

**UNIVERSIDADE DO RIO GRANDE DO SUL  
INSTITUTO DE GEOCIÊNCIAS  
DEPARTAMENTO DE GEOGRAFIA**

**MARCELO FOSCHIERA DE MESQUITA**

**SENSORIAMENTO REMOTO PARA ESTIMATIVA DE SEQUESTRO DE  
CARBONO: UMA REVISÃO BIBLIOMÉTRICA**

**PORTO ALEGRE**

**2024**

**MARCELO FOSCHIERA DE MESQUITA**

**SENSORIAMENTO REMOTO E SEQUESTRO DE CARBONO: UMA REVISÃO  
BIBLIOMÉTRICA**

Trabalho de Conclusão de Curso apresentado ao Curso de bacharel em Geografia da Universidade Federal do Rio Grande do Sul, como requisito parcial para obtenção do grau de Bacharel em Geografia.

Orientador: Prof. Dr. Clódis de Oliveira  
Andrades Filho

Coorientadora: Me. Pâmela Boelter  
Herrmann

**PORTO ALEGRE**

**2024**

**MARCELO FOSCHIERA DE MESQUITA**

**SENSORIAMENTO REMOTO PARA ESTIMATIVA DE SEQUESTRO DE  
CARBONO: UMA REVISÃO BIBLIOMÉTRICA**

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharel em Geografia da Universidade Federal do Rio Grande do Sul, como requisito parcial para obtenção do grau de Bacharel em Geografia.

Aprovado em 23 de fevereiro de 2024.

**BANCA EXAMINADORA**

---

Prof. Dr. Clódis de Oliveira Andrades Filho

Instituto de Geociências

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

ORIENTADOR

---

Prof. Dr. Marcos Wellausen Dias de Freitas

Instituto de Geociências

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

---

Me. Catherine Vargas Goulart

Programa de Pós-Graduação em Sensoriamento Remoto

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

A minha mãe, razão de minha existência e fonte de amor incondicional.

Ao meu irmão, sempre disponível e prestativo.

A minha namorada, pelo amor e carinho.

A Deus.

## AGRADECIMENTOS

À Universidade Federal do Rio Grande do Sul e a todos os professores e servidores, em especial aos do Instituto de Geociências que, através do seu empenho e motivação tornam esta instituição uma rica e importante fonte de conhecimento.

Ao orientador Prof. Dr. Clódis de Oliveira Andrades Filho pelo constante cuidado, atenção, e entusiasmo pela pesquisa e pelo bem-estar do pesquisador.

À coorientadora Pâmela Boelter Herrmann pela ajuda e por estar sempre à disposição para compartilhar seu conhecimento e para ouvir minhas preocupações acerca desse trabalho.

À Deus, pelo qual sempre busquei ajuda nos momentos difíceis.

Aos meus amigos, que me deram todo o apoio durante minha jornada acadêmica.

À Emily, fonte de minha alegria e amor, e por estar sempre ao meu lado. Por ser a quem recorro nos piores e nos melhores momentos.

Ao meu irmão, pela ajuda e caridade. Sem ele este trabalho não existiria.

À minha mãe pela minha vida. Todas minhas conquistas devo ao seu amor, cuidado e incentivo que não conhece limites. Ela continua sendo sempre a inspiração e referência de uma vida certa e iluminada, e sigo sempre seus passos.

“A vida é feita de momentos fugazes, mas  
são esses momentos que dão sentido a  
nossa existência.”

Gabriel Garcia Márquez

## RESUMO

O sequestro de carbono é uma estratégia para reduzir a quantidade de CO<sub>2</sub> na atmosfera e mitigar seus impactos nas mudanças climáticas. O sensoriamento remoto oferece técnicas capazes de estimar o sequestro de carbono na vegetação, tornando esse método mais atrativo para a redução de CO<sub>2</sub>. Neste trabalho, realizamos uma revisão sistemática da literatura usando o método PRISMA e analisamos o estado atual do assunto no meio acadêmico. Observamos tendências e particularidades, além de avaliar as metodologias empregadas nos estudos sobre sequestro de carbono por meio do sensoriamento remoto. O tema parece estar ganhando popularidade, com autores de países como China e Índia contribuindo. A vantagem do baixo custo em comparação com técnicas de medição de campo motiva o uso do sensoriamento remoto para calcular biomassa e estoque de carbono.

**Palavras-Chaves:** Sequestro de Carbono; Sensoriamento Remoto; PRISMA; Vegetação.

## ABSTRACT

Carbon sequestration is a strategy to reduce the amount of CO<sub>2</sub> in the atmosphere and mitigate its impacts on climate change. Remote sensing offers techniques capable of estimating carbon sequestration in vegetation, making this method more attractive for CO<sub>2</sub> reduction. In this work, we conducted a systematic literature review using the PRISMA method and analyzed the current state of the subject in the academic environment. We observed trends and particularities, as well as evaluated the methodologies employed in the studies on carbon sequestration through remote sensing. The topic seems to be gaining popularity, with authors from countries such as China and India contributing. The advantage of low cost compared to field measurement techniques motivates the use of remote sensing to calculate biomass and carbon stock.

**Keywords:** Carbon Sequestration; Remote Sensing; PRISMA; Vegetation.

## LISTA DE SIGLAS

AGB: Biomassa acima do solo (*Above-Ground Biomass*)

ARVI: *Atmospherically Resistant Vegetation Index*

AMSR2: *Advanced Microwave Scanning Radiometer 2*

AVI: *Ashburn Vegetation Index*

AWiFS: *Advanced Wide Field Sensor*

BI: *Bare soil Index*

BLUE: Faixa espectral do azul

CC: Crédito de Carbono

CIVE: *Color Index of Vegetation*

CO<sub>2</sub>: Dióxido de Carbono

DVI: *Difference Vegetation Index*

EC: Estoque de Carbono

ETM+: *Enhanced Thematic Mapper Plus*

EVI: *Enhanced Vegetation Index*

EVI2: *Enhanced Vegetation Index 2*

ExG: *Excess Green index*

ExGR: *Excess Green minus Red index*

GEE: Gases de Efeito Estufa

GI: *Simple Ratio 554/677 Greenness Index*

GLA: *Green Leaf Algorithm*

GNDVI: *Green Normalized Difference Vegetation Index*

IAF: Índice de Área Foliar

IPVI: *Infrared Percentage Vegetation Index*



IV: Índice de Vegetação

IVI: *Ideal Vegetation Index*

kNDVI: *Kernel NDVI*

Ku-VOD: *Ku-Band Vegetation Optical Depth*

LANDSAT: *Land Remote Sensing Sattelite*

L-VOD: *L-Band Vegetation Optical Depth*

MCARI: *Modified Chlorophyll Absorption in Reflectance Index*

mNDVI: *Modified NDVI*

MSR: *Modified Simple Ratio*

MSS: *Multispectral ScanOner System*

ND45: *Normalized Difference between Landsat TM bands 4 and 5*

NDGI: *Normalized Difference Greenness Index*

NDII: *Normalized Difference Infrared Index*

NDI45: *Normalized Difference Index between Landsat TM bands 4 and 5*

NDVI: *Normalized Difference Vegetation Index*

NDWI: *Normalized Difference Water Index*

NGRDI: *Normalized Green-Red Difference Index*

NIR: *Faixa espectral do infravermelho próximo (Near Infrared)*

OLI: *Operational Land Imager*

OSAVI: *Optimized Soil-Adjusted Vegetation Index*

PAQ: *Potencial de Aquecimento Global*

PDI: *Processamento de Imagem*

PSSR: *Pigment Specific Simple Ratio*

PRI: *Photochemical Reflectance Index*

PRISMA: Revisões Sistemáticas e Meta-Análises

PVI: *Perpendicular Vegetation Index*

RBVI: *Red-Blue Vegetation Index*

RDVI: *Renormalized Difference Vegetation Index*

RED: Faixa espectral do vermelho

RENDVI: *Normalized Difference 750/710 Red Edge NDVI*

RERVI: *Red Edge Ratio Vegetation Index*

RGVI: *Red-Green Vegetation Index*

RS: Razão Simples (*Simple Ratio*)

RVI: *Ratio Vegetation Index*

S2REP: *Sentinel-2 Red Edge Position index*

SARVI: *Soil and Atmospherically Resistant Vegetation Index*

SAVI: *Soil-Adjusted Vegetation Index*

SC: Sequestro de Carbono

SI: *Shadow Index*

SIPI: *Structure Insensitive Pigment Index*

SMOS: *Soil Moisture and Ocean Salinity*

SR: Sensoriamento Remoto

SWIR: Faixa espectral do infravermelho de ondas curtas (shortwave infrared)

TBVI: *Three-band Vegetation Index*

TC: *Tree Canopy Percentage*

TCARI: *Transformed Chlorophyll Absorption in Reflectance Index*

TI: *Thermal Index*

TM: *Thematic Mapper*

TPI: *Topographical Position Index*

TSAVI: *Transformed Soil Adjusted Vegetation Index*

TVI: *Transformed Vegetation Index*

VEG: *Vegetativen*

WDRVI: *Wide Dynamic Range Vegetation Index*

WI: *Woebbecke Index*

X-VOD: *X-Band Vegetation Optical Depth*

## LISTA DE FIGURAS

Figura 1 - Imagem simples com representação numérica. ....	19
Figura 2 - Fluxograma da metodologia. ....	34
Figura 3 - Nuvem de palavras de correlações de palavras-chave. ....	36
Figura 4 – Número de artigos publicados por país. ....	40
Figura 5 - Mapa de número de artigos por país. ....	41
Figura 6 - Porcentagem de artigos por área de conhecimento. ....	42
Figura 7 - Quantidade de artigos por ano. ....	43
Figura 8 - Mapa de redes de países ao longo dos anos. ....	45
Figura 9 - Mapa de áreas de estudo por país. ....	48
Figura 10 - Ocorrência de uso de sensores da série Landsat. ....	50
Figura 11 - Número de ocorrências de índices de vegetação. ....	51

## LISTA DE TABELAS

Tabela 1 – PAQ de GEEs relativos ao CO <sub>2</sub> .....	16
Tabela 2 - <i>MultiSpectral Scanner System</i> (MSS).....	21
Tabela 3 - <i>Thematic Mapper</i> (TM). ....	21
Tabela 4 - <i>Enhanced Thematic Mapper Plus</i> (ETM+).....	22
Tabela 5 - <i>Operational Land Imager</i> (OLI).....	22
Tabela 6 - <i>Thermal Infrared Sensor</i> (TIRS). ....	23
Tabela 7 - Anos de lançamento e operação dos satélites Sentinel. ....	<b>Erro!</b>
<b>Indicador não definido.</b>	
Tabela 8 – Artigos por país.....	39
Tabela 9 - Quantidade de áreas de estudo por país.....	47

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>12</b>
1.1	OBJETIVOS .....	13
1.1.1	<b>Objetivo Geral.....</b>	<b>13</b>
1.1.2	<b>Objetivos Específicos .....</b>	<b>14</b>
<b>2</b>	<b>REFERÊNCIAL TEÓRICO.....</b>	<b>15</b>
2.1	SEQUESTRO DE CARBONO .....	15
2.1.1	<b>Histórico do Sequestro de Carbono .....</b>	<b>15</b>
2.1.2	<b>Crédito de Carbono.....</b>	<b>16</b>
2.1.3	<b>Carbono na vegetação.....</b>	<b>16</b>
2.2	SENSORIAMENTO REMOTO E PROCESSAMENTO DE IMAGEM .....	18
2.2.1	<b>Sensores Espectrais .....</b>	<b>19</b>
2.2.2	<b>Operações Aritméticas .....</b>	<b>25</b>
2.2.3	<b>Comportamento espectral da vegetação e índices espectrais .....</b>	<b>28</b>
2.3	REVISÃO SISTEMÁTICA.....	31
<b>3</b>	<b>METODOLOGIA .....</b>	<b>34</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÃO.....</b>	<b>38</b>
4.1	PRODUÇÃO DE ARTIGOS POR PAÍSES.....	38
4.2	ÁREAS DE CONHECIMENTO .....	41
4.3	EVOLUÇÃO TEMPORAL .....	42
4.4	UTILIZAÇÃO DE SENSORIAMENTO REMOTO NOS ARTIGOS .....	45
4.5	ÁREAS DE ESTUDO .....	46
4.6	REGIÕES ESPECTRAIS .....	49
4.7	SENSORES.....	49
4.8	ÍNDICES DE VEGETAÇÃO .....	51
<b>5</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>53</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>55</b>
	<b>ANEXOS .....</b>	<b>63</b>
	ANEXO A.....	64



## 1 INTRODUÇÃO

O maior desafio que o mundo enfrenta hoje é o aumento da temperatura devido à emissão de Gases de Efeito Estufa (GEE). O principal contribuinte para as alterações climáticas é o dióxido de carbono ( $\text{CO}_2$ ) libertado pelo consumo de combustíveis fósseis, responsável por aproximadamente 80% das emissões globais de GEE (VIEIRA BARRETO; CRISTINA; FREITAS, 2009). O sequestro de carbono (SC) é uma das estratégias para mitigar esses efeitos nas mudanças climáticas, pois envolve a retirada de  $\text{CO}_2$  da atmosfera e o seu armazenamento em reservatórios naturais, como solos, florestas e oceanos (IPCC, 2018). Embora seja uma medida promissora, há desafios a serem superados para torná-la efetiva e confiável.

Uma das principais dificuldades é a falta de padronização nos métodos de medição e cálculo do SC, já que diferentes condições ambientais e uso e ocupação do solo podem influenciar os resultados. Além disso, é preciso garantir a permanência do SC, pois atividades de uso de terra afetam o fluxo de processos de geração e armazenamento de  $\text{CO}_2$  no solo (VIEIRA BARRETO; CRISTINA; FREITAS, 2009). Apesar desses desafios, o SC ainda apresenta grande potencial para contribuir na luta contra as mudanças climáticas, desde que seja encarado como uma medida complementar à redução das emissões de gases de efeito estufa (VIEIRA BARRETO; CRISTINA; FREITAS, 2009).

Tendo em vista essas limitações metodológicas, o sensoriamento remoto (SR) pode contribuir para superar alguns desses desafios, oferecendo informações espaciais e temporais em diferentes escalas (CAMPBELL, 1996). O sensoriamento remoto é uma técnica que apresenta diversas vantagens, como a cobertura ampla e contínua do território, a rapidez na obtenção dos dados e a possibilidade de integração com outras fontes de informação (CAMPBELL, 1996).

Por meio do SR, é possível estimar a biomassa vegetal e o estoque de carbono em diferentes ecossistemas, como florestas, savanas e pastagens (CAMPBELL, 1996). Essas estimativas podem ser utilizadas para avaliar o potencial de SC em diferentes regiões e cenários, bem como para monitorar as mudanças na cobertura vegetal e no uso da terra que podem afetar esse potencial. Para isso, utiliza-se o



Índice de Área Foliar (IAF), para estimar a quantidade de cobertura vegetal de uma área. Nos campos de cima da serra, Daniela Silva e Clódis Andrades-Filho (2021) verificaram, através de análise temporal de imagens de satélite, áreas manejadas pelo fogo que não possuíam licenças para tal, demonstrando a importância das técnicas de SR para fins de fiscalização ambiental. Na Amazônia, Seixas e Pinheiro (2014) aplicaram técnicas de SR para verificar o comportamento das chuvas e sua alteração em áreas desmatadas. O estudo do SC assume uma relevância crucial para os profissionais da área ambiental, especialmente no contexto das mudanças climáticas. Conhecer as técnicas de SR empregadas na medição de biomassa e no cálculo do SC é fundamental para compreender melhor as estratégias de mitigação e adaptação aos efeitos do aquecimento global. Além disso, entender como funciona o SC fornece subsídios para o desenvolvimento de projetos de restauração ecológica, para a implementação de políticas públicas voltadas para o meio ambiente e para a identificação de áreas prioritárias para a conservação da biodiversidade.

