN~ 42000 km² (a) NDVI Landsat 8/OLI; (b) NDVI Sentinel 2A/MSI; (c) SAVI Landsat 8/OLI; (d) SAVI Sentinel 2A/MSI; (e) SR Landsat 8/OLI e (f) SR Sentinel 2A/MSI.

Os resultados das variáveis dos sensores radares em forma de intensidade de retroespalhamento (IR, γ°) das polarizações $\sigma^\circ\text{HH}$ e $\sigma^\circ\text{HV}$ (Alos 2/Palsar 2-Banda L = 23.6 cm) e $\sigma^\circ\text{VV}$ e $\sigma^\circ\text{VH}$ (Sentinel 1B- Banda C = 5.7 cm) mostram que a polarização $\sigma^\circ\text{HH}$ apresentou valor mínimo, máximo, médio e desvio padrão de IR igual a -14, -3, -8.7 e ± 3.03 respectivamente, $\sigma^\circ\text{HV}$ (-19, -

9, -13.3 ± 2.52), $\sigma^{\circ}\text{VH}$ ($-29, 22, -24.75 \pm 3.85$) e $\sigma^{\circ}\text{VV}$ ($-29, -17, -23.21 \pm 3.65$). A correlação linear entre as polarizações ($\sigma^{\circ}\text{HH}$, $\sigma^{\circ}\text{HV}$, $\sigma^{\circ}\text{VV}$ e $\sigma^{\circ}\text{VH}$) e dados de BLAS pode ser vista na figura 17. Nota-se claramente que ao aumentar o valor médio de BLAS, a IR também tende a aumentar na linha de regressão, porém algumas variáveis correlacionam-se melhor com BLAS em relação as outras.

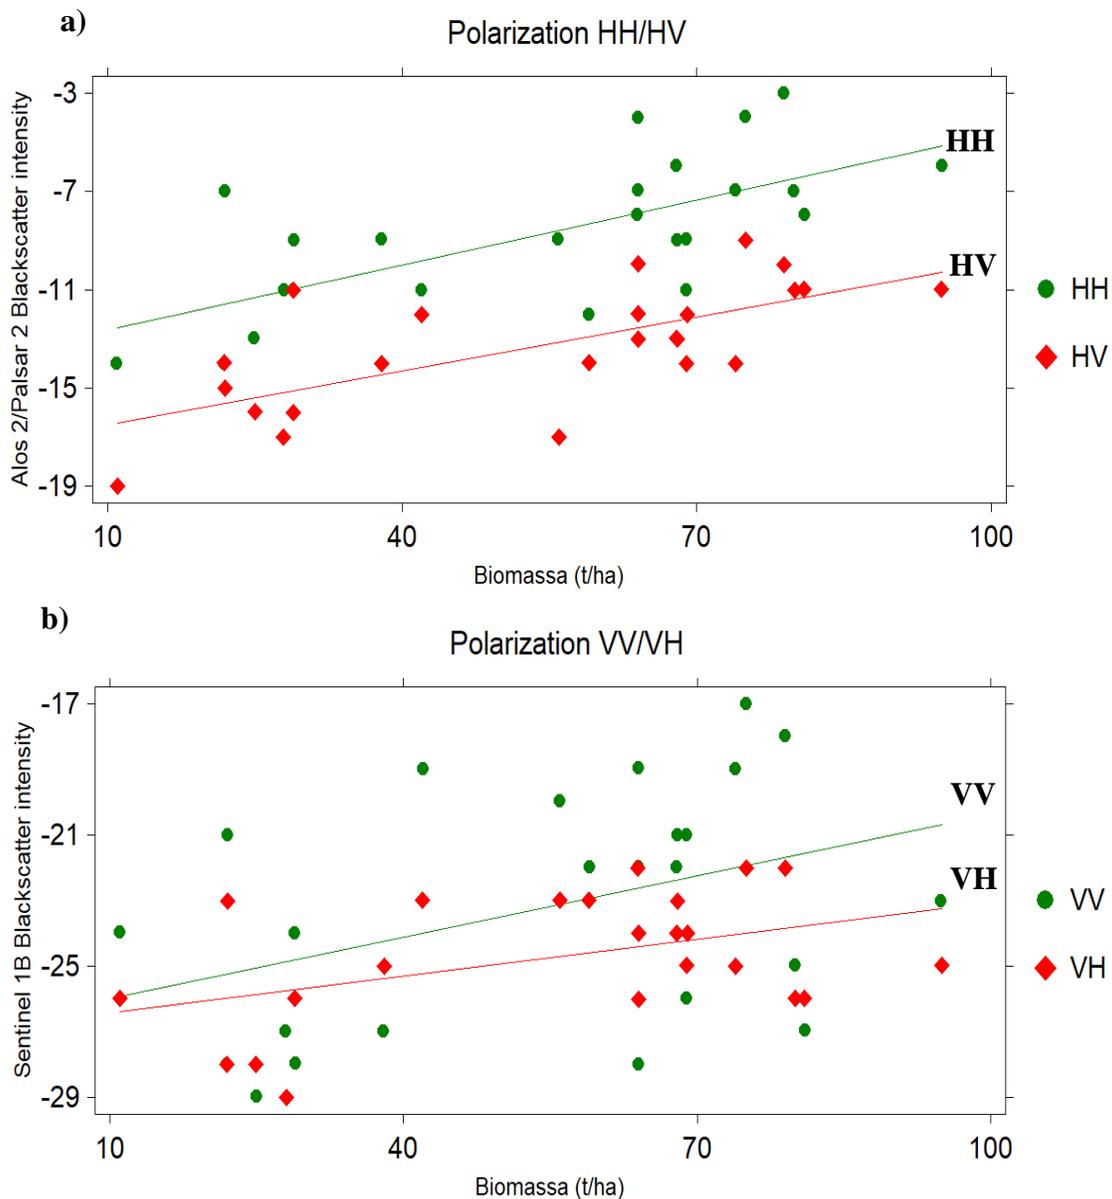


Figura 17: Relação entre a intensidade de retroespalhamento (γ_0 , dB) e a biomassa estimada ($\text{BLAS} \sim \text{t} \cdot \text{ha}^{-1}$). (a) Polarizações $\sigma^{\circ}\text{HH}$ e $\sigma^{\circ}\text{HV}$ (banda L-SAR ~ 23.6 cm) da imagem Alos 2/Palsar 2 e (b) polarizações $\sigma^{\circ}\text{VV}$ e $\sigma^{\circ}\text{VH}$ (banda C-SAR ~ 5.7 cm) da imagem Sentinel 1B.

Embora as variáveis radar (HH, HV, VV e VH) tenham apresentado uma relação com a BLAS nota-se que IR das polarizações obtidos no modo horizontal ($\sigma^{\circ}\text{HH}$) do Palsar 2 e vertical ($\sigma^{\circ}\text{HV}$) do Palsar 2 apresentam uma boa relação com BLAS (com coeficiente de determinação igual: $R^2 = 0.58$ e $R^2 = 0.55$ respectivamente) em relação a outras polarizações ($\sigma^{\circ}\text{VV}$ ~ $R^2 = 0.27$ e $\sigma^{\circ}\text{VH}$ ~ $R^2 = 0.33$) porque os seus valores encontram-se mais próximo da linha de regressão e consequentemente maior R^2 . Segundo Lee e Potter (2009) às polarizações $\sigma^{\circ}\text{HH}$ recebem melhor o sinal do retroespalhamento em relação as polarizações combinadas ($\sigma^{\circ}\text{VV}$ e $\sigma^{\circ}\text{VH}$). Ryan *et al.* (2012) acrescentam que estudos anteriores demonstraram que essas polarizações $\sigma^{\circ}\text{HH}$ e $\sigma^{\circ}\text{HV}$ são mais sensíveis à biomassa do que $\sigma^{\circ}\text{VV}$ e $\sigma^{\circ}\text{VH}$. Segundo Carreiras *et al.* (2013) a floresta de Miombo na Província da Zambézia, também mostrou que as polarizações $\sigma^{\circ}\text{HH}$ e $\sigma^{\circ}\text{HV}$ de sensor Palsar correlacionam-se melhor com os dados de biomassa. As correlações de outras variáveis espectrais com BLAS podem ser visualizadas no Anexo 5.

5.2. Biomassa e carbono florestal

5.2.1. Biomassa

A RNN é uma das maiores reservas do País com cerca de 42000 km², formada por diversas formações vegetais, sendo que a mais dominante é a floresta de Miombo apresentando-se em densidade baixa, média e alta (Ribeiro *et al.*, 2008). Segundo a classificação de Marzoli (2007) a floresta de Miombo ocupa uma extensão pouco acima de 80% da área total da RNN, as outras formações incluem pequenas áreas arbustivas, pradarias, agricultura itinerante por vezes associada com arbustos, *dambos*, vegetação herbácea, vegetação ribeirinha, corpos de água, solo exposto e áreas habitacionais. Algumas espécies arbóreas registadas durante o levantamento dos dados do campo são: *Brachystegia boehmii*, *Brachystegia spiciformis*, *Julbernardia globiflora*, *Diplorhynchus condylocarpon*, *Pseudolachnostylis maprouneifolia*, *Pterocarpus angolensis*, *Combretum sp* e *Terminalia brachystemma*. Essas espécies também foram observadas por Ribeiro *et al.* (2013) na RNN, num estudo sobre a dinâmica da floresta de Miombo em termos de composição, estrutura e biomassa.

A classe de cobertura abaixo dos 10% corresponde ao solo exposto, corpos de água, áreas habitacionais, áreas agrícolas e áreas com vegetação arbustiva muito dispersa, essas áreas ocupam um pouco mais de 7000 km² (21%). A primeira classe de cobertura considerada floresta neste

estudo (10% - 25%) apresenta uma maior extensão dentro da RNN, ocupando cerca de 40% da área total da reserva. Essas áreas apresentam um mosaico de capim e outras árvores lenhosas dispersas ou agrupadas, ocorrendo em sua maior parte ao longo dos rios. A segunda classe do nível de cobertura florestal (25% - 50%) ocupa cerca de 32.2% da área total da reserva, sendo encontrado Miombo aberto em maior parte da sua extensão. Os últimos níveis de cobertura (50% - 75% e 75% - 100%) apresentam as menores áreas com cerca de 6.5% e 0.21% da área total respectivamente. Essas áreas são dominadas pelo Miombo denso, e uma parte ocorre no topo e nas encostas das montanhas Mecula e Jao.

A distribuição da biomassa pelas classes de cobertura no presente estudo está em concordância com trabalhos científicos ligados a estimativa da biomassa e estoque de carbono. Um dos exemplos é o estudo feito por Carreiras *et al.* (2013) realizado no distrito de Lugela na província da Zambézia usando dados de radar de abertura sintética da banda L. No estudo referido constatou-se que a biomassa e o estoque de carbono aumentam com o aumento de densidade de cobertura do dossel. Araújo (1999) afirma que embora as áreas com maior cobertura de dossel apresentem maior BLAS por hectare, em muitos casos, as mesmas áreas apresentam menor tamanho em extensão o que acaba influenciando nos valores totais de BLAS. Esse cenário notou-se também no presente estudo, onde as áreas com maior cobertura do dossel apresentam áreas menores (ver tabela 10).

O número de indivíduos por hectare (ind/ha) por cada classe de cobertura apresenta uma variação, como mostra a tabela 10. A densidade dos indivíduos variou da seguinte maneira: 332 ind/ha (10% - 25%), 426 ind/ha (25% - 50%), 564 ind/ha (50% - 75%) e 633 ind/ha (75% - 100%). A média de BLAS também varia em função da cobertura do dossel, às classes com maior cobertura do dossel apresentam maiores valores de BLAS em relação as classes de menor cobertura.

