

UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
INSTITUTO DE CIÊNCIAS AMBIENTAIS E AGRÁRIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM QUALIDADE AMBIENTAL

SAMUEL LACERDA DE ANDRADE

COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS DIGITAIS  
NA DETECÇÃO DE ALVOS INDICADORES DE IMPACTO AMBIENTAL EM  
LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA.

UBERLÂNDIA  
MINAS GERAIS – BRASIL  
2016

SAMUEL LACERDA DE ANDRADE

COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS DIGITAIS  
NA DETECÇÃO DE ALVOS INDICADORES DE IMPACTO AMBIENTAL EM  
LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA.

Dissertação apresentada à Universidade Federal de  
Uberlândia, como requisito parcial exigido pelo Programa  
de Pós-graduação em Qualidade Ambiental – Mestrado,  
área de concentração Gestão Ambiental, para obtenção do  
título de “Mestre”.

Orientador

Prof. Dr. Claudionor Ribeiro da Silva

UBERLÂNDIA  
MINAS GERAIS – BRASIL  
2016

Dados Internacionais de Catalogação na Publicação (CIP)  
Sistema de Bibliotecas da UFU, MG, Brasil.

---

- A553c  
2016      Andrade, Samuel Lacerda de, 1988  
            Comparação de métodos de classificação de imagens digitais na  
            detecção de alvos indicadores de impacto ambiental em linhas de  
            transmissão de energia / Samuel Lacerda de Andrade. - 2016.  
            83 f. : il.
- Orientador: Claudionor Ribeiro da Silva.  
            Dissertação (mestrado) - Universidade Federal de Uberlândia,  
            Programa de Pós-Graduação em Qualidade Ambiental.  
            Inclui bibliografia.
1. Ecologia - Teses. 2. Qualidade ambiental - Teses. 3. Impacto  
            ambiental - Teses. I. Silva, Claudionor Ribeiro da. II. Universidade  
            Federal de Uberlândia. Programa de Pós-Graduação em Qualidade  
            Ambiental. III. Título.

SAMUEL LACERDA DE ANDRADE

COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS DIGITAIS  
NA DETECÇÃO DE ALVOS INDICADORES DE IMPACTO AMBIENTAL EM  
LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA.

Dissertação apresentada à Universidade Federal de  
Uberlândia, como requisito parcial exigido pelo Programa  
de Pós-graduação em Qualidade Ambiental – Mestrado,  
área de concentração Gestão Ambiental, para obtenção do  
título de “Mestre”.

APROVADA em 14 de Janeiro de 2015.

Prof. Dr. Claudionor Ribeiro da Silva

UFU

Prof. Dr. Fernando Luiz de Paula Santil

UFU

Prof. Dr. Ângelo Evaristo Sirtoli

UFPR

Prof. Dr. Claudionor Ribeiro da Silva  
IG-UFU  
(Orientador)

UBERLÂNDIA  
MINAS GERAIS – BRASIL  
2016

## AGRADECIMENTOS

Agradeço a Deus por me conceder a oportunidade de estudar, ter uma profissão e galgar cada vez mais conhecimento. Ressalto também a importância de toda minha família por me apoiar em todas as minhas decisões referentes aos meus desejos e anseios profissionais. Agradeço também a minha namorada, pela paciência e compreensão durante esse período de dedicação, tenho a convicção que em muitos momentos não foi fácil, por fim, agradeço ao meu orientador, que com brilhantismo cumpriu o seu papel de me guiar durante o percurso acadêmico do mestrado.

## SUMÁRIO

LISTA DE FIGURAS .....	a
LISTA DE TABELAS .....	b
RESUMO .....	i
ABSTRACT .....	ii
1. INTRODUÇÃO .....	1
1.1. OBJETIVOS .....	4
1.1.1. Objetivo Geral .....	4
1.1.2. Objetivos Específicos .....	5
1.2. JUSTIFICATIVA .....	5
1.3. HIPÓTESE .....	6
2. REFERENCIAL TEÓRICO .....	6
2.1. LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA .....	6
2.3. CLASSIFICAÇÃO E SEGMENTAÇÃO DE IMAGENS DIGITAIS .....	10
2.3.1. Método da Máxima Verossimilhança - MaxVer .....	10
2.3.2. Método das Redes Neurais Artificiais - RNA .....	11
2.3.3. Método da Segmentação Orientada ao Objeto .....	14
2.4. SISTEMA <i>LASER SCANNER</i> - LiDAR .....	15
3. MATERIAIS E MÉTODO .....	18
3.1. ÁREA DE ESTUDO .....	18
3.2. MATERIAL UTILIZADO .....	21
3.3. MÉTODO .....	25
3.3.1 Definição das Classes Usadas no Processo de Classificação .....	26
3.3.2. Avaliação dos Resultados .....	29
3.3.3. Interpolação dos Dados LiDAR .....	30
3.3.4. Classificação por Máxima Verossimilhança - MaxVer .....	31
3.3.5. Classificação por Redes Neurais Artificiais - RNA .....	32
3.3.6. Classificação Usando Segmentação Orientada a Objeto .....	33
4. RESULTADOS E DISCUSSÃO .....	35
4.1. CLASSIFICAÇÃO POR MAXVER USANDO SOMENTE FOTOS .....	35
4.2. CLASSIFICAÇÃO POR MAXVER USANDO FOTOS E DADOS LiDAR .....	45
4.3. CLASSIFICAÇÃO POR RNA USANDO SOMENTE FOTOS .....	47

4.4. CLASSIFICAÇÃO POR RNA USANDO FOTOS E DADOS LiDAR .....	56
4.5. SEGMENTAÇÃO E CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO COM FOTO E COM FOTO INTEGRADA AO DADO LiDAR .....	59
4.6. COMPARAÇÃO ENTRE OS MÉTODOS DE CLASSIFICAÇÃO UTILIZADOS	63
5. CONCLUSÕES .....	66
REFERÊNCIAS .....	68

## LISTA DE FIGURAS

FIGURA 7. Subestação de energia Ibicoara.....	7
FIGURA 8. Esquema com AII, ADA e AID.....	9
FIGURA 1. Exemplo de configuração de Redes Neurais Artificiais. ....	12
FIGURA 2. Exemplo matemático de problema não linearmente separável. ....	12
FIGURA 3. Exemplo de objeto detectado por segmentação orientada ao objeto. ....	14
FIGURA 4. Escaneamento do terreno com Laser Scanner - LiDAR.....	16
FIGURA 5. Interpolação com o vizinho mais próximo. ....	17
FIGURA 6. Interpolação com o inverso da distância.....	18
FIGURA 9. Localização da área de estudo. ....	20
FIGURA 10. Recortes das fotos aéreas utilizadas.....	22
FIGURA 11. Legenda usada nas classificações. ....	29
FIGURA 12. Imagem classificada referente ao Recorte 1 (MaxVer). ....	36
FIGURA 13. Imagem classificada referente ao Recorte 2 (MaxVer). ....	38
FIGURA 14. Imagem classificada referente ao Recorte 3 (MaxVer). ....	40
FIGURA 15. Imagem classificada referente ao Recorte 4 (MaxVer). ....	41
FIGURA 16. Imagem classificada referente ao Recorte 5 (MaxVer). ....	43
FIGURA 17. Imagem classificada referente ao Recorte 2 (MaxVer – Fotos/LiDAR). .	45
FIGURA 18. Imagem classificada referente ao Recorte 5 (MaxVer – Fotos/LiDAR). .	46
FIGURA 19. Imagem classificada referente ao Recorte 1 (RNA).....	48
FIGURA 20. Imagem classificada referente ao Recorte 2 (RNA). ....	50
FIGURA 21. Imagem classificada referente ao Recorte 3 (RNA). ....	51
FIGURA 22. Imagem classificada referente ao Recorte 4 (RNA). ....	53
FIGURA 23. Imagem classificada referente ao Recorte 5 (RNA). ....	54
FIGURA 24. Imagem classificada referente ao Recorte 2 (RNA – Fotos/LiDAR). ....	56
FIGURA 25. Imagem classificada referente ao Recorte 5 (RNA – Fotos/LiDAR). ....	58
FIGURA 26. Imagem classificada referente ao Recorte 2a (Segmentação – Foto). ....	60
FIGURA 27. Imagem classificada referente ao Recorte 2b (Segmentação – Foto/LiDAR). ....	60
FIGURA 28. Comparação entre as áreas medidas com os métodos MaxVer e RNA....	66



## LISTA DE TABELAS

TABELA 1. Tamanho e áreas das fotos aéreas usadas. ....	24
TABELA 2. Valores de concordância com base no índice Kappa.....	30
TABELA 3. Valores aplicados aos parâmetros da RNA.....	33
TABELA 4. Valores e atributos utilizados no processo de segmentação. ....	34
TABELA 5. Áreas (em hectares) dos Usos de Solo dos 5 Recortes. ....	36
TABELA 6. Erros de Comissão e Omissão - Recorte 1 (MaxVer).....	38
TABELA 7. Erros de Comissão e Omissão - Recorte 2 (MaxVer).....	39
TABELA 8. Erros de Comissão e Omissão - Recorte 3 (MaxVer).....	40
TABELA 9. Erros de Comissão e Omissão - Recorte 4 (MaxVer).....	42
TABELA 10. Erros de Comissão e Omissão - Recorte 5 (MaxVer).....	43
TABELA 11. Erros de Comissão e Omissão - Recorte 2 (MaxVer com Foto/LiDAR). 46	
TABELA 12. Erros de Comissão e Omissão - Recorte 5 (MaxVer com Foto/LiDAR). 47	
TABELA 13. Áreas (em hectares) das classes obtidas com a classificação por RNA... 48	
TABELA 14. Erros de Comissão e Omissão - Recorte 1 (RNA).....	49
TABELA 15. Erros de Comissão e Omissão - Recorte 2 (RNA).....	51
TABELA 16. Erros de Comissão e Omissão - Recorte 3 (RNA).....	52
TABELA 17. Erros de Comissão e Omissão - Recorte 4 (RNA).....	54
TABELA 18. Erros de Comissão e Omissão - Recorte 5 (RNA).....	56
Tabela 19. Erros de Comissão e Omissão - Recorte 2 (RNA com Foto/LiDAR). ....	57
TABELA 20. Erros de Comissão e Omissão - Recorte 5 (RNA com Foto/LiDAR). ....	59
TABELA 21. Erros de Comissão e Omissão - Recorte 2 (Segmentação com Foto). ....	61
TABELA 22. Erros de Comissão e Omissão - Recorte 2 (Segmentação com Foto/LiDAR). ....	62
TABELA 23. Índices Kappa obtidos em todos os recortes e métodos testados.....	63

## RESUMO

ANDRADE, SAMUEL LACERDA **Comparação de métodos de classificação de imagens digitais na detecção de alvos indicadores de impacto ambiental em linhas de transmissão de energia elétrica.** 2016. 81 p. Dissertação (Mestrado Programa de pós-graduação em qualidade ambiental/ Gestão Ambiental) Universidade Federal de Uberlândia. <sup>1</sup>.

Os empreendimentos do setor energético, para transportar energia, são compostos por cabos e estruturas metálicas e embora estes tragam benefícios, sua instalação e operação podem ocasionar impactos ambientais relevantes ao longo do seu trecho de passagem. Nesse contexto, o objetivo desse estudo é identificar áreas de “solo exposto”, que podem estar relacionadas a processos de erosão, e “fragmentos de vegetação nativa”, na área diretamente afetada das linhas de transmissão de energia, por meio de técnicas computacionais e de dados de sensoriamento remoto. Foram realizados testes em Ortofotos, usando os classificadores de Máxima Verossimilhança e Redes Neurais, bem como a Segmentação Orientada ao Objeto, integrando as Ortofotos com dados *Laser Scanner*. Os resultados foram analisados com base nos erros de comissão (acurácia do usuário), omissão (acurácia do produtor) e índice kappa. Segundo o índice Kappa calculado, os resultados mostraram variações entre o índice moderado e excelente, indicando resultados expressivos no que diz respeito à metodologia utilizada. Referente aos erros de Comissão e Omissão, confusões no processo de classificação ocorreram entre classes que apresentavam *pixels* com valores digitais similares, dentro de uma mesma cena, principalmente dentro das classes que apresentam diferentes tipologias de vegetação. No que diz respeito ao diagnóstico ambiental, encontrado na área diretamente afetada da linha de transmissão, nota-se que o trecho, de forma amostral, indicou um elevado índice antrópico de ocupação. As classes “Campo Limpo” e “Solo Exposto” tiveram maior destaque, especialmente por englobar áreas com atividades agropecuárias. A área diretamente afetada do empreendimento analisado necessita de atenção quanto à recomposição vegetal das áreas identificadas. Ressalta-se que o resultado encontrado é um primeiro esforço de diagnóstico e investigação, sendo necessárias visitas pontuais a campo para elaboração do planejamento de metas de recuperação.

**Palavras- chave:** Classificação de imagens, Impacto Ambiental, Lidar, Linhas de Transmissão de Energia.

---

<sup>1</sup>Orientador: Prof. Dr. Claudionor Ribeiro da Silva- UFU

## ABSTRACT

The projects in the energy sector, related to transmission lines, are composed of cables and metal structures, although providing benefits, the installation and operation still have significant environmental impacts along its stretch of passage. In this context, the aim of this study is to identify areas of "soil exposed", which may be related to erosion processes, and "fragments of native vegetation" in the range of direct influence of power transmission lines through computational techniques and remote sensing data. Tests were lead on Orthophotos, using the Maximum Likelihood Classifiers and Neural Networks, as well as the Object-Oriented Segmentation, integrating the Orthophotos with Laser Scanner data. The results analyzed based on Commission errors (accuracy of the user), Omission (accuracy producer) and kappa index. According to Kappa index calculated, the results showed variations between moderate and excellent content, indicating significant results with regard to the methodology used. Referring to the Commission and Omission errors, disarray in the classification process took place between classes presenting pixels with similar digital values within the same scene, especially within the classes that have different types of vegetation. With respect to the environmental diagnosis found in the range of direct influence of the transmission line, the portion of the sample median, indicates a high rate of anthropogenic interference. The class "*Campo Limpo*" had greater prominence, especially in areas with agricultural activities. The areas directly affected need attention as their recovery. It is emphasized that the results, which are found, is the first effort of diagnosis and research, requiring occasional visits *in loco* to prepare the planning recovery goals.