A compreensão sobre o SC é uma competência valiosa para os profissionais da Geografia, que devem se manter atualizados e preparados para os desafios ambientais contemporâneos. Sendo assim, esta pesquisa tem a intenção de contribuir com a síntese e consolidação do conhecimento acerca do uso do SR para a estimativa do SC no Brasil. Apesar dos avanços tecnológicos e do crescente interesse em utilizar essa técnica para estimar o SC, há ainda brechas na literatura científica em relação à consolidação das abordagens teóricas e à realização de um levantamento bibliográfico abrangente nessa área específica.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo Geral

O objetivo geral deste trabalho é levantar e analisar as metodologias de sensoriamento remoto na estimativa de SC vegetal, por meio de um levantamento bibliográfico integrado e detalhado.

### **1.1.2 Objetivos Específicos**

Revisar os conceitos-chave de processamento de imagens e cálculo de biomassa vegetal, bem como o levantamento bibliográfico das principais técnicas de sensoriamento remoto utilizadas na avaliação da cobertura vegetal e SC.

Identificar os principais métodos de cálculo de biomassa vegetal, incluindo modelagem e medições diretas, com análise de características, precisão e confiabilidade para estimativa de SC.

Identificar as lacunas no conhecimento atual e propor abordagens mais eficientes e integradas para a avaliação da cobertura vegetal e estimativa de SC.

## 2 REFERÊNCIAL TEÓRICO

### 2.1 SEQUESTRO DE CARBONO

#### 2.1.1 Histórico do Sequestro de Carbono

O carbono é um elemento essencial para a vida na Terra, mas também é o principal responsável pelo efeito estufa e mudanças climáticas. A queima de combustíveis fósseis, desmatamento e agropecuária são as principais fontes de emissão de CO<sub>2</sub>, contribuindo para o aquecimento global e seus impactos negativos no meio ambiente e na sociedade. Diante dessa urgência, governos e entidades no geral buscam reduzir as emissões e mitigar seus efeitos, destacando o SC como uma estratégia importante, incentivada pelos créditos de carbono (SAPORTA; YOUNG, 2009).

Após o protocolo de Kyoto (PK) o SC surgiu como uma possibilidade de retorno financeiro pela redução de GEE, com países desenvolvidos patrocinando projetos em países em desenvolvimento (MOREIRA; GIOMETTI, 2008). O Mecanismo de Desenvolvimento Limpo (MDL) visa reduzir emissões através de projetos que envolvam tecnologias mais eficientes, uso de energias renováveis, racionalização energética, florestamento e reflorestamento (LOPES, 2002).

Em 2015, foi assinado o Acordo de Paris, que traz alguns conceitos do PK, e tem como objetivo reduzir o aquecimento global para idealmente 1,5 °C (UFNCC, 2018). O acordo tem uma proposta de adoção voluntária, ao invés do caráter obrigatório do PK, e incentiva a divulgação constante das ações necessárias para o combate ao aquecimento global. Segundo o parágrafo 2 do artigo 5 do Acordo de Paris:

As Partes são encorajadas a adotar medidas para implementar e apoiar, inclusive por meio de pagamentos por resultados, o marco existente conforme estipulado em orientações e decisões afins já acordadas sob a Convenção para: abordagens de políticas e incentivos positivos para atividades relacionadas a redução de emissões por desmatamento e degradação florestal, e o papel da conservação, do manejo sustentável de florestas e aumento dos estoques de carbono florestal nos países em desenvolvimento;

e abordagens de políticas alternativas, tais como abordagens conjuntas de mitigação e adaptação para o manejo integral e sustentável de florestas, reafirmando ao mesmo tempo a importância de incentivar, conforme o caso, os benefícios não relacionados com carbono associados a tais abordagens. (MCTIC; SEPED; CGCL, 2021)

### 2.1.2 Crédito de Carbono

O crédito de carbono é um incentivo fiscal para estimular o SC em diversos locais e organizações, contando com a adesão de países e organizações privadas. Ele é calculado com base no Potencial de Aquecimento Global (PAQ) de diversos GEE (Tabela 1). Por convenção, foi definido que um crédito de carbono equivale a uma tonelada de CO<sub>2</sub> capturado na atmosfera. Outros GEE possuem equivalência a créditos de carbono baseado na proporção de PAQ relativo ao CO<sub>2</sub>.

Tabela 1 – PAQ de GEEs relativos ao CO<sub>2</sub>. Fonte: (IPCC, 2002)

<i>GEE</i>	<i>PAQ em 100 anos</i>
<i>CO2 – Dióxido de Carbono</i>	1
<i>CH4 – Metano</i>	23
<i>N2O – Óxido Nitroso</i>	296

*Direct Global Warming Potentials (mass basis) relative to carbon dioxide (for gases for which the lifetimes have been adequately characterized). (IPCC, 2002)*

Dessa forma, é crucial incentivar práticas de SC como estímulo econômico para a redução de emissões de gases de efeito estufa e a preservação ambiental, visando um futuro mais sustentável e resiliente para todos.

### 2.1.3 Carbono na vegetação

Uma opção amplamente adotada para o SC é o por meio florestal, uma vez que as florestas armazenam mais carbono do que o presente na atmosfera,

desempenhando um papel vital na manutenção do equilíbrio do estoque global de carbono (VIEIRA BARRETO; CRISTINA; FREITAS, 2009).

O fluxo de CO<sub>2</sub> entre esses dois sistemas é regulado por dois processos independentes: a produção primária bruta e a respiração (KIRSCHBAUM et al., 2001). A produção primária bruta terrestre (GPP), que é definida como a quantidade de absorção de carbono pela vegetação através da fotossíntese à escala do ecossistema, se torna fundamental para o balanço global de carbono, sendo o primeiro passo pelo qual o CO<sub>2</sub> entra na biosfera (SUN et al., 2019). A respiração, chamada de efluxo de CO<sub>2</sub> do solo, consiste na liberação de CO<sub>2</sub> pela respiração das plantas e pelos organismos do solo (KIRSCHBAUM et al., 2001). É através desses dois processos em que o carbono é transferido da atmosfera (na forma de CO<sub>2</sub>), para a biosfera, e armazenado nela tanto acima do solo quanto abaixo dele. A biomassa é o termo utilizado para a quantidade de elementos contidos na composição de seres vivos. Para estimativa da quantidade de carbono na vegetação, calcula-se sua biomassa.

## 2.2 SENSORIAMENTO REMOTO E PROCESSAMENTO DE IMAGEM

O processamento de imagens de sensoriamento remoto tem como função primordial “fornecer ferramentas para facilitar a identificação e a extração da informação contida na imagem, para posterior interpretação” (CRÓSTA, 1992).

O Sensoriamento Remoto é uma área em crescimento, revolucionando diversos campos de atuação por sua capacidade de interação e tomada de decisão por meio de imagens e programas computacionais (TULLIO, 2018). Essa ciência e arte buscam obter informações precisas sobre objetos, áreas ou fenômenos sem a necessidade de contato físico direto, através da análise de dados obtidos por dispositivos especializados (CRÓSTA, 1992).

Um dos alicerces do processamento de imagem digital é a manipulação das diferentes propriedades da matriz da imagem, composta por pixels. Cada pixel é composto por três valores, chamados convencionalmente de “x, y e z”. Os dois primeiros valores representam a localização de um pixel em uma grade, representando a imagem. Já o valor “z” é o chamado “nível de cinza” (Figura 1), que corresponde a “média de intensidade da energia refletida ou emitida pelos diferentes materiais presentes nesse pixel” (CRÓSTA, 1992).

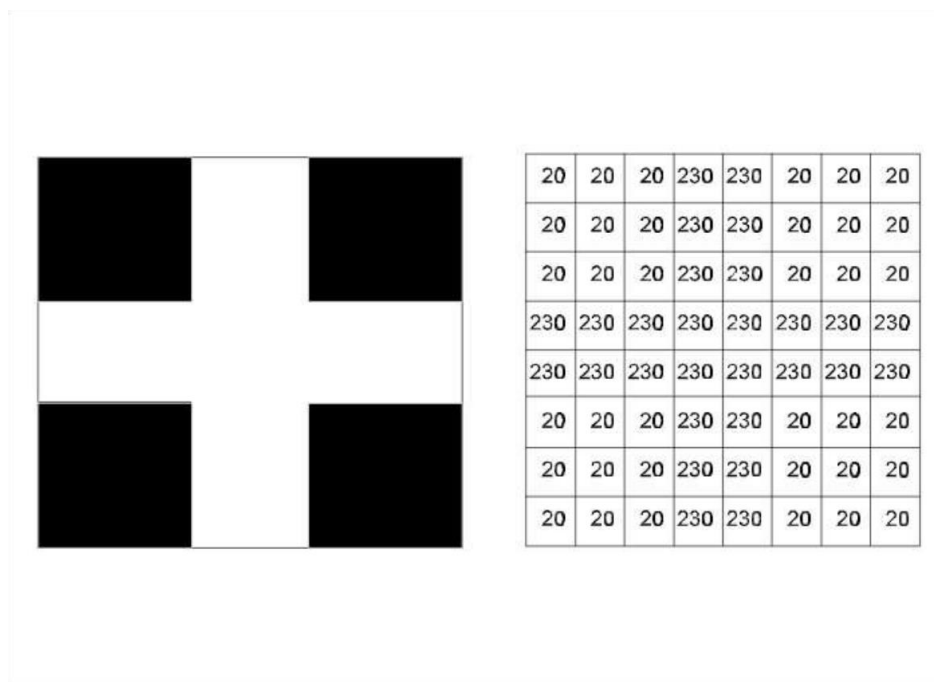


Figura 1 - Imagem simples com representação numérica. Fonte: (CRÓSTA, 1992)

As imagens de satélite utilizadas no SR são georreferenciadas, e cada um de seus pixels representa uma área da superfície da terra. Para referência, o satélite Landsat 8 possui uma resolução de 30 m de resolução multiespectral, conforme a U.S. GEOLOGICAL SURVEY (2021). O georreferenciamento de imagens de satélite permite observar a superfície terrestre com diferentes referências temporais, e realizar operações que auxiliam no melhor entendimento dela.

### 2.2.1 Sensores Espectrais


Os sensores espectrais são os instrumentos de captura de dados da superfície terrestre, e os utilizados pelo SR geralmente são instalados nos sistemas de satélites que circundam nosso planeta. Existe uma série de diferentes sistemas de satélites lançados ao longo do tempo, por diversos países e instituições. Abaixo, estão descritas algumas famílias de satélites e seus sensores, assim como suas faixas espectrais de detecção.

### 2.2.1.1 Land Remote Sensing Satellite (LANDSAT)

A série LANDSAT teve início na segunda metade da década de 60 e foi gerenciada pela *National Aeronautics and Space Administration* (NASA) e pela *U.S. Geological Survey* (USGS) (EMBRAPA, 2022).

No Quadro 1, é possível observar os anos de lançamento e de término de operação dos satélites Landsat.

Quadro 1 - Histórico de operação de satélites Landsat. Fonte: (EMBRAPA, 2022)



Os sensores embarcados nos satélites Landsat possuem diferentes bandas e resoluções espectrais. Abaixo, na Tabela 2, Tabela 3, Tabela 4, Tabela 5 e Tabela 6 estão listados os principais sensores da série.

#### 2.2.1.1.1 Multispectral Scanner System (MSS)

O sensor MSS está presente nos satélites Landsat 1, Landsat 2, Landsat 3, Landsat 4 e Landsat 5.



Tabela 2 - *MultiSpectral Scanner System* (MSS). Fonte: (EMBRAPA, 2022)

<b>Sensor</b>	<b>Bandas Espectrais</b>	<b>Resolução Espectral</b>	<b>Resolução Espacial</b>	<b>Resolução Temporal</b>	<b>Área Imageada</b>	<b>Res. Radiométrica</b>
<i>MSS</i> ( <i>MultiSpectral Scanner System</i> )	(B4) VERDE	0.5 - 0.6 $\mu\text{m}$	57 x 79 m	18 dias (L1-L3);	185 km	6 bits (L1-L3); 8 bits (L4-L5)
	(B5) VERMELHO	0.6 - 0.7 $\mu\text{m}$				
	(B6)	0.7 - 0.8 $\mu\text{m}$				
	INFRAVERMELHO PRÓXIMO			16 dias (L4-L5)		
	(B7)	0.8 - 1.1 $\mu\text{m}$				
	INFRAVERMELHO PRÓXIMO					
	(B8)	10.41-12.6 $\mu\text{m}$				
	INFRAVERMELHO TERMAL					

s.d. = sem dados/informações

### 2.2.1.1.2 *Thematic Mapper* (TM)

O sensor TM está presente nos satélites Landsat 4 e Landsat 5.

Tabela 3 - *Thematic Mapper* (TM). Fonte: (EMBRAPA, 2022)

<b>Sensor</b>	<b>Bandas Espectrais</b>	<b>Resolução Espectral</b>	<b>Resolução Espacial</b>	<b>Resolução Temporal</b>	<b>Área Imageada</b>	<b>Res. Radiométrica</b>
<i>TM</i> ( <i>Thematic Mapper</i> )	(B1) AZUL	0.45 - 0.52 $\mu\text{m}$	30 m	16 dias	185 km	8 bits
	(B2) VERDE	0.52 - 0.60 $\mu\text{m}$				
	(B3) VERMELHO	0.63 - 0.69 $\mu\text{m}$				
	(B4)	0.76 - 0.90 $\mu\text{m}$				
	INFRAVERMELHO PRÓXIMO					
	(B5)	1.55 - 1.75 $\mu\text{m}$				
	INFRAVERMELHO MÉDIO					
	(B6)	10.4 - 12.5 $\mu\text{m}$	120 m			
INFRAVERMELHO TERMAL						
(B7)	2.08 - 2.35 $\mu\text{m}$	30 m				
INFRAVERMELHO MÉDIO						

s.d. = sem dados/informações

### 2.2.1.1.3 *Enhanced Thematic Mapper Plus* (ETM+)

O sensor ETM+ está presente no satélite Landsat 7.

Tabela 4 - *Enhanced Thematic Mapper Plus* (ETM+). Fonte: (EMBRAPA, 2022)

<b>Sensor</b>	<b>Bandas Espectrais</b>	<b>Resolução Espectral</b>	<b>Resolução Espacial</b>	<b>Resolução Temporal</b>	<b>Área Imageada</b>	<b>Res. Radiométrica</b>	
<i>ETM+ (Enhanced Thematic Mapper Plus)</i>	(B1) AZUL	0.45-0.515 $\mu\text{m}$	30 m	16 dias	183 km	8 bits	
	(B2) VERDE	0.525-0.605 $\mu\text{m}$					
	(B3) VERMELHO	0.63 - 069 $\mu\text{m}$					
		(B4)	0.76 - 0.90 $\mu\text{m}$				
		INFRAVERMELHO PRÓXIMO					
		(B5)	1.55 - 1.75 $\mu\text{m}$				
		INFRAVERMELHO MÉDIO					
		(B6)	10.4 - 12.5 $\mu\text{m}$	60 m			
		INFRAVERMELHO TERMAL					
	(B7)	2.09 - 2.35 $\mu\text{m}$	30 m				
	INFRAVERMELHO MÉDIO						
	(B8)	0.52 - 0.90 $\mu\text{m}$	15 m				
	PANCROMÁTICO						

s.d. = sem dados/informações

#### 2.2.1.1.4 Operational Land Imager (OLI)

O sensor OLI está presente no satélite Landsat 8.