A BLAS média obtida para toda área foi de $55 \text{ t} \cdot \text{ha}^{-1}$ e os valores variam entre $11 \text{ t} \cdot \text{ha}^{-1} \pm 23.57$ a $95 \text{ t} \cdot \text{ha}^{-1} \pm 23.57$, correspondendo a BLAS mínima e máxima, respectivamente. Os estudos de Carreiras *et al.* (2013) e Ribeiro *et al.* (2008) mostram valores médios de BLAS de $30 \text{ t} \cdot \text{ha}^{-1}$ e $56.8 \text{ t} \cdot \text{ha}^{-1}$ respectivamente. Outros resultados similares aos do presente estudo foram obtidos também por Ryan *et al.* (2012), onde estimaram um valor médio de BLAS florestal de $45 \text{ t} \cdot \text{ha}^{-1}$ para uma floresta de Miombo em Gorongosa e Nhamatanda na província de Sofala.

A diferença das médias de BLAS por nível de cobertura é estatisticamente significativa a partir da análise da variância com $\alpha = 0.05$ ($F_{\text{calculado}} \sim 72.8 > F_{\text{critico}} \sim 3.02$), ou seja, os dados mostram que

existem evidências suficientes que indicam que existe diferença nas médias de biomassa nas quatro classes de cobertura florestal. A tabela resumo de ANOVA está patente no Anexo 6. Tomo (2012) no estudo sobre as estimativas de estoque de carbono na floresta do Miombo em Gondola também notou que a diferença de biomassa entre tipos florestais era estatisticamente significativo nas Florestas Densas (FD), Florestas Abertas (FA), Outras Formações Lenhosas (OFL) e Áreas Agrícolas (AA). A tabela 10 para além de apresentar a BLAS em $t \cdot ha^{-1}$, também mostra a BLAS total em toneladas dentro das parcelas de amostragem e o número de indivíduos contabilizados por hectare por classe de cobertura.

Tabela 10: Classes de cobertura florestal, número de parcelas de amostragem por cada nível de cobertura, número de indivíduos (ind/ha), biomassa total em locais de amostragem (t) e biomassa média ($t \cdot ha^{-1}$).

Classes de Cobertura Florestal	Área (Km ²)	# Parcelas	Contagem	Biomassa	
			(ind/ha)	Total (t)	Média (t/ha)
10% - 25%	16702	8	332	203	25.5 ± 7.76*
25% - 50%	15208	7	426	416	59.6 ± 8.67*
50% - 75%	2748	5	564	356	71.0 ± 3.24*
75% - 100%	85	4	633	336	84.0 ± 7.54*
Total	34743	24	1955	1311	-

* Desvio Padrão da biomassa estimada

A figura 18 faz uma comparação do valor médio de BLAS obtido neste estudo e os valores obtidos nos estudos de Mugasha e Chamshana (2002), Ribeiro *et al.* (2008), Ryan *et al.* (2012) e Macia (2016) na floresta de Miombo. Os resultados mostram que as estimativas estão dentro do intervalo dos valores médios estimados em florestas de Miombo (Ribeiro *et al.*, 2013). Segundo Desanker *et al.* (1997) as estimativas típicas das florestas de Miombo estão em torno de $55 t \cdot ha^{-1}$ nas zonas baixas, variando entre $21 t \cdot ha^{-1}$ – $84 t \cdot ha^{-1}$. De acordo com o mesmo autor, o Miombo húmido maduro apresenta uma média de $90 t \cdot ha^{-1}$, variando entre $21 t \cdot ha^{-1}$ - $159 t \cdot ha^{-1}$.

Comparando especificamente os resultados de estimativa de BLAS deste estudo, com os de Desanker *et al.* (1997) nota-se que os intervalos de estimativas destacadas nas zonas baixas e no Miombo húmido foram observadas neste estudo ($11 t \cdot ha^{-1}$ - $95 t \cdot ha^{-1}$), uma vez que a RNN tem maior extensão e engloba o Miombo aberto, médio e denso (Ribeiro *et al.*, 2008).

Porém existem estudos que estimaram BLAS muito acima do valor estimado neste estudo, por exemplo Munishi e Shear (2004) citados por Lisboa (2014) estimaram cerca de $872 \text{ t}\cdot\text{ha}^{-1}$ e $648 \text{ t}\cdot\text{ha}^{-1}$ para as florestas não perturbadas das Reservas Florestais de Usambara e Uluguro (Tanzânia) respectivamente. Os autores afirmam que esses valores altos estão relacionados com o local onde as parcelas foram estabelecidas, uma vez que o estudo foi realizado nas zonas montanhosas onde a precipitação média anual (PMA) é de 2.900 mm a 4.000 mm.

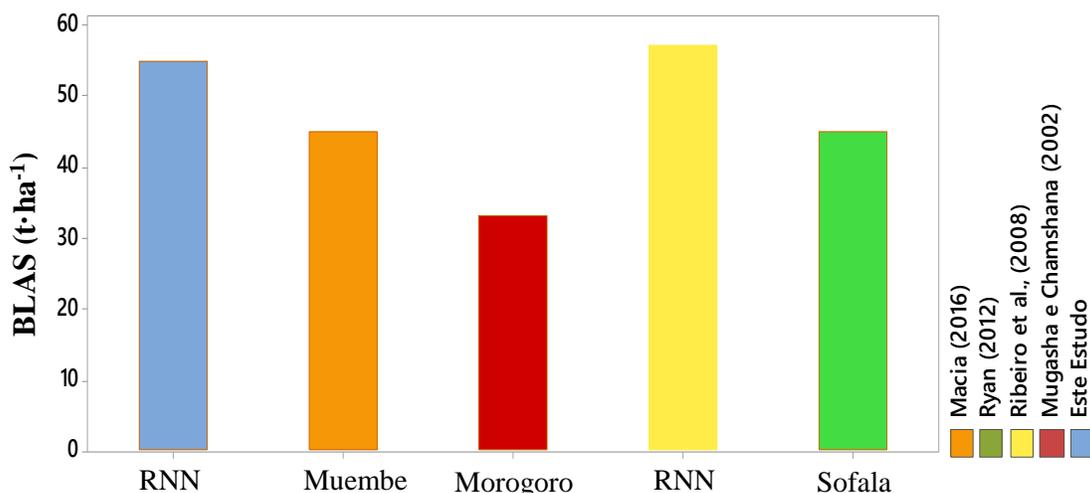


Figura 18: Comparação gráfica BLAS do presente estudo (RNN) em relação a BLAS obtida por Mugasha e Chamshana (2002) em Tanzânia, Ribeiro *et al.* (2008) na RNN, Ryan *et al.* (2012) em Gorongosa e Nhamatanda e Macia (2016) no distrito de Muembe na província de Sofala. Todas estimativas foram obtidas nas florestas de Miombo.

O inventário de biomassa realizado em 2014 nas florestas de Miombo da África Austral em coordenação com GIZ mostra que a média de BLAS na região é $30,98 \text{ t}\cdot\text{ha}^{-1}$ (Mueller, 2015). O inventário determinou também separadamente a biomassa para os estratos de floresta intacta ($40,05 \text{ t}\cdot\text{ha}^{-1}$) e para os estratos de floresta não intacta ($25,25 \text{ t}\cdot\text{ha}^{-1}$), os quais foram anteriormente definidos com base na interpretação de imagens de satélite (Mueller, 2015). Esse cenário também foi constatado neste estudo em que áreas intactas ou seja áreas com uma cobertura de dossel de 75% - 100% apresentaram maiores estimativas de BLAS ($84,0 \pm 7,54 \text{ t}\cdot\text{ha}^{-1}$). Em contra partida as áreas não intactas ou seja áreas com coberturas de 10% - 25% apresentam menores estimativas de BLAS ($25,5 \pm 7,76 \text{ t}\cdot\text{ha}^{-1}$).

O coeficiente de variação (CV) entre BLAS mínimo e máximo é de 44% apresentando uma variação dos dados, essa variação pode ser explicada pela variação das florestas de Miombo (Miombo aberto, médio e denso) devido ao tipo de solo, precipitação e altitude; fazendo com que uma região seja diferente da outra (Pereira, 2002; Ribeiro *et al.*, 2008; Carreiras *et al.*, 2013).

Alguns autores como Pereira (2002) e Siteo *et al.* (2013) acrescentam que em regiões florestais que apresentam assentamentos humanos tem sido observado que em alguns locais de amostragem a baixa densidade de BLAS é devido à exploração dos recursos naturais por parte das comunidades. Analisando nesta perspectiva, as parcelas com baixa densidade de BLAS para além de serem explicadas por factores como solo, precipitação e altitude também podem ser explicadas pelo nível de perturbação da floresta devido às actividades humanas como: a prática de agricultura itinerante que é realizada simultaneamente com o corte de lenha, bem como a exploração de madeira (Howard, 1991).

Segundo Ribeiro *et al.* (2008) e Cangela (2014) a RNN apresenta um crescimento acelerado da população, acompanhado pela expansão das áreas agrícolas, caça furtiva, corte de lenha e produção de carvão reduzindo a densidade de BLAS em algumas áreas. Estudo feito por Ryan *et al.* (2012) na região Gorongosa e Nhamatanda, usando imagens de satélite chegaram a conclusão que as áreas perturbadas devido aos eventos de desmatamento reduziram a biomassa de 33,5 para 11,9 t·ha⁻¹ em média no período de 2007 a 2010.

5.2.2. Estoque de carbono florestal

O estoque de carbono obtido pela fracção de 50% da biomassa recomendado pela IPCC (2003) mostra valores que variam em função das classes de cobertura. O estoque médio de carbono estimado foi de $27.5 \pm 9.7 \text{ tC}\cdot\text{ha}^{-1}$. O estoque de carbono em função de cobertura foi estimado em $12.7 \text{ t}\cdot\text{ha}^{-1}$ (10% - 25%), $29.8 \text{ t}\cdot\text{ha}^{-1}$ (25% - 50%), $35.5 \text{ t}\cdot\text{ha}^{-1}$ (50% - 75%) e $42.0 \text{ t}\cdot\text{ha}^{-1}$ (75% - 100%). Essa distribuição de estoque de carbono condiz com o que já foi apresentado anteriormente na BLAS, uma vez em o estoque de carbono também aumenta com a densidade florestal (tabela 11).

Tabela 11: Classes de cobertura florestal, número de parcelas de amostragem, carbono total em locais de amostragem (t) e carbono médio ($\text{t}\cdot\text{ha}^{-1}$) por nível de cobertura florestal.

Classes de Cobertura Florestal	# Parcelas	Carbono	
		Total (t)	Médio (t/ha)
10% - 25%	8	101.5	12.7 (± 3.88)
25% - 50%	7	208	29.8 (± 4.34)
50% - 75%	5	178	35.5 (± 1.62)
75% - 100%	4	168	42.0 (± 3.77)
Total	24	655.5	-

O estoque de carbono médio obtido no estudo de Tomo (2012) no distrito de Gondola foi de $42 \text{ t}\cdot\text{ha}^{-1}$ numa área de 5788 Km^2 . Ribeiro *et al.* (2013) estimaram as densidades de carbono médio para toda área da RNN em $34.72 \pm 17.93 \text{ tC}\cdot\text{ha}^{-1}$, variando de $10 \text{ tC}\cdot\text{ha}^{-1}$ a $80.8 \text{ tC}\cdot\text{ha}^{-1}$, sendo que o valor mais alto foi observado em parcelas não perturbadas ao longo da RNN. Campbell (1995) estimou o estoque médio de carbono em $34 \text{ t}\cdot\text{ha}^{-1}$ na floresta densa de Miombo em Zâmbia. Siteo *et al.* (2013) descrevendo as estimativas de carbono nas Províncias de Moçambique usando equações e parâmetros do IPCC (2003) mostrou que a província de Niassa apresentou um valor médio de estoque de carbono de $42.2 \text{ tC}\cdot\text{ha}^{-1}$ acima e abaixo solo.