## 1. INTRODUÇÃO

A inquietação com o destino da humanidade em vista da degradação e destruição dos recursos naturais disponíveis no planeta vem tomando um lugar privilegiado entre as preocupações humanas, principalmente pela divulgação dos intensos impactos advindos das ações antrópicas. Nos dias atuais têm-se observado o aumento da degradação do meio ambiental e seus reflexos na vida humana em escala mundial. COSTA et al. 2012).

A questão ambiental, pautada pelos problemas ecológicos e de impactos ambientais causados pelo homem (poluição, contaminação de corpos hídricos, instalação de empreendimentos poluidores, acidentes que afetam o meio ambiente entre outros), ou não, contribuem para que o tema ganhe cada vez mais notoriedade, trazendo a preocupação de um contingente de pessoas que passam a se preocupar com os impactos ambientais, especialmente aqueles causados por grandes empreendimentos, tais como a mineração, instalação de barragens e de redes de transmissão de energia elétrica.

O crescimento econômico de um país passa pela ampliação e modernização do seu sistema energético, ou seja, o aumento da arrecadação passa pela ampliação de infraestrutura e isso demanda mais consumo de energia elétrica.

Em relação ao consumo de energia elétrica no Brasil, e sua projeção de aumento de demanda, segundo dados da ANEEL, tem-se o crescimento de 5,8% ao ano, no período de 1973 a 2011. Nos próximos dez anos, o planejamento energético do MME, considerando os estudos do Plano Decenal de Expansão de Energia (PDE) 2021, indica uma taxa média de crescimento de 4,9% ao ano para o consumo de eletricidade (ANEEL, 2014).

Com o aumento dessa demanda, necessariamente há o desencadeamento de construção de empreendimentos energéticos a fim de se obter mais energia elétrica, e consequentemente o aumento do impacto ambiental.

É importante lembrar que os impactos ambientais causados pelo homem, não são frutos apenas de uma civilização contemporânea, eles já vêm sendo ocasionados desde o início da evolução humana. No início o homem era nômade, migrava em busca de

alimentos que a natureza oferecia, mas, com o passar dos anos, ele desenvolveu técnicas de cultivo, concentrando a oferta de alimentos. A agricultura rudimentar se inicia nesse momento e, com o passar das décadas e com o aprimoramento das relações comerciais, o uso da Terra passou a ser cada vez mais intenso. Nota-se que sempre houve a exploração dos recursos ambientais, porém, se considerados os impactos ambientais modernos, é possível uma visualização de que o dano sofrido no passado era relativamente baixo, devido a fatores como tamanho da população, avanço das relações capitalistas, entre outros.

As preocupações a respeito dos impactos ambientais causados pelo homem são recentes na história da humanidade. Pode-se citar a década de 70 como início dos debates internacionais, como a Conferência de Estocolmo (1972), evento em que foi criado o Programa das Nações Unidas para o Meio Ambiente (PNUMAS/ PNUD). A partir desse marco, ocorreram outros debates na tentativa de se discutir a utilização dos recursos naturais no planeta: Comissão Mundial para o Meio Ambiente e Desenvolvimento (1983), Conferência Mundial de Desenvolvimento e Meio Ambiente (1992), Protocolo de Quioto (1997), Conferência Mundial Sobre Desenvolvimento Sustentável - Rio+10 (2002) e Rio+20 (2012) (MINISTÉRIO DO MEIO AMBIENTE, 2014)

Em síntese considera-se Impacto Ambiental “...qualquer alteração das propriedades físicas, químicas e biológicas do meio ambiente, causada por qualquer forma de matéria ou energia resultante das atividades humanas...” citação direta Resolução (CONAMA nº001, 1986, p.636)

Sendo conceituado portanto os impactos ambientais, salienta-se que as instalações e operações de empreendimentos energéticos, requerem prévio licenciamento ambiental, considerados seus potenciais de impactos sobre o meio ambiente. O *sítio online* do IBAMA traz a definição do termo Licenciamento Ambiental da seguinte forma:

O licenciamento ambiental é uma obrigação legal prévia à instalação de qualquer empreendimento ou atividade potencialmente poluidora ou degradadora do meio ambiente e possui como uma de suas mais expressivas características a participação social na tomada de decisão, por meio da realização de Audiências Públicas como parte do processo. Essa obrigação é compartilhada pelos Órgãos Estaduais de Meio Ambiente e pelo IBAMA, como partes integrantes do SISNAMA (Sistema Nacional de Meio Ambiente). O Ibama atua, principalmente, no licenciamento de grandes projetos de infraestrutura

que envolvam impactos em mais de um estado e nas atividades do setor de petróleo e gás na plataforma continental (IBAMA, 2014).

Em um processo de licenciamento ambiental são apresentados dados relativos ao sistema de produção do empreendimento, sua capacidade de poluição, seus equipamentos de controle instalados e suas mitigações propostas (esses itens sofrem variações de acordo com a etapa do licenciamento requerida ao órgão ambiental). Desse modo, o técnico ambiental do órgão fiscalizador e regularizador analisa as tecnologias e o modo de exploração no qual o empreendimento se propõe a operar, aplicando normas e técnicas ambientais reguladoras, para que o empreendimento cause o menor dano ambiental possível. Fica evidente que os avanços científico-tecnológicos, somados ao aprimoramento dos sistemas de gestão e de legislação ambiental, são fundamentais para minimizar e controlar os impactos causados pela civilização humana, uma vez que é impossível evitá-los, dada a necessidade de produção, especialmente de alimentos.

Como aparato legal, em âmbito nacional, atualmente, pode-se citar a Política Nacional do Meio Ambiente, orientada pela Lei 12.651 de 25 de Maio de 2012, que norteia as demais Leis estaduais e municipais. No que diz respeito à preservação ambiental, essa Lei prevê para atividades potencialmente poluidoras o Licenciamento Ambiental, processo no qual são definidas ações mitigadoras e de controle ambiental para os impactos ambientais causados pela instalação e operação de empreendimentos poluidores (LEI. 12.651, 2012).

Com relação ao estado da Bahia, local onde está localizada a área de estudo desse esforço, temos o SEIA (Sistema Estadual de Informações Ambientais e de Recursos Hídricos) que é o principal instrumento de planejamento e execução das políticas e da regulação ambiental no Estado, fundamentado nas políticas estaduais de meio ambiente e de recursos hídricos. O sistema é norteado principalmente pela Lei Estadual nº 10.431/06 que dispõe sobre a Política de Meio Ambiente e de Proteção à Biodiversidade do Estado da Bahia e a lei nº 10.432/06 que dispõe sobre a Política Estadual de Recursos Hídricos, cria o Sistema Estadual de Gerenciamento de Recursos Hídricos (SEMA, 2016).

No que diz respeito às Linhas de Transmissão de Energia Elétrica (LTs) no território brasileiro, essas apresentam grandes extensões devido à longa distância entre as unidades produtoras de energia e os centros urbanos consumidores. Essas obras de engenharia podem apresentar impactos ambientais por um perímetro geralmente longo, que delimita toda a sua faixa de implantação; Esses impactos estão associados à fase de

implantação, período em que se têm as obras de instalação do empreendimento e na fase de monitoramento, período em que há o trânsito de veículos, máquinas e pessoas para a manutenção da infraestrutura instalada. Para analisar essas grandes áreas, os setores de planejamento, bem como os projetos de expansão do sistema elétrico, demandam informações espaciais precisas, elaboradas em formato digital ou mesmo em mapas impressos. A aplicação das geotecnologias pode significar um melhoramento nas análises espaciais do setor, tornando os processos de tomada de decisão mais rápidos, eficientes e menos onerosos. Uma forma mais rápida e econômica de resolver esse problema é fazendo uso de dados espaciais, como imagens digitais obtidas por Fotogrametria e/ou Sensoriamento Remoto.

A utilização desses produtos mais refinados no processo de modernização do setor elétrico, como as fotos aéreas e os produtos *Laser Scanner*, permitem resultados mais acurados em relação à identificação de feições referentes ao uso e ocupação do solo. Esses produtos de alta qualidade fazem com que se tenham, tecnicamente, ações rápidas e precisas em relação à mitigação e reversão de impactos ambientais de forma geral. Esse fator é importante, dado que as imagens e dados altimétricos de baixa resolução espacial não apresentam precisão nos resultados, especialmente em empreendimentos lineares, onde a faixa a ser trabalhada deve ser representada em grandes escalas. Produtos de baixa resolução podem ser utilizados apenas como indicador, necessitando, impreterivelmente, de verificações *in locu*.

Partindo da premissa de que hoje as áreas de planejamento, bem como projetos de expansão do sistema elétrico, abrem vista para outras modalidades de informações, tais como mapas/dados impressos, manuais e digitais, a aplicação de tecnologia informatizada, em conjunto com produtos cartográficos digitais de precisão/acurácia, como é proposto nesse estudo, pode significar um melhoramento nas análises espaciais do setor de energia elétrica, tornando os processos de tomada de decisão mais eficientes e menos onerosos.

## 1.1. OBJETIVOS

### 1.1.1. Objetivo Geral

O objetivo geral desse trabalho é identificar/detectar alvos (as áreas de solo exposto, que são indicativos eminentes de processos erosivos, e perda da cobertura

vegetal) indicadores de impacto ambiental em área diretamente afetada de LTs que são comumente exigidos nos diagnósticos e relatórios de Licenciamento Ambiental referente a esses empreendimentos.

### 1.1.2. Objetivos Específicos

Para que se alcance o objetivo geral, tem-se os seguintes objetivos específicos:

- Interpolação de dados LiDAR pelo método da “distância mínima ao quadrado”; com a utilização do software Spring; e aplicação desses dados nos Recortes 2 e 5.
- Classificação das imagens digitais ou ortofotos (Recortes 1 ao 5) e das ortofotos+LiDAR (Recorte 2 e 5), usando o classificador Máximaverossimilhança implementado no software Envi 4.8.
- Classificação das imagens digitais ou ortofotos (Recortes 1 ao 5) e das ortofotos+LiDAR (Recortes 2 e 5), com base em Redes Neurais Artificiais, também implementada no software Envi 4.8.
- Segmentação orientada ao objeto das imagens digitais ou ortofotos (Recorte 2) e ortofotos+LiDAR (Recorte 2), seguida da classificação dos segmentos pelo método do “vizinho mais próximo”, ambos implementados no software Envi EX.

## 1.2. JUSTIFICATIVA

Visando a diminuição dos impactos ambientais causados pelo setor de produção de energia elétrica no Brasil, em específico nos Biomas do Cerrado e da Caatinga, é necessário dado que o desenvolvimento de ferramentas computacionais possibilita a simplificação e rapidez nos processos de obtenção de diagnósticos ambientais e sociais.

O uso e a divulgação de imagens geradas por satélites multissensores, a melhoria da qualidade dos produtos oriundos da fotogrametria digital, os produtos altimétricos, gerados pela tecnologia LiDAR (Light Detection and Ranging), e avanços recentes na informática, podem trazer uma nova perspectiva de eficácia e rapidez de análise, referentes aos impactos ambientais causados por empreendimentos energéticos.

A metodologia proposta permite obter informações reais, com eficiência, sobre os fatores ambientais de relevância para os processos de licenciamento ambiental, ou seja, é uma ferramenta eficiente de diagnóstico de problemas ambientais das áreas de



instalação dos empreendimentos da Linha de Transmissão de energia elétrica, fazendo com que haja economia de tempo e recursos humanos para a realização de medidas de controle e mitigação.

É sabido que o setor de energia elétrica é fundamental para o desenvolvimento de um país. Contudo, existem formas (hidroelétrica, eólica, nuclear, solar, etc.) de geração de energia que causam mais ou menos danos ao ambiente. No Brasil, a maior fonte de geração de energia ainda é a hidroelétrica, o que pode causar grandes problemas ambientais se não forem tomadas as devidas providências, especialmente devido as grandes extensões de linhas de transmissão, que vão da fonte geradora até o usuário. Uma forma mais econômica de diagnosticar esses danos é fazendo uso da geotecnologias, mapeando grandes áreas com imagens de alta resolução e com variados sensores, como os dados analisados nessa pesquisa.

### 1.3. HIPÓTESE

Se mesmo oneroso e demorado, o monitoramento de todo e qualquer empreendimento de linha de transmissão de energia elétrica necessita de informações sobre os fatores ambientais de relevância para os processos de licenciamento ambiental; então uma forma mais rápida e econômica de identificação dos principais fatores ambientais do meio físico é por meio de técnicas apropriadas de classificação/segmentação e do uso de geotecnologias, com a integração de imagens de altíssima resolução espacial e dados altimétricos precisos; porque a utilização dessas técnicas e geotecnologias possibilita o estudo de grandes áreas, de forma automática, reduzindo os custos envolvidos nos processos convencionais de levantamento dessa informação (solo exposto e perda da vegetação nativa), como o deslocamento de equipes e equipamentos.

## 2. REFERENCIAL TEÓRICO

### 2.1. LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA

No que diz respeito às linhas de transmissão de energia, o Brasil é praticamente interligado por redes de transmissão de energia de Norte a Sul, com exceção dos

Estados do Amazonas, Roraima, Acre, Amapá, Rondônia, que ainda não fazem parte do sistema integrado de eletrificação nacional (ANEEL, 2016).

A complexidade do sistema permite que haja troca na geração e fornecimento de energia, o que é extremamente importante nos períodos de seca, quando os níveis dos reservatórios caem abruptamente. A LT é um sistema utilizado para transmitir energia elétrica de uma fonte geradora para os centros consumidores. A transmissão de energia elétrica é feita através de extensões de cabos, geralmente de alumínio, que são sustentados por grandes estruturas metálicas (torres) fixas ao solo; Estas podem ser encontradas em quatro tipos de capacidade, 138, 230, 345 e 750 KV Para cada tipo, aplica-se Normas de construção do projeto, principalmente a NBR 5422 (ANEEL, 2016).