Tabela 5 - *Operational Land Imager* (OLI). Fonte: (EMBRAPA, 2022)

<b>Sensor</b>	<b>Bandas Espectrais</b>	<b>Resolução Espectral</b>	<b>Resolução Espacial</b>	<b>Resolução Temporal</b>	<b>Área Imageada</b>	<b>Res. Radiométrica</b>	
<i>OLI (Operational Land Imager)</i>	(B1) COSTAL	0.433 - 0.453 $\mu\text{m}$	30 m	16 dias	185 km	12 bits	
	(B2) AZUL	0.450 - 0.515 $\mu\text{m}$					
	(B3) VERDE	0.525 - 0.600 $\mu\text{m}$					
		(B4) VERMELHO	0.630 - 0.680 $\mu\text{m}$				
		(B5)	0.845 - 0.885 $\mu\text{m}$				
		INFRAVERMELHO PRÓXIMO					
		(B6)	1.560 - 1.660 $\mu\text{m}$				
		INFRAVERMELHO MÉDIO					
		(B7)	2.100 - 2.300 $\mu\text{m}$				
	INFRAVERMELHO MÉDIO						
	(B8)	0.500 - 0.680 $\mu\text{m}$	15 m				
	PANCROMÁTICO						
	(B9) Cirrus	1.360 - 1.390 $\mu\text{m}$	30 m				

s.d. = sem dados/informações

O sensor OLI possui técnicas de calibração melhoradas, resultando em uma coleta de dados mais eficiente do que seus predecessores (NASA, 2013). O Satélite Landsat 8 opera com uma resolução radiométrica de 12 bits, permitindo uma

discriminação mais fina dos valores de reflectância. Isso contribui para uma melhor classificação de cobertura terrestre e detecção de mudanças (NASA, 2013).

#### 2.2.1.1.5 Thermal Infrared Sensor (TIRS)

O sensor TIRS está presente no satélite Landsat 8.

Tabela 6 - Thermal Infrared Sensor (TIRS). (EMBRAPA, 2022)

<b>Sensor</b>	<b>Bandas Espectrais</b>	<b>Resolução Espectral</b>	<b>Resolução Espacial</b>	<b>Resolução Temporal</b>	<b>Resolução Radiométrica</b>	<b>Área Imageada</b>
TIRS (Thermal Infrared Sensor)	(B10) LWIR - 1	10.30 - 11.30 $\mu\text{m}$	100 m	16 dias	12 bits	185 km
	(B11) LWIR - 2	11.50 - 12.50 $\mu\text{m}$				

s.d. = sem dados/informações

#### 2.2.1.2 Missão Sentinel (SENTINEL)

A série de satélites Sentinel começou a ser lançada em 2014 e foi desenvolvida a partir de um projeto da Agência Espacial Europeia (ESA)/Comissão Europeia em atendimento ao Programa Copernicus (EMBRAPA, 2021).

Abaixo no Quadro 2 estão detalhados os períodos de lançamento e de operação dos satélites da família Sentinel.

Quadro 2 - Anos de lançamento e operação dos satélites Sentinel. Fonte: (EMBRAPA, 2021)

Satélite	2010										2020									
	0	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9
SENTINEL-1A					■	■	■	■	■	■										
SENTINEL-1B						■	■	■	■	■										
SENTINEL-2A						■	■	■	■	■										
SENTINEL-2B							■	■	■	■										
SENTINEL-3A							■	■	■	■										
SENTINEL-3B								■	■	■										
SENTINEL-5P								■	■	■										

■ Lançamento/Operação  
■ Operação  
■ Operação/Término  
■ Falha no Lançamento

Abaixo se encontram os sensores presentes nos satélites da série Sentinel.

#### 2.2.1.2.1 *Synthetic Aperture Sattelite (SAR)*

O sensor SAR está presente nos satélites Sentinel-1A, Sentinel-1B, Sentinel-2A, Sentinel-2B.

De acordo com a EMBRAPA, (2021):

O sensor SAR está a bordo dos quatro primeiros satélites da série Sentinel. Os radares têm capacidade de obter imagens tanto diurnas quanto noturnas, já que a frequência da que emite (entre 8 a 4 GHz ou 3,8 – 7,5 cm – Banda C) é baixa e não é barrada pela atmosfera terrestre. O radar tem suporte para polarização de HH+HV, VV+VH e HH com uma resolução espacial de 5 metros e resolução radiométrica de 10 bits. (EMBRAPA, 2022)

#### 2.2.1.2.2 *Multispectral Imager (MSI)*

O sensor MSI está presente nos satélites Sentinel-2A e Sentinel-2B.

De acordo com a EMBRAPA, (2021):

O sensor MSI foi lançado a bordo dos satélites Sentinel-2A e Sentinel-2B. Foi desenhado para operar no modo “Push-broom” e ter alta resolução espacial (10m) com 12 bandas espectrais (variando de 442 nm até 2.202 nm). (EMBRAPA, 2022)

#### 2.2.1.2.3 *Ocean and Land Color Instrument (OLCI)*

O sensor OLCI está presente nos satélites Sentinel-3A e Sentinel-3B.

De acordo com a EMBRAPA, (2021):

O sensor OLCI é um espectrorradiômetro que mede a radiação solar refletida pela Terra com resolução espacial de 300m em 21 bandas espectrais (opera entre 400 nm até 1.040nm). Seu objetivo é monitorar o uso e ocupação das

terras e as áreas oceânicas, além de coletar informações sobre a atmosfera terrestre. (EMBRAPA, 2022)

#### 2.2.1.2.4 *Sea and Land Surface Temperature Radiometer (SLSTR)*

O sensor SLSTR está presente nos satélites Sentinel-3A e Sentinel-3B.

De acordo com a EMBRAPA, (2021):

O sensor SLSTR, a bordo do satélite Sentinel-3A e Sentinel-3B, mede a temperatura da superfície terrestre, seja massas d'água, seja a parte continental, para fornecer informações sobre clima e temperatura para aplicações meteorológicas. Possui resolução de 500m para as bandas do visível e da região do Infravermelho (variando de 554 nm até 2.255 nm); para a região do termal (que vai de 3.742 nm até 10.854 nm), oferece imagens com 1 km de resolução espacial. (EMBRAPA, 2021)

### 2.2.2 Operações Aritméticas

Através da visualização de uma imagem não somente como um todo, mas sim como um conjunto de valores ordenados em grade, é possível realizar operações aritméticas com esses números, possibilitando assim, uma manipulação da imagem de maneiras inéditas, a fim de trazer à tona informações previamente “ocultas”. Segundo (CRÓSTA, 1992):

Várias operações matemáticas simples são usadas em processamento digital de imagens de S.R., no sentido de analisar imagens multi-espectrais (diferentes bandas espectrais de uma mesma cena) e/ou multi-temporais (bandas individuais adquiridas sobre uma mesma área em diferentes datas). (CRÓSTA, 1992)

As operações aritméticas são realizadas em cada um dos pixels da imagem, variando os níveis de cinza deles. As quatro comumente usadas são a adição, subtração, multiplicação e divisão.

### 2.2.2.1 Adição

A adição consiste na soma dos níveis de cinza de duas imagens. Como o intervalo do nível de cinza é de 0 a 255, o resultado da soma é dividido por dois, gerando assim uma média entre os dois pixels. Essa operação é útil para reduzir as irregularidades ou ruídos do pixel de uma das imagens, já que a média resultante do pixel se aproxima do valor ideal sem ruído.

$$Pixel_{resultante} = \frac{Pixel_a + Pixel_b}{2}$$

Equação 1 - Adição de *Pixels*. (ZANOTTA; ET AL., 2019)

Onde:

$Pixel_{resultante}$  = *Pixel* resultante;

$Pixel_a$  = *Pixel* da imagem A;

$Pixel_b$  = *Pixel* da imagem B.

### 2.2.2.2 Subtração

A subtração por outro lado, é comumente utilizada para ressaltar diferenças entre as imagens. Ao subtrair os pixels, é possível verificar a diferença de energia refletida ou emitida no local ao longo de um intervalo de tempo, possibilitando a identificação de anomalias, ou desvios do padrão, em uma dada localidade. Para evitar pixels com o valor negativo, é adicionado 255 no resultado da subtração.

$$Pixel_{resultante} = \frac{(Pixel_a - Pixel_b) + 255}{2}$$

Equação 2 - Subtração de *Pixels*. (ZANOTTA; ET AL., 2019)

Onde:

$Pixel_{resultante}$  = *Pixel* resultante;

$Pixel_a$  = *Pixel* da imagem A;

$Pixel_b = Pixel$  da imagem B.

### 2.2.2.3 Multiplicação

Esta operação não é amplamente utilizada devido a sua alta distorção dos valores dos pixels das imagens. Como o valor de um pixel varia entre 0 e 255, esta multiplicação ultrapassa os limites da renderização da imagem. Para corrigir esse desvio, é necessário dividir o resultado por 255. A multiplicação, na prática, é utilizada para mascarar nuvens em imagens de satélite. Segundo Zanotta et al. (2019) uma máscara é uma imagem binária em que os pixels com valor zero são eliminados na imagem resultante da multiplicação.

$$Pixel_{resultante} = \frac{Pixel_a \times Pixel_b}{255}$$

Equação 3 - Multiplicação de Pixels. (ZANOTTA; ET AL., 2019)

Onde:

$Pixel_{resultante} = Pixel$  resultante;

$Pixel_a = Pixel$  da imagem A;

$Pixel_b = Pixel$  da imagem B.

### 2.2.2.4 Divisão

A divisão dos níveis de cinza, também conhecido como razão de bandas, é uma das operações mais utilizadas no SR e é comumente realizada através de imagens com bandas distintas. Segundo Crósta (1992):

A divisão serve para realçar intensamente as diferenças espectrais de um par de bandas, sendo que os extremos branco e preto da distribuição de níveis de cinza representam as maiores diferenças em reflectância entre as duas bandas consideradas. (ZANOTTA; ZORTEA; FERREIRA, 2019)

A operação de divisão é comumente usada para destacar variações espectrais e características em aplicações geológicas, agrícolas e ambientais através de vários índices espectrais criados com diferentes propósitos.

### **2.2.3 Comportamento espectral da vegetação e índices espectrais**

Assim como diversos tipos de materiais visíveis da superfície da terra, a vegetação possui suas próprias características relativas à reflectância e absorção da radiação. A folha é uma parte vital de qualquer tipo de vegetação, um órgão que possui diversos tecidos, cada um com suas particularidades. Dentro dela ocorrem os fenômenos da interação com a radiação eletromagnética: a reflexão, transmissão e absorção (ZANOTTA et al., 2019).

No âmbito do SR, a categorização das ondas eletromagnéticas, com base em seus comprimentos de onda no espectro, é de suma importância para o processamento de imagens, já que permitem explorar as características espectrais dos diferentes alvos da paisagem. Entre as técnicas, destacam-se as operações aritméticas, a partir das quais é possível obter índices espectrais.

#### **2.2.3.1. Índices Espectrais**

Índices de vegetação (IV) são operações aritméticas realizadas entre bandas de uma imagem. Esses índices buscam explorar o comportamento espectral da vegetação para realçar determinadas características das plantas (ZANOTTA et al., 2019).

Um dos índices comumente usados é chamado de razão simples (*simple ratio* - RS) (ZANOTTA et al., 2019). Este índice é o valor da razão entre o valor de reflectância da região espectral do infravermelho próximo (*Near Infrared* – NIR) e o valor de reflectância da região espectral do vermelho visível (RED), conforme a Equação 4:



$$SR = \frac{NIR}{RED}$$

Equação 4 – Cálculo do SR. (ZANOTTA; ZORTEA; FERREIRA, 2019)

Onde:

RS = Razão simples;

NIR = Região do infravermelho próximo;

RED = Região do vermelho visível.

Um exemplo de índice espectral é o *Índice de Vegetação da Diferença Normalizada (Normalized Difference Vegetation Index - NDVI)*, aplicado pela equação proposta por Rouse, Haas e Deering (1973). É um dos índices espectrais mais utilizados, já que se demonstra fortemente correlacionado com a densidade e vigor da vegetação, sendo uma medida essencial para compreender seu comportamento (ZANOTTA et al., 2019).

O NDVI explora a diferença entre a refletância do infravermelho próximo e vermelho, oferecendo valiosas informações sobre o desenvolvimento vegetal (SILVA; DE ALMEIDA; LEITE, 2020). O NDVI é calculado pela diferença e pela soma das intensidades de luz refletidas nas bandas do vermelho e do infravermelho próximo em cada pixel, conforme a fórmula:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Equação 5 - Cálculo do NDVI. (ZANOTTA et al., 2019)

Onde:

NDVI = *Normalized Difference Vegetation Index*;

NIR = *Near Infra-red* (Região espectral do infravermelho);

RED = Região espectral do vermelho.

A vegetação é um dos objetos passíveis de análise a partir da utilização desse cálculo, visto que a clorofila possui alta absorção na faixa do vermelho e alta reflectância na faixa do infravermelho próximo (CRÓSTA, 1992).

O NDVI foi utilizado para mensurar o estoque de carbono em florestas urbanas através de uma análise temporal feita por Myeoung, Nowak e Duggin (2006). A pesquisa utilizou técnicas de PDI para criar imagens da cidade de Syracuse, no estado de Nova Iorque, nos Estados Unidos da América. Os resultados dos estudos demonstram que a normalização das imagens temporais da vegetação urbana produziu bons resultados (MYEONG; NOWAK; DUGGIN, 2006), e que a análise temporal através de imagens históricas às vezes se prova a única maneira de estimar o EC histórico de um local, dada a falta de medições históricas em campo de árvores urbanas (MYEONG; NOWAK; DUGGIN, 2006).

Outro índice proposto por Huete et al. (2002) é o Índice de Vegetação Aprimorado (*Enhanced Vegetation Index – EVI*). Esse índice foi desenvolvido para ser utilizado com produtos do sensor Modis, e inclui a banda do azul (BLUE), além das utilizadas no NDVI.

$$EVI = 2,5 \times \frac{NIR - RED}{NIR + 6 \times RED - 7,5 \times BLUE + 1}$$

Equação 6 - Cálculo do EVI.

Onde:

EVI = *Enhanced Vegetation Index*;

NIR = *Near Infra-red* (Região espectral do infravermelho);

RED = Região espectral do vermelho;

BLUE = Região espectral do azul.

Segundo Zanotta et al. (2019) “o EVI provou ser mais sensível a mudanças estruturais no dossel (diferenças no IAF) e menos suscetível à saturação em condições de elevada biomassa”.

O NDVI possui algumas derivações, e um exemplo delas é o Índice de Vegetação Ajustado ao Solo (*Soil-Adjusted Vegetation Index – SAVI*). Este IV foi proposto por Huete (1988). Ele “[...] busca minimizar a contribuição do solo e, assim, destacar a resposta de vegetação” (ZANOTTA et al., 2019). Abaixo se encontra o cálculo proposto por Huete, (1988), onde é adicionada a constante L à equação do NDVI:

$$SAVI = \frac{(NIR - RED) \times (1 + L)}{(NIR + RED + L)}$$

Equação 7 - Cálculo do SAVI.