A variação de estoques de carbono estimados no campo ao nível das parcelas pode ser explicada pelos factores ambientais (IPCC, 2003). De acordo com Siteo e Tchaúque (2007) o carbono contido na biomassa varia em função de factores ambientais e humanos, entre os quais destaca-se o balanço entre a fotossíntese e respiração das plantas, sucessão natural devido à regeneração

natural, crescimento e mortalidade das plantas e actividades humanas como é o caso de colheita de produtos florestais e queimadas descontroladas. Conforme os mesmos autores, variações de altitude têm efeito directo sobre a radiação solar e a temperatura, o aumento da latitude implica uma redução da radiação solar, temperatura e precipitação e conseqüentemente reduz a quantidade de biomassa. Watzlawick *et al.* (2009) acrescentam que a extensão da área também contribui para a variação do estoque de carbono ao nível das parcelas, sendo que as áreas maiores apresentam grandes variações de carbono, o mesmo foi observado neste estudo devido a variação estrutural da vegetação, onde o carbono varia entre $12.7 \pm 3.88 \text{ tC}\cdot\text{ha}^{-1}$ e $42.0 \pm 3.77 \text{ tC}\cdot\text{ha}^{-1}$.

No contexto REDD+, os resultados obtidos neste estudo revelam que a RNN além de ser a maior área de conservação no país e a décima quarta ao nível mundial (Ribeiro *et al.*, 2013), apresenta um grande reservatório de carbono. Esses valores são catalisadores para implementação do projecto REDD+, para além de contribuírem com as iniciativas nacionais de MRV para REDD +, pois fornecem uma visão geral de estoque de carbono em diferentes classes de cobertura do dossel na RNN assim como nas outras áreas com as mesmas condições à da área de estudo.

Segundo Moutinho *et al.* (2001) as florestas consideradas como maiores sumidouros de carbono não podem ser vistas apenas como um ponto importante para o mercado de carbono, mas também devem ser vista como um ponto importante para o manejo. Segundo Rocha (2002) as florestas assumem importante papel de fixadoras de carbono, agindo como sumidouros de carbono, ou também como grandes fontes de emissão. A má gestão dessas áreas, pode tornar as mesmas áreas como grandes fontes de emissão de carbono na atmosfera, contribuindo com um dos elementos principais de gases de efeito estufa como metano (CH_4), o dióxido de carbono (CO_2) e os clorofluorcarbonos (Moutinho *et al.*, 2001).

De acordo com FUPEF (2001) uma boa gestão de uma área de conservação deve incluir programas de vida selvagem, biomassa, incêndios, queimadas e actividades humanas. Esses programas devem ser desenvolvidos em harmonia para não colocar em causa a integridade da conservação da biodiversidade. Os resultados obtidos por Ribeiro *et al.* (2013) na RNN mostraram que o sistema de manejo na RNN está mais focado na vida selvagem e menos na vegetação, incêndios e actividades humanas. Esse aspecto coloca a RNN como um ponto principal na conservação da biodiversidade e na implementação do projecto REDD+, por forma a evitar que grandes

quantidades de carbono fixado sejam emitidos para atmosfera a médio ou longo prazo devido as queimadas e actividades humanas (FAO, 2010).

A RNN tem registando o crescimento populacional acelerado dentro e fora dos seus limites (Allan *et al.*, 2017). Por isso a gestão apropriada em termos de REDD + terá que ser determinada em consulta com as comunidades locais, gestores da RNN e autoridades florestais. No entanto, as experiências de benefícios através da devolução de 20% das taxas de conservação podem ser um bom ponto de partida para envolver as comunidades na gestão sustentável dos recursos florestais (Ribeiro *et al.*, 2013).

5.3. Ajuste da equação de biomassa

5.3.1. Estatísticas de ajuste da equação espacial de biomassa

A partir das estatísticas de ajuste de equações alométricas foi possível seleccionar e comparar os modelos. As equações apresentadas abaixo provêm da integração dos dados de biomassa com variáveis ópticas e radar. A tabela 12 mostra de forma resumida as equações e os respectivos parâmetros estatísticos.

Tabela 12: Estatísticas das equações desenvolvidas na regressão *Stepwise*. Estão presente na tabela os parâmetros β_0 , β_1 , β_2 e β_3 , intervalo de confiança (95%), coeficiente de determinação ajustado (R^2_{aj}), erro padrão da estimativa em percentagem ($S_{yx}\%$), estatística F e Valor Ponderado (VP).

Equação (#)	Estatísticas										
	Parâmetros				IC (95%)		R^2_{aj}	$S_{xy} (\%)$	F	VP	AIC
	β_0	β_1	β_2	β_3	L_I	L_S					
a) 1	20.19	156.1			28.75	49.09	46.66	17.27	11.5	11	179
b) 2	134.3	3.23	3.88		47.06	72.08	52.08	16.36	6.95	10	137
c) 3	92.4	110.1	4.66		42.76	67.31	65.85	13.81	16.68	06	128
d) 4	126.5	151.4	250.1	6.63	7.17	44.50	87.50	12.02	18.85	03	123

Legenda das equações:

- a) $BLAS_{(t/ha)} = 20.19 + 156.1 NDVI2$ (1)
- b) $BLAS_{(t/ha)} = 134.3 + 3.23 \sigma^{oHH} + 3.88 \sigma^{oHV}$ (2)
- c) $BLAS_{(t/ha)} = 92.4 + 110.1 NDVI2 + 4.66 \sigma^{oHV}$ (3)
- d) $BLAS_{(t/ha)} = 126.5 - 151.4 NDVI1 + 250.1 NDVI2 + 6.63 \sigma^{oHV}$ (4)

A tabela 12 mostra as quatro equações que foram desenvolvidas na regressão *stepwise*, nas doze combinações feitas (figura 14), onde selecionou-se apenas quatro equações que apresentam melhores estatísticas. É possível notar através das estatísticas que o modelo número 4 apresenta maior coeficiente de determinação ($R^2_{aj} = 87.5\%$), menor erro padrão da estimativa em percentagem ($S_{yx\%} = 12.02$), maior estatística $F = 18.85$, menor valor dos escores ($VP = 03$) e menor critério de informação de Akaike ($AIC = 123$). O valor de 0.88 de R^2_{aj} da equação 4, significa que cerca de 88% da variação do peso total de biomassa por hectare é explicada pelas variáveis espectrais como NDVII, NDVI2 e $\sigma^{\circ}HV$, porém cerca de 12% da variação da biomassa dentro das parcelas é explicada pelas variáveis não analisadas neste estudo e o erro residual de estimativa da equação (Frieman, 20002).

No que diz respeito a $S_{yx\%}$, a equação 4 apresentou 12 % do erro, o que significa que a equação vai estimar BLAS com cerca de 88% de precisão. As equações 1, 2 e 3 apresentam precisão de estimativas de 82.73%, 83.37% e 86.19% respectivamente. De acordo com o método de selecção através de valor ponderado (VP), a equação 4 ocupa a primeira posição ($VP = 3$), seguida de equação 3 ($VP = 6$), equação 2 ($VP = 10$) e equação 1 ($VP = 11$).

Quanto às variáveis usadas nas equações, nota-se que $\sigma^{\circ}VV$ e $\sigma^{\circ}VH$ não foram selecionados para criação das equações. Como já havia sido destacado anteriormente, essas duas variáveis ($\sigma^{\circ}VV$ e $\sigma^{\circ}VH$) apresentam uma correlação baixa em relação a BLAS com um coeficiente de determinação de 0.27 e 0.33, respectivamente. Segundo Eastman e Andes (2006) as variáveis radar são conhecidas por serem melhores previsores de BLAS quando combinadas com imagens ópticas, porém os mesmos autores acrescentam que quando as variáveis são obtidas num sensor de comprimento de onda de banda curta ($\sigma^{\circ}VV$ e $\sigma^{\circ}VH$ banda C-SAR ~ 5.7 cm), como é o caso do Sentinel 1B usado neste estudo, elas poderão não se correlacionar melhor com BLAS devido à saturação dos *pixels* (Ribeiro *et al.* 2008), ou seja, chega se ao um certo ponto que a BLAS aumenta e os valores dos *pixels* tendem a manter-se devido a saturação (JAXA, 2007).

Shimada *et al.* (2006) acrescentam que sensores radares são extremamente sensíveis à textura, devido a sua natureza e geometria de observação. Assim, diferenças de rugosidade são salientadas com maior rigor nas imagens geradas por estes sensores. À medida que a rugosidade aumenta, a proporção do sinal de retroespalhamento em direção ao sensor aumenta (Foody, 1992). Sendo assim, para análises de biomassa em locais com grande variação da textura ao nível da superfície

são recomendadas as imagens radares de sensores com um comprimento de onda que não seja de banda curta (Kuntschik, 2004).

Alguns trabalhos científicos demonstram que os índices NDVI e SAVI estimam melhor a biomassa, como é o exemplo do trabalho feito por Watzlawick *et al.* (2009) utilizando dados do sensor Multiespectral (MS) do satélite IKONOS (imagens de 4 metros de resolução espacial com as bandas MS-1, MS-2, MS-3, MS-4, razão da banda 4 e 3, NDVI e SAVI) para estimar a biomassa encontrou R^2_{aj} de 0.75, onde as variáveis selecionadas foram banda 4, SAVI e NDVI.

Os procedimentos de teledetecção podem influenciar na qualidade dos dados espectrais, contribuindo para que estas se correlacionem melhor com BLAS (Shimada *et al.*, 2006). Na teledetecção, os erros podem estar relacionados ao sensor, às variações de temperatura, humidade e iluminação do meio e ainda pela interpretação da imagem. Segundo Júnior *et al.* (2014) tratando-se de dados de teledetecção podem existir erros relacionados com o tempo entre as datas de medição em campo e a data de passagem do sensor pela área, além da maior área da parcela (100 m x 100 m) em relação à área do *pixel* (900 m² ou 100 m²). Por isso o uso de dados e equações deste estudo devem ser feito tendo em conta as datas de aquisição das imagens (final da época chuvosa), uma vez que as variáveis espectrais variam ao longo do ano (Rodrigues, 1990).

Ferraz *et al.* (2013) estimaram a biomassa aérea num fragmento da floresta em Minas Gerais usando imagens de alta resolução espacial (4 metros) do sensor Multiespectral (MS) do satélite IKONOS II e ALOS, tendo ajustado a equação usando dados de banda 4, $\sigma^{\circ}HH$ e biomassa. Segundo os autores o uso da banda 4 e $\sigma^{\circ}HH$ apresentaram resultados satisfatórios ($R^2_{aj} = 0.4$), sendo o mesmo resultado explicado pela variável (infravermelho próximo) e HH estarem estreitamente relacionadas com a vegetação; isto é, ocorre uma alta refletância da energia pela vegetação, em função da estrutura interna das células (Ferraz *et al.*, 2013).

As equações 1, 2 e 3 apesar de apresentarem valores baixos (em relação a equação 4) com R^2_{aj} de 0.47, 0.52 e 0.66, respectivamente, o erro de predição na estimativa de biomassa é considerado satisfatório para um método de estimativa não destrutiva, principalmente para o tipo de vegetação que apresenta uma distribuição espacial muito heterogénea (Júnior *et al.*, 2014).