As LTs aéreas, de corrente alternada e contínua, são obras de engenharia caracterizadas por linearidade de grandes extensões, e em geral passam por regiões de grande diversidade morfológica e com diferentes soluções, tanto na determinação de seu traçado, quanto na escolha das tecnologias necessárias á sua implementação. Devido a essas peculiaridades, apresentam desafios específicos e grandiosos dos pontos de vista logístico e de conservação ambiental (MENDES, SILVA; 2005).

Um projeto de instalação de LTs envolve uma série de fatores complexos, que devem ser analisados prematuramente por equipes multidisciplinares. Como fatores técnicos para a instalação podem ser citados: as características elétricas da linha (nível de tensão, potência, ampacidade, ruídos, nível de isolamento, cabos para-raios), topografia da região de interesse, características das fundações, travessias e questões econômicas de custo de implantação. O projeto é preconizado por Normas Técnicas rigorosas que necessitam ser observadas pelos profissionais envolvidos, em todos seus aspectos. Além disto, é importante enfatizar que o projeto de uma linha tem uma perspectiva mínima de trinta anos de utilização, o que faz com que restrições temporais de uso da linha também sejam determinantes (LABEGALINI et al. 1992). Na Figura 7 encontra-se uma das subestações de energia do trecho da linha de transmissão das cidades de Ibicoara/Brumado, uma torre e o segmento de linha de transmissão de energia elétrica.

FIGURA 1. Subestação de energia Ibicoara.



Fonte: Jornal digital Brumado Agora.

2.2. ÁREAS INFLUENCIADAS PELO EMPREENDIMENTO no que diz respeito à área de estudo, antes de sua escolha, foram realizadas pesquisas em trabalhos, Normas Técnicas, Resoluções, Leis e Documentos Ambientais, com o propósito de obter uma orientação de qual seria a real área interpretativa a respeito dos impactos ambientais causados pela operação/implantação de uma linha de transmissão de energia elétrica. Nesse levantamento de informações, alguns conceitos foram encontrados e serão debatidos nesse trabalho:

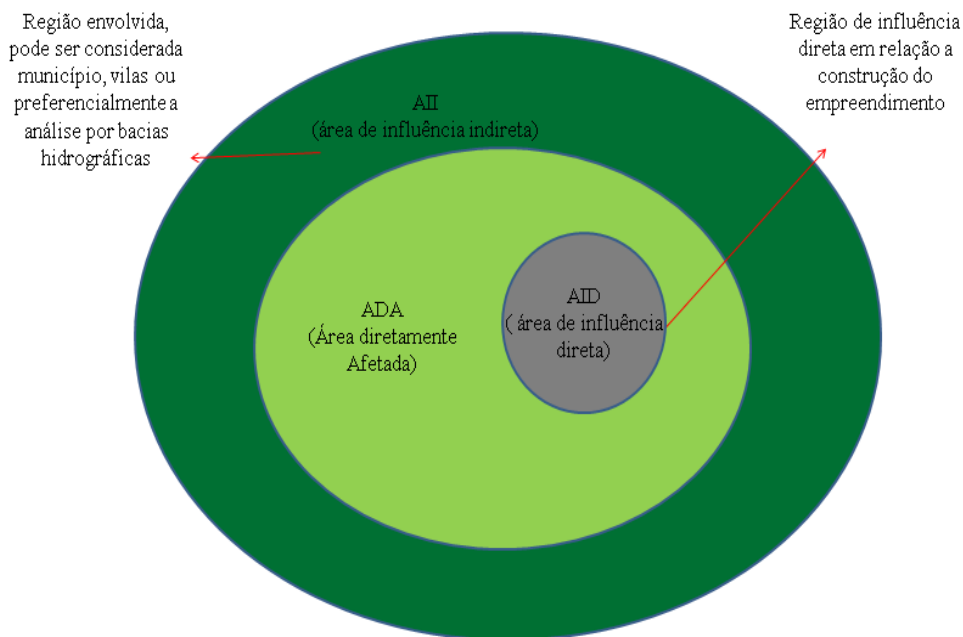
- **Faixa de Segurança:** A faixa também possui a nomenclatura de faixa de passagem; esta pode ser definida como faixa de domínio ou servidão.
- **Faixa de Domínio:** A faixa de domínio é a porção de Terras adquirida pela companhia proprietária do empreendimento e já possuidor da porção de Terra atravessada pela LT.
- **Faixa de Servidão:** Porção de uso restrito da faixa determinada. Esse uso não deve trazer malefícios à estrutura da LT em questão. A companhia proprietária não é obrigada a comprar essa porção de Terras.

A aquisição ou não da área na largura de faixa (enquadrando na faixa de domínio ou de servidão) está condicionada ao nível de tensão da linha de transmissão e ao sistema de conexão. As LTs com tensões maiores ou iguais a 230 kV, com conexão no Sistema Interligado Nacional (SIN), possuem faixa de servidão própria. A Largura da faixa de segurança é definida tecnicamente em função da tensão das linhas (Souza, 2012).

Tratando-se da análise de uso e ocupação do solo e havendo a necessidade de verificação de Impacto Ambiental, o conceito de faixa de segurança e a metragem usada em sua definição tornam-se ineficiente, dada a continuidade dos fatores envolvidos no processo. A faixa de segurança e sua metragem devem ser definidas, principalmente, pelos riscos que a LT pode causar à saúde da comunidade vizinha afetada.

Além dessas definições de faixas, trabalhos técnicos (EIAs- Estudos de Impacto Ambiental e RIMAs- Relatórios de Impacto Ambiental) e outros relacionados ao Licenciamento Ambiental definem outros termos como: “Área de Influência Indireta - AII”, “Área Diretamente Afetada - ADA” e “Área de Influência Direta - AID”. A primeira área é definida na Resolução CONAMA nº 305 de 2002 e é entendida como o local onde, usualmente, é determinado pela equipe especializada, o ponto do impacto ambiental do empreendimento; a ADA é um conceito criado por profissionais da área de meio ambiente, não há referências no que diz respeito à legislação, mas pode ser entendida como o local onde estão ocorrendo os primeiro impactos referente à instalação do empreendimento; Por fim, a Área de Influência Direta, é um conceito trabalhado na Resolução CONAMA nº 349 de 2004, que estabelece a área normalmente associada à região geográfica onde está instalado o empreendimento.

FIGURA 2. Esquema com AII, ADA e AID.



## 2.3. CLASSIFICAÇÃO E SEGMENTAÇÃO DE IMAGENS DIGITAIS

No que diz respeito às análises de imagens de satélites, o seu objetivo principal é a identificação e localização de objetos que tenham significado ao pesquisador. Existem dois grandes grupos a serem identificados: os primeiros são os ditos objetos (linhas, estradas, rios, córregos, etc.) o segundo, são as regiões (talhões de vegetação, agricultura, etc.). Os processos de identificação geram objetos formados por *pixels* descritos pelas suas geometrias e respostas espectral (ERTHAL et al, 1991).

Convencionalmente o padrão de análise digital tem sido a classificação realizada ponto a ponto o que considera exclusivamente atributos espectrais, ou seja, é considerada a intensidade dos níveis de cinza em diferentes bandas do espectro, esse padrão, portanto, também passa vir a ser um fator limitante (ERTHAL et al, 1991).

De acordo com Guimarães (2000), o mapeamento de uso e ocupação do solo faz se imperativo em um estudo de meio ambiente, à medida que essa análise requer o conhecimento da dinâmica natural de evolução do meio e da sua potencialidade de utilização. Nesse contexto esse trabalho visa trabalhar em seus objetivos gerais a melhor alternativa ao resultado mais contundente, experimentando técnicas computacionais utilizando a Classificação e a Segmentação de imagem. Segue descritas as técnicas que serão aplicadas.

### 2.3.1. Método da Máxima Verossimilhança - MaxVer

O método da Máxima verossimilhança já é tradicionalmente usado em trabalhos que envolvem imagens de digitais de Sensoriamento Remoto e/ou Fotogrametria. Porém há dificuldade em se encontrar artigos que utilizem esse método para a aplicação em Linhas de Transmissão de Energia. O método considera que a distribuição espectral dos *pixels* que formam as classes analisadas segue um padrão Gaussiano ou Normal (RIBEIRO; BAPTISTA e BIAS, 2015). O método de classificação Max Ver também pode ser entendido como o método de classificação, que considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos (INPE, 2006).

No que diz respeito à aplicação para estudos que envolvem Linhas de Transmissão de energia, Wosny, Oliveira e Santo (2005) aplicaram a metodologia de classificação da Máxima Verossimilhança, entre outros, em um estudo ambiental para a

identificação de irregularidades em trecho administrado pela Eletrosul; Em conclusão, não consideraram o resultado satisfatório, sendo a técnica aplicada em imagens Quickbird.

A classificação de Máxima Verossimilhança em Linhas de transmissão de energia, também foi trabalhada por Moraes (2011), com o propósito de se trabalhar avaliação temática em imagens RapidEye. O autor julga que a classificação apresenta resultados semelhantes ao método de segmentação e também não faz análises que despontam a um excelente resultado.


### 2.3.2. Método das Redes Neurais Artificiais - RNA

O sistema de Redes Neurais Artificiais (RNA) surgiu como uma área da informática cujo objetivo básico era criar modelos artificiais do cérebro humano, de forma a permitir que computadores “reproduzissem pensamentos”. A técnica tem a pretensão de replicar operações do cérebro humano que apenas utilizam como inspiração fatores conhecidos sobre o seu funcionamento, visando obter melhores desempenhos na resolução de problemas para os quais métodos tradicionais de computação têm se mostrado inadequados (MORAIS et al., 2009).

A RNA foi concebida para realizar tarefas complicadas, em diferentes áreas, como uma estratégia de modelagem matemática de problemas complexos. É modelada como um sistema de entradas e saídas. Ao contrário de outras estratégias de modelagem, não é necessário conhecer a relação matemática entre as entradas e saídas. Para atender essa premissa, uma RNA é constituída por unidades de processamento simples, chamados de neurônios artificiais, que calculam funções matemáticas às entradas recebidas, chamadas funções de ativação (SILVA; VIANNA e MORAES, 2012).

De maneira genérica, as RNAs consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos como o cérebro humano, até mesmo seu comportamento. Essa tarefa contempla o aprendizado, os erros, as novas tentativas, até que se chegue ao acerto ou próximo dele. Trata-se de técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma extensa rede neural artificial pode ter milhares de unidades de processamento (MOREIRA, 2005).

FIGURA 3. Exemplo de configuração de Redes Neurais Artificiais.




Fonte: (TAFNER, 1998)

O funcionamento ocorre como mostrado na Figura 1. Nessa configuração são fornecidos os dados para a “camada de entrada”, em seguida, internamente, há o processamento desses dados de entrada, segundo pesos pré-estabelecidos pelo usuário (camada intermediária); se o resultado for alcançado, há então a passagem do resultado para os neurônios de saída. Porém, se não houver sucesso no produto gerado, os dados retornam para processamento interno até obter um resultado satisfatório.

As Redes Neurais artificiais possuem uma infinidade de algoritmos para o trabalho de reconhecimento de padrões estatísticos, podem ser citados Kohonen, Perceptron, Adaline, Backpropagation entre outros. Tendo uma função cada uma. Com relação à Backpropagation, utilizada nesse trabalho, implementada no software Envi 4.8, tem-se como vantagem a solução de problemas “não linearmente separáveis”, o que alguns algoritmos não resolvem (LANHELLAS, 2016). Note que no problema representado na Figura 4 não há como separar o padrão “x” do padrão “o”, traçando um simples segmento de reta. Isso significa que o problema matemático não pode ser resolvido linearmente (LANHELLAS, 2016).

FIGURA 4. Exemplo matemático de problema não linearmente separável.



Fonte: (LANHELLAS, 2016)

O funcionamento de uma RNA no treinamento em backpropagation é realizado em duas etapas: A princípio é apresentado padrões de entrada na rede, a atividade flui entre as camadas ocultas, até que se tenha um dado de saída e, na segunda etapa, a primeira saída obtida é comparada com uma saída desejada e se essa saída estiver errada (um grande erro), o erro é recalculado e repropagado, até que se encontre uma saída desejada (CARVALHO, 2016).

Alguns softwares de processamento digital de imagens já têm o método de classificação por RNA implementado, por exemplo, os softwares: ENVI 5.0 e Idrisi. No Envi 5.0, a função utilizada é a “Backpropagation”, estruturada em camadas, com o sistema de propagação neural de aprendizado supervisionado.

Com relação a aplicações de Rede Neurais em classificação de imagens já existem uma gama de obras na literatura, como em Queiroz et al (2004), os quais realizam um estudo comparativo entre as classificações Max Ver e Rede Neurais, concluindo através do índice Kappa que os resultados são substanciais. Podemos citar ainda Ribeiro; Baptista e Bias (2007), que também comparam os dois métodos, mais agora para ambiente urbano, que aponta resultados melhores, porém demorados na utilização de Redes Neurais em relação a Max Ver. Cita-se também o trabalho realizado por Ribeiro e Centeno (2001), que confirmam a viabilidade de uso de Redes Neurais com trabalho no qual se tem um número reduzido de amostras.

Há também inúmeras aplicações na literatura se tratando de redes neurais na ciência da computação, engenharia de produção, ciências médicas entre outras, demonstrando que o processamento de imagens por Redes Neurais tem apresentado



excelentes resultados, permitindo a obtenção de informação processada para tomadas de decisão.