Onde:

SAVI = *Soil-adjusted vegetation index*;

NIR = *Near Infra-red* (Região espectral do infravermelho);

RED = Região espectral do vermelho;

A constante L adicionada tem como objetivo “[...] minimizar as influências do solo nos dados espectrais e permitir uma melhor caracterização da resposta espectral da vegetação, principalmente em condições de baixo IAF.” (ZANOTTA et al., 2019). Segundo Huete, (1988), o valor da constante L deve ser inversamente proporcional ao do IAF. Para dosséis com baixo IAF (entre 0 e 0,5), recomenda-se o valor de L = 1, e para áreas onde a influência do solo é nula, considera-se L = 0, onde o SAVI se torna idêntico ao NDVI (ZANOTTA et al., 2019).

## 2.3 REVISÃO SISTEMÁTICA

Autores proeminentes, como Moher et al. (2009) trataram sobre o método de Itens de Relato Preferenciais para Revisões Sistemáticas e Meta-Análises (Preferred Reporting Items for Systematic Reviews and Meta-Analyses — PRISMA), amplamente utilizado nesse tipo de revisão. O PRISMA é uma recomendação embasada em evidências para relatar revisões sistemáticas e meta-análises, que têm como objetivo

sintetizar os resultados de pesquisas relevantes sobre questões clínicas ou científicas (MOHER et al., 2009).

O propósito essencial do PRISMA é aprimorar a qualidade e transparência dos relatórios, facilitando a avaliação crítica e a reprodução dos estudos pelos leitores (MOHER et al., 2009). Embora sua ênfase esteja nas revisões que avaliam ensaios clínicos randomizados, ele pode ser adaptado para outros tipos de pesquisas, especialmente as relacionadas a intervenções (MOHER et al., 2009).

O PRISMA é composto por uma lista de verificação com 27 itens e um fluxograma com quatro fases, que devem ser rigorosamente seguidos pelos autores ao elaborar o artigo de revisão sistemática ou meta-análise (MOHER et al., 2009). A lista de verificação abrange os principais aspectos do título, resumo, introdução, métodos, resultados, discussão e financiamento do estudo, oferecendo uma orientação clara sobre o que deve ser relatado em cada seção (MOHER et al., 2009). O fluxograma, por sua vez, apresenta o número de registros identificados, incluídos e excluídos em cada etapa da busca e seleção dos estudos, fornecendo explicações detalhadas dos motivos das exclusões (MOHER et al., 2009).

O método PRISMA foi utilizado em diversos estudos de revisão sistemática, como pesquisa de transmissão doméstica do SARS-CoV-2 (MADEWELL et al., 2020), estudo sobre religião e espiritualidade em estudantes universitários (DUCHE-PÉREZ et al., 2024), sobre determinantes genéticos nas preferências alimentares (HEJAZI et al., 2024), e muitos outros.

Além disso, para complementar a análise bibliográfica, a revisão teórica também contará com a utilização de mapas bibliométricos. Essas representações visuais das relações entre conceitos, autores, periódicos ou outras entidades bibliográficas permitirão uma análise quantitativa do conhecimento científico e da estrutura da área ou disciplina estudada. Esses 'mapas do panorama científico' são principalmente derivados da análise de dados quantitativos baseados na literatura (bibliométricos) e são empregados principalmente para exibir estruturas de conhecimento ('cognitivas') em áreas científicas (TIJSSEN, 1993).

O *VOSviewer* (JAN VAN ECK; WALTMAN, 2023) é uma ferramenta gratuita para construção e visualização de redes bibliométricas, que podem mostrar as

relações entre periódicos, pesquisadores, publicações ou termos extraídos de um conjunto de dados. O software permite analisar diferentes tipos de redes, como coautoria, coocorrência, citação, acoplamento bibliográfico e cocitação, usando diferentes métodos de peso e pontuação. O software aceita dados de várias fontes, como *Web of Science*, *Scopus*, *PubMed* e arquivos de texto.

O *VOSviewer* foi utilizado em pesquisas bibliométricas na área de conhecimento do SR, como em revisões sobre avanços em crescimento de precisão de cafés (SANTANA et al., 2021), sobre o uso de SR em análise de fogo em formações campestres (HERRMANN; NASCIMENTO; DE FREITAS, 2022), sobre fontes de dados e ferramentas para análise e detecção de mudanças na linha da costa (ANKRAH; MONTEIRO; MADUREIRA, 2022) e sobre o uso de drones para monitoramento de enchentes (IQBAL et al., 2023).

### 3 METODOLOGIA

A condução da pesquisa para o TCC adotou uma abordagem estruturada, detalhada no fluxograma da Figura 2 e no passo-a-passo em sequência:

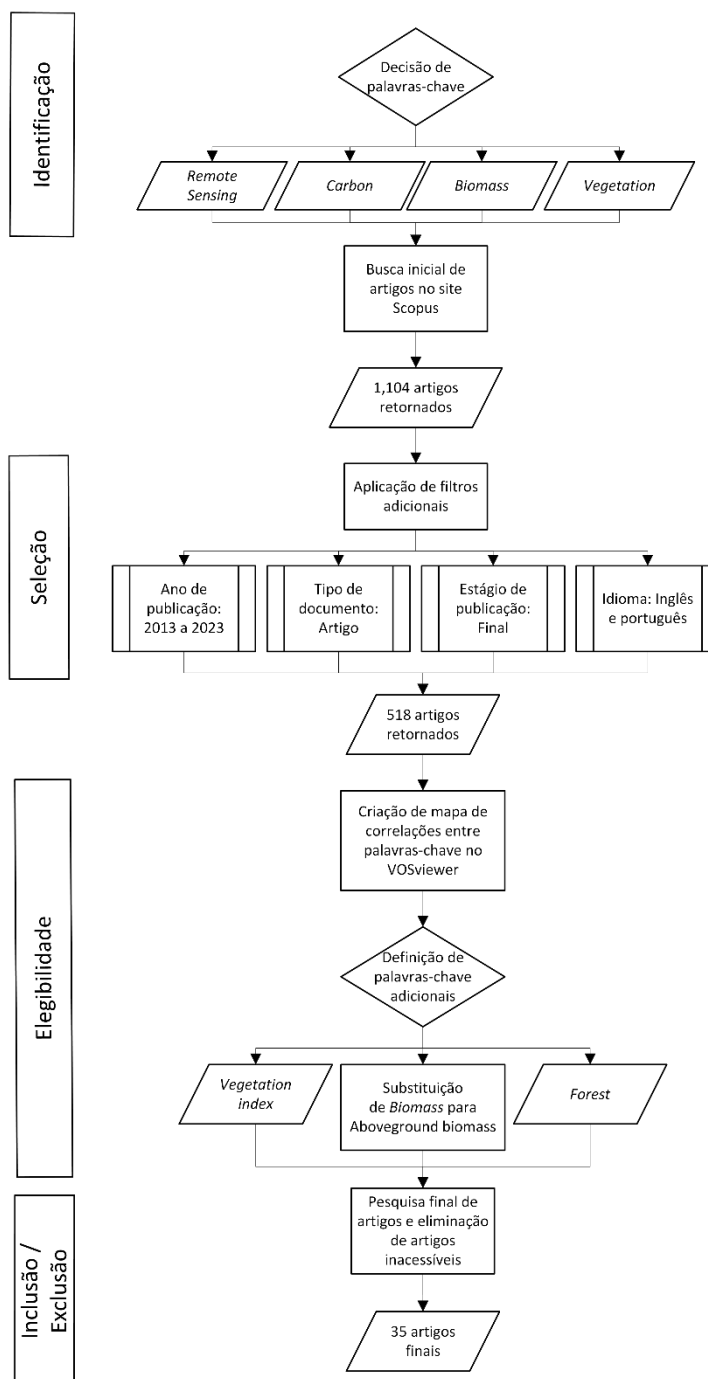


Figura 2 - Fluxograma da metodologia. Fonte: Autor.

Primeiramente, a busca por artigos pertinentes ao tema foi realizada no site Scopus. A confirmação e login na plataforma foram realizados utilizando as credenciais institucionais da UFRGS.

Na etapa de identificação da pesquisa compreendeu escolha de quatro palavras-chave fundamentais: *Remote Sensing*, *Carbon*, *Biomass* e *Vegetation*. Cada uma dessas palavras-chave desempenhou um papel crucial na definição e delimitação do escopo da pesquisa, contribuindo para uma abordagem abrangente e específica ao mesmo tempo.

A palavra-chave "*Remote Sensing*" foi eleita como o ponto central da busca, representando o núcleo temático da pesquisa. Essa escolha refletiu o foco primordial na utilização de tecnologias de sensoriamento remoto para compreender dinâmicas da biomassa e estimar sequestro e emissões de carbono para subsidiar cálculos de créditos de carbono, constituindo o eixo principal da investigação.

O termo "*Carbon*" desempenhou um papel significativo ao delimitar as relações específicas entre o sensoriamento remoto e o elemento central da pesquisa, o carbono. Esta escolha permitiu uma análise mais precisa das interações entre as informações obtidas por sensoriamento remoto e a presença de carbono nas áreas de estudo, destacando a importância dessa variável nas avaliações ambientais.

A escolha do termo "*Vegetation*" foi decisiva para a delimitação do escopo da pesquisa a áreas de cobertura vegetal. Essa palavra-chave foi escolhida como um filtro inicial, visando concentrar a análise no uso de sensoriamento remoto em ambientes com vegetação predominante. Isso possibilitou excluir outras fontes de sequestro de carbono, como a vegetação marinha, focando exclusivamente em ambientes terrestres.

A palavra-chave "*Biomass*" foi selecionada estrategicamente para abordar a dimensão quantitativa da vegetação. A escolha dessa palavra-chave visou compreender como a biomassa, em suas diferentes formas e distribuições, influencia as estimativas de crédito de carbono.

Dessa maneira, cada palavra-chave foi estrategicamente escolhida para agregar valor à pesquisa, fornecendo uma base sólida para a posterior análise e





A análise da nuvem de palavras resultou em ajustes na busca de textos acadêmicos. Houve a substituição do termo "*Biomass*" por "*Aboveground Biomass*" para especificar a biomassa acima do solo. Adicionalmente, os termos "*Vegetation Index*" e "*Forest*" foram incorporados para refinar a pesquisa, especificando o tipo de índice utilizado na estimativa de sequestro de carbono e limitando a pesquisa a áreas florestais, respectivamente.

A fase final de inclusão/exclusão, com os ajustes mencionados, resultou em 41 artigos considerados relevantes. Destes 41 artigos, 6 não estavam disponíveis para consulta pelo acesso institucional e, portanto, foram descartados da pesquisa. Os dados dos 35 artigos restantes foram então importados no *VOSviewer* para criar mapas de relações.

Posteriormente, ocorreu uma leitura dos 35 artigos para a análise final de suas metodologias. Com base em suas metodologias, foi organizado um quadro comparativo com informações, sendo elas: A área de estudo, as regiões espectrais utilizadas, os sensores utilizados, e os índices vegetais utilizados. Esta tabela base permitiu derivar outras informações importantes sobre a metodologia, como o mapa das áreas de estudo e a quantidade de índices utilizados.

## 4 RESULTADOS E DISCUSSÃO

Os trinta e cinco artigos resultantes foram agrupados e analisados para se obter medições e inferências quantitativas sobre eles. Acerca dos textos resultantes da pesquisa na base de dados Scopus, vale ressaltar algumas informações. Devido às limitações na pesquisa, todos os textos retornados pela busca são do tipo artigo em periódico científico indexado, no estágio final de publicação, e foram publicados entre o período definido de busca de dez anos (entre 2013 e 2023). Dentre as linguagens de artigos delimitadas pela pesquisa na base de dados (inglês e português), somente foram encontrados resultados de artigos escritos na língua inglesa.

Por meio dos metadados dos artigos, foram realizadas análises acerca dos países de origem dos artigos, de suas áreas de conhecimento e da evolução temporal das publicações, ao longo de dez anos (2013-2023). E através da leitura e análise de suas metodologias, foi elaborado um quadro comparativo com informações específicas, sendo elas: Área de estudo, regiões espectrais, sensores utilizados e índices vegetais. O quadro comparativo está localizado no ANEXO A.

Tanto na análise dos metadados, quanto na análise das metodologias, percebe-se uma ausência do Brasil como produtor de artigos e como área de estudo — Com exceção do artigo de Wang et al. (2023b). É possível que no processo de filtragem da pesquisa final de textos acadêmicos, artigos brasileiros tenham sido excluídos, o que não indica necessariamente uma ausência do Brasil no uso de ferramentas de SR para estimativa de SC e cálculo de biomassa vegetal, mas sim que a especificação de algumas características do tema, como índices de vegetação e florestas, não estão presentes nos textos brasileiros. Uma pesquisa posterior em repositórios de dados acadêmicos brasileiros pode trazer um panorama mais detalhado sobre o estado do estudo do tema no Brasil.

### 4.1 PRODUÇÃO DE ARTIGOS POR PAÍSES

A análise dos dados revela que a China se destacou como líder na produção de artigos relacionados ao tema, contribuindo de maneira significativa com um total de 15 publicações, conforme evidenciado na Tabela 7 e na Figura 4. Paralelamente, Índia e Estados Unidos apresentaram desempenhos comparáveis, ambos contribuindo com 8 artigos cada.

Tabela 7 – Artigos por país. Fonte: Autor.

<b>Nome</b>	<b>Artigos</b>
<i>China</i>	15
<i>Índia</i>	8
<i>Estados Unidos</i>	8
<i>Alemanha</i>	4
<i>Paquistão</i>	3
<i>Colômbia</i>	2
<i>França</i>	2
<i>Indonésia</i>	2
<i>África do Sul</i>	2
<i>Reino Unido</i>	2
<i>Austrália</i>	1
<i>Camarões</i>	1
<i>Canadá</i>	1
<i>República Tcheca</i>	1
<i>Dinamarca</i>	1
<i>Equador</i>	1
<i>Finlândia</i>	1
<i>Malásia</i>	1
<i>Moçambique</i>	1
<i>Nigéria</i>	1
<i>Portugal</i>	1
<i>Rússia</i>	1
<i>Coréia do Sul</i>	1
<i>Suíça</i>	1
<i>Tailândia</i>	1
<i>Vietnã</i>	1
<i>Zimbabwe</i>	1
<i>Total</i>	65




Figura 4 – Número de artigos publicados por país. Fonte: Autor.

Visualizando o mapa da Figura 5, percebe-se que a distribuição internacional do interesse na temática é evidenciada pela participação de diversos países. Alemanha, Paquistão, Colômbia, França, Indonésia, África do Sul e Reino Unido, entre outros, também contribuíram com múltiplos artigos.