Kasischke *et al.* (1997) utilizaram o sensor radar abordo no satélite JERS-1 com banda L de comprimento de onda igual a 23.5 cm (com imagens de 18 metros de resolução espacial) para

estimar biomassa em florestas de *Pinus spp*, onde encontraram regressões com R^2_{aj} igual a 0.69, 0.72 e 0.78 utilizando respectivamente, as polarizações $\sigma^{\circ}HH$, $\sigma^{\circ}HV$ e $\sigma^{\circ}VV$. Júnior *et al.* (2014), acrescentam que as variáveis espectrais correlacionam se mais ainda com a biomassa quando trata-se de florestas plantadas, devido à sua homogeneidade, por isso o coeficiente de ajustamento (R^2_{aj}) deve estar acima dos 0.5. Para as florestas nativas valores de R^2_{aj} em torno de 0.5 são aceitáveis, como mostram as equações 1, 2 e 3.

Resultados similares de R^2_{aj} obtidos nas equações 1, 2 e 3 foram encontrados por Ribeiro *et al.* (2008), esses autores desenvolveram uma equação de estimativa de biomassa espacial na RNN usando o índice da razão simples (SR) e dados radarsat (Biomassa = $-5.19 + 0.074 * \text{Radarsat} + 1.56 * \text{SR}$, $R^2_{aj} = 0.55$), os autores acrescentam que o uso de RADARSAT de banda C (comprimento de onda de 5,7 cm) e o derivado de ETM + proporcionam um substituto razoavelmente bom da biomassa lenhosa na RNN. Embora a banda C SAR tenha provado ser saturada a uma biomassa de 5 kg m^{-2} devido ao comprimento de onda de banda curta.

Outros resultados similares do bom desempenho das variáveis espectrais e os dados de campo também foram observados por Kuntschik (2004) ao utilizar no seu estudo imagens do sensor ETM+ do Landsat 7 e imagens do sensor radar do JERS-1. No geral, resultados satisfatórios da integração de variáveis ópticas e radar têm sido notórios na literatura. Watzlawick *et al.* (2009) afirma que os sensores do satélite ALOS são muito usados nas últimas décadas na predição de biomassa florestal devido ao seu bom desempenho. Esses sensores utilizados isoladamente como o AVNIR-2 e o PALSAR possuem estimativas razoáveis, porem o modelo que utiliza a integração destes sensores possui uma boa estimativa de biomassa (Haripriya, 2000).

5.3.2. Comparação das equações

A figura 19 mostra a variação de BLAS dentro das parcelas usando as quatro equações (1, 2, 3 e 4). As equações apresentam um comportamento proporcional quanto ao aumento e diminuição de BLAS ao longo das parcelas, porém apresentam erros de estimativas diferentes entre elas. Para melhor compreensão valores apresentados na figura 19, o critério de variação de Akaike (ΔAIC) entre equações é apresentado para entender melhor se existe semelhança ou diferença das equações na estimativa de BLAS. A estatística de AIC mostra que a diferença das equações 4 e 3 é igual a 5 ($\Delta AIC = 5$), esse valor indica que existe menor diferença entre elas (Akaike, 1985).

A diferença entre AICs das equações 2 e 4 ($\Delta AIC = 14$), 1 e 4 ($\Delta AIC = 56$), 2 e 3 ($\Delta AIC = 9$), 1 e 3 ($\Delta AIC = 51$) e 1 e 2 ($\Delta AIC = 42$) apresentam $\Delta AIC > 4$, evidenciando que existe razões suficientes para afirmar que as equações são estatisticamente diferentes entre elas (Zanette, 2017). Macia (2016) no distrito de Muembe em Niassa também observou diferenças entre os modelos da função polinomial, exponencial e potencial a partir da análise de Akaike, tendo encontrado os seguintes valores 54.86, 14.30 e 71.41, respectivamente.

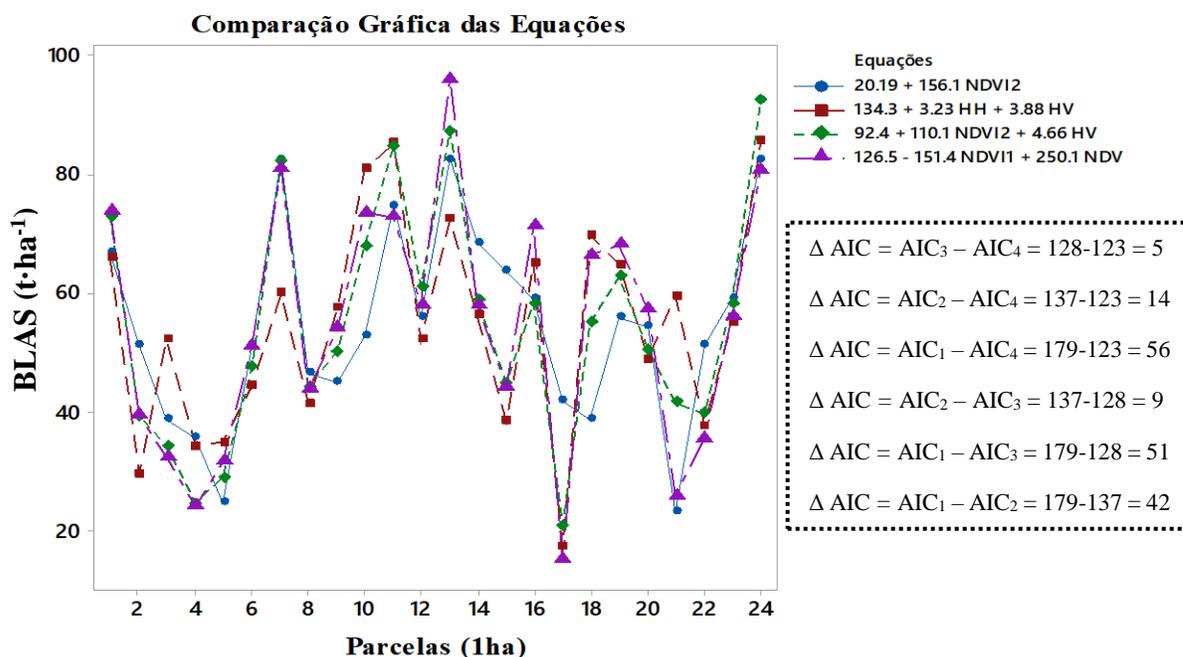


Figura 19: Variação da BLAS ao longo das parcelas de amostragem e valores de ΔAIC das equações 1, 2, 3 e 4.

5.3.3. Distribuição gráfica dos resíduos

Avaliação dos resíduos ao longo da linha de regressão é crucial na selecção do melhor modelo (Zanette, 2017), essa análise permite detectar ao longo da linha de regressão os erros de tendências que podem estar a ocorrer em alguma amplitude de classe de uma ou mais variáveis independentes (variáveis espectrais) que não foram detectadas pelas estatísticas que medem a precisão da equação (Kennedy, 2008). A figura 20 a, b, c e d apresenta a distribuição dos resíduos das quatro equações descritas anteriormente. A leitura foi avaliada ao nível das parcelas (BLAS - $t \cdot ha^{-1}$), pois trata-se de dados espectrais e a sua leitura dificilmente é feita ao nível da árvore individual (DAP).

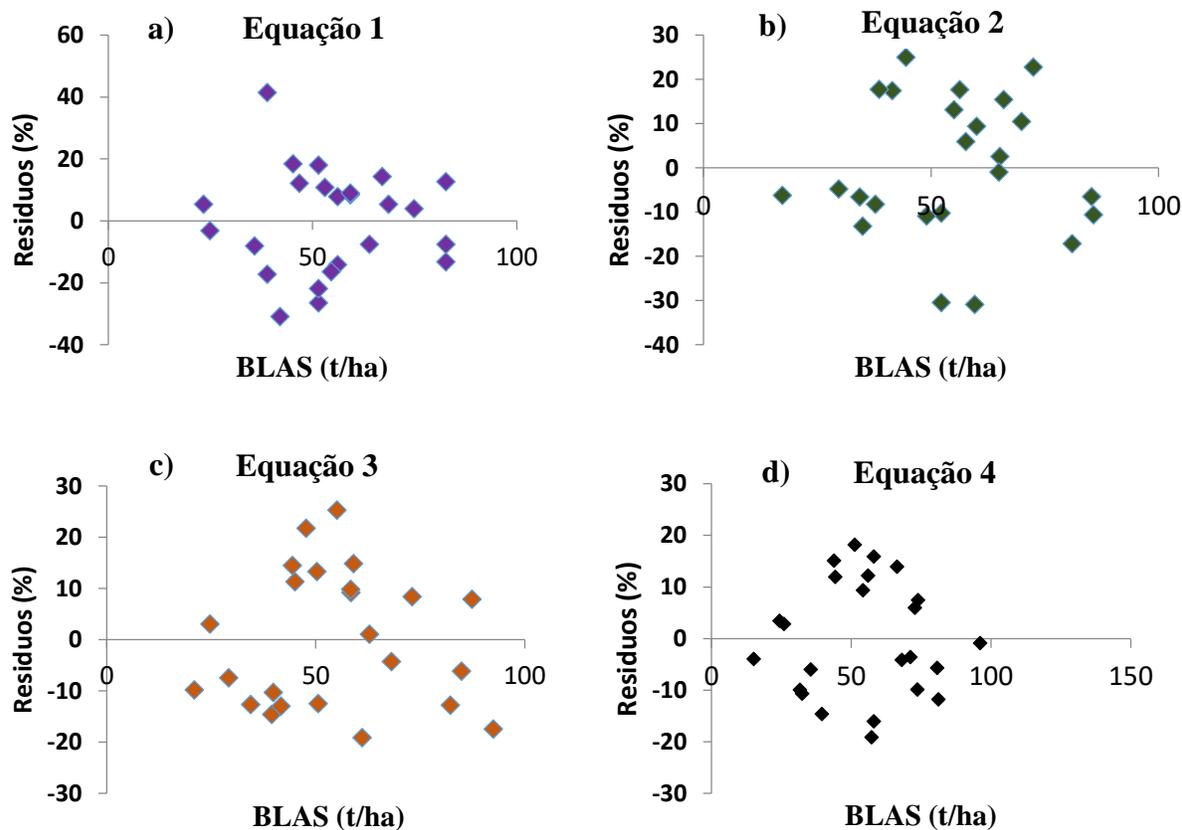


Figura 20: Distribuição gráfica dos resíduos das quatro equações (a) equação 1, (b) equação 2, (b) equação 3 e (c) equação 4

A distribuição dos resíduos na figura 20 a), b) e c) apresenta uma maior variação ao longo da linha de regressão quando comparado com a figura 20 d). A amplitude de resíduos através das diferenças do maior e menor resíduo das equações 1, 2, 3 e 4 são respectivamente 10.4, 6, 6 e 1.08, mostrando que a equação 4 apresenta menor erro de estimativa de BLAS.

Todas as equações apresentaram um aumento do erro de estimativa em algumas parcelas, uma tendência verificada com persistência quando BLAS atinge $50 \text{ t}\cdot\text{ha}^{-1}$. Essa sobrestimativa do erro residual pode ser explicada pela variação dos valores espectrais ao longo da superfície, sendo que em algumas parcelas, as variáveis (NDVII, NDVI2, $\sigma^{\circ}\text{HH}$ e $\sigma^{\circ}\text{HV}$) apresentaram valores altos, médios e baixos. A variação dos valores digitais nas parcelas não está directamente correlacionada com a variação do DAP a nível da árvore individual. Porém, essa sobrestimativa não é estatisticamente significativa nas quatro equações de acordo com o teste *t-student* (equação 1, $p = 0.90$; equação 2, $p = 0.90$; equação 3, $p = 0.96$ e equação 4, $p = 0.98$).

5.3.4. Equação seleccionada de biomassa

Depois da análise minuciosa dos criterios de selecção da melhor equação descritos na literatura, chegou-se à conclusão que a equação 4 é a melhor, por ter apresentado maior valor de R^2_{aj} , menor valor de $S_{yx\%}$, maior estatística F , menor VP, menor AIC, distribuição gráfica dos resíduos na linha de regressão, menor amplitude da variação dos resíduos e menor erro de estimativa (tabela 13) (Zanette, 2017).