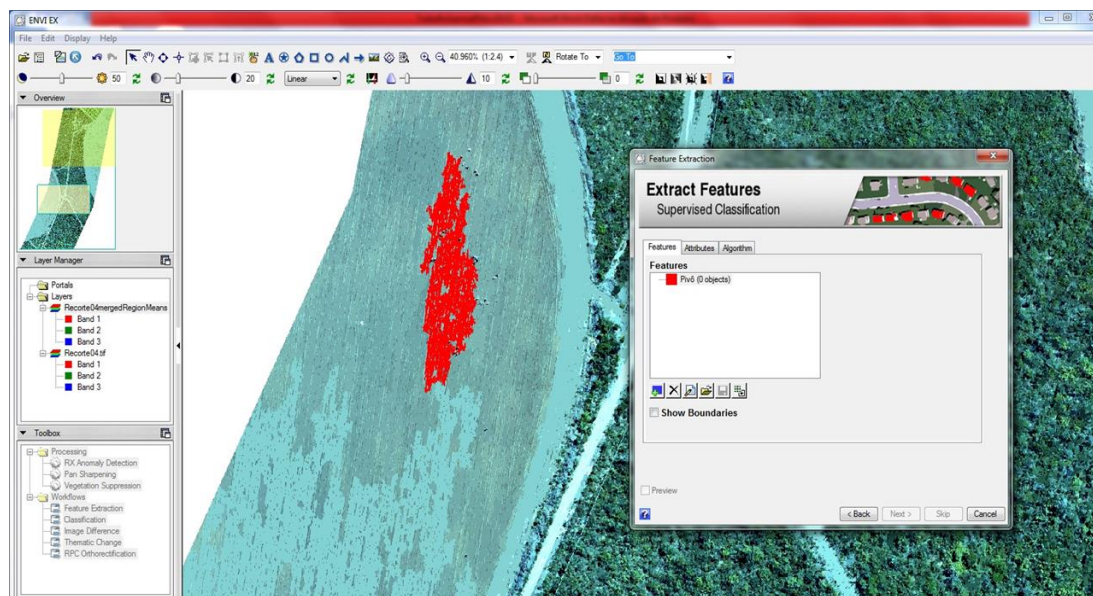
### 2.3.3. Método da Segmentação Orientada ao Objeto

Segundo Moreira (2003), a segmentação de imagens é um processo realizado anteriormente à classificação, que consiste em dividir a imagem em regiões homogêneas, ou seja, separar os atributos espectrais da imagem em regiões homogêneas. Isto é, unir os *pixels* que possuem características similares.

A técnica de segmentação é comumente tratada em dois formatos: *pixel-a-pixel* e orientada a objetos. A segmentação *pixel-a-pixel* utiliza apenas informações espectrais de cada *pixel* para localizar regiões homogêneas, podendo utilizar ou não a estatística. A outra forma de segmentação é com base no objeto, onde a análise é realizada sobre os objetos presentes na imagem, e não apenas nos *pixels*, levando em conta informações complementares como espacial, espectral, de textura e de forma (BERNADI et al., 2006).

A Figura 3 mostra um exemplo de objeto detectado após a segmentação da imagem.

FIGURA 5. Exemplo de objeto detectado por segmentação orientada ao objeto.



Fonte: O autor usando o software ENVI 5.0.

Um dos classificadores de segmentos mais utilizados no processo de segmentação é o *K-Nearest Neighbor* – KNN (vizinho mais próximo), devido à simplicidade matemática e à redução do tempo de processamento. O KNN foi sugerido por Cover e Hart (1966). Essa técnica é um método de estimação de densidade conceitualmente simplório e de fácil utilização. O algoritmo do vizinho mais próximo é uma técnica bastante simples, dividida principalmente em duas partes, onde a primeira refere-se à amostragem, onde as múltiplas amostras são inseridas em um plano n-dimensional, de acordo com seus atributos. A segunda parte consiste na classificação, onde os padrões a serem classificados são comparados com os amostrados e inseridos na classe do objeto com menor distância Euclidiana até ele (BEZERRA, 2006).

Com o surgimento dos novos sistemas de sensores aéreos e orbitais, os classificadores tradicionais, com abordagem “*pixel a pixel*” (Máxima Verossimilhança) e por regiões (Segmentação), vêm sendo alvo de diversos estudos comparativos. Esses estudos se justificam devido ao fato de o elevado grau de detalhes em imagens de alta resolução espacial apresentar uma grande confusão espectral causada pela repetição de alvos naturais e sintéticos, pela complexidade e heterogeneidade causadas por tamanho e formas diversas, e composições variadas.

Os usos da técnica de segmentação na literatura podem ser vistos em Oliveira (1999), Vasconcelos e Novo (2004), Oliveira e Silva (2005) e Sano (2008). Esses autores trabalharam a segmentação de imagens multiespectrais a fim de se obter resultado refinado a respeito do uso e ocupação do solo de regiões de estudo específicas. Nesses trabalhos foram utilizados parâmetros diversos, como o grau de similaridade, tamanho mínimo, textura e respostas espectrais. De maneira geral, a técnica de segmentação foi classificada nesses estudos como uma excelente ferramenta auxiliadora do processo de classificação, economizando tempo de processamento e trazendo resultados satisfatórios.

## 2.4. SISTEMA LASER SCANNER - LiDAR

O sistema LiDAR consiste em gerar basicamente coordenadas tridimensionais do objeto de interesse em um curto período de tempo. Para haver uma obtenção de dados acurados e precisos, é necessário obter-se uma sincronização ideal entre todo o sistema de obtenção de dados (BEIRÃO, 2011).


A tecnologia LiDAR é capaz de gerar rapidamente um denso e acurado modelo digital de terreno e/ou estrutura vertical de uma superfície. Para muitas aplicações que necessitam de alta acurácia nos modelos de elevação, a tecnologia LiDAR oferece

capacidades técnicas únicas: reduz custos de operações de campo e reduz o tempo e esforço de pós-processamento se comparado aos métodos de levantamento tradicionais. (SHAFER, 2004).

Como especificado por Centeno (2004), o sistema de varredura a laser é composto por três principais partes: a unidade de medição laser, encarregada de emitir e receber o sinal *Laser Scanner*, um sistema de varredura optomecânico e uma unidade de registro de medições de apoio.

Essa tecnologia emite o pulso a laser e é capaz de armazenar a resposta em três conjuntos distintos: primeiro pulso, último pulso e imagem de intensidade. O funcionamento dos pulsos pode ser entendido na Figura 4.

FIGURA 6. Escaneamento do terreno com Laser Scanner - LiDAR.



Fonte: Adaptado de Municípiã (2016) e Brandalize, (2004).

O produto das medições realizadas pelo sistema de varredura laser consiste em uma nuvem extensa e condensada de pontos de coordenadas tridimensionais (X, Y e Z), que são distribuídos de forma irregular na superfície do terreno, variando de acordo com o padrão de varredura (CENTENO e MITISHITA, 2007).

Com relação à precisão apresentada pelo sistema, ela pode ser relativa, de acordo com o modelo a ser trabalhado e de acordo com a precisão do GNSS que é utilizado. Em resumo, para X e Y a oscilação é de  $\pm 50$  cm e, em relação à coordenada Z, há uma variação de 10 a 15 cm.

A nuvem de pontos obtida deve ser processada de modo a gerar um Modelo Digital de Terreno (MDT), modelando a superfície de forma tridimensional. De maneira geral, o tempo utilizado para o tratamento, e posterior processamento dos dados, é extenso, devido ao esforço computacional de se interpretar a nuvem de pontos. Essa


nuvem de pontos é irregularmente distribuída na área de controle, necessitando que eles sejam alocados para uma grade regular, cujo tamanho dessa grade está relacionado com a densidade de pontos por  $m^2$  (DALMOLIN e SANTOS, 2004).

A transição da nuvem de pontos LiDAR para uma grade regular demanda a aplicação de um interpolador. Os métodos de interpolação, como definidos por Botelho et al. (2005), têm por finalidade atribuir valores a novos pontos locados em um campo de valores já existente, em que o resultado é apresentado em uma contínua malha de pontos, contendo, desse modo, os antigos e os novos pontos.

Os interpoladores, portanto, atribuem valores aos pontos interpolados com uma maior igualdade relacionada aos pontos mais próximos. Existem interpoladores já estudados e testados quanto a sua eficiência, sendo alguns deles já consagrados na literatura específica, como é o caso do vizinho mais próximo (VMP), inverso da distância elevado a uma potência (IDP) e krigagem. Os dois primeiros são mais simples matematicamente.

O método do vizinho mais próximo, aplicado ao processamento e formação da malha regular de pontos, se assemelha ao mesmo método utilizado para a classificação de imagens (Figura 7). Há a atribuição de pesos aos pontos mais próximos de cada nó. Quando regularmente espaçados, a utilização do método se torna eficiente para criar malha regular de pontos. É bastante eficaz para o preenchimento de lacunas faltantes de dados não exigindo potência do computador em seu processamento, já que os valores são apenas mudados de posição (MAZZINI e SCHETTINI, 2009).

FIGURA 7. Interpolação com o vizinho mais próximo.




Fonte: Castro (2015).

O método IDP estipula pesos aos pontos que são inversamente proporcionais à distância elevada a uma potência (Figura 6), que normalmente é quadrática. Esse

interpolador apresenta resultados satisfatórios mesmo tendo por base uma matemática simples (ISAAKS; SRIVASTAVA, 1989).

FIGURA 8. Interpolação com o inverso da distância.



Fonte: Castro (2015).

Por fim, a Krigagem é considerada na literatura uma eficiente metodologia de interpolação de dados. Ela utiliza o dado tabular e sua posição geográfica para calcular as interpolações. O método tem por base o princípio da Primeira Lei de Geografia de Tobler, que diz que as unidades de análise mais próximas entre si são mais próximas em valores, do que unidades mais distantes. A krigagem faz uso de funções matemáticas para acrescentar pesos maiores nas posições mais próximas aos pontos amostrais e pesos menores nas posições mais distantes, formando, desse modo, os novos pontos interpolados com base nas novas combinações lineares de dados.

### 3. MATERIAIS E MÉTODO

#### 3.1. ÁREA DE ESTUDO

Com relação à área estudada, são encontrados dois principais Biomas, o Cerrado, a Caatinga e espécies que apontam a presença de zonas de transição entre eles (RIMA- IBICOARA/BRUMADO, 2009).

Como segundo maior Bioma em extensão da América do Sul, e ocupando cerca de 22% do território do Brasil, o Cerrado abrange os estados do Goiás, Tocantins, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Bahia, Maranhão, Piauí, Rondônia, Paraná, São Paulo e Distrito Federal, além dos enclaves no Amapá, Roraima e Amazonas.

Possui excepcional importância, abrigando as nascentes das bacias hidrográficas da Amazônia, Tocantins, São Francisco e Prata. Essas bacias hidrográficas são de grande importância e também possuem a maior extensão hidrográfica da América do Sul. Os fatores de extensão, geologia, clima e hidrografia, caracterizam o Cerrado com exponencial importância perante aos seus recursos naturais. O principal ameaçador a essa riqueza tem sido principalmente a expansão agropecuária, sendo o plantio de grãos, o causador dos maiores desmatamentos (MINISTÉRIO DO MEIO AMBIENTE, 2016).

Em relação à Caatinga, pode-se destacar que é o único Bioma exclusivamente Brasileiro. Possui sua maior parte territorial na porção Nordeste do Brasil, ocupando uma área de aproximadamente 844.453 Km<sup>2</sup>. Possui uma grande riqueza a ser explorada pelo mundo científico; os seus aspectos naturais: fauna, flora, clima e solo e geologia, foram pouco explorados até então. É a região semiárida do globo terrestre com maior incidência de população humana, aproximadamente 27 milhões de pessoas. A degradação ambiental relacionada a esse Bioma está principalmente ligada aos desmatamentos para os fins energéticos e agrícolas (MINISTÉRIO DO MEIO AMBIENTE, 1996).

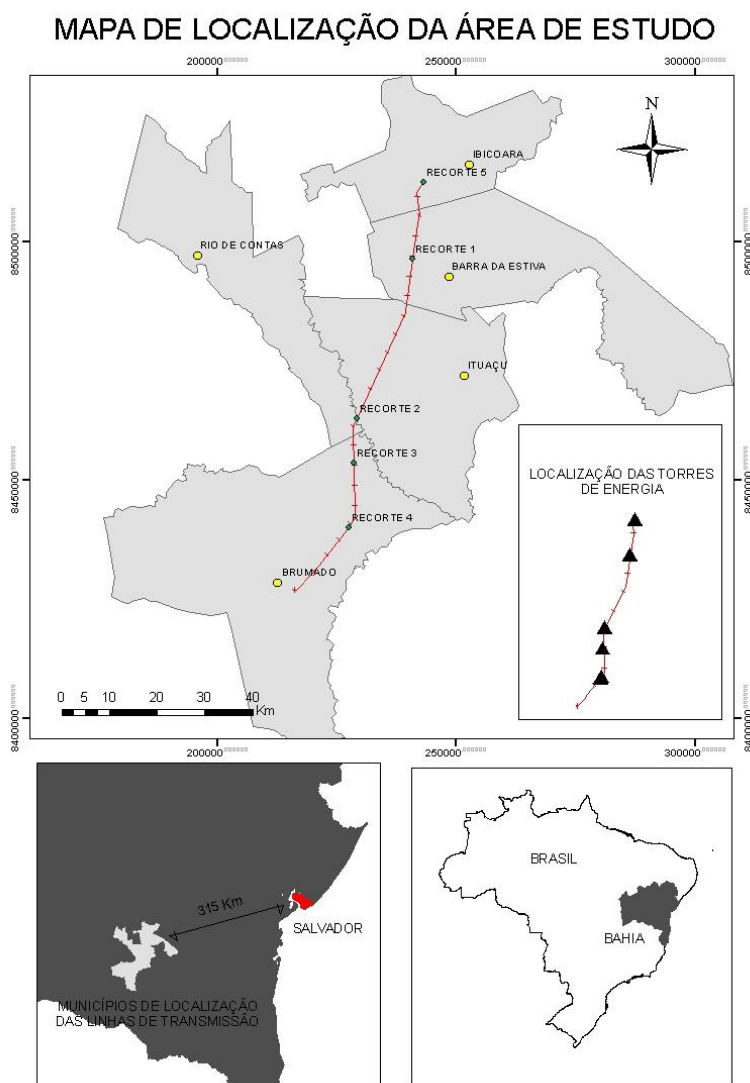
A manutenção desses Biomas deve ser assegurada em prol do equilíbrio ambiental da região. Equilíbrio esse que reflete diretamente na vida da população, em fatores como o uso da água, qualidade do ar e água, clima, entre outros. Desse modo, a visualização do cenário e a manutenção deste se torna essencial para a vida.