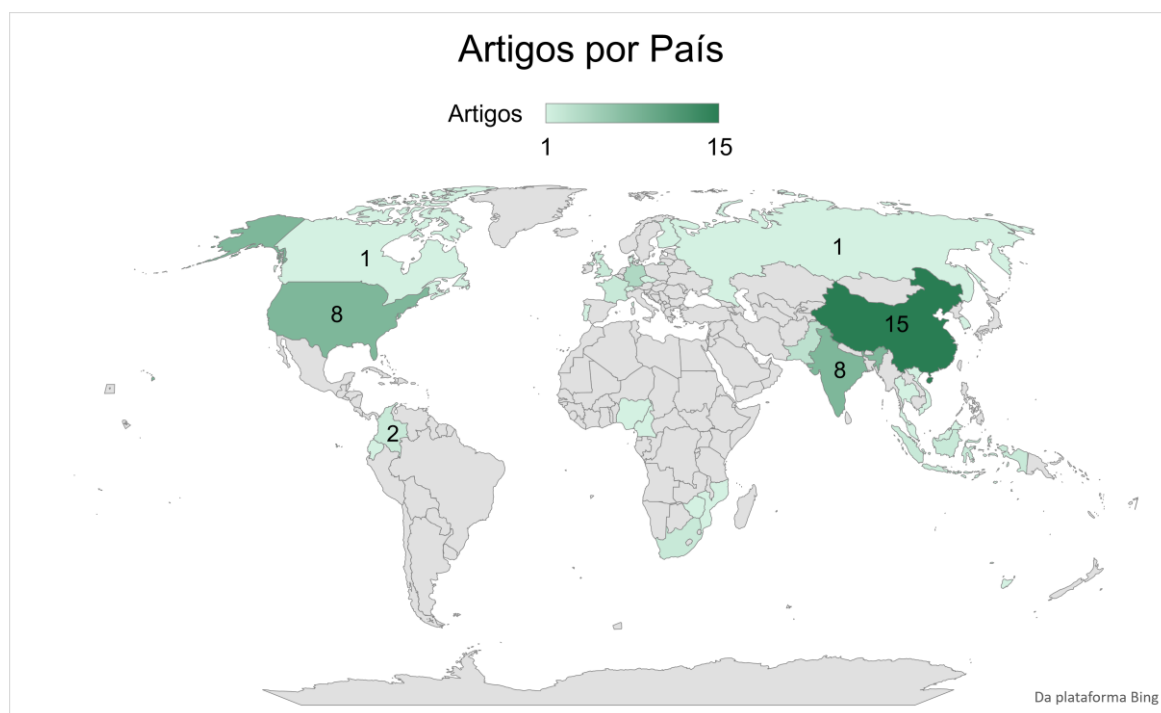


Figura 5 - Mapa de número de artigos por país. Fonte: Autor.

## 4.2 ÁREAS DE CONHECIMENTO

Através da Figura 6, é possível realizar a análise por áreas de conhecimento. Ela revela que a pesquisa relacionada ao tema em questão demonstra uma concentração notável na área de Ciências Agrárias e Biológicas, com um total de 19 artigos representando 29% do total analisado. Além disso, Ciências Planetárias e da Terra e Ciência Ambiental emergem como áreas de contribuição expressiva, com 14 e 13 artigos, respectivamente, representando 22% e 20% do conjunto de publicações analisadas.

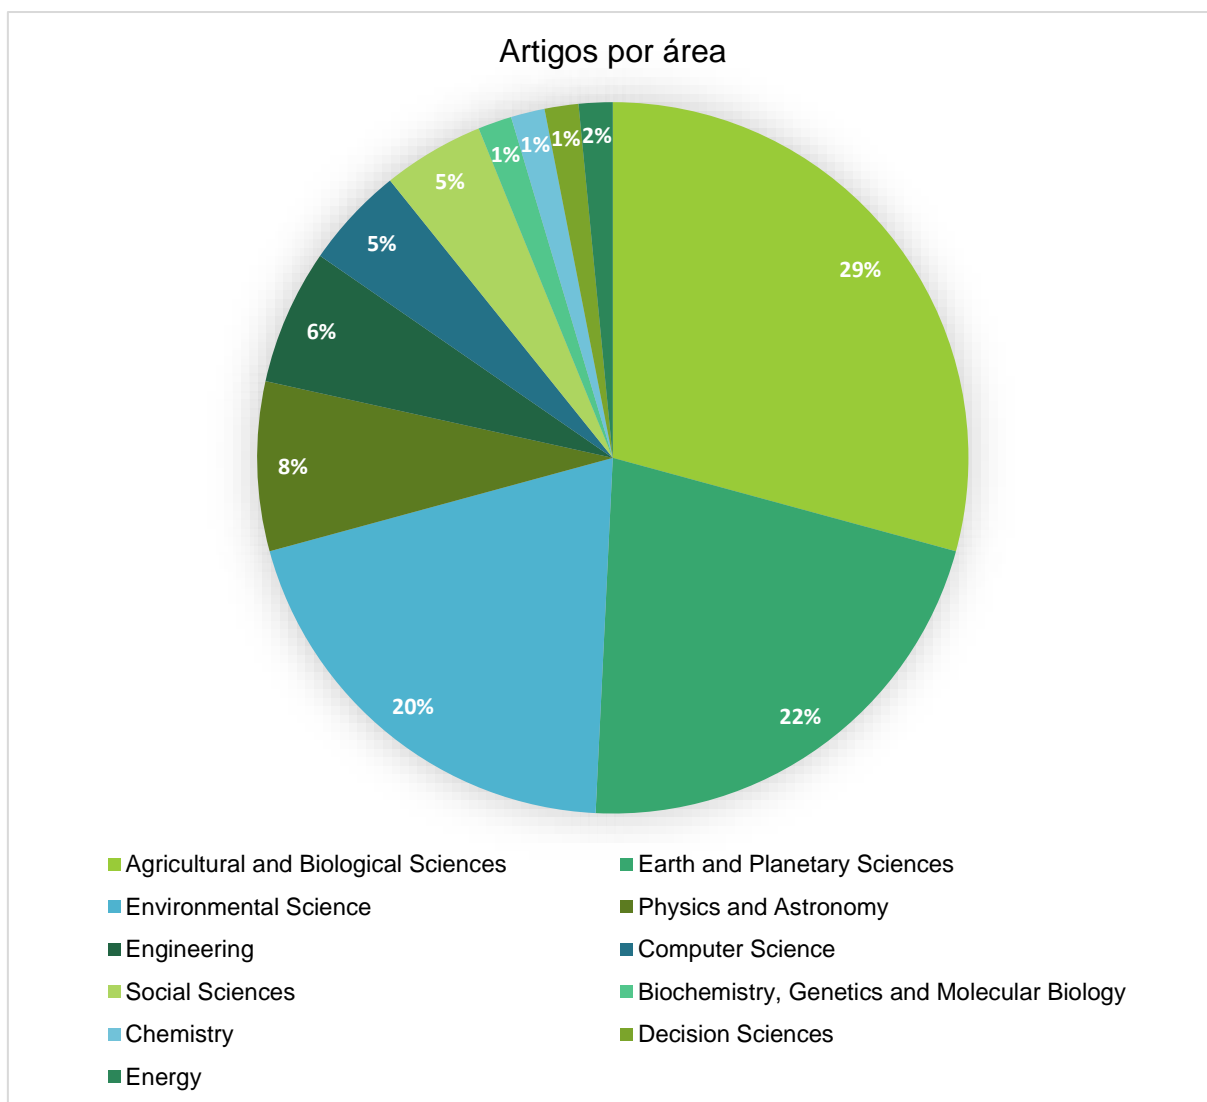


Figura 6 - Porcentagem de artigos por área de conhecimento. Fonte: Autor.

Paralelamente, a contribuição de disciplinas como Física e Astronomia, Engenharia, Ciências da Computação e Ciências Sociais destaca a abrangência e a interdisciplinaridade do tema analisado.

### 4.3 EVOLUÇÃO TEMPORAL

A análise temporal revela uma evolução significativa na produção de artigos sobre o tema entre os anos de 2013 e 2023, com uma média anual de 4 publicações.

Na Figura 7 se pode observar que nos primeiros anos, de 2013 a 2016 houve um aumento gradual no número de publicações, culminando em 2016, quando foram registrados 6 artigos.

O uso de SR para estimativa de EC é um tópico que ganha cada vez mais espaço no meio acadêmico. Percebe-se através da Figura 7 que houve um aumento progressivo no período de dez anos, entre 2013 e 2023. Em 2016 houve um aumento acentuado na produção de artigos desse tema, havendo após isso uma estabilização até o aumento vertiginoso em 2023 com onze artigos publicados nessa data. Esses dados indicam uma tendência de crescimento do tema, já que o SR traz ferramentas e escalas de dados diferentes das técnicas de mensuração de EC em campo.

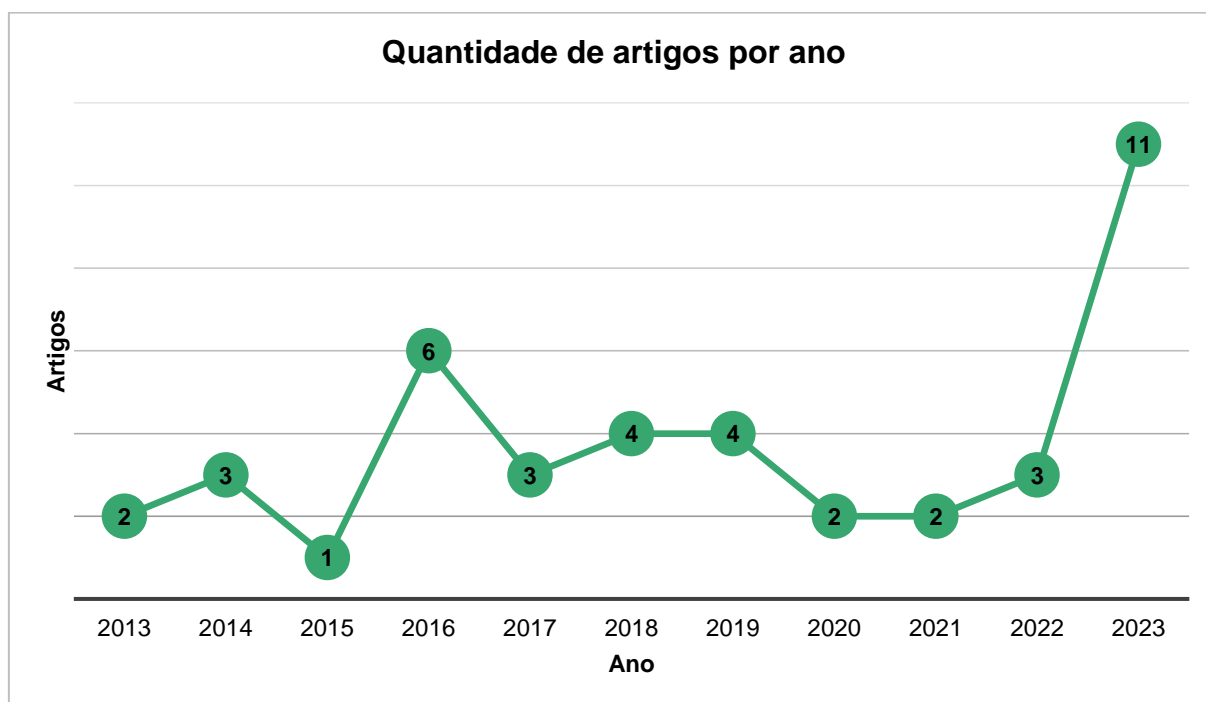


Figura 7 - Quantidade de artigos por ano. Fonte: Autor

No mapa de redes de países ao longo do tempo, é possível observar a atualidade de publicações por autores de um determinado país, bem como a relação entre autores de diferentes países. O mapa da Figura 8 representa países de origem de autores que participaram de publicações dos artigos selecionados, no período especificado.

O critério de seleção desta rede foi através de artigos que possuísem pelo menos dois autores de países distintos, a fim de demonstrar a relação de colaboração de países, e a atualidade dessas relações. O tamanho do nome de cada país representa a quantidade de autores que possuem publicações dentre os artigos selecionados, a espessura do link de relação indica publicações conjunta entre autores dos dois países, e as cores representam a atualidade de publicações de um país.

O mapa de redes da Figura 8 ilustra alguns países com autores de artigos recentes, como a Austrália, França, Malásia e Suíça, e alguns países com uma média de ano de publicação mais baixa, como China e Estados Unidos, além do Reino Unido, Colômbia e Equador. Nota-se, no entanto, que quase todos os países com publicações mais recentes compartilham coautoria com a China e os Estados Unidos.

Apesar de haver uma contribuição significativa de artigos desses dois países, percebe-se que a China possui uma quantidade maior de artigos recentes, se comparado com os Estados Unidos. Esta informação é corroborada pela Figura 5 e a Tabela 7, que exibem a China como o maior produtor de artigos sobre o tema, durante o período avaliado.

Vale ressaltar também, a ausência da Índia na Figura 8, apesar de possuir um número considerável de publicações, evidenciado pela Figura 5 e pela Tabela 7. Essa ausência é um indicativo de que autores indianos realizaram publicações, porém elas não possuem colaborações com países estrangeiros.



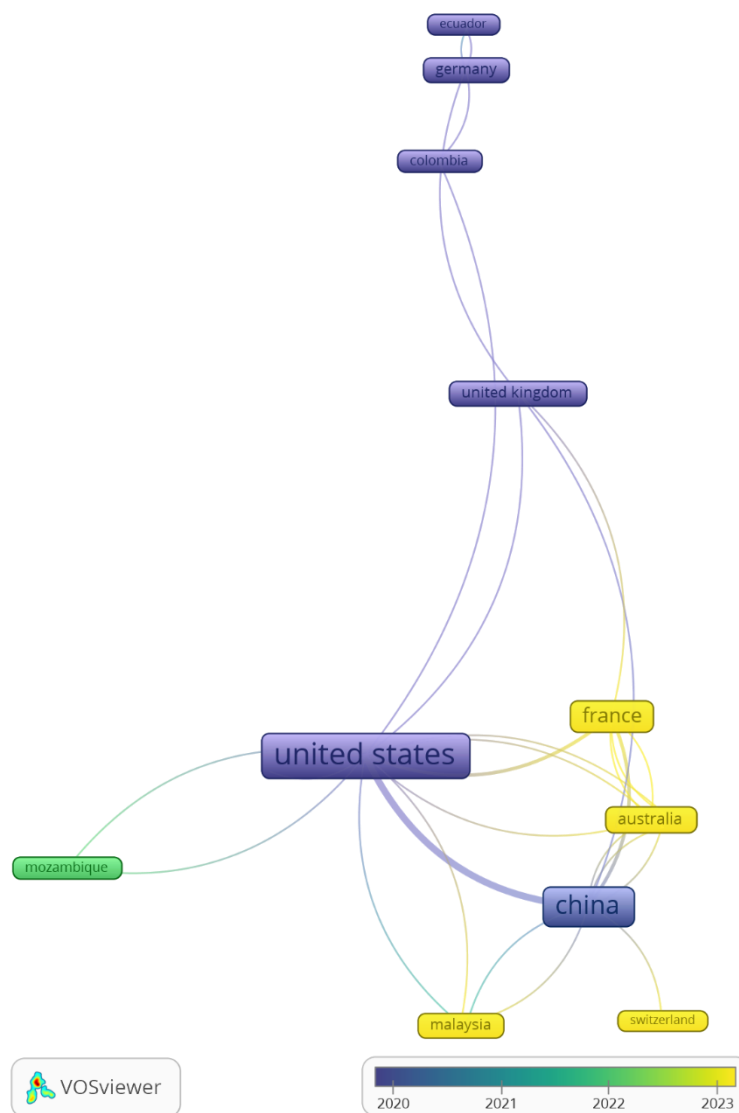


Figura 8 - Mapa de redes de países ao longo dos anos. Fonte: Autor.