Tabela 13: Estatística da melhor equação

Modelo Linear Múltiplo	Estatísticas								
	Parâmetros	IC (95%)		R^2_{aj}	$S_{yx\%}$	F	VP	AIC	Resíduo
		L_1	L_S						
$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \varepsilon$	β_0	80.80	172.2	0.88	12.1	18.9	3	123	2.83
	β_1	265.2	377.0						
	β_2	131.7	368.6						
	β_3	3.890	9.380						

$$\text{BLAS}_{(t/\text{ha})} = 126.5 - 151.4 \text{ NDVII} + 250.1 \text{ NDVI2} + 6.63 \sigma^{\circ}\text{HV} + 2.83$$

O coeficiente de estimativa mostra uma relação forte entre a BLAS obtida com a equação de Brown *et al.* (1989), usada no presente estudo para estimar a BLAS nas parcelas e a BLAS obtida a partir da equação desenvolvida no presente estudo a uma escala maior. A figura 21 mostra a dispersão da BLAS das duas equações ao longo da linha de regressão ($R^2 = 0.77$).

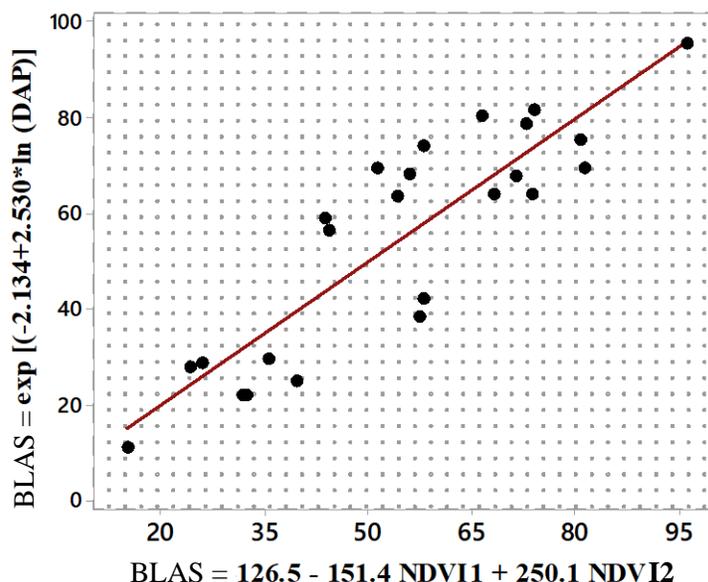


Figura 21: Diagrama de dispersão de BLAS estimada no campo a partir da equação de Brown *et al.* (1989) e BLAS obtida através da melhor equação espacial selecionada no presente trabalho.

Dada à importância da floresta de Miombo na regulação dos fluxos de carbono e controle das mudanças climáticas, com suas funções ecológicas essenciais para a manutenção da vida de muitas espécies e de processos ecológicos (Frost, 1996; Chidumayo, 2013), tornou-se essencial obter uma equação espacial que se ajuste melhor a dados de campo. A melhor equação desenvolvida neste estudo demonstra a eficácia do uso de técnicas de teledetecção, em especial a integração de dados Alos 2/Palsar 2 e Landsat 8/OLI na estimativa de BLAS nas florestas de Miombo. Com esta equação a RNN pode visualizar a BLAS e carbono mesmo em áreas mais recônditas.

Os resultados aqui apresentados podem contribuir para o monitoramento e proteção do ecossistema, auxiliando a sua gestão (Pereira, 2002). Salienta-se ainda o potencial dos dados ópticos e radar para estimar e mapear a BLAS com boa acurácia contribuindo com as estimativas ao nível da paisagem de BLAS e carbono florestal relevantes no âmbito de políticas de redução do desmatamento e controle do aquecimento global.

5.4. Mapa de densidade de biomassa e carbono florestal

O mapa de densidade de BLAS e carbono florestal a nível da paisagem (figura 22), desenvolvida no *ArcGis 10.2 (Raster calculator)* a partir da melhor equação criada no presente estudo, mostra que existem locais dentro da RNN sem ou com baixa quantidade de carbono florestal (primeira classe: 0% - 10%), destacando-se áreas com o solo exposto, locais com corpos de água, campos agrícolas e áreas habitacionais, ocupando uma extensão pouco acima de 7000 km². As áreas com maior cobertura florestal apresentaram maior densidade de BLAS e carbono florestal (figura 22), destacando-se áreas montanhosas que atingem cerca de 1500 m de altitude e uma parte da região Oeste (O) da Reserva, que é dominada por vegetação maioritariamente coberta por florestas de média a alta densidade, onde a PMA média anual está um pouco acima de 1200 mm (SGDRN, 2005).

Estes resultados consolidam e estão de acordo com os resultados encontrados por Ribeiro *et al.* (2008), onde uma das parcelas foi estabelecida em uma área com cerca de 180 t·ha⁻¹ de BLAS. Esse valor está próximo do valor encontrado neste estudo, sendo que mesma área apresenta cerca de 200 t·ha⁻¹ de BLAS. Essas áreas são remotas de difícil acesso, extensas e com escassez de dados (Ribeiro *et al.*, 2008). Todavia este estudo mostra que as técnicas de teledetecção permitem adquirir informações biofísicas das áreas remotas, menos exploradas pela comunidade científica a uma escala ao nível da paisagem com alocação de poucos recursos financeiros (Watzlawick *et al.*, 2009).

Nas últimas décadas, são desenvolvidos vários estudos de estimativa de BLAS e carbono florestal usando métodos directos ou destrutivos e criação de equações alométricas a partir dos dados de inventário florestal, porém estudos que visam a quantificação de BLAS e conteúdo de carbono com variáveis de teledetecção ainda são escassos na literatura Moçambicana, dificultando duma certa forma a discussão dos resultados obtidos com mais profundidade. Por outro lado é muito difícil uma comparação directa dos trabalhos devido à escala e métodos usados em diferentes pesquisas (Salimon *et al.*, 2011). Contudo os resultados obtidos neste estudo servirão de base para estudos futuros. Porém, para efeitos de comparação pesquisas futuras são necessárias no processo da estimativa de BLAS na floresta de Miombo ao nível da escala da paisagem, integrando dados ópticos e radar em diferentes estações do ano.

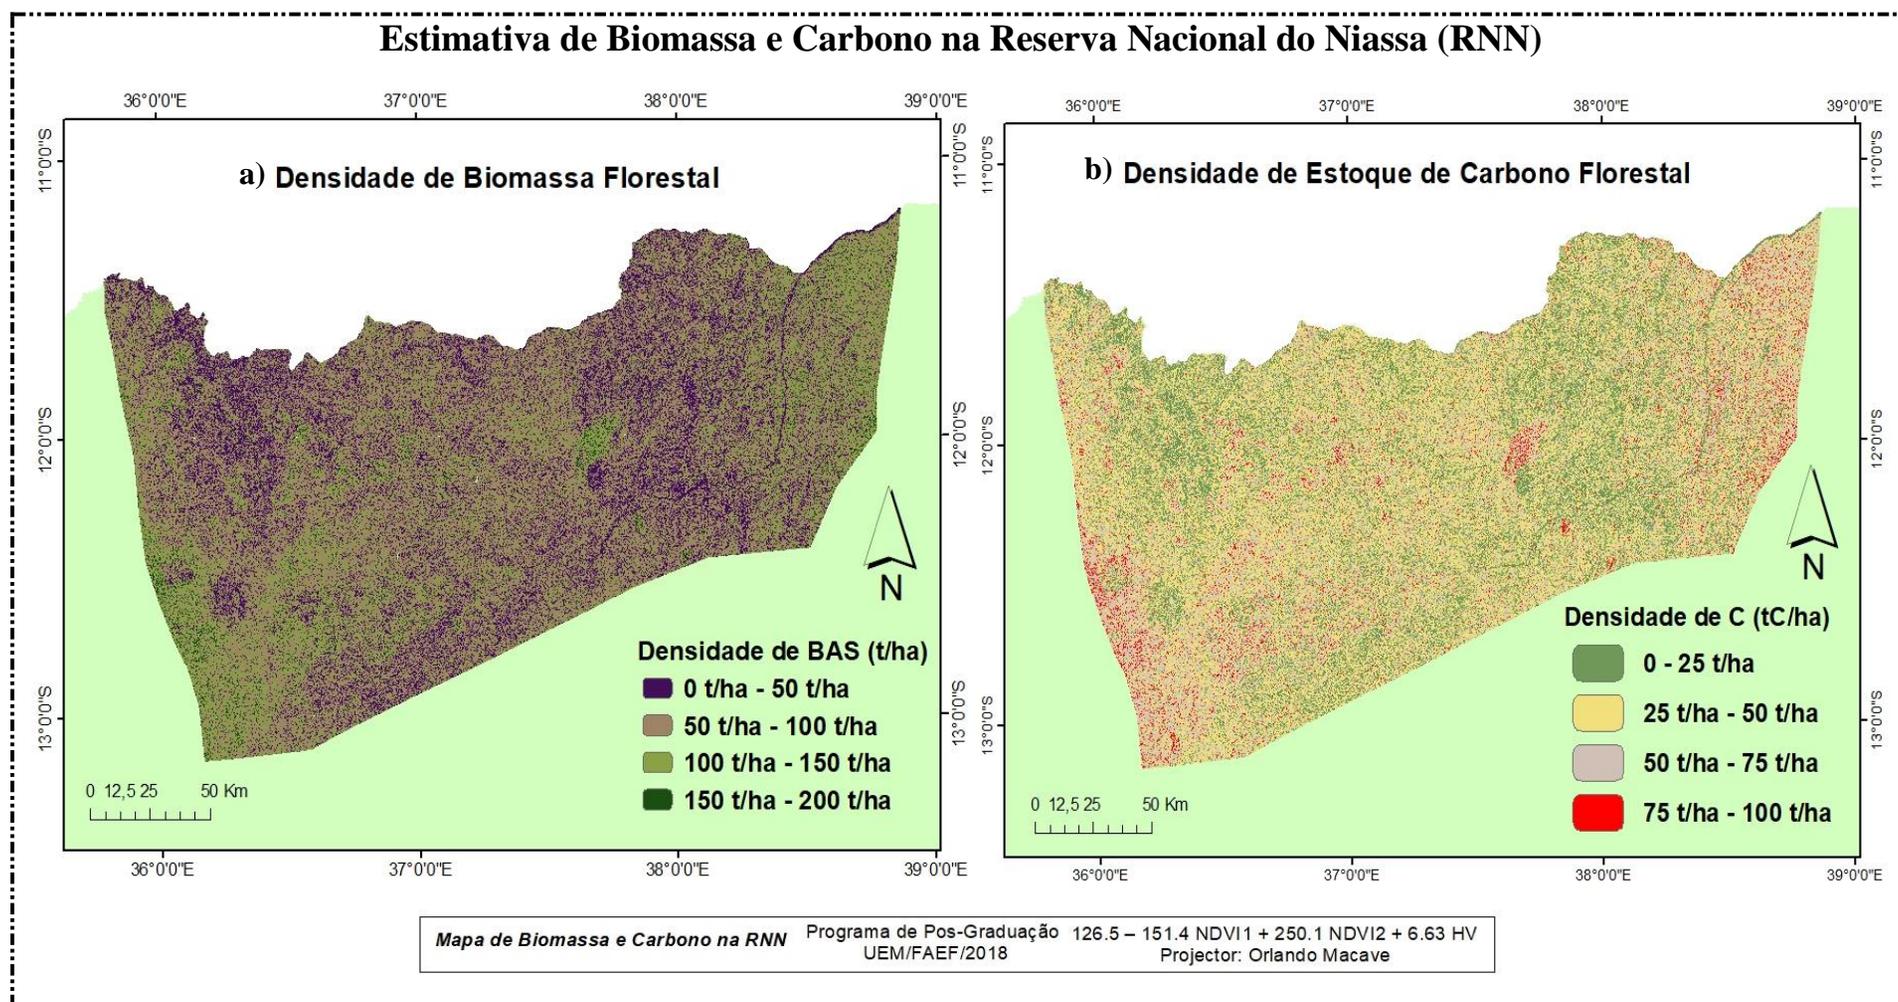


Figura 22: Mapa de densidade de biomassa acima do solo (a) e carbono florestal (b) na Reserva Nacional do Niassa usando uma equação alométrica desenvolvida no presente estudo

6. CONCLUSÕES

Os resultados revelam que a integração das variáveis NDVI1 e NDVI2 derivado do sensor OLI e MSI respectivamente e de radar a partir de retroespalhamento da polarização $\sigma^{\circ}\text{HV}$ de Alos 2/Palsar 2 são melhores previsores de biomassa e que a equação apresenta estatísticas de ajuste altas e satisfatórias. A equação espacial de biomassa selecionada ($\text{BLAS} = 126.5 - 151.4 \text{NDVI1} + 250.1 \text{NDVI2} + 6.63 \sigma^{\circ}\text{HV} + 2.83$) apresenta um R^2_{aj} igual a 0.88 e $S_{yx\%}$ igual a 12. Todavia, as equações 1, 2, e 3 também apresentaram valores estatísticos aceitáveis quando estes são comparados com a literatura com um R^2_{aj} de 0.47, 0.52 e 0.66, respectivamente. Com esses valores nota-se claramente que variáveis espectrais ópticas e radar utilizadas neste estudo permitem estimar a biomassa em escala da paisagem reduzindo o custo e tempo despendidos com inventários florestais.