Com relação aos solos, esses merecem atenção especial. Na região são encontrados em sua maioria Latossolos Vermelhos- Amarelos Distróficos e Argissolos. Os solos encontrados são profundos, apresentam elevada porosidade e elevada capacidade de drenagem (RIMA- IBICOARA/BRUMADO, 2009). Essas características favorecem o aparecimento de processos erosivos quando associados a atividades antrópicas, como a que ocorre fortemente na região, em específico, as atividades agrícolas. Durante a elaboração desse trabalho, devido á alta resolução espacial e espectral das imagens trabalhadas, a classificação dos tipos de solo, foi um dos desafios encontrados; Sendo encontrado na mesma cena, porções de solos de horizontes superficiais vermelhos ou avermelhados, que são associados a solos com características mais argilosas e solos com aspecto acinzentado, que possuem média textura, caracterizados com a maior presença de areia.

As diferenças quanto à pedologia, são importantes ao se averiguar que solos com características mais arenosas são mais susceptíveis a processos erosivos ao invés de solos que possuem maior quantidade de argila em sua composição.

Assim, a área de estudo foi composta por cinco recortes/fragmentos que estão contidos no perímetro da Linha de Transmissão de Energia Elétrica de 230 kV - Ibicoara/Brumado (pertencente à CHESF), correspondente a 46,81Km. A LT em questão está a aproximadamente 315 Km de Salvador e corta o perímetro de cinco municípios do Estado da Bahia, de Sul para Norte: Brumado, Rio de Contas, Ituaçu, Barra da Estiva e Ibicoara. Está situada entre as coordenadas UTM WGS84 (Fuso 24L): (E=215488.00m, N=8426538.00m) - limite inferior, e (E=243117.00m e N=8513091.00m) - limite superior, como mostrado na Figura 9.

FIGURA 9. Localização da área de estudo.



Fonte: O Autor

### 3.2. MATERIAL UTILIZADO

Em consulta ao RIMA (Relatório de Impacto Ambiental), elaborado pela equipe Ingá Engenharia e Consultoria LTDA, referente ao empreendimento da LT do trecho Ibicoara\Brumado 230KV, observou-se que foi definida a AID com 40m, sendo 20m para cada lado do eixo principal da linha, e a Área Diretamente Afetada com 1000m, sendo 500m para cada lado do eixo principal.


Desse modo, a fim de se obter a melhor representatividade para um estudo de fatores ambientais de relevância, buscou-se o apoio, via projeto de pesquisa, da companhia CHESF (Companhia Hidroelétrica do Alto do São Francisco), para obtenção de imagens de alta resolução com a metragem de 500m para cada lado da linha. Devido à grande extensão e ao alto custo do material solicitado, foram cedidos pela CHESF trechos/recortes de 300m, sendo 150m para cada trecho da linha, o que já relata uma boa representatividade dos impactos gerados pela instalação/manutenção do empreendimento.

Os recortes foram escolhidos de forma a representarem locais com incidência de vegetação nativa (grande porte) de área de preservação permanente e reserva legal (mata ciliar), pontos com possível início de processos erosivos, e outras feições como solo exposto, cultivo, corpos d'água e pastagem (Consultar Figura 9).


Foram utilizadas fotos aéreas (RGB) de 5 (cinco) recortes da área de interesse (recortes 1, 2, 3, 4 e 5, mostrados na Figura 13, e dados LiDAR referentes às áreas dos recortes 2 e 5 (Figura 14). Os recortes 1, 2, 3, 4 e 5 possuem tamanhos de (6064x8628), (7922x9386), (5030x8026), (8886x9412) e (8403x9458) *pixels*, respectivamente. Todas as fotos possuem resolução espacial de 0,10m. As fotografias aéreas multiespectrais foram adquiridas já processadas, sendo somente realizadas correções quanto ao sistema de referência, transformado para o sistema WGS 84, que é compatível com o sistema de origem, o Sirgas 2000. Os recortes podem ser verificados na Figura 10, também é sinalizado o traçados da linha de transmissão e os pontos de localização das torres de energia.




FIGURA 10. Recortes das fotos aéreas utilizadas.



Recorte 1




Recorte 2



Recorte 3




Recorte 4



Portanto, destaca-se que foi utilizada uma faixa de aproximadamente 150 m para cada lado, com variedade de cobertura, mostrando o local onde ocorrem os impactos ambientais com maior relevância ao posicionamento do empreendimento. Foi mantido o conceito de Área Diretamente Afetada (ADA), como rege a legislação aplicável Resolução CONAMA nº 305 de 2002. Nesse local, geralmente há forte indícios de impactos ambientais recorrentes das atividades de instalação e manutenção de estruturas. Acredita-se que a ampliação do universo para aplicação das técnicas de classificação/segmentação permite uma melhor leitura geoespacial sobre os fatores ambientais e antrópicos de ocupação da região, de forma contínua, nos arredores das torres e das linhas.

Com relação aos dados *Laser scanner* (LiDAR), foram coletados com densidade de 15 pontos por m<sup>2</sup> e posteriormente reamostrado para uma grade com a mesma resolução espacial das fotos aéreas. A coleta foi realizada utilizando um aparelho sensor Optech ALTM Pegasus HD500 sensor que foi calibrado para coletar em densidade de 15 pontos/m<sup>2</sup>. Esse equipamento pertence à empresa Lactec/ UFPR, responsável pelo levantamento na área. Salienta-se que todo o material foi cedido pela Companhia Hidroelétrica do

FIGURA 11. Imagem com os dados LiDAR dos Recortes 2 (b) e 5 (a).



( a )

( b )

A Tabela 1 mostra os dados técnicos de dimensão referentes às imagens apresentadas na Figura 11.

TABELA 1. Tamanho e áreas das fotos aéreas usadas.

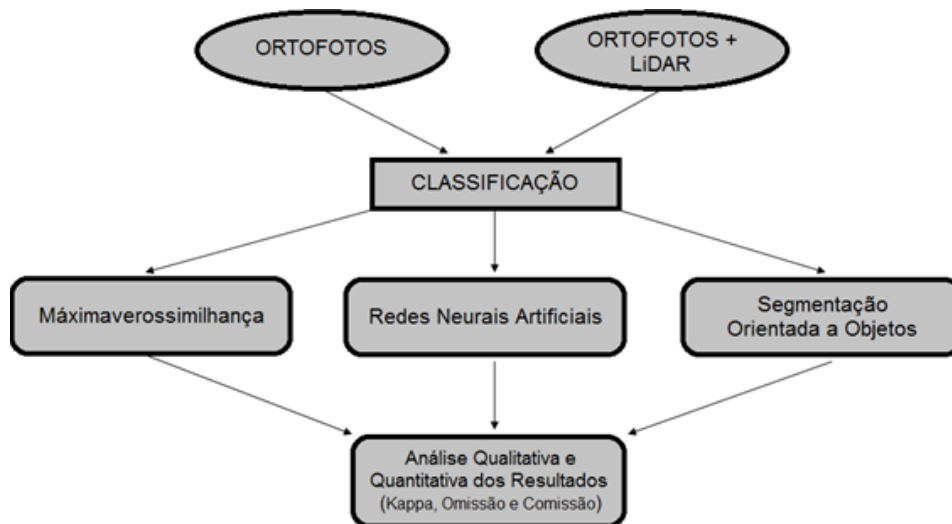
Recorte	Largura da AID (m)	Lado (nº de <i>pixels</i> )	Altura (nº de <i>pixels</i> )	Tamanho <i>pixel</i> (m)	Área (ha)
1	300	6.064	8.628	0,1	26,16
2	300	7.922	9.386	0,1	37,17
3	310	5.030	8.026	0,1	20,18
4	300	8.886	9.412	0,1	41,81
5	300	8.403	9.458	0,1	39,73

Foram utilizados os softwares de processamento digital de imagens ENVI 4.8, ENVI 5.0 e ENVI EX, comercializados pela empresa SulSoft. Para a montagem de um banco de dados e pré-análises da região de estudo, foi utilizado o software ArcGis 10.0, desenvolvido pela empresa *Environmental Systems Research Institute* (ESRI), ambos adquiridos pela Universidade Federal de Uberlândia e instalados no laboratório SIGEO, do curso de Engenharia de Agrimensura e Cartográfica. Alguns tratamentos dos dados foram realizados em softwares livres como o SPRING-5.2.6 e o QGis. A base cartográfica (levantamento topográfico) com o posicionamento das torres e as linhas de energia foram cedidas pela CHESF.

### 3.3. MÉTODO

Para identificar os fatores causadores de impactos ambientais de interesse, na AID da LT (230 KV) Ibicoara/Brumado, a metodologia proposta foi dividida em cinco etapas, como mostra o fluxograma descrito na Figura 12.

FIGURA 12. Fluxograma do método proposto.



A primeira etapa refere-se à preparação dos dados, especialmente a interpolação dos dados LiDAR para geração de uma grade regular com espaçamentos de 0,10 metros. A segunda etapa consiste na classificação das imagens multiespectrais dos cinco recortes (Recortes 1, 2, 3, 4 e 5) da área de estudo, utilizando o classificador da Máxima-verossimilhança, somada com a classificação, usando o mesmo classificador, das duas imagens referentes aos Recortes 2 e 5, porém integradas com os dados *Laser Scanner*.

A terceira etapa foi executada com os mesmos dados (imagens e LiDAR) e experimentos da etapa anterior, porém o processo de classificação teve por base as Redes Neurais Artificiais (RNA), configuradas para esse fim. A quarta etapa trata da segmentação orientada a objeto da imagem correspondente ao recorte 2, com e sem dados LiDAR, seguida de uma classificação de segmentos utilizado o método do “vizinho mais próximo”. Por fim, a última etapa refere-se à análise e comparação dos resultados obtidos com os algoritmos testados.

### 3.3.1 Definição das Classes Usadas no Processo de Classificação

Na área de estudo foram observadas formações do Cerrado e de Caatinga e zonas de transição entre estes. No trecho de Ibicoara até os municípios que compõem a área chamada de Serra Geral, observa-se o Cerrado com áreas de transição para Campo Rupestre, Campo Sujo e o Cerrado *Stricto Sensu*.

O Campo Sujo ocupa grande extensão territorial ao longo do traçado de implantação da LT, juntamente com a formação de Campo Limpo, podendo ser encontrada em todo o trecho entre a subestação de Ibicoara até as bordas da Serra. O Campo Limpo é predominantemente herbáceo, com raros arbustos, ausência completa de árvores e apresenta composição florística bem variável. O Cerrado *Stricto sensu* constitui-se de plantas arbustivas-arbóreas, adaptadas ao ambiente seco, com caules e galhos grossos e retorcidos, distribuídos de forma esparsa, intercalada por uma cobertura de ervas, gramíneas e espécies semi-arbustiva.

O Cerrado *Stricto sensu* está presente no alto da Serra das Almas (maior altitude) e em alguns morros, em áreas de transição com a Caatinga. A foto abaixo (Figura 10) foi tirada pela equipe do EIA/Rima Ibicoara/Brumado, onde pode ser verificado as transições de vegetação.

FIGURA 13. Foto com a presença de Campo Limpo, Vegetação de Caatinga e Vegetação de transição.





Ainda em relação às formações encontradas na área, no que tange aos corpos hídricos de maior volume, foram verificadas vegetação do tipo de Mata de Galeria, Mata Ciliar e espécies de transição Cerrado/Caatinga (Figura 14).

FIGURA 14. Foto mostrando vegetação de Mata de Galeria e Mata Ciliar.



Relacionado á Caatinga, encontra-se vegetação Arbórea e Arbustiva (árvores e arbustos distribuídas espaçadamente), como mostra a Figura 12, em praticamente toda a área de estudo. Estas formações estão bastante relacionadas à presença de aglomerações humanas (pequenas vilas) ou projetos agropecuários. Essas aglomerações ali estabelecidas provavelmente encontraram situação adequada para a confirmação dessas atividades.

FIGURA 15. Foto com a presença de Vegetação Densa de Caatinga arbustiva.



Diante da particularidade dos Biomas Cerrado e Caatinga existentes na área de estudo, apresentadas em detalhes nesse texto, em seção oportuna, foram definidas as seguintes classes para o processo de classificação/segmentação:

- **Campo Limpo:** Classe composta por Cerrado *Stricto Senso*, Talhão de Agricultura, Campo Limpo, Campo Rupestre (Cerrado) e Campo Sujo.
- **Vegetação de Caatinga/ Vegetação de Transição:** Classe composta por Vegetação de Caatinga e Vegetação de transição do Cerrado.
- **Vegetação Densa:** Classe composta por Mata Seca e Cerradão.
- **Mata Ciliar:** Classe composta por Mata de Galeria e Mata Ciliar.
- **Edificações:** Classe composta por Estrutura da Subestação de energia (Válido para a metodologia aplicada no Recorte 5) e telhado (Válido apenas para o método de Segmentação aplicado no Recorte 2).
- **Solo Exposto:** Classe composta por Áreas degradadas, Solo Exposto.
- **Sombra:** Classe composta por *Pixels* correspondentes ao efeito de sombreamento de objetos como a vegetação e edificações.
- **Água:** Classe composta por Água.

A Figura 16 mostra a legenda usada no processo de classificação com suas respectivas cores e nomes.

FIGURA 11. Legenda usada nas classificações.



Esse estudo foca a maior discussão em torno da presença das classes que apontam a presença de vegetação nativa e/ou remanescente, que são as classes: Vegetação Densa + Vegetação de Caatinga e a classe Solo Exposto, por apontarem os fatores de interesse relacionados aos Impactos Ambientais ocorridos por processos naturais ou antrópicos em virtude da presença das estruturas da Linha de Transmissão de energia elétrica.

### 3.3.2. Avaliação dos Resultados

Os resultados foram analisados com base nos erros de comissão (acurácia do usuário), omissão (acurácia do produtor) e índice kappa. Os erros de inclusão/comissão referem aos *pixels* atribuídos a uma determinada classe, oriundos de erros de classificação das outras classes. A acurácia do produtor refere-se aos erros de exclusão/omissão; isto é, os *pixels* de uma determinada classe são atribuídos erroneamente a outras classes. O índice kappa é utilizado para a verificação global de concordância entre as amostras de referência das classes usadas e os resultados dos classificadores usados. Os erros de comissão ( $E_c$ ) e omissão ( $E_o$ ) e o índice kappa ( $k$ ) são determinados, respectivamente, pelas equações 2, 3 e 4.

$$E_c = \frac{X_{+i} - X_{ii}}{X_{+i}} \quad (2)$$



$$Eo = \frac{X_{i+} - X_{ii}}{X_{i+}} \quad (3)$$

$$k = \frac{N \cdot \sum X_{ii} - \sum X_{i+} \cdot X_{+i}}{N^2 - \sum X_{i+} \cdot X_{+i}} \quad (4)$$

Onde,  $X_{ii}$  é a concordância observada na diagonal da matriz confusão, na posição  $i$ ;  $X_{i+}$  e  $X_{+i}$  são a soma da linha e coluna  $i$  da matriz confusão, respectivamente; e, juntos, são os produtos marginais ou a concordância esperada; e  $N$  é o total de elementos/*pixels* observados.