#### 4.4 UTILIZAÇÃO DE SENSORIAMENTO REMOTO NOS ARTIGOS

O SC é um tema que gera debate tanto no âmbito público quanto no privado. É de interesse público, pois aumentar o EC é uma das medidas para se reduzir o aquecimento global, descrito no Acordo de Paris (MCTIC; SEPED; CGCL, 2021). O tema é também de interesse privado, pois através do mercado cada vez maior de CC, a captura e armazenamento de carbono em florestas e vegetação, se torna não só uma medida de sustentabilidade, mas é também uma alternativa rentável para o setor.

É razoável, portanto, afirmar que a busca por diferentes técnicas de mensuração dessa captura de CO<sub>2</sub> é um investimento que gera retorno primeiramente ambiental, e em segundo plano, financeiro.

O SR possibilita a estimativa de SC em grandes extensões territoriais e por um custo mais reduzido se comparado a estimativa de SC com métodos em campo, conforme observado no trabalho de Pechanec et al. (2017), no seu trabalho de estimativa de EC no território da República Tcheca utilizando dados Landsat.

O SR, no entanto, foi também muito utilizado em conjuntos com outras técnicas de mensuração de EC, podendo assim se obter um retrato mais preciso sobre o SC de uma dada área. O estudo de Sa e Fan (2023) utilizou além de dados do sensor Landsat-8 OLI e do Sentinel-2A, medições amostrais em campo de áreas de 0,06 ha, a fim de aumentar a precisão da estimativa de AGB.

Macave et al. (2022) em seu estudo conduzido no norte de Moçambique, selecionaram vinte e quatro áreas de um hectare para a medição e identificação de árvores com diâmetro ao nível do peito entre 5 cm e 83 cm, para estimativa de suas biomassas. Além das medições de campo, foram utilizados os sensores Landsat-8 OLI, Sentinel-2/MSI, dados da banda C do sensor Sentinel-1B e dados da banda L do sensor ALOS/PALSAR-2.

## 4.5 ÁREAS DE ESTUDO

Em textos acadêmicos em que se aplica técnicas de sensoriamento remoto e processamento de imagem, é imperativo que se tenha definida uma área de estudo onde tais procedimentos serão empregados. Fundamental nas pesquisas de sensoriamento remoto, ela geralmente contém em suas dimensões o objeto de estudo, de onde serão extraídas informações e análises cruciais para o tema abordado.

Nos artigos analisados, foi possível identificar suas áreas de estudo, uma parte fundamental de sua metodologia. Em sua grande maioria, os textos apresentavam

uma descrição geográfica extensa, com informações sobre sua localização, geomorfologia, clima e ecossistema.

Tanto na Tabela 8, quanto na Figura 9, é perceptível que a maioria dos estudos realizados no período de análise, se deram na China e Índia, ambos compondo cerca de 49% das áreas de estudo total. Estes números se relacionam com a informação de países com afiliação nos textos estudados, onde também se observa uma grande presença dos mesmos países, e indicam um envolvimento de instituições e/ou pesquisadores com a mesma nacionalidade das áreas estudadas.

Tabela 8 - Quantidade de áreas de estudo por país. Fonte: Autor.

<b>Países</b>	<b>Quantidade</b>
<i>China</i>	11
<i>Índia</i>	6
<i>Estados Unidos</i>	2
<i>Paquistão</i>	2
<i>Colômbia</i>	2
<i>Indonésia</i>	2
<i>Brasil</i>	1
<i>Equador</i>	1
<i>México</i>	1
<i>Camarões</i>	1
<i>Moçambique</i>	1
<i>Zimbabwe</i>	1
<i>África do sul</i>	1
<i>Tchéquia</i>	1
<i>Vietnã</i>	1
<i>Coréia do Sul</i>	1
<i>Total</i>	35

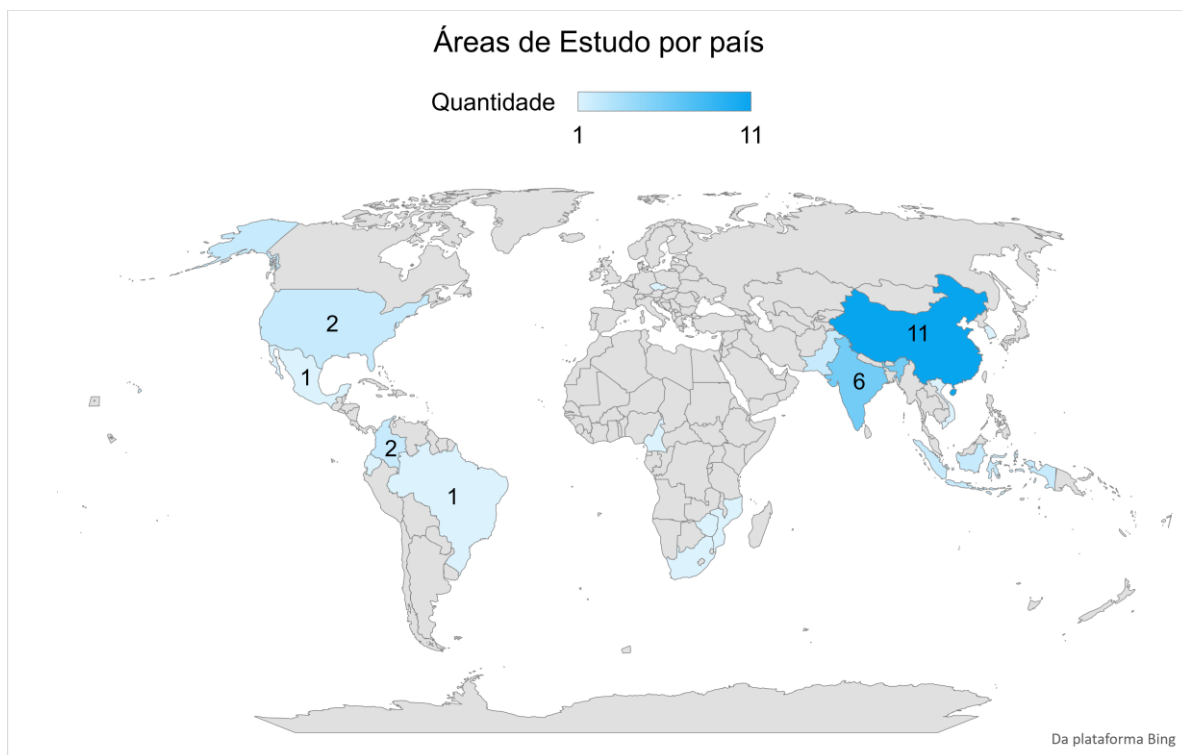


Figura 9 - Mapa de áreas de estudo por país. Fonte: Autor

Analisando os países autores de artigos e as áreas de estudo, é possível observar algumas informações valiosas sobre os estudos na área. Primeiramente, é importante salientar a importância dos países asiáticos na produção de conhecimento sobre uso de SR para estimativa de EC. A China e Índia são os países do maior número de autores e afiliações dos artigos analisados, além de possuírem a maior quantidade de áreas de estudo. Isso indica um grande investimento de produção de conhecimento por autores locais. Autores dos Estados Unidos também participaram do cenário de produção acadêmica, porém, percebe-se poucas áreas de estudo localizadas neste país, indicando uma forte contribuição estrangeira.

De fato, ao observar lado a lado a Tabela 8 e a Figura 9, percebe-se a contribuição estrangeira nas produções revisadas. Países como o Canadá, Alemanha, França e Rússia, possuem contribuições em estudos com áreas de análise diferentes. A contribuição nacional é um fator fundamental na produção de conhecimento científico, evidenciado por esses fatos.

## 4.6 REGIÕES ESPECTRAIS

Em pesquisas de sensoriamento remoto, as regiões espectrais (ou bandas), compõem uma importante fonte de dados para as análises e processamento necessário. Cada região espectral revela características específicas da área observada, e a combinação e manipulação de diferentes bandas é um importante processo para se obter informações da área.

No quadro comparativo (ANEXO A), as regiões espectrais utilizadas foram agrupadas pelos sensores utilizados, e na ausência da especificação de sensor, foram listadas conforme o texto. É importante ressaltar que nem todos os artigos explicitam quais bandas foram utilizados para a pesquisa, porém nesses casos é possível inferir as regiões espectrais através do uso dos índices vegetais apresentados no texto, já que as fórmulas deles explicitam a faixa espectral necessária para seu cálculo.

## 4.7 SENSORES

Para a execução da metodologia dos artigos analisados, foram utilizados vários sensores espectrais, e uso deles varia de acordo com o foco da pesquisa. Todos os textos possuíam uma descrição dos sensores utilizados, porém nem todos possuíam uma descrição detalhada dos sensores, trazendo as vezes uma descrição vaga, ou somente a fonte de dados originária das imagens utilizadas.

Dos trinta e cinco artigos analisados, foram contabilizados que vinte e quatro dos trinta e cinco artigos utilizaram sensores da série Landsat, oito do sensor Modis e oito da série de sensores Sentinel. Na Figura 10 estão listados todos os usos dos sensores da série Landsat nas pesquisas analisadas.




Figura 10 - Ocorrência de uso de sensores da série Landsat. Fonte: Autor

Percebe-se através da Figura 10, que uma grande parte dos artigos utilizou dados do sensor OLI a bordo do satélite Landsat-8 (40%). O satélite Landsat-8 teve o seu lançamento e início de operações em 2013 e celebrou uma década de funcionamento em 2023 (U.S. GEOLOGICAL SURVEY, 2023). Entre os diversos sensores da série Landsat, é compreensível a escolha de se utilizar um dos sensores mais recentes, principalmente para pesquisas em que uma análise histórica mais aprofundada não seja o foco principal. O sensor OLI a bordo do Landsat 8 possui aprimoramentos em relação aos antecessores (NASA, 2013).

A disponibilidade gratuita dos dados dos sensores, tanto da série Landsat, quanto da série Sentinel, aparentam ser um dos motivos que levaram a uma utilização elevada deles nos artigos analisados. Para Sa e Fan (2023) além da cobertura global e atualizações frequentes, a disponibilização gratuita torna os dados dos satélites Landsat 8 e Sentinel-2 valiosas fontes de dados para a monitoração permanente das dinâmicas do carbono na vegetação (SA; FAN, 2023). Este é também um dos motivos apresentados por Salazar Villegas et al. (2023), onde é descrito que os dados gratuitos da série Sentinel permitem estimativas de AGB a um custo reduzido (SALAZAR VILLEGAS et al., 2023).

## 4.8 ÍNDICES DE VEGETAÇÃO

Os IV's são operações entre diferentes faixas do espectro eletromagnético. Por meio delas, é possível obter informações específicas sobre diferentes objetos e materiais presentes na superfície terrestre. No quadro comparativo estão listados todos os índices vegetais utilizados nos artigos. Dentre os 35 artigos analisados, somente o artigo de Wang et al. (2023a) não utilizou IV's em sua pesquisa, e dentre os trinta e quatro restantes, sete artigos utilizaram somente um IV.

Abaixo, na Figura 11, se encontra a quantidade de IV's que foram utilizados nas pesquisas avaliadas, omitindo os IV com somente uma ocorrência.




Figura 11 - Número de ocorrências de índices de vegetação. Fonte: Autor.

Na Figura 11 é visível a grande utilização do NDVI no processamento de imagem, para se obter informações acerca a cobertura vegetal, já que dentre os trinta e artigos analisados, trinta utilizaram o NDVI em suas pesquisas, sozinhos ou em conjunto com outros índices. Além do NDVI, os índices EVI e SAVI também foram muito utilizados, com treze e doze ocorrências respectivamente.

Existem em alguns estudos, diferentes variações de cálculos de IV já estabelecidos. Um exemplo desses são do artigo de Sa e Fan (2023), onde é argumentado que estudos existentes utilizaram diversos métodos para a criação de

novos IV's para evitar o problema de IV's existentes ignorarem informações importantes que podem estar em outras bandas espectrais, e que diferentes áreas de estudo e dados produzem respostas diferentes a diferentes bandas espectrais (SA; FAN, 2023). Por outro lado, o artigo fala que existem poucos estudos sobre outras bandas incluídas em diferentes IV's, e a diferença em resultados deles em diferentes bandas (SA; FAN, 2023). Portanto, o estudo se utiliza do método exaustivo para estabelecer os índices NDVI e RVI através da geração de índices relativos, cada um com um peso diferente dependendo da banda principal utilizada. Abaixo estão os cálculos dos dois índices.

$$mNDVI_{ij} = \frac{m \times Band_i - Band_j}{m \times Band_i + Band_j}$$

Equação 8 - Cálculo do NDVI relativo. (SA; FAN, 2023)

$$mRVI_{ij} = \frac{m \times Band_i}{Band_j}$$

Equação 9 - Cálculo do RVI relativo. (SA; FAN, 2023)

Onde:

m = Peso;

i = Cada uma das bandas do sensor;

j = Cada uma das bandas do sensor, exceto a banda i.

No quesito do uso da técnica de exaustão utilizada, o artigo relata que o uso de NDVI relativos com a adição do fator de peso aumenta significativamente a sensibilidade do índice em relação ao uso de NDVI em suas bandas espectrais originais. Para o prosseguimento dos estudos, o RVI foi escolhido ao invés do NDVI devido aos melhores resultados de coeficiente de determinação da distribuição de IV's relativos em diferentes bandas (SA; FAN, 2023).

O artigo de Pechanec et al., (2017) difere da maioria dos analisados, no sentido de que o IV utilizado para a pesquisa não inclui o NDVI, de fato, o índice escolhido foi o ND45, que utiliza bandas espectrais do NIR e SWIR (em vez das bandas do NIR e



RED do NDVI). O estudo de Pechanec et al. (2017) avalia o estoque de carbono das florestas da república Tcheca, utilizando imagens do sensor Landsat-7 ETM+. O autor cita Sanga-Ngoie, Iizuka e Kobayashi (2012) para dizer que o NDVI possui problemas com o efeito de saturação com um valor de biomassa maior, e menciona Liu Zhu, (2015), cujo trabalho aponta que o índice NDVI possui uma relação maior com AGB no outono do que no período de crescimento. O índice ND45 foi escolhido com base em análise de resultado de diferentes índices, baseado em outros estudos realizados em duas localidades no Canadá, com a vegetação similar à da República Tcheca (GOODENOUGH et al., 2000).

O texto conclui que a utilização de técnicas de SR em grandes áreas (como a da República Tcheca) foram favoráveis. Os valores de estoque de carbono de toda área obtiveram uma variação de somente 4.6% (PECHANEC et al., 2017). Os resultados obtidos através de SR provaram ser comparáveis com métodos de observação de campo, e são uma alternativa mais barata, e em alguns casos, a única opção disponível para esse cálculo, visto a inacessibilidade de áreas florestais.

## **5 CONSIDERAÇÕES FINAIS**

O SC é uma das alternativas para reduzir a taxa de liberação de CO<sub>2</sub> na atmosfera, ajudando assim a reduzir os processos de aquecimento global pelos quais passamos atualmente. Neste cenário, a busca pelo aprimoramento de técnicas e ferramentas que auxiliem na mensuração de CO<sub>2</sub> estocados na vegetação, se provam um objetivo importante e necessário para a luta contra as mudanças climáticas causadas pelo homem.

Pela análise dos metadados dos artigos selecionados, e suas metodologias, foi possível perceber que o uso de SR para estimativa de SC é um tema que vêm ganhando visibilidade ao longo do tempo, e se mostra um tópico atual, com base na grande quantidade de artigos publicados no ano de 2023, em relação ao período histórico avaliado.