A BLAS na RNN varia em função do nível de cobertura de dossel florestal, as classes com maior cobertura apresentam maior valor de estimativa de BLAS. A BLAS média para toda área foi estimada em $55 \text{ t}\cdot\text{ha}^{-1}$. Os valores médios observados por nível de cobertura são: $25.5 \text{ t}\cdot\text{ha}^{-1}$, $59.6 \text{ t}\cdot\text{ha}^{-1}$, $71.0 \text{ t}\cdot\text{ha}^{-1}$ e $84.0 \text{ t}\cdot\text{ha}^{-1}$ correspondentes aos intervalos de 10% - 25% (40% da área total da reserva), 25% - 50% (32.2%), 50% - 75% (6.5%) e 75% - 100% (0.21%), respectivamente. A diferença das médias de BLAS por nível de cobertura é estatisticamente significativa a partir da variância (ANOVA) onde $F_{\text{calculado}} (72.8) > F_{\text{critico}} (3.02)$ a 95% de nível de significância ($\alpha = 0.05$), ou seja existe diferenças significativas nos valores estimados de biomassa.

O estoque médio de carbono foi estimado em $27.5 \text{ tC}\cdot\text{ha}^{-1}$. Dentro dos níveis de cobertura florestal existe uma variação de estoque de carbono. Para a classe 10% - 25% o valor estimado foi de $12.7 \pm 3.87 \text{ tC}\cdot\text{ha}^{-1}$, $29.8 \pm 4.34 \text{ tC}\cdot\text{ha}^{-1}$ para 25% - 50%, $35.5 \pm 1.62 \text{ tC}\cdot\text{ha}^{-1}$ para 50% - 75% e $84.0 \pm 3.77 \text{ tC}\cdot\text{ha}^{-1}$ para 75% - 100%.

As estimativas obtidas neste estudo estão dentro do intervalo recomendado na literatura para as florestas secas de Miombo. Tendo em conta a extensão da RNN, percebe-se que a reserva é um grande reservatório de carbono. Portanto, recomenda-se que o sistema de manejo da RNN esteja também focado no manejo da vegetação, queimadas e actividades humanas e não apenas na vida selvagem.

7. RECOMENDAÇÕES

a) Investigadores

- Estudos de estimativa de biomassa e carbono ao nível da paisagem usando dados de satélite ainda são incipientes. Este corresponde ao segundo estudo levado a cabo na RNN depois do primeiro trabalho feito por Ribeiro *et al.* (2008), por isso estudos adicionais de monitoramento de biomassa e carbono são necessários para consolidar os resultados deste estudo e para fins de comparação.
- Sabe-se que cinco estações fenológicas podem ser distinguidas no Miombo: estação quente-seca antes das chuvas, início da estação chuvosa, meio da estação chuvosa, estação chuvosa tardia e estação fria e seca. Neste estudo devido ao factor tempo, apenas foram usadas imagens do fim da época chuvosa (Abril), considerando que a intensidade de retroespalhamento (*backscatter*) do ALOS, Sentinel e índices de vegetação variam ao longo das épocas do ano, por isso recomenda-se que seja feita uma análise de variáveis espectrais em períodos que não foram analisados neste estudo.

b) Reserva Nacional do Niassa

- Uma vez que o resultado de ajuste da equação espacial de biomassa mostra que as variáveis espectrais usadas são melhores previsores da variável de resposta, apresentando estatísticas de ajuste satisfatórias. Recomenda-se que seja aplicada a equação desenvolvida nesse estudo na estimativa de BLAS a longo prazo, o que pode constituir uma medida de redução dos custos e tempo despendido. Para além disso, a equação desenvolvida fornece dados ao nível da paisagem mesmo em locais menos explorados e de difícil acesso.
- No contexto REDD+, as estimativas efectuadas neste estudo e a equação espacial de regressão desenvolvida são uma fonte crucial para iniciativas MRV REDD+ na área de estudo, assim como em outras áreas com mesmas características edáficos climáticos. Por isso recomenda-se a implementação de iniciativas REDD+ na área de estudo para uma melhor gestão de recursos florestais e criação de renda para as comunidades locais, reduzindo a degradação florestal permitindo que o carbono seja mantido a longo prazo.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- Akaike, H. 1985. "**Prediction and entropy**", in Atkinson, A. C. Fienberg, S. E., A Celebration of Statistics, Springer.
- Allan, J. R, Grossmann. F, Craig. R, Alastair. N, Maina. J, Flower. K, Bampton. J, Deffontaines. J, Miguel. C, Araquechande. B and Watson. J. E.M. 2017. **Patterns of Forest Loss in one of Africas Last Remaining Wilderness Areas: Niassa National Reserve (northern Mozambique)**.
- Araújo, L. S. D. 1999. **Análise da cobertura vegetal e de biomassa em áreas de contato floresta/savana a partir de dados TM/LANDSAT e JERS-1.**, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. Dissertação de Mestrado.
- Aronoff, S. 1989. **Geographical Information Systems - A Management Perspective**. Ottawa: WDI.
- Brown, S.; Gillespie, A. J. R.; Lugo, A.E. 1989. **Biomass estimation methods for tropical forests with applications to forest inventory data**. Forest Science, Lawrence, v. 35.
- Brown, S. 2002. **Measuring carbon in forests: current status and future challenges**. Environmental Pollution. .
- Campbell, B.M, Cunliffe RN, Gambiza J. 1995. **Vegetation structure and small-scale pattern in Miombo woodland**, Marondera. Bothalia .
- Cangela, A. C. 2014. **Caracterização e mapeamento do regime de queimadas na Reserva Nacional de Niassa**. UEM/Faculdade de Agronomia e Engenharia Florestal.
- Carreiras, M. B. Melo, J B. Vasconcelos, M, J. 2013. **Estimating the Above-Ground Biomass in Miombo Savanna Woodlands (Mozambique, East Africa) Using L-Band Synthetic Aperture Radar Data**.
- CEAGRE, & Winrock International. 2016. **Agentes e causas de desmatamento e degradação florestal em Moçambique**. Maputo, Moçambique.
- Chave, J.; Andalo, C. Brown, S.; Cairns, M. A.; Chambers, J. Q.; Eamus, D.; Fölster, H.; Fromard, F.; Higuchi, N.; Kira, T.; Lescure, J. P.; Nelson, B. W.; Ogawa, H.; Puig, H.; Riéra, B. e Yamakura, T. 2005. **Tree allometry and improved estimation of carbon stocks and balance in tropical forests**.

- Chaves, J, M. Sano, E, E. Meneses, P, R. 2000. **Uso de imagens de radar como ferramenta auxiliar na identificação de elementos geológicos na região do Cerrado.**
- Chidumayo, 1988. **A Re-Assessment of Effects of Fire on Miombo Regeneration in the Zambian Copperbelt.** Journal of Tropical Ecology.
- Chidumayo, EN. 2013. **Estimating tree biomass and changes in root biomass following clear-cutting of Brachystegia-Julbernardia (Miombo) woodland in central Zambia.** Environmental Conservation.
- Colwell, R.N. 1983. **Manual of Remote Sensing.** 2. ed. [S. l.]: American Society of Photogrammetry.
- Congalton, R.; Green, K. 2009. **Assessing the Accuracy of Remotely Sensed Data - Principles and Practices.** Boca Raton: CRC Press, Taylor & Francis Group.
- Coura, S. M. 2007. **Mapeamento de vegetação do estado de minas Gerais utilizando dados modis.** INPE. Brasil.
- Craig, G. C. 2009. **Aerial survey of wildlife in the Niassa reserve and adjacent areas.** Maputo, Moçambique.
- Cunliffe, R., Mandondo, A., Games, I., Ngarivhume, J. & Doré, D. 2009. **Reconciling conservation goals with agriculturally based livelihoods. A proposal for future development of the Niassa National Reserve and surrounding areas.** Imperial Tobacco Project, Harare, Zimbabwe.
- Desanker, P.V., P.G.H. Frost, C.O. Frost, C.O. Justice, and R.J. Scholes, (eds.). 1997. **The Miombo Network: Framework for a Terrestrial Transect Study of Land-Use and Land-Cover Change in the Miombo Ecosystems of Central Africa,** IGBP Report 41, The International Geosphere-Biosphere Programme (IGBP), Stockholm, Sweden.
- Dobson, M.C.; Ulaby, F.T.; Pierce, L.E. 1995. **Land cover classification and estimation of terrain attributes using Synthetic Aperture Radar.** Remote Sensing of Environment.
- Du Preez M-L. 2014. **Southern Africa's dryland forest, climate change, and the water-energy-food security nexus.** Occasional Paper 189. Johannesburg: South African Institute of International Affairs.

- Eastman, J.R. Idrisi Andes. 2006. **Guide to GIS and Image Processing**. Clark Laboratory. Clark University. Worcester/MA. USA.
- Elachi, C. 1987. **Introduction to Physics and Techniques of Remote Sensing**. Nova Iorque. Wiley & Sons.
- ESA. 2013. **Sentinel-2. Optical High-Resolution Mission for GMES Operational Services” Remote Sensing of Environment**.
- Falcão, M., P. Noa, Micas. 2016. **Definição de Florestas, Desmatamento e Degradação Florestal no âmbito do REDD+**. Moçambique.
- FAO. 2003. **State of the Worlds Forest**. Rome Italy
- FAO. 2008. **Water and the Rural Poor Interventions for improving livelihoods in sub-Saharan Africa**. Rome Italy.
- FAO. 2010. **The State of Food Insecurity in the World**. Addressing Food and insecurity in protracted crises. Rome Italy
- Fehrmann, L. e Kleinn, C. 2005. **A k – Nearest Neighbor Approach for Estimation of single – Tree Biomass**. Proceedings of the Seventh Annual forest inventory and Analysis Symposium.
- Ferraz, A, S. Soares, V, P. Soares, C. P, Ribeiro, C. A, Gleriani. J. M. 2013. **Uso de imagens do satélite IKONOS II para estimar biomassa aérea de um fragmento de floresta estacional semidecidual**. Brasil.
- Floriano, E, P. Muller, I. Finger, C. Schneider, P, R. 2006. **Ajuste e seleção de modelos tradicionais para série temporal de dados de Altura de árvores**. Ciência florestal. Santa maria. Brasil.
- Fonseca, A., 1998. **Participação Comunitária na Gestão da Reserva do Niassa. Uma contribuição para análise espacial**. Universidade Eduardo Mondlane.
- Foody, G. M. 1992. **On the compensation for change agreement in image classification accuracy assessment**. Photogrammetric Engineering and Remote Sensing.