A confiabilidade dos resultados obtidos nesse estudo foi analisada de acordo com os intervalos dos valores de kappa propostos por Landis e Koch (1977), conforme Tabela 2.

TABELA 2. Valores de concordância com base no índice Kappa.

Índice Kappa (k)	Concordância
0,00	Pobre
0,00 a 0,20	Ligeira
0,21 a 0,40	Considerável
0,41 a 0,60	Moderada
0,61 a 0,80	Substancial
0,81 a 1,00	Excelente

### 3.3.3. Interpolação dos Dados LiDAR

No presente estudo, o interpolador utilizado para geração do MDT (Modelo Digital do Terreno) foi inverso da distância ao quadrado (IDP). Esse método atribui maior peso aos pontos mais próximos ao local da interpolação, o que satisfaz a premissa da originalidade dos dados utilizados, como mostra a Equação 6. Nesse método é calculada a distância entre todos os pontos mais próximos e é adotado o valor do ponto cuja distância for menor.

$$\hat{Z}_i = \frac{\sum_{j=1}^n \left[ \frac{1}{d_{eij}^2} \cdot Z_j \right]}{\sum_{j=1}^n \left[ \frac{1}{d_{eij}^2} \right]} \quad (6)$$

onde  $\hat{Z}_i$  é o valor interpolado;  $Z_i$  é o valor do atributo amostrado; e  $d_{ij}$  é a distância euclidiana entre o ponto amostrado e o estimado, calculada pela equação 7.

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (7)$$

onde  $d_{ij}$  é a distância euclidiana entre o ponto amostrado e o estimado;  $x_i, x_j, y_i, y_j$  são coordenadas dos pontos.

Os dados de levantamento LiDAR usados nessa pesquisa correspondem ao último retorno de pulso laser, fazendo com que assim exista uma maior homogeneidade nas altitudes coletadas pelo sistema LiDAR.

O processamento foi realizado no software SPRING-5.2.6 no qual os dados originais foram importados por meio de um arquivo com formato (.txt) e, posteriormente, esses dados foram transformados em uma grade regular de pontos com espaçamento de 0,1m, sendo que esta etapa gastou aproximadamente 37 horas de processamento. A grade regular de pontos foi salva no formato (.raw), com o intuito de facilitar o intercâmbio dos dados processados com outros softwares. A imagem contendo os dados altimétricos com alta resolução (0,1m) foi gerada no software ENVI-5.0 e, posteriormente, feito um recorte para somente a área de interesse.

#### 3.3.4. Classificação por Máxima Verossimilhança - MaxVer

Para a classificação por Máxima Verossimilhança foi utilizado o programa ENVI 4.8; que faz uso do algoritmo proposto por Richards (1999), definido pela Equação 8.

$$g_i(x) = \ln(p(w_i)) - \frac{1}{2} \cdot \ln(|\Sigma_i|) - \frac{1}{2} \cdot (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (8)$$

onde,  $i$  corresponde a  $i$ -ésima classe em análise;  $x$  é o vetor  $n$ -dimensional das observações (em classificação de imagens,  $x$  é o valor do *pixel* e  $n$  é o número de bandas),  $p(w_i)$  representa a probabilidade de determinada classe ocorrer na imagem em análise (essa probabilidade é assumida para todas as classes definidas na classificação),

$|\Sigma_i|$  é o determinante da matriz variância-covariância,  $\Sigma_i^{-1}$  é a inversa da matriz variância-covariância, e  $m_i$  é o vetor de médias das classes em análise.

Na metodologia de classificação de Máxima Verossimilhança é pressuposto que as estatísticas em cada classe, cada banda, serão normalmente distribuídos, fazendo com que todos os *pixels* sejam classificados, a menos que seja estabelecido um limite. Cada *pixel* é classificado na classe de maior probabilidade.

No programa ENVI 4.8, ao se iniciar a tela para a classificação em Máxima Verossimilhança, nas opções para dados de área em Thershold, é oferecida opções de configuração. Nessa dissertação será trabalhada a configuração de valor único, que representa um limiar único para todas as classes. Desse modo não há limitação de *pixels* na classificação.

### 3.3.5. Classificação por Redes Neurais Artificiais - RNA

Essa etapa foi realizada no software ENVI 5.0, que oferece alternativas de configuração da RNA backpropagation para a classificação de imagens. Segue uma explanação a respeito dos parâmetros utilizados, tendo por base o manual *online* da *Exelis* e/ou próprio tópico de ajuda do programa.

O parâmetro “Limiar de Contribuição” é utilizado no ajuste de pesos interno de um nó, na interação em questão. O algoritmo de treino ajusta os pesos entre os nós de forma iterativa e, de forma opcional, os limiares de nó, para que haja a minimização do erro entre a camada de saída e o resultado desejado. Quanto menor o valor desse parâmetro, menor o ajuste e regularização, maior as generalizações e mais pobres serão os resultados.

Outro parâmetro importante que o software permite configurar é a “Taxa de Treinamento” que determina a velocidade do treinamento. Quanto maior a taxa, maior a velocidade e maior a possibilidade de erros e generalizações. Quanto menor a taxa, menor a velocidade do treinamento, e maior a possibilidade acertos.

O “Momento de Treinamento” é o parâmetro que determina a “Taxa de Impulso”. Seu efeito é a mudança ao longo da direção de classificação. Quanto maior a taxa, menor é a oscilação.

Um dos critérios de parada do treinamento é o valor do “RMS” (Root Mean Square). O valor atribuído a esse parâmetro determina o valor/erro limite que as iterações devem atingir. Ao alcançar esse erro limite, o processamento para e o

resultado encontrado é tido como produto final. Quanto menor esse valor, mais acurado é o resultado.

Com relação ao “Número de Camadas Ocultas”, esse parâmetro é utilizado para indicar o tamanho da rede, em termos de camadas. Um aumento no valor desse parâmetro não indica necessariamente melhoria no resultado. É preciso ser analisado com cautela em cada caso estudado. O valor 1 (um), indicando uma única camada oculta/intermediária, já atende a maioria dos casos. Além de apresentar bons resultados, ainda reduz o tempo de processamento. Quando a classificação for linear, indica que não há necessidade de camadas ocultas, atribuindo valor 0 (zero) a esse parâmetro, mas quando houver a necessidade de separação de classes distintas, deve-se colocar camadas intermediárias, atribuindo, assim, 1 (um) ou superior ao referido parâmetro.

O “Número de Iterações de Treinamento” diz respeito à quantidade de iterações que serão realizadas, até que o processo seja encerrado. Quanto maior o número de iterações, mais tentativas de obtenção de melhores resultados e maior será o tempo de processamento.

Com relação ao “Limite Mínimo de Ativação de Saída”, esse parâmetro delimita o valor de ativação do *pixel* a ser classificado. Assim, se o valor do *pixel* for inferior, o mesmo não será classificado.

Nesse estudo foram utilizados os valores dos parâmetros apresentados na Tabela 3.

TABELA 3. Valores aplicados aos parâmetros da RNA.

<b>Critério</b>	<b>Valores adotados</b>
Ativação	Logística
Treinamento de Contribuição Theshold	0.900
Treinamento de taxa	0.200
Treinamento de Momento	0.900
Treinamento RMS Critério de Saída	0.100
Camadas Ocultas	1
Número de Treinamento	400
Valor Mínimo de Ativação de Saída	Não Preenchido

### 3.3.6. Classificação Usando Segmentação Orientada a Objeto

O processo de segmentação e classificação dos segmentos detectados foi realizado no software ENVI EX. Nesse software é necessário o fornecimento de pelo menos 6 (seis) parâmetros para a execução da segmentação. O primeiro parâmetro diz

respeito à “Escala” na qual o agrupamento de *pixels* será segmentado. Quanto maior o valor desse parâmetro maior a tentativa de aglomeração e, por consequência, maior será a área dos aglomerados.

Em relação ao parâmetro “Nível de Fusão”, ele é utilizado para demonstrar em que grau devem ser aglomerados os segmentos de *pixels* anteriormente criados. Quanto maior seu valor, maiores serão os blocos/aglomerados criados. Portanto, esse parâmetro deve ser definido tendo em mente o tamanho do objeto de interesse, para que esse objeto não seja aglutinado com outros.

Na etapa seguinte “Encontrar Objetos” tem-se duas opções: “Com-Limiar” e “Sem-Limiar”. A função “Com-Limiar” trata de um novo método de fusão/aglomeração para refinar o resultado da segmentação obtida no passo anterior. É útil na extração de feição pontual, como um edifício. A opção “Sem-Limiar” desconsidera a execução da função “Com-Limiar”.

Os próximos parâmetros referem-se aos atributos relacionados aos aspectos dos objetos: espectral (máximo, mínimo, média e desvio padrão em cada banda), textura (conjunto, média, variância e entropia), espacial (área, comprimento, compactação, convexidade, solidez, forma e alongamento, dentre outros) e customizado (razão de bandas e sistema IHS). Cada um dos atributos tem importância particular, como a textura na identificação de vegetação densa e a forma na identificação de áreas com cultivo, que são geralmente retangulares/talhões ou circulares/pivôs.

Nesse estudo foram utilizados todos os parâmetros relacionados às características do objeto: espectral, textura e espacial, por entender que todas elas são importantes no processo de identificação das feições de interesse (solo exposto e vegetação). Adicionalmente, foi escolhida a opção “Sem-Limiar”, uma vez que não existe interesse em feição pontual. Os valores atribuídos à “Escala” e “Fusão”, respectivamente, foram 30 e 90. Uma descrição geral dos parâmetros usados pode ser vista na Tabela 4.

TABELA 4. Valores e atributos utilizados no processo de segmentação.

<b>Critério</b>	<b>Valores adotados</b>
Escala	30
Fusão de Segmentos	90
Sem-Limiar (No Thersholding)	Assinalado
Espectral	Assinalado
Textura	Assinalado

Após a segmentação inicia-se o processo de classificação dos segmentos. O ENVI EX apresenta dois classificadores para essa função que são: o *K-Nearest Neighbor* e o *Support Vector Machine* (SVM). No método de classificação *K Nearest Neighbor* a dimensão espacial “n” é definida pelo número de atributos de objetos utilizados durante a classificação. A escolha do valor ideal do parâmetro K depende do conjunto de dados e dos dados de treinamento, onde valores maiores tendem a reduzir o efeito de ruído dos valores extremos (ENVI EX, 2015).

Nesse estudo foi utilizado o método do Vizinho Mais Próximo. Na classificação por KNN foram utilizados os valores 30 e 1 para os parâmetros “Limiar - Thershold” e “Vizinhança – Neighbors”. No que diz respeito ao Limiar/Thershold, quanto maior o valor, maior o índice de confiança das interações em relação ao vizinho mais próximo. Quanto ao valor atribuído ao parâmetro “Vizinhança”, quanto maior o valor, maior a interação com a vizinhança, o que pode reduzir a chance de erros.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. CLASSIFICAÇÃO POR MAXVER USANDO SOMENTE FOTOS

Nesse tópico foram realizados cinco experimentos usando as cenas/recortes do trecho da LT-Ibicoara/Brumado, apresentadas na Figura 13. A discussão acerca desses experimentos teve por base os erros de Comissão, Omissão e o índice Kappa, sendo analisado o uso, cobertura e ocupação do solo, com ênfase nas classes de interesse que são aquelas que apontam a presença de vegetação nativa, remanescente ou em recomposição.

A Tabela 5 apresenta as áreas de cada feição correspondente ao uso, cobertura e ocupação da superfície terrestre, presente nos 5 recortes em estudo. Em uma análise global, estatisticamente verifica-se a superioridade da área coberta por “Vegetação de Caatinga/Vegetação de Transição”, representando 35% da área total analisada. Com menos representatividade, tem-se a classe “Água” e “Edificação” que, juntas, não alcançaram 1% da área total. Destaca-se que foi criada a classe “Fundo”, representando o “Back Ground” das cenas/ imagens. Essa classe, no entanto, foi excluída da análise de uso, cobertura e ocupação do solo. Embora não represente um objeto específico, a classe

“Sombra” não será excluída das análises, tendo em vista que também está se averiguando a capacidade de classificação dos métodos.

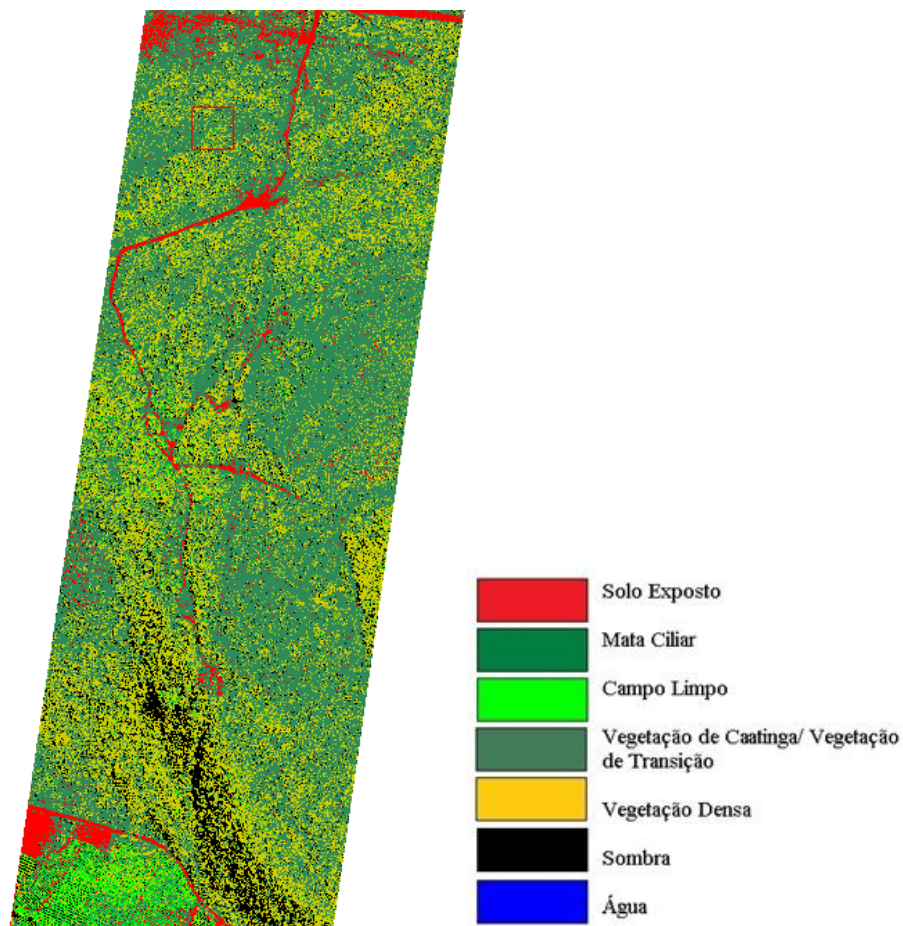
TABELA 5. Áreas (em hectares) dos Usos de Solo dos 5 Recortes.