É válido ressaltar que a maior quantidade de publicações foi de países asiáticos, contabilizando mais da metade das autorias e contribuições contabilizadas. Além disso, os países que mais possuem autoria de artigos são também os que mais possuem áreas de estudos, demonstrando assim não só um interesse pelo tema, mas também na aplicabilidade dele no seu território. Os Estados Unidos também demonstraram uma produção de textos acadêmicos considerável, mesmo que possuam uma baixa quantidade de áreas de estudo. Uma revisão bibliométrica sobre o tema, aprofundando o aspecto temporal e geográfico das publicações, pode trazer o movimento histórico mundial sobre a taxa de publicações ao longo do tempo, podendo-se observar e inferir tendências sobre o interesse no uso de SR para mensuração de SC.

Um tema em comum entre várias das pesquisas são os benefícios da disponibilidade gratuita de dados, como em dados dos satélites Landsat e Sentinel. A possibilidade de se obter valiosos dados de forma gratuita, reduz de forma significativa os custos da utilização de técnicas de SR para o monitoramento de EC em áreas de vegetação, e é um dos fatores que tornam a utilização de SR uma alternativa não somente viável, mas as vezes a única alternativa possível.

Em síntese, o crescente interesse e os investimentos em pesquisas relacionadas ao uso do SR para estimativa de SC não apenas refletem a urgência global em enfrentar as mudanças climáticas, mas também reconhecem a importância fundamental da vegetação na mitigação dos impactos ambientais. À medida que avançamos, torna-se imperativo aprimorar continuamente as ferramentas e técnicas de medição para melhor compreender e gerenciar nosso ambiente natural. Este é um desafio crucial para a ciência e a prática, e requer esforços contínuos e colaborativos na busca por soluções sustentáveis

## REFERÊNCIAS BIBLIOGRÁFICAS

AHMAD, N. et al. Comparative Analysis of Remote Sensing and Geo-Statistical Techniques to Quantify Forest Biomass. **Forests**, v. 14, n. 2, 1 fev. 2023.

ANKRAH, J.; MONTEIRO, A.; MADUREIRA, H. Bibliometric Analysis of Data Sources and Tools for Shoreline Change Analysis and Detection. **Sustainability (Switzerland)**, v. 14, n. 9, 2022.

ASKAR et al. Estimating aboveground biomass on private forest using sentinel-2 imagery. **Journal of Sensors**, v. 2018, 2018.

BHARDWAJ, D. R. et al. Variation of biomass and carbon pool with NDVI and altitude in sub-tropical forests of northwestern Himalaya. **Environmental Monitoring and Assessment**, v. 188, n. 11, 1 nov. 2016.

BORDOLOI, R. et al. Satellite based integrated approaches to modelling spatial carbon stock and carbon sequestration potential of different land uses of Northeast India. **Environmental and Sustainability Indicators**, v. 13, 1 fev. 2022.

BYRD, K. B. et al. A remote sensing-based model of tidal marsh aboveground carbon stocks for the conterminous United States. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 139, p. 255–271, 1 maio 2018.

CAMPBELL, J. B. **Introduction to remote sensing**. 2. ed. [s.l: s.n.].

CHANG, Z. et al. Estimating Aboveground Carbon Dynamic of China Using Optical and Microwave Remote-Sensing Datasets from 2013 to 2019. **Journal of Remote Sensing (United States)**, v. 3, 1 jan. 2023.

CLERICI, N. et al. Estimating aboveground biomass and carbon stocks in periurban Andean secondary forests using very high resolution imagery. **Forests**, v. 7, n. 7, 9 jul. 2016.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. 1. ed. Campinas: UNICAMP, 1992.

DAS, S.; SINGH, T. P. Forest Type, Diversity and Biomass Estimation in Tropical Forests of Western Ghat of Maharashtra Using Geospatial Techniques. **Small-scale Forestry**, v. 15, n. 4, p. 517–532, 1 dez. 2016.

DEB, D. et al. An alternative approach for estimating above ground biomass using Resourcesat-2 satellite data and artificial neural network in Bundelkhand region of India. **Environmental Monitoring and Assessment**, v. 189, n. 11, 1 nov. 2017.

DUBE, T. et al. Intra-and-inter species biomass prediction in a plantation forest: Testing the utility of high spatial resolution spaceborne multispectral rapideye sensor and advanced machine learning algorithms. **Sensors (Switzerland)**, v. 14, n. 8, p. 15348–15370, 20 ago. 2014.

DUBE, T. et al. Estimating soil organic and aboveground woody carbon stock in a protected dry Miombo ecosystem, Zimbabwe: Landsat 8 OLI data applications. **Physics and Chemistry of the Earth**, v. 105, p. 154–160, 1 jun. 2018.

DUCHE-PÉREZ, A. B. et al. Religion and Spirituality in University Students: A Systematic Review of the Literature. **International Journal of Religion and Spirituality in Society**, v. 14, n. 4, p. 135–162, 12 dez. 2024.

EMBRAPA. **Sentinel**. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/sentinel>>. Acesso em: 13 fev. 2024.

EMBRAPA. **Landsat**. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/landsat>>. Acesso em: 13 fev. 2024.

GAO, L.; CHAI, G.; ZHANG, X. Above-Ground Biomass Estimation of Plantation with Different Tree Species Using Airborne LiDAR and Hyperspectral Data. **Remote Sensing**, v. 14, n. 11, 1 jun. 2022.

GIDEON NEBA, S. et al. Assessment and prediction of above-ground biomass in selectively logged forest concessions using field measurements and remote sensing data: Case study in South East Cameroon. **Forest Ecology and Management**, v. 329, p. 177–185, 1 out. 2014.

GOODENOUGH, D. G. et al. Determination of above ground carbon in Canada's forests - A multi-source approach. **Pacific Forestry Centre**, p. 949–953, 26 jul. 2000.

HEJAZI, J. et al. Genetic determinants of food preferences: a systematic review of observational studies. **BMC Nutrition**, v. 10, n. 1, p. Article 24, 1 dez. 2024.

HERRMANN, P. B.; NASCIMENTO, V. F.; DE FREITAS, M. W. D. Fire Analysis in Grasslands using Remote Sensing: A Systematic Review | Sensoriamento Remoto Aplicado a Análise de Fogo em Formações Campestres: Uma Re-visão Sistemática. **Revista Brasileira de Cartografia**, v. 74, n. 2, p. 437–458, 2022.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, nov. 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, ago. 1988.

IPCC. **Climate Change 2001: The Scientific Basis**. Disponível em: <[https://web.archive.org/web/20070329000822/http://www.grida.no/climate/ipcc\\_tar/wg1/248.htm](https://web.archive.org/web/20070329000822/http://www.grida.no/climate/ipcc_tar/wg1/248.htm)>. Acesso em: 3 fev. 2024.

IQBAL, U. et al. Drones for Flood Monitoring, Mapping and Detection: A Bibliometric Review. **Drones**, v. 7, n. 1, 2023.

JAN VAN ECK, N.; WALTMAN, L. **VOSviewer Manual**. , 31 out. 2023.

KHAN, K. et al. Assessment of sentinel-2-derived vegetation indices for the estimation of above-ground biomass/carbon stock, temporal deforestation and carbon emissions estimation in the moist temperate forests of pakistan. **Applied Ecology and Environmental Research**, v. 18, n. 1, p. 783–815, 2020.

KIRSCHBAUM, M. U. F. et al. **Definitions Of Some Ecological Terms Commonly Used In Carbon Accounting**. [s.l: s.n.]. Disponível em: <<https://www.researchgate.net/publication/239863843>>.

LEE, Y. S. et al. Mapping forest vertical structure in Jeju Island from optical and radar satellite images using artificial neural network. **Remote Sensing**, v. 12, n. 5, 1 mar. 2020.

LI, L. et al. Lidar with multi-temporal MODIS provide a means to upscale predictions of forest biomass. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 198–208, 1 abr. 2015.

LI, W. et al. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system. **Ecological Indicators**, v. 67, p. 637–648, 1 ago. 2016.

LIU, L. et al. Improving artificial forest biomass estimates using afforestation age information from time series Landsat stacks. **Environmental Monitoring and Assessment**, v. 186, n. 11, p. 7293–7306, 3 out. 2014.

LIU, Q. et al. Nature Environment and Pollution Technology An International Quarterly Scientific Journal Spatial Distribution Characteristics of Biomass and Carbon Storage in Forest Vegetation in Chongqing Based on RS and GIS. v. 15, p. 1381–1388, 2016.

LOPES, I. **O Mecanismo de Desenvolvimento Limpo – MDL: guia de orientação**. Rio de Janeiro: Fundação Getulio Vargas, 2002.

MACAVE, O. A. et al. Modelling Aboveground Biomass of Miombo Woodlands in Niassa Special Reserve, Northern Mozambique. **Forests**, v. 13, n. 2, 1 fev. 2022.

MADEWELL, Z. J. et al. Household Transmission of SARS-CoV-2: A Systematic Review and Meta-analysis. **JAMA Network Open**, v. 3, n. 12, p. Article e2031756, 14 dez. 2020.

MCTIC; SEPED; CGCL. **Acordo de Paris**. [s.l: s.n.]. Disponível em: <[https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/acordo-de-paris-e-ndc/arquivos/pdf/acordo\\_paris.pdf](https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/acordo-de-paris-e-ndc/arquivos/pdf/acordo_paris.pdf)>. Acesso em: 1 fev. 2024.

MOHER, D. et al. Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. **PLoS Medicine**, v. 6, n. 7, p. e1000097, 21 jul. 2009.

MOREIRA, H. M.; GIOMETTI, A. B. DOS R. Protocolo de Quioto e as possibilidades de inserção do Brasil no Mecanismo de Desenvolvimento Limpo por meio de projetos em energia limpa. **Contexto Internacional**, v. 30, n. 1, p. 9–47, abr. 2008.

MYEONG, S.; NOWAK, D. J.; DUGGIN, M. J. A temporal analysis of urban forest carbon storage using remote sensing. **Remote Sensing of Environment**, v. 101, n. 2, p. 277–282, 2006.

NASA. **Landsat 8**. Disponível em: <<https://landsat.gsfc.nasa.gov/article/landsat-data-continuity-mission/>>. Acesso em: 9 fev. 2024.

NGUYEN, H. H.; VU, H. D.; RÖDER, A. Estimation of above-ground mangrove biomass using landsat-8 data-derived vegetation indices: A case study in quang ninh province, Vietnam. **Forest and Society**, v. 5, n. 2, p. 506–525, 2021.

PANDEY, P. C. et al. Forest biomass estimation using remote sensing and field inventory: a case study of Tripura, India. **Environmental Monitoring and Assessment**, v. 191, n. 9, 1 set. 2019.

PECHANEC, V. et al. Carbon stock in forest aboveground biomass - Comparison based on Landsat data. **Central European Forestry Journal**, v. 63, n. 2–3, p. 126–132, 1 jun. 2017.

ROUSE, J. W. , J. et al. **Monitoring Vegetation Systems in The Great Plains with ERTS**. 1973. Disponível em: <<https://ntrs.nasa.gov/search.jsp?R=19740022614>>

SA, R.; FAN, W. Estimation of Forest Parameters in Boreal Artificial Coniferous Forests Using Landsat 8 and Sentinel-2A. **Remote Sensing**, v. 15, n. 14, 1 jul. 2023.

SALAZAR VILLEGAS, M. H. et al. Examining the Potential of Sentinel Imagery and Ensemble Algorithms for Estimating Aboveground Biomass in a Tropical Dry Forest. **Remote Sensing**, v. 15, n. 21, 1 nov. 2023.

SANGA-NGOIE, K.; IIZUKA, K.; KOBAYASHI, S. Estimating CO<sub>2</sub> sequestration by forests in oita prefecture, Japan, by combining LANDSAT ETM+ and ALOS satellite remote sensing data. **Remote Sensing**, v. 4, n. 11, p. 3544–3570, nov. 2012.

SANTANA, L. S. et al. Advances in precision coffee growing research: A bibliometric review. **Agronomy**, v. 11, n. 8, 2021.

SAPORTA, L. A.; YOUNG, C. E. Créditos de carbono e o reflorestamento do entorno da REBIO de Poços das Antas, Brasil. 2009.

SEIXAS, I. M.; PINHEIRO, E. S. Sensoriamento remoto aplicado à análise chuva-vegetação na Amazônia Central. v. 18, p. 3, 2014.

SHARMA, L. K.; NATHAWAT, M. S.; SINHA, S. Top-down and bottom-up inventory approach for above ground forest biomass and carbon monitoring in REDD framework using multi-resolution satellite data. **Environmental Monitoring and Assessment**, v. 185, n. 10, p. 8621–8637, out. 2013.

SILVA, D. S. DA; ANDRADES-FILHO, C. DE O. Uso do fogo nos campos de altitude do sul do Brasil: análise do licenciamento ambiental a partir de geotecnologias. **Revista Brasileira de Meio Ambiente**, v. 9, n. 1, p. 146–164, 2021.

SILVA, L. A. P. DA; DE ALMEIDA, M. I. S.; LEITE, M. E. Comportamento do NDVI em Savanas Considerando os Aspectos do Ambiente – APA do Rio Pandeiros – MG. **Espaço Aberto**, v. 10, n. 2, p. 71–85, 22 out. 2020.

SUKARNA, R. M.; BIRAWA, C.; JUNAEDI, A. Mapping above-ground carbon stock of secondary peat swamp forest using forest canopy density model landsat 8 oli-tirs: A case study in central kalimantan indonesia. **Environment and Natural Resources Journal**, v. 19, n. 2, p. 165–175, 2021.

SUN, Z. et al. Evaluating and comparing remote sensing terrestrial GPP models for their response to climate variability and CO<sub>2</sub> trends. **Science of the Total Environment**, v. 668, p. 696–713, 2019.

TIJSSSEN, R. J. W. A scientometric cognitive study of neural network research: Expert mental maps versus bibliometric maps. **Scientometrics**, v. 28, n. 1, p. 111–136, set. 1993.



TULLIO, L. **Aplicações e princípios do sensoriamento remoto**. [s.l.] Antonella Carvalho de Oliveira, 2018.

UNFCCC. **The Paris Agreement**. Disponível em: <<https://web.archive.org/web/20210319205057/https://unfccc.int/process-and-meetings/the-paris-agreement/the-paris-agreement>>. Acesso em: 5 mar. 2024.

URBAZAEV, M. et al. Improved multi-sensor satellite-based above ground biomass estimation by selecting temporally stable forest inventory plots using NDVI time series. **Forests**, v. 7, n. 8, 4 ago. 2016.

U. S. GEOLOGICAL SURVEY; LANDSAT MISSIONS. **Landsat 8**. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-8>>. Acesso em: 5 mar. 2024.

U.S. GEOLOGICAL SURVEY. **Celebrating a Decade of Landsat 8**. Disponível em: <<https://www.usgs.gov/landsat-missions/news/celebrating-a-decade-landsat-8>>. Acesso em: 12 fev. 2024.

VIEIRA BARRETO, L.; CRISTINA, A.; FREITAS, S. SEQUESTRO DE CARBONO. **ENCICLOPEDIA BIOSFERA**, v. 5, n. 7, 2009.

WALLIS, C. I. B. et al. Modeling tropical montane forest biomass, productivity and canopy traits with multispectral remote sensing data. **Remote Sensing of Environment**, v. 225, p. 77–92, 1 maio 2019.