- Freitas, M. A. S. 2005. **Um Sistema de Suporte à Decisão para o Monitoramento de Secas Meteorológicas em Regiões Semi-Áridas**. Revista Tecnologia (UNIFOR), Fortaleza, v. Suplem.
- Frost, P., 1996. **The ecology of Miombo woodlands**. In: Campbell, B. (Ed.), *The Miombo In Transition: Woodlands and Welfare in Africa*. Centre for International Forestry Research, Bogor, Indonesia, pp. 11–57.
- Friedman, J. 2002. **Stochastic gradient boosting**. *Comput. Stat. Data Anal.*
- Furian, 2014. Peter Hermes. **Espectro Eletromagnético**. Disponível em: <<http://www.infoescola.com/fisica/espectro-eletromagnetico/>>.
- FUPEF, Fundação de Pesquisas do Paraná. 2001. **Conservação do bioma da floresta com araucária: relatório final**. Diagnóstico de remanescentes florestais. Curitiba.
- GIZ, 2014. **Field Inventory Results: Transboundary Test Area Malawi-Zambia**, Autor/ Editor: Consortium GAF AG and DFS Deutsche Forstservice GmbH.
- Hansen, J, M. Sto, G, Russell e Kharecha, P. 2013. **Climate sensitivity, Sea level, and atmospheric carbon dioxide**. *Phil trans Roy.*
- Hardy, C.C. 2005. **Wildland fire hazard and risk: Problems, definitions, and context**. *Forest Ecology and Management*, 211(1-2). Available at: <http://linkinghub.elsevier.com/retrieve/pii/S037811270500040X> [Accessed February 28, 2013].
- HariPriya, G. S. 2000. **Estimates of Biomass in Indian Forests**. *Biomass and Bioenergy*.
- Holben, B. N.; Tucker, C. J.; Fan, C. J. 1980. **Spectral assessment of soybean leaf area and leaf biomass**. *Photogrammetric Engineering and Remote Sensing*.
- Howard, J. A. 1991. **Remote Sensing of Forest Resources – Theory and Application**. London: Ed. Chapman & Hall.
- IPCC. 2003. **Good Practice Guidance for Land Use, Land-Use Change and forestry**. National Inventory Reports.
- IPCC. 2006. **Guidelines for National Greenhouse Gas Inventories**. Institute for Global Environment Strategies (IGES).

- IPCC. 2007. **Climate Change: Synthesis report.** Painel Intergovernamental sobre as Mudanças Climáticas. Genebra, Suíça.
- IPCC. 2014. **Climate Change: Synthesis report.** Quinto relatório. Painel Intergovernamental sobre as Mudanças Climáticas.
- JAXA. 2006a. **The 2nd ALOS Research Announcement: Calibration and Validation, Utilization Research, and Scientific Research.** Earth Observation Research Center, Japan Aerospace Exploration Agency. <http://www.eorc.jaxa.jp/ALOS/en/ra/ra2_guide.htm.
- JAXA. 2007. **ALOS User Handbook.** Earth Observation Research Center, Japan Aerospace Exploration Agency. 2007. Disponível em:<<http://www.eorc.jaxa.jp/ALOS/en/doc/handbk.htm>>.
- JAXA. 2014. **Press Release. Advanced Land Observing Satellite. ALOS 2.**
- Júnior, C. L, Lima. Accioly. L. J, Giongo. V. Lima. R. L, Sampaio. E. V, Menezes. R. S. 2014. **Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índice de vegetação.**
- Kasischke, E.S.; Melack, J.M.; Dobson, M.C. 1997. The use of imaging readers for ecological applications – a review. **Remote Sensing of Environment.**
- Kennedy. P, 2008. **A guide to econometrics. Machassachusetts:** Black well publishing
- Kuntschik, G. 2004. **Estimativa de biomassa vegetal lenhosa em cerrado por meio de sensoriamento remoto óptico e de radar.** Universidade de São Paulo, São Paulo, Tese de Doutorado.
- Le Maire, G.; Marsden, C.; Nouvellon, Y.; Grinand, C.; Hakamada, R.; Stape, J. L.; Laclau, J. P. 2001. **MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass. Remote Sensing of Environment.**
- Lisboa, S. N. 2014. **Estimativa de biomassa em Floresta sempre verde de Montanha da Reserva Florestal de Moribane.** UEM.
- Macia, F. 2016. **Equação alométrica para floresta do distrito de Muembe na Província de Niassa.**
- Machado, S. do A. Conceição, M. B, Figueiredo, D. J. 2002. **Modelagem do volume individual para diferentes idades e regimes de desbaste em plantações de *Pinus oocarpa*.**

- MAE: Ministério da Administração Estatal. 2005. **Perfil do Distrito de Mecula**. Portal do Governo.
- Marques, G. E. 2015. **Geoprocessamento como ferramenta na análise de incêndios e queimadas através do uso de imagem do satélite landsat 8**. Viçosa Minas Gerais – Brasil.
- Marzoli, A. (2007). **Avaliação Integrada das Florestas em Moçambique (AIFM): Inventário Florestal Nacional**. Maputo: MINAG/DNTF.
- Matallo Junior., H. 2003. **A desertificação no mundo e no Brasil**. In: SCHENKEL, C. S. e MATALLO JR, H (Org). **Desertificação**. Brasília: UNESCO.
- Mathe, M. F. 2013. **Modelação sig na avaliação do risco de incêndios na reserva nacional do Niassa**. Universidade de Lisboa.
- Moreira, M. A. 2003. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Ed. UFV. 2ª ed. Viçosa, MG.
- Moutinho, P; Nepstad, D Santilli, M; Carvalho, G; Batista, Y. 2001. **As oportunidades para Amazonia com a redução das emissões de gases do efeito estufa**. IPAM. 8 p.
- Mueller, A. 2014. **Development of integrated monitoring systems Natural Resources Management for REDD+ in SADC**.
- Mugasha, A. G., and S. A. O. Chamshama 2002. **Tree biomass and volume estimation for Miombo woodlands at Kitulangalo, Morogoro, Tanzania, in Indicators and Tools for Restoration and Sustainable Management of Forests in East Africa**, I-TOO Working.
- Pereira, C. Michaque, M.; Kanji, F. 2002. **Estratégia de Capacitação na área de Certificação Floresta**. Maputo: UEM/FAEF/DNFFB – GRNB.
- Pereira, F, R. 2016. **Sensoriamento remoto lidar e óptico aplicados à estimativa de biomassa aérea de manguezais: estudo de caso na apa de Guapimirim**. Rio de Janeiro.
- Ribeiro, N. Siteo, A. A. Guedes, B. S. Staiss, C. 2002. **Manual de Silvicultura Tropical**. Maputo: UEM/FAEF/DEF.
- Ribeiro, N. S., Shugart, H. H., Swap, R. J., Okin, G. S. 2007. **Five-year period of fire regime in the miombo woodlands of Niassa reserve, Mozambique**. *Journal of Forest Ecology and Management*.
- Ribeiro, N. S., Shugart, H. H., Allen, R. W. 2008. **Aboveground biomass and leaf area index (LAI) mapping for Niassa Reserve, northern Mozambique**.

- Ribeiro, N. S., Shugart, H. H., Swap, R. J., Okin, G. S. 2009. **The influence of rainfall, vegetation, elephants and people on fire frequency of miombo woodlands, northern Mozambique.** *Journal of Forest Ecology and Management.*
- Ribeiro, N. S, Matos CN, Moura IR, Washington-Allen RA, Ribeiro AI. 2013. **Monitoring vegetation dynamics and carbon stock density in Miombo woodlands. Carbon Balance and Management.**
- Ribeiro, N.S. A Cangela, A Chauque, R. R. Bandeira e Ribeiro Barros. 2017. **Characterisation of spatial and temporal distribution of the fire regime in Niassa National Reserve, northern Mozambique.**
- Rocha, M. T. O. 2002. **Aquecimento global e os instrumentos de mercado para a solução do problema.** In: Saqueta, C. R, Witzlawick, L. F. Balbinot, R. Ziliotto, M. A, Gomes, F. S. As florestas e carbon. Curitiba: UFPR.
- Rodrigues, M. 1990. **Introdução ao Geoprocessamento.** In: Simpósio Brasileiro de Geoprocessamento, I. São Paulo. Anais... São Paulo: Escola Politécnica/USP.
- Ryan, C.; Williams, M.; Grace, J. 2012. **Above- and Belowground Carbon Stocks in a Miombo Woodland Landscape of Mozambique.** Biotropica.
- Salimon, C. I., Putz, F. E., Menezesfilho, L., Anderson, A., Silveira, M., Foster Brown, I., Oliveira, L.C. 2011. **Estimating state-wide biomass carbon stocks for a REDD plan in Acre, Brazil.** Forest Ecology and Management.
- Sanquenta, W. Dalla, C. e Fernandes. 2006. **Inventários Florestais: Planejamento e Execução.** Curitiba.
- Shimada, M., ITO, N., Watanabe, M., Moriyama, T., Tadono, T. 2006. **“PALSAR initial calibration and validation results,”** Proc. SPIE.
- Silva, A. L. G. 2002. **Descrição dos Principais Sistemas de Sensores Orbitais em Operação.** Departamento de cartografia, Instituto de Geociência Universidade Federal Fluminense.
- Sitoe, A., Tchaúque, F. 2007. **Medição da Biomassa lenhosa Utilizando informação do Inventario florestal.** Direcção Nacional de Terras e Florestas. Unidade de Inventario Florestal. Maputo.
- Sitoe, A., Guedes. B. S, Nhantumbo, I. 2013. **Linha de referência, Monitoria, Relatório e Verificação para REDD+ em Moçambique.** Relatório do País.

- Sociedade de Gestão da Reserva Nacional de Niassa (SGDRN). 2010. **Bolentim informativo da Reserva Nacional de Niassa-Janeiro**. Lugenda. Maputo, Moçambique.
- SGDRN. 2007. **Plano de Maneio da Reserva Nacional de Niassa 2007-2012**. Sociedade para a Gestão e Desenvolvimento da Reserva Nacional do Niassa Moçambique.
- SRN, (2006). **Plano de maneio da Reserva Nacional do Niassa**, Sociedade para a Gestão e Desenvolvimento da Reserva do Niassa Moçambique.
- Thornthwaite, C.W. 1948. **An approach toward a rational classification of climate**. Geographical Review. New York.
- Timberlake, J., 2004. **Botanical Survey of the Niassa Reserve**, Mozambique; Prepared for Sociedade para a Gestão e Desenvolvimento da Reserva do Niassa Moçambique.
- Tomo, F. A. 2012. **Estimativas de stock de carbono nas florestas de miombo em Gondola**. Trabalho de Licenciatura em Engenharia Florestal. UEM/FAEF. Maputo. Agosto.
- Tucker, C. J. 1979. **Red and photographic infrared linear combinations for monitoring vegetation**. Remote Sensing of Environment.
- UNEP (United Nations Environment Programme), 1997. **World atlas of desertification**. 2ED. UNEP, London.
- Uetela, A. E. 2014. **Dinâmica e Prognose de Produção de uma Floresta de Miombo utilizando Matriz de Transição**. Curitiba. Brasil.
- United States Geological Survey (USGS). 2013. **Frequently Asked Questions about the Landsat Missions**. Disponível em: <http://landsat.usgs.gov/band_designations_landsat_satellites.php>.
- Viganó, H. A. Borges, E. F. Franca-Rocha, W. J. S. 2011. **Análise do desempenho dos índices de vegetação NDVI e SAVI a partir de imagens Aster**. In: Simpósio Brasileiro de Sensoriamento Remoto. Anais... Curitiba.
- Watzlawick, L.F. 2009 **Estimativa de biomassa e carbono em Floresta Ombrófila Mista e plantações florestais a partir de dados de imagens do satélite Ikonos II**. Curitiba, PR: UFPR.