Classe	Rec. 1	Rec. 2	Rec. 3	Rec. 4	Rec. 5	Total	%
Mata Ciliar	0,00	2,55	0,00	1,47	0,00	4,02	3
Vegetação Densa	7,07	0,00	1,17	0,00	1,67	9,93	7
Campo Limpo	5,08	6,96	1,18	20,19	0,00	33,43	23
Vegetação de Caatinga/Transição	11,83	12,74	11,75	3,52	11,74	51,59	35
Solo Exposto	0,30	7,97	16,08	7,38	8,65	40,40	28
Sombra	0,00	0,11	1,18	1,41	0,032	2,75	2
Água	2,03	1,03	0,00	0,00	0,00	3,06	0
Edificação	0,00	0,00	0,00	0,00	0,00	0,89	0

Em uma análise visual e com base nos dados estatísticos de classificação do Recorte 1 (Figura 17), a classe dominante é a “Vegetação de Caatinga/Vegetação de Transição” e a classe “Solo Exposto” é a que possui menor área. Se contabilizadas todas as classes que somam a vegetação, tem-se uma porcentagem de 68% (Tabela 2), o que denota a um aspecto conservacionista do Recorte analisado.

No primeiro recorte (Recorte 1) o índice Kappa medido foi de 0,8422, o que caracteriza a classificação como “Excelente”, segundo Tabela 2 de concordância dos valores Kappa. A imagem classificada, referente ao Recorte 1, pode ser verificada na Figura 17.

FIGURA 12. Imagem classificada referente ao Recorte 1 (MaxVer).



Ressalta-se que a legenda de classes apresentada na Figura 17 é válida para todas as imagens classificadas nesse estudo. Com relação aos processos erosivos, ligados à classe “Solo Exposto”, nota-se regiões potenciais ao Norte da imagem (Figura 17), áreas que devem ser investigadas atentamente pelos técnicos responsáveis. Também há, próximo aos locais de instalação das torres, áreas que possuem o potencial de evolução desse fenômeno, merecendo medidas de contenção.

As feições “Vegetação Densa” e “Vegetação de Caatinga/ Vegetação de Transição” apresentaram maior erro referente à Comissão (Tabela 6), indicando uma confusão espectral entre as duas classes, em conjunto com a classe “Campo Limpo”. Esse erro se dá devido à similaridade da resposta espectral dos alvos/vegetação, em ambas as classes, presentes na imagem analisada. O primeiro recorte (Recorte 1) apresenta uma infinidade de tons de verde, tornando difícil a segregação entre as feições da classe vegetação. Em relação à Omissão, a classe “Vegetação de Caatinga/Vegetação de Transição” foi a que apresentou maior índice, relatando uma certa confusão na classificação dos *pixels* dessa classe em outras classes.

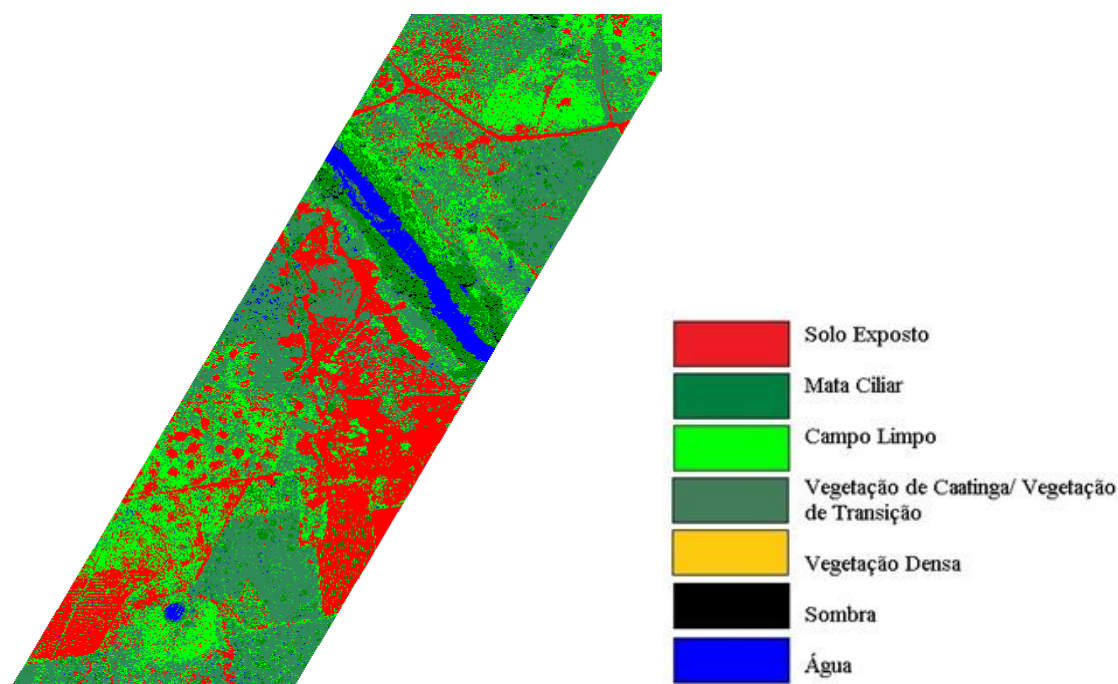


TABELA 6. Erros de Comissão e Omissão - Recorte 1 (MaxVer).

Classes	Comissão (%)	Omissão (%)
Vegetação Densa	40,91	26,42
Campo Limpo	3,41	5,03
Vegetação de Caatinga/ Vegetação de Transição	30,00	39,66
Solo Exposto	0,00	0,00
Sombra	0,00	0,00

Em relação á segunda imagem (Recorte 2) classificada (Figura 18), as classes “Solo Exposto”, “Campo Limpo”, “Vegetação de Caatinga/ Vegetação de Transição” e “Corpos Hídricos” apresentaram, visualmente, resultados satisfatórios. A vegetação de “Mata Ciliar” foi identificada com precisão, permitindo a análise da defasagem de cobertura vegetal, segundo a legislação ambiental vigente, o Código Florestal nº 12.651 de 2012. Nesse caso, em específico, como o curso d ‘água possui metragem maior que 10 metros, a APP (Área de Preservação Permanente) deveria ter 50 metros, o que não ocorre na imagem classificada, que apresenta uma APP variações entre 35 e 40 metros de largura. Nesse tipo de análise em corpos hídricos (APP), o conhecimento sobre a legislação atual e o histórico da área se faz necessário para a decisão sobre os procedimentos de recuperação ambiental na área de preservação.

FIGURA 13. Imagem classificada referente ao Recorte 2 (MaxVer).



Nesse mapa temático (Recorte 2), o índice Kappa calculado foi de 0,9583, o que classifica a segmentação como “Excelente”, segundo a referência de concordância (Tabela 2).

A Tabela 5 mostra as áreas de cada feição correspondente ao uso, cobertura e ocupação do solo, presente no Recorte 2. Nesse mapa temático a feição “Vegetação de Caatinga/Vegetação de Transição” é predominante, ocupando 12,74 ha da área total analisada nesse recorte/ imagem. A feição com menor relevância é a classe “Água”, com 1,03 ha.

As feições “Água” e “Vegetação de Caatinga/Vegetação de Transição” apresentam maiores erros de Comissão (Tabela 7), indicando que 71,13% de suas áreas foram afetadas/somadas, erroneamente, com *pixels* de outras classes. É visível na Figura 18, nas duas margens do rio, que a feição “Água” recebeu vários *pixels* erroneamente de outras classes. Por outro lado, cinco classes apresentaram 0% de Omissão, são elas: “Mata Ciliar”, “Campo Limpo”, “Vegetação de Caatinga/Vegetação de Transição” e “Solo Exposto”, apontando que nenhum ou poucos *pixels* de outras classes tenham sido inseridos nessas feições. Todas as classes, com exceção da “Sombra”, apresentaram relativamente baixos valores de erros de Omissão, o que significa que quase todos os *pixels* verdadeiramente pertencentes a essas classes foram rotulados corretamente.

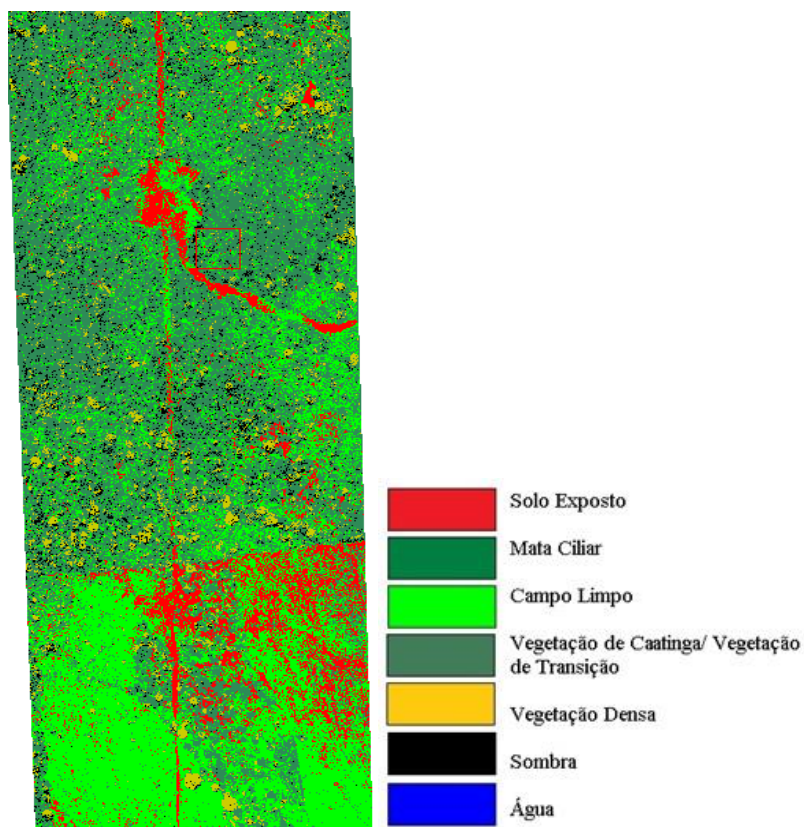
TABELA 7. Erros de Comissão e Omissão - Recorte 2 (MaxVer).

Classes	Comissão (%)	Omissão (%)
Mata Ciliar	2,37	0,00
Campo Limpo	8,23	0,00
Vegetação de Caatinga/ Vegetação de Transição	14,29	0,00
Solo Exposto	0,00	0,00
Sombra	0,00	47,19
Água	5,35	3,04

Na terceira imagem (Recorte 3) classificada (Figura 19), nota-se um predomínio das áreas de “Vegetação de Caatinga/Vegetação de Transição” e “Campo Limpo”. Destaca-se que o classificador deu ótima resposta na separação dessas duas classes; isso se deu, especialmente, pela diferença significativa de tonalidade das classes. Nas regiões Sul e Leste da imagem, os fragmentos de pastagem, que são enquadrados em “Campo Limpo”, foram visualmente bem identificados. Nesse recorte, a categoria “Vegetação Densa” foi a menos expressiva da classe de cobertura vegetal. Para uma

análise comparativa, os valores de áreas das feições “Vegetação de Caatinga/Vegetação de Transição” e “Vegetação Densa” são 11,75 ha e 1,17 ha, respectivamente.

FIGURA 14. Imagem classificada referente ao Recorte 3 (MaxVer).



O índice Kappa, medido na classificação do Recorte 3, foi de 0,8156, colocando a classificação também na classe “Excelente”, com padrões mínimos de aceitação. As classes “Campo Limpo” e “Vegetação de Caatinga/Vegetação de Transição” apresentaram maior erro referente à Comissão (Tabela 8), indicando uma confusão na distinção dessas classes entre si e com as demais classes existentes na cena.

TABELA 8. Erros de Comissão e Omissão - Recorte 3 (MaxVer).