WANG, G. et al. Mapping the Spatial Distribution of Aboveground Biomass in China's Subtropical Forests Based on UAV LiDAR Data. **Forests**, v. 14, n. 8, 1 ago. 2023a.

WANG, H. et al. Seasonal variations in vegetation water content retrieved from microwave remote sensing over Amazon intact forests. **Remote Sensing of Environment**, v. 285, 1 fev. 2023b.

WANG, Y. et al. Fine-Resolution Forest Height Estimation by Integrating ICESat-2 and Landsat 8 OLI Data with a Spatial Downscaling Method for Aboveground Biomass Quantification. **Forests**, v. 14, n. 7, 1 jul. 2023c.

ZANOTTA, D.; ZORTEA, M.; FERREIRA, M. **Processamento de Imagens de Satélite**. São Paulo: Oficina de Textos, 2019.

ZHANG, L. et al. Deep learning based retrieval of forest aboveground biomass from combined LiDAR and landsat 8 data. **Remote Sensing**, v. 11, n. 12, 1 jun. 2019a.

ZHANG, M. et al. Estimating forest aboveground carbon storage in Hang-Jia-Hu using landsat TM/OLI data and random forest model. **Forests**, v. 10, n. 11, 1 nov. 2019b.

ZHENG, Z. et al. Remotely sensed functional diversity and its association with productivity in a subtropical forest. **Remote Sensing of Environment**, v. 290, 15 maio 2023.

ZHU, X.; LIU, D. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 222–231, 1 abr. 2015.

## ANEXOS

## ANEXO A

Artigo	Ano	Área de Estudo	Regiões Espectrais	Sensores	Índices	Autor
A remote sensing-based model of tidal marsh aboveground carbon stocks for the conterminous United States	2018	Estados Unidos continental	NAIP (Bandas 1 a 4); Sentinel-1A (Banda C); Landsat-7 ETM+ (Bandas 4 e 5)	LANDSAT-7 ETM+, LANDSAT-8 OLI, Sentinel-1A, NAIP	TBVI, WDRVI, SAVI, NDVI, NDWI	(BYRD et al., 2018)
Above-Ground Biomass Estimation of Plantation with Different Tree Species Using Airborne LiDAR and Hyperspectral Data	2022	Fazenda florestal Gaofeng em Nanning, província de Guangxi, China	Bandas 1 a 125	RIEGLIMS-Q680i AISA Eagle II sensor	NDVI, EVI, SAVI, PRI, TCARI, MCARI, OSAVI, SARVI	(GAO; CHAI; ZHANG, 2022)
An alternative approach for estimating above ground biomass using Resourcesat-2 satellite data and artificial neural network in Bundelkhand region of India	2017	Madhya Pradesh e Uttar Pradesh, Índia	Resourcesat-2 AWiFS (Bandas 2 a 5)	sensor AWiFS do satélite Resourcesat-2	NDVI	(DEB et al., 2017)
Assessment and prediction of above-ground biomass in selectively logged forest concessions using field measurements and remote sensing data: Case study in Southeast Cameroon	2014	Unidade de Manejo Florestal em Camarões	MODIS (Bandas 1 a 4)	MODIS 250m	NDVI	(GIDEON NEBA et al., 2014)

Artigo	Ano	Área de Estudo	Regiões Espectrais	Sensores	Índices	Autor
Assessment Of Sentinel-2-Derived Vegetation Indices for The Estimation Of Above-Ground Biomass/Carbon Stock, Temporal Deforestation And Carbon Emissions Estimation In The Moist Temperate Forests Of Pakistan	2020	Battagram, Khyber-Pakhtunkhwa, Paquistão	0.45-0.48 (blue), 0.52-0.59 (green), 0.62-0.68 (red), 0.77-0.86 (NIR)	LANDSAT-7 ETM+, LANDSAT-8 OLI, Sentinel-2	EVI, GNDVI, NDVI, SAVI, TSAVI, NDII, NDWI, RENDVI, RERVI	(KHAN et al., 2020)
Carbon stock in forest aboveground biomass – comparison based on Landsat data	2017	República Tcheca	0.45-0.48 (blue), 0.52-0.59 (green), 0.62-0.68 (red), 0.77-0.86 (NIR)	LANDSAT-7 ETM+	ND45	(PECHANEC et al., 2017)
Comparative Analysis of Remote Sensing and Geo-Statistical Techniques to Quantify Forest Biomass	2023	Abbottabad, Paquistão	0.45-0.48 (blue), 0.52-0.59 (green), 0.62-0.68 (red), 0.77-0.86 (NIR)	Sentinel-2A	EVI2, MSR, NDVI, SAVI, ARVI, RERVI, S2REP, SIPI	(AHMAD et al., 2023)
Deep Learning Based Retrieval of Forest Aboveground Biomass from Combined LiDAR and Landsat 8 Data	2019	Conghua, província de Guangdong, China	Landsat-8 OLI (Bandas 1 a 9)	LANDSAT-8 OLI, Leica ALS50-II	NDVI, SR, EVI, ARVI, SAVI, MSAVI, OSAVI	(ZHANG et al., 2019a)
Estimating Aboveground Biomass and Carbon Stocks in Periurban Andean Secondary Forests Using Very High Resolution Imagery	2016	Florestas periurbanas em Bogotá, Colômbia	0.45-0.48 (blue), 0.52-0.59 (green), 0.62-0.68 (red), 0.77-0.86 (NIR)	VHR GeoEye-1, Pleiades-1A	NDVI, RVI, NDGI, TVI	(CLERICI et al., 2016)
Estimating aboveground biomass on private forest using sentinel-2 imagery	2018	Gunung Kidul, província de Yogyakarta, Indonésia	bands 4, 3, 2	Sentinel-2 level 1-C	NDVI, EVI, MSR, SR, NDI45, S2REP, GNDVI	(ASKAR et al., 2018)

<b>Artigo</b>	<b>Ano</b>	<b>Área de Estudo</b>	<b>Regiões Espectrais</b>	<b>Sensores</b>	<b>Índices</b>	<b>Autor</b>
Estimating Aboveground Carbon Dynamic of China Using Optical and Microwave Remote-Sensing Datasets from 2013 to 2019	2023	China	L-band (1.4 GHz), X-band(10.7 GHz, com resolução espacial de 0.25°)	SMOS, AMSR2, MODIS	NDVI, LAI, TC	(CHANG et al., 2023)
Estimating Forest Aboveground Carbon Storage in Hang-Jia-Hu Using Landsat TM/OLI Data and Random Forest Model	2019	Hang-Jia-Hu, Província Zhejiang, China	Landsat-5 LM, Landsat-8 OLI (banda 1 a 6)	LANDSAT-5 LM, LANDSAT-8 OLI	NDVI, SAVI, DVI, SR, EVI	(ZHANG et al., 2019b)
Estimating soil organic and aboveground woody carbon stock in a protected dry Miombo ecosystem, Zimbabwe: Landsat 8 OLI data applications	2018	Muskvi Woodlands, Harare, Zimbabwe	Não Informado	LANDSAT-8 OLI	RVI, NDVI, SAVI	(DUBE et al., 2018)
Estimation of Above-Ground Mangrove Biomass Using Landsat-8 Data- Derived Vegetation Indices: A Case Study in Quang Ninh Province, Vietnam	2021	Quang Ninh, Vietnã	Landsat-8 OLI (Bandas 2 a 7)	LANDSAT-8 OLI	SR, NDVI, SAVI, EVI	(NGUYEN; VU; RÖDER, 2021)
Estimation of Forest Parameters in Boreal Artificial Coniferous Forests Using Landsat 8 and Sentinel-2A	2023	Floresta de Saihanba, Chengde, China	Landsat-8 OLI (Bandas 1 a 8, 11, 12)	LANDSAT-8 OLI, Sentinel-2A	NDVI, RVI, DVI, EVI, RDVI, SAVI, OSAVI	(SA; FAN, 2023)

<b>Artigo</b>	<b>Ano</b>	<b>Área de Estudo</b>	<b>Regiões Espectrais</b>	<b>Sensores</b>	<b>Índices</b>	<b>Autor</b>
Examining the Potential of Sentinel Imagery and Ensemble Algorithms for Estimating Aboveground Biomass in a Tropical Dry Forest	2023	Região do vale do rio Madalena, Colômbia	Sentinel-1 SAR (Banda C), Sentinel-2 (Bandas 2 a 8, 11 a 13)	Sentinel-1 SAR, Sentinel-2 MSI	NDVI, LAI	(SALAZAR VILLEGAS et al., 2023)
Fine-Resolution Forest Height Estimation by Integrating ICESat-2 and Landsat 8 OLI Data with a Spatial Downscaling Method for Aboveground Biomass Quantification	2023	Província de Jilij, China	Bandas 1 a 7	ICESat-2 LANDSAT-8 OLI	NDVI	(WANG et al., 2023c)
Forest biomass estimation using remote sensing and field inventory: a case study of Tripura, India	2019	Estado de Tripuria, Índia	Não Informado	MOD15A2H, MOD13A1	NDVI	(PANDEY et al., 2019)
Forest Type, Diversity and Biomass Estimation in Tropical Forests of Western Ghat of Maharashtra Using Geospatial Techniques	2016	Região ocidental de Ghat do estado de Maharashtra, na Índia	Não Informado	LANDSAT TM	NDVI, MSR, RDVI, RVI, MSAVI, OSAVI, IVI	(DAS; SINGH, 2016)
Improved multi-sensor satellite-based above ground biomass estimation by selecting temporally stable forest inventory plots using NDVI time series	2016	Estado de Campeche e estado de Chiapas, México	L-Band	ALOS PALSAR, LANDSAT, MODIS MOD13Q1	NDVI	(URBAZAEV et al., 2016)

<b>Artigo</b>	<b>Ano</b>	<b>Área de Estudo</b>	<b>Regiões Espectrais</b>	<b>Sensores</b>	<b>Índices</b>	<b>Autor</b>
Improving artificial forest biomass estimates using afforestation age information from time series Landsat stacks	2014	Distrito de Yulin, China	0.45-0.48 (blue), 0.52-0.59 (green), 0.62-0.68 (red), 0.77-0.86 (NIR)	LANDSAT-8 OLI, Landsat TM/ETM+, Landsat MSS, MODIS	NDVI, SR, PVI, EVI, SAVI	(LIU et al., 2014)
Intra-and-inter species biomass prediction in a plantation forest: Testing the utility of high spatial resolution spaceborne multispectral rapideye sensor and advanced machine learning algorithms	2014	Floresta do clã sappi em KwaZulu-Natal, África do Sul	RapidEye (Bandas 1 a 5)	RapidEye	SR, RVI, NDVI, DVI, MSR, TVI, IPVI, GI, PSSR	(DUBE et al., 2014)
Lidar with multi-temporal MODIS provide a means to upscale predictions of forest biomass	2015	Califórnia, Estados Unidos	Não Informado	GEMINI ALTM (Lidar), MODIS (MOD13Q1, MOD13A1, MOD13A2, MOD15A2)	NDVI, EVI, LAI	(LI et al., 2015)
Mapping above-ground carbon stock of secondary peat swamp forest using forest canopy density model Landsat 8 OLI-TIRS: A case study in central Kalimantan Indonesia	2021	Província do Kalimã Central, Indonésia	LANDSAT-8 OLI (Bandas 1 a 13)	LANDSAT-8 OLI	AVI, BI, SI, TI	(SUKARNA; BIRAWA; JUNAEDI, 2021)
Mapping forest vertical structure in Jeju Island from optical and radar satellite images using artificial neural network	2020	Seogwipo-si, Jeju-do, Coreia do Sul	L-band	Kompsat-3, TerraSar-X, ALOS PALSAR-1	NDVI, NDWI	(LEE et al., 2020)



<b>Artigo</b>	<b>Ano</b>	<b>Área de Estudo</b>	<b>Regiões Espectrais</b>	<b>Sensores</b>	<b>Índices</b>	<b>Autor</b>
Mapping the Spatial Distribution of Aboveground Biomass in China's Subtropical Forests Based on UAV LiDAR Data	2023	Província Jiangxi, China		DJI M300 RTK onboard Lidar sensor		(WANG et al., 2023a)
Modeling tropical montane forest biomass, productivity, and canopy traits with multispectral remote sensing data	2019	Regiões de Bombuscaro, San Francisco, Cajanuma, no Equador		LANDSAT-8	TPI, EVI, RGVI, RBVI	(WALLIS et al., 2019)
Modelling Aboveground Biomass of Miombo Woodlands in Niassa Special Reserve, Northern Mozambique	2022	Reserva Especial do Niassa (NSR) no norte de Moçambique.	Vermelho, infravermelho, e banda-C	LANDSAT-8 OLI, Sentinel 2A/MSI, Sentinel 1B	NDVI, SAVI, SR	(MACAVE et al., 2022)
Nature Environment and Pollution Technology an International Quarterly Scientific Journal Spatial Distribution Characteristics of Biomass and Carbon Storage in Forest Vegetation in Chongqing Based on RS and GIS	2016	Cidade de Chongqing, China	Landsat TM (Bandas 1, 2, 3, 4, 5, 7)	LANDSAT TM	RVI, NDVI, ARVI, MSAVI, EVI	(LIU et al., 2016)
Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system	2016	Bacia Huailai-Yanqing, 84 km ao norte de Pequim, China.	red (R, 625 nm), green (G, 550 nm), and blue (B, 485 nm)	Duas câmeras SONYA6000 em um VANT	GLA, NGRDI, ExG, ExGR, CIVE, VEG, WI	(LI et al., 2016)

<b>Artigo</b>	<b>Ano</b>	<b>Área de Estudo</b>	<b>Regiões Espectrais</b>	<b>Sensores</b>	<b>Índices</b>	<b>Autor</b>
Remotely sensed functional diversity and its association with productivity in a subtropical forest	2023	Monte Shennongjia, província de Hubei, China	Sentinel-2 (Bandas 1 a 9, 11, 12, 13)	Leica ALS70-HP (Lidar), Sentinel-2, LANDSAT-8	LAI, EVI, NDVI, mNDVI, kNDVI	(ZHENG et al., 2023)
Satellite based integrated approaches to modelling spatial carbon stock and carbon sequestration potential of different land uses of Northeast India	2022	Nordeste da Índia		MODIS, Landsat TM, Landsat ETM, Landsat-8 OLI, IKONOS, RADAR, Sentinel-1A, LIDAR	NDVI, SAVI, ARVI	(BORDOLOI et al., 2022)
Seasonal variations in vegetation water content retrieved from microwave remote sensing over Amazon intact forests	2023	Amazon Forest, Brazil		SMOS-IC, ASCAT-IB C-VO, AMSR2 X-VOD, VODCA X-VOD	LAI, NDVI, EVI, Ku-VOD, X-VOD, L-VOD	(WANG et al., 2023b)
Top-down and bottom-up inventory approach for above ground forest biomass and carbon monitoring in REDD framework using multi-resolution satellite data	2013	Himachal Pradesh, Índia	Landsat-5 TM (Bandas 1 a 5, 7); LISS-III (Bandas 2 à 5)	Landsat-5 TM, IRS-P6 LISS-III, MODIS 250m	NDVI	(SHARMA; NATHAWAT; SINHA, 2013)
Variation of biomass and carbon pool with NDVI and altitude in subtropical forests of northwestern Himalaya	2016	Himachal Pradesh, Índia		LANDSAT LISS III	NDVI	(BHARDWAJ et al., 2016)