Wertz-Kanounnikoff, S., Siteo, A. e Salomão, A. (2011) **Como o REDD+ está a emergir nas florestas secas da África Austral? Um instantâneo de Moçambique**. Publicação ocasional 31. CIFOR. Abril.

White, F. 1983. **The Vegetation of África**. Natural Resources Research 20, UNESCO, Paris.

World Wide Fund For Nature (WWF). 2012. **Miombo Eco-region Report “Home of the Zambezi” Conservation Strategy: 2011-202**. Harare.

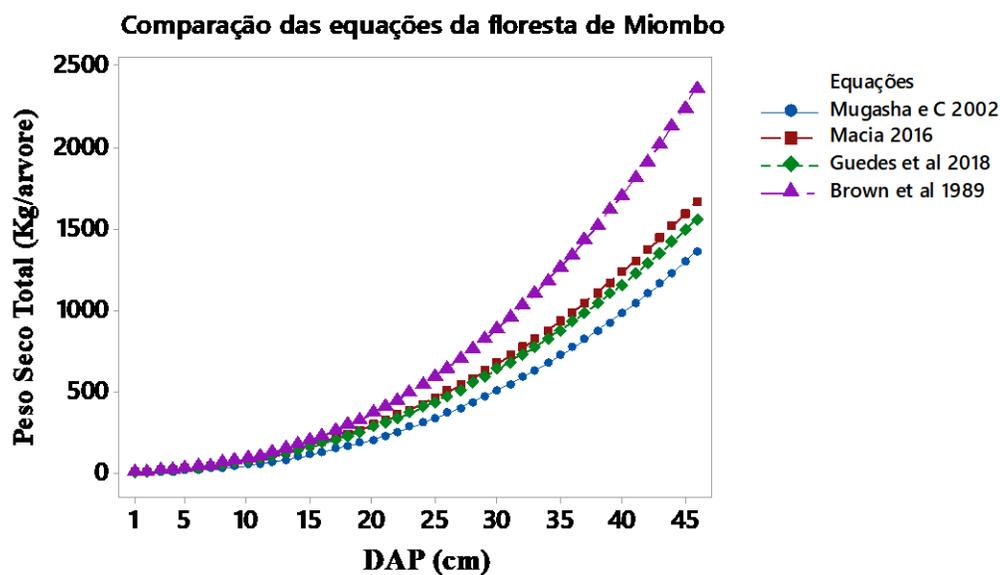
Zanette, V, H. 2017. **Equações alométricas de biomassa aérea mista no Paraná**. Curitiba. Brasil.

ANEXOS

ANEXO 3

Estatísticas dos modelos

	Mugasha	Brown	Macia	Guedes
N	24	24	24	24
Sum	7449	1311	1068	1022
Lo 95% CI	254.69	44.672	36.795	35.241
Mean	310.38	54.625	44.500	42.583
Up 95% CI	366.06	64.578	52.205	49.926
SD	131.88	23.570	18.247	17.388
Variance	17392	555.55	332.96	302.34
SE Mean	26.920	4.8112	3.7247	3.5493
C.V.	42.490	43.149	41.005	40.833
Minimum	62.000	11.000	10.000	10.000
Median	361.50	64.000	51.000	49.000
Maximum	542.00	95.000	76.000	73.000



ANEXO 4

Dados médios de BLAS e variáveis independentes (NDVI1, SAVI1, SR1, NDVI2, NDVI2, SR2, $\sigma^{\circ}\text{HH}$, $\sigma^{\circ}\text{HV}$, $\sigma^{\circ}\text{VV}$ e $\sigma^{\circ}\text{VH}$) em cada parcela

Plot Iha	Código do Plot	Biomassa estimada (t/ha)	Variáveis Independentes									
			LANDSAT 8/OLI			Sentinel 2/MSI			ALOS/PALSAR 2		Sentinel 1B	
			NDVI 1	SAVI 1	SR 1	NDVI 2	SAVI 2	SR 2	$\sigma^{\circ}\text{HH}$	$\sigma^{\circ}\text{HV}$	$\sigma^{\circ}\text{VH}$	$\sigma^{\circ}\text{VV}$
1	AS	89	0.35	0.33	5.0	0.30	0.31	3.5	-7,64	-11,2	-26,16	-27,0
2	AP	25	0.20	0.30	3.0	0.20	0.30	2.2	-13,1	-16,1	-27,62	-28,9
3	DR	22	0.15	0.10	4.0	0.12	0.11	3.2	-7,04	-15,3	-23,29	-21,4
4	CP	28	0.10	0.40	3.5	0.10	0.40	2.3	-10,6	-16,9	-28,67	-27,0
5	CR	22	0.35	0.30	2.0	0.10	0.30	2.0	-13,6	-14,3	-28,06	-28,1
6	CS	69	0.20	0.32	3.8	0.20	0.30	3.4	-10,6	-14,3	-24,94	-25,7
7	ER	69	0.45	0.37	5.0	0.40	0.40	4.5	-8,99	-11,6	-23,62	-21,4
8	EP	59	0.20	0.15	4.0	0.17	0.13	4.0	-11,5	-14,3	-23,27	-22,3
9	CQ	64	0.18	0.15	2.8	0.16	0.11	2.0	-8,32	-12,8	-25,65	-28,1
10	ES	64	0.25	0.20	6.0	0.21	0.18	5.5	-4,28	-10,2	-22,43	-18,7
11	DP	79	0.50	0.32	7.5	0.35	0.30	5.0	-3,30	-9,89	-22,13	-18,4
12	FP	42	0.30	0.24	4.5	0.23	0.20	4.0	-10,8	-12,2	-22,86	-19,3
13	FR	95	0.40	0.30	4.0	0.40	0.28	3.3	-6,48	-10,5	-25,00	-23,4
14	FQ	74	0.33	0.27	3.6	0.31	0.25	3.1	-6,75	-14,5	-24,87	-19,0
15	FS	56	0.27	0.20	3.0	0.28	0.15	3.0	-9,47	-16,8	-22,60	-20,4
16	AR	68	0.20	0.18	2.5	0.25	0.15	2.4	-5,56	-13,2	-23,68	-20,8
17	AQ	11	0.15	0.12	2.0	0.14	0.10	1.2	-13,8	-18,7	-26,14	-24,5
18	BP	80	0.12	0.10	2.0	0.12	0.08	1.8	-6,90	-10,8	-25,73	-25,4
19	DQ	64	0.25	0.21	3.8	0.23	0.20	3.5	-7,33	-11,8	-23,88	-22,3
20	BS	38	0.20	0.18	3.0	0.22	0.14	2.5	-9,37	-14,2	-25,46	-27,0
21	BQ	29	0.20	0.15	2.5	0.10	0.15	2.0	-9,47	-11,4	-26,00	-28,4
22	BR	29	0.23	0.20	3.5	0.20	0.20	3.0	-10,6	-16,0	-25,77	-24,4
23	EQ	68	0.30	0.26	4.0	0.25	0.23	4.0	-8,66	-13,2	-23,48	-21,8
24	DS	75	0.76	0.40	6.5	0.40	0.35	6.0	-3,73	-9,42	-22,00	-16,8
		Total	6.13	5.75	91.5	5.29	5.32	77.4	-207.9	-319.5	593.2	-560

Fim da tabela

ANEXO 5

Correlações das variáveis (Spearman, nível de significância de 95%)

	Biomassa	N1	SA1	SR1	N2	SA2	SR2	HH
NDVI1	0,625							
SAVI1	0,278	0,528						
SR1	0,466	0,797	0,510					
NDVI2	0,700	0,898	0,506					
SAVI2	0,198	0,465	0,980	0,001				
SR2	0,505	0,765	0,447	0,020	0,034			
$\sigma^{\circ}HH$	0,696	0,602	0,102	0,000	0,001	0,055		
$\sigma^{\circ}HV$	0,698	0,593	0,213	0,001	0,006	0,839	0,002	
$\sigma^{\circ}VH$	0,469	0,617	0,091	0,003	0,041	0,412	0,002	0,000
$\sigma^{\circ}VV$	0,414	0,633	0,111	0,001	0,005	0,444	0,000	0,001

ANEXO 6

Resumo de ANOVA

<i>Grupo</i>	<i>Contagem</i>	<i>Soma</i>	<i>Média</i>	<i>Variância</i>
10% - 25%	8	203.2009	25.40011	60.88663
25% - 50%	7	415.8033	59.40048	73.26006
50% - 75%	5	355.7627	71.15253	9.517912
75% - 100%	4	335.537	83.88424	58.25576

ANOVA

<i>Fonte da variação</i>	<i>SQ</i>	<i>gl</i>	<i>MQ</i>	<i>F</i>	<i>Valor-P</i>	<i>F crítico</i>
Entre grupos	11782.58	3	3927.526	72.82599	6.1211	3.098391
Dentro dos grupos	1078.606	20	53.93028			
Total	12861.18	23				

ANEXO 7

Normalidade dos dados a partir do teste de Shapiro Wilk

<i>Variáveis</i>	<i>N</i>	<i>Shapiro Wilk</i>	<i>P calculado</i>
NDVI 1	24	0.2090	0.5124*
SAVI 1	24	0.3190	0.0000*
SR 1	24	0.8777	0.0561*
NDVI2	24	0.8234	0.0075*
SAVI 2	24	0.7182	0.0632*
SR 2	24	0.9254	0.0769*
$\sigma^{\circ}\text{HH}$	24	0.9607	0.4517*
$\sigma^{\circ}\text{HV}$	24	0.9491	0.2591*
$\sigma^{\circ}\text{VH}$	24	0.9378	0.1385*
$\sigma^{\circ}\text{VV}$	24	0.9394	0.1581*

Observações: todos os valores das variáveis analisadas seguem uma distribuição normal através do teste de Shapiro Wilk P_w , pois todos os valores de P calculado são menores que os valores obtidos de Shapiro Wilk a um nível de significância de 5% ($P \text{ calculado} < P_w$).

ANEXO 8

Estatística descritiva

Variável	Média	DesvPad	CoefVar	Soma	SQ	Mínimo	Máximo
Biomassa	54,60	23,65	43,31	1310,30	84398,52	11,09	95,21
NDVI1	0,2554	0,1244	48,70	6,1300	1,9215	0,18	0,76
SAVI1	0,2396	0,0913	38,13	5,7500	1,5695	0,1000	0,4000
SR1	3,813	1,408	36,93	91,500	394,430	2,000	7,500
NDVI2	0,2204	0,1060	48,10	5,2900	1,4245	0,0200	0,4000
SA2	0,2217	0,0956	43,12	5,3200	1,3894	0,0800	0,4000
SR2	3,225	1,207	37,42	77,400	283,120	1,200	6,000
$\sigma^{\circ}\text{HH}$	-8,665	2,913	-33,62	-207,953	1997,003	-13,797	-3,302
$\sigma^{\circ}\text{HV}$	-13,315	2,491	-18,71	-319,569	4397,949	-18,650	-9,424
$\sigma^{\circ}\text{VH}$	-24,718	1,874	-7,58	-593,232	14744,256	-28,672	-21,955
$\sigma^{\circ}\text{VV}$	-23,355	3,638	-15,58	-560,526	13395,680	-28,862	-16,840