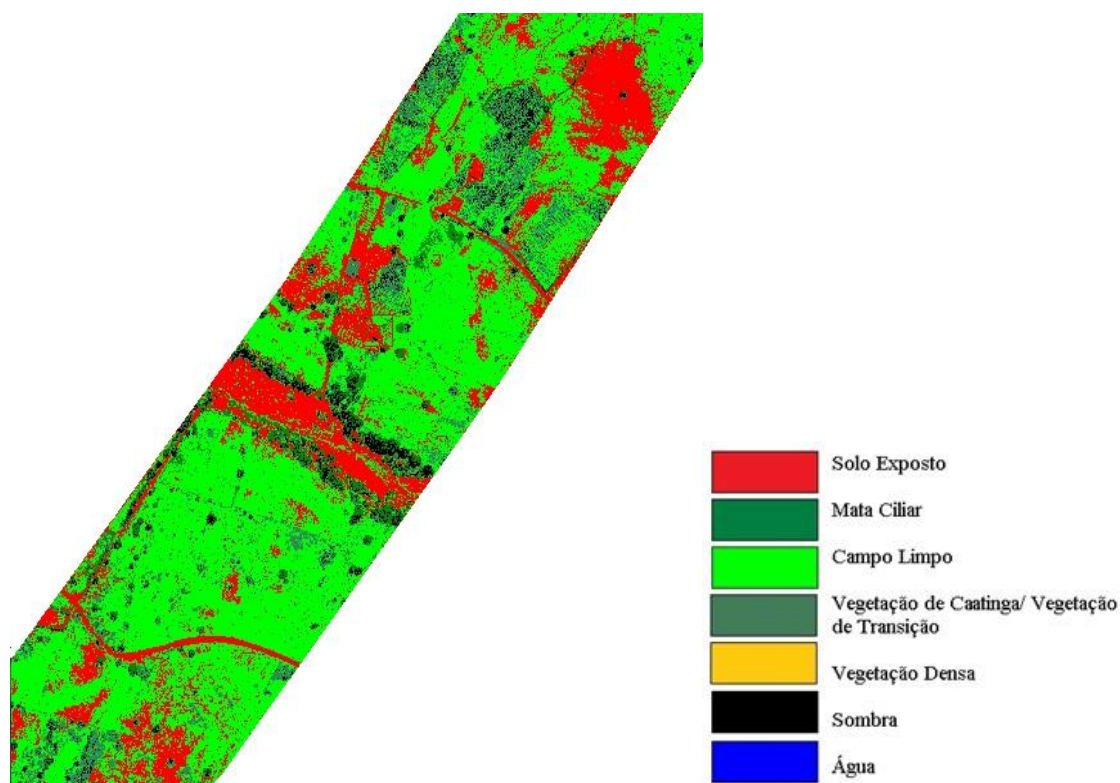
Classes	Comissão (%)	Omissão (%)
Vegetação Densa	0,00	10,00
Vegetação de Caatinga/Vegetação de Transição	37,12	18,49
Campo Sujo	25,37	0,00
Solo Exposto	0,00	25,89
Sombra	0,00	15,73

Nos locais onde estão locadas as Torres, verifica-se a predominância de aberturas na vegetação, feitas de maneira intencional para instalação e manutenção dessas estruturas. Percebe-se também a existência de trechos com solo exposto nas proximidades das torres, com ocorrências mais fortes nas classes “Vegetação de Caatinga/Vegetação de Transição” e “Campo Limpo”. São pontos que merecem atenção especial, pois possuem potencial para o desenvolvimento de processos erosivos.

Em relação à Omissão, somente a classe “Vegetação de Caatinga/Vegetação de Transição” não apresentou problemas. Os maiores erros de Omissão ocorreram nas classes “Solo Exposto”, “Campo Limpo” e “Sombra”. Em relação ao “Solo Exposto” e “Campo Limpo” o erro ocorreu nas áreas com pastagem, onde a feição não é totalmente pura, confundindo espectralmente essas duas classes.

Com relação às percepções referentes à classificação (Figura 20) da quarta imagem (Recorte 4), a grande variabilidade de tonalidades, alusivas principalmente ao “Solo Exposto”, fizeram com que, nesse trecho da linha de transmissão, fossem realizados vários testes a fim de se obter o melhor resultado. Os testes foram realizados alterando as diferentes classes de “Solo Exposto” existentes. A imagem resultante apresenta a predominância de “Campo Limpo” e “Solo Exposto”, mostrando o potencial uso antrópico da região. Percebe-se a ausência de vegetação nativa no entorno do curso d’água presente na cena, havendo a necessidade de recomposição vegetal da APP, segundo legislação vigente, de aproximadamente 50 metros para cada margem.

FIGURA 15. Imagem classificada referente ao Recorte 4 (MaxVer).



No resultado obtido com o recorte 4, o índice Kappa foi de 0,9935, classificando o resultado como “Excelente”. Com relação à Comissão (Tabela 9), apenas “Campo Limpo” e “Vegetação de Caatinga/ Vegetação de Transição” apresentaram valores não nulos, porém de baixa magnitude, mostrando a eficiência do classificador.


TABELA 9. Erros de Comissão e Omissão - Recorte 4 (MaxVer).

Classes	Comissão (%)	Omissão (%)
Mata Ciliar	0,00	0,00
Campo Limpo	8,70	0,00
Vegetação de Caatinga/ Vegetação de Transição	2,60	1,32
Solo Exposto	0,00	0,43
Sombra	0,00	4,08

Em relação à Omissão, o maior erro encontrado foi o valor referente à feição “Sombra”, com 4,08%. Devido aos baixos valores de erros de Comissão e Omissão e o alto valor de Kappa, essa imagem apresentou a melhor resposta em relação aos três outros recortes estudados.

No resultado obtido com o Recorte 5, o índice Kappa foi de 0,9805, indicando uma excelente classificação em termos gerais. A imagem classificada pode ser observada na Figura 21.

FIGURA 16. Imagem classificada referente ao Recorte 5 (MaxVer).



Com relação à Comissão (Tabela 10), apenas as classes “Vegetação de Caatinga/Vegetação de Transição” e “Vegetação Densa” apresentaram valores não nulos, sendo a classe “Vegetação de Caatinga/Vegetação de Transição” identificada com o valor de 38,58%, relatando a dificuldade do classificador ao lidar com esse tipo de cena. É realmente uma cena que apresenta grande confusão espectral, dificultando até a coleta de amostra homogênea. Visualmente, pode-se perceber na Figura 21 a mistura espectral da classe “Edificação” com a classe “Solo Exposto”, especialmente na região mais ao Norte da imagem. Os valores nulos de erros de Comissão e Omissão da classe “Edificação” retratam o cuidado que se deve ter na escolha das amostras de validação e na análise da matriz confusão.

TABELA 10. Erros de Comissão e Omissão - Recorte 5 (MaxVer).

Classes	Comissão (%)	Omissão (%)
Vegetação Densa	7,22	18,15
Solo Exposto	0,00	0,00
Vegetação de Caatinga/ Vegetação de Transição	38,58	18,69
Sombra	0,00	0,00
Edificação	0,00	0,00

Em relação à Omissão, o maior valor medido foi para a classe “Vegetação de Caatinga/Vegetação de Transição”, com 18,69%, muito próximo do valor encontrado na classe “Vegetação Densa” cujo o valor foi de 18,15%. As outras duas classes presentes na cena tiveram os erros de omissão nulos. A classe “Edificação” foi altamente afetada pela Omissão, o que é perceptível visualmente na Figura 21, especialmente em áreas com solo exposto.

Com relação às diversas tonalidades encontradas para a mesma classe, como a classe “Solo Exposto”, as amostragens foram parceladas em diversas classes, tais como “solo 1”, “solo 2”, “solo n” e somadas posteriormente. Também como observações gerais, tem-se que devido à alta resolução espacial das imagens/fotos, a definição isolada das classes “Vegetação Densa”, “Campo Limpo” e “Vegetação de Caatinga/Vegetação de Transição” tornaram-se difíceis. A respeito das edificações, essas são impossíveis de serem isoladas como única classe, já que é a resposta se aproxima da classe “Solo Exposto”. Como observado, a classe “Sombra” apresenta os *pixels* relacionados ao sombreamento da imagem, ganhando destaque em relação às outras cenas analisadas.

A análise global do uso, cobertura e ocupação do solo é de suma importância para a identificação dos pontos de maior fragilidade ambiental do empreendimento instalado. De maneira sucinta, os pontos de fragilidade ambiental dizem respeito aos impactos físicos. Ocorrem principalmente em relação à vegetação e ao solo exposto. Em uma análise ambiental geoespacial podem ser observados três principais fatores: as características de vegetação, quantidade de solo exposto e o alto índice de uso antrópico, como a utilização agrícola ou movimentações relacionadas à manutenção das torres na região.

De acordo com a Tabela 5, a área estudada possui 51,5902 ha de “Vegetação de Caatinga/Vegetação de Transição”, sendo a classe dominante nas áreas analisadas, o que mostra um aspecto de conservação ambiental relevante na região. A região estudada possui como segunda e terceira classe dominante o “Campo Limpo” e “Solo Exposto” relatando a importância e representatividade do uso antrópico.

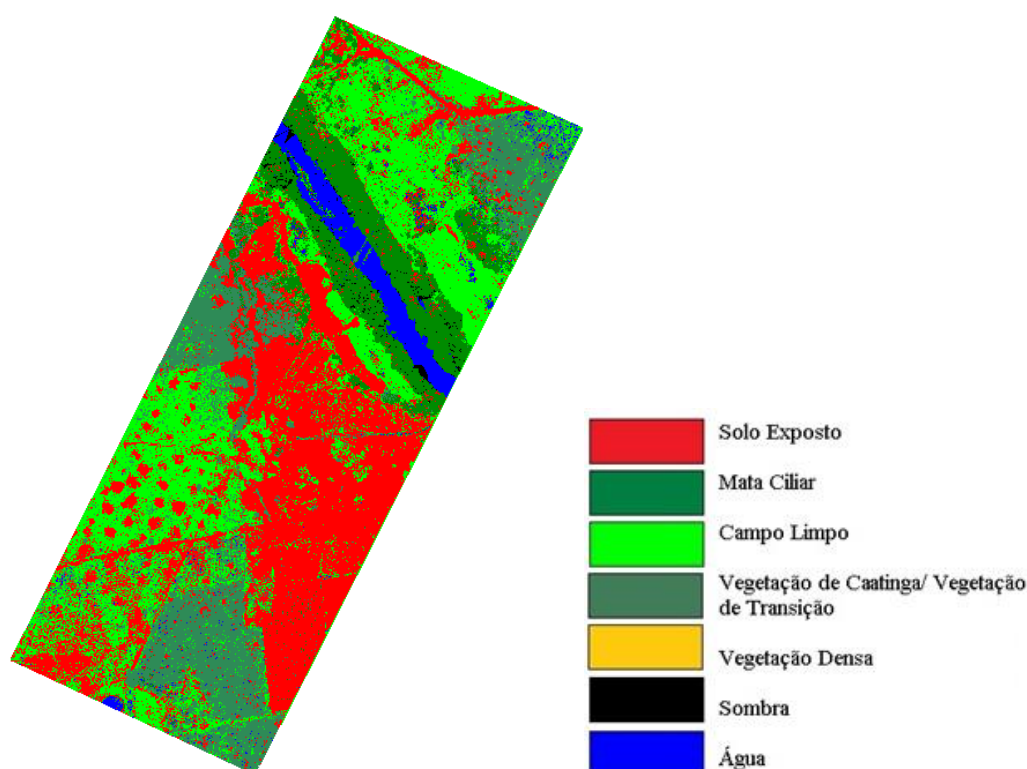


#### 4.2. CLASSIFICAÇÃO POR MAXVER USANDO FOTOS E DADOS LiDAR

Nesse tópico serão realizados testes em dois recortes (Recortes 2 e 5) com a utilização dos dados *Laser Scanner* do trecho Ibicora/ Brumado. Os resultados serão analisados segundo os erros de Comissão, Omissão e índice Kappa.

No resultado obtido com o Recorte 2 (Figura 22), o índice Kappa medido foi de 0,9735, valor que indica uma excelente classificação em termos gerais, segundo a Tabela 2. Segue imagem classificada para verificação.

FIGURA 17. Imagem classificada referente ao Recorte 2 (MaxVer – Fotos/LiDAR).



Com relação à Comissão (Tabela 11), destaca-se a classe “Sombra” com 42,21%; índice que denota um alto índice de erro na classificação. Atribui-se a essa correlação o fato de que a classe “Água”, em alguns pontos, apresenta resposta espectral semelhante à classe “Sombra”. Com relação ao erro de Omissão tem-se o maior valor na classe “Mata Ciliar”, com 6,88%. Esse erro denota a confusão realizada frente aos *pixels* de vegetação nessa cena. Com relação à identificação visual dos alvos, a imagem apresenta boa aglomeração relacionada a classe “Solo Exposto” e classes relacionadas a vegetação, facilitando, assim, a análise de uma equipe de campo para verificar as razões pelo qual a área apresenta pontos de impacto ambiental.




TABELA 11. Erros de Comissão e Omissão - Recorte 2 (MaxVer com Foto/LiDAR).

Classes	Comissão (%)	Omissão (%)
Mata Ciliar	0,89	6,88
Campo Limpo	0,00	0,49
Vegetação de Caatinga/ Vegetação de Transição	0,13	0,00
Solo Exposto	0,02	0,00
Sombra	42,21	1,94
Água	0,00	0,04

O índice Kappa medido no mapa temático referente ao Recorte 5 foi de 0,9498. Esse valor indica uma excelente classificação, em termos gerais, segundo a Tabela 2. A classificação pode ser verificada na Figura 23.

FIGURA 18. Imagem classificada referente ao Recorte 5 (MaxVer – Fotos/LiDAR).



Com relação à Comissão (Tabela 12), a única classe a apresentar erro diferente de zero foi a classe “Vegetação de Caatinga/Vegetação de Transição”, que apresentou o erro de 18,54%. Esse erro expressa que 18,54% dos *pixels* de outras classes foram classificados erroneamente nessa classe.

TABELA 12. Erros de Comissão e Omissão - Recorte 5 (MaxVer com Foto/LiDAR).

<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Vegetação Densa	0,00	16,10
Solo Exposto	0,00	0,00
Vegetação de Caatinga/ Vegetação de Transição	18,54	0,00
Sombra	0,00	0,00
Edificação	0,00	0,11

Em relação à Omissão, foram encontrados os valores de 16,10% para “Vegetação Densa” e 0,11% para a classe “Edificação”. Destaca-se que pela primeira vez dentre as metodologias testadas a classe “Edificação” apresentou erros em uma das variáveis analisadas. Essa ocorrência do erro de Omissão mostra o ganho com o uso do dado LiDAR, que aponta os *pixels* que deixaram de ser rotulados como “Edificação”.

Com relação a identificação visual dos alvos relacionados ao “Solo Exposto”, ponto de investigação devido ao impacto ambiental gerado pela instalação do empreendimento (Subestação de energia), a classificação com a utilização dos dados *Laser Scanner* foi eficiente, relatando com bastante precisão os pontos de interesse. Em relação aos alvos da classe “Vegetação Densa”, o talhão principal, encontrado na imagem, visualmente foi muito fragmentado, havendo uma confusão entre a classe “Vegetação Densa” e Vegetação de “Caatinga/Vegetação de transição”.

#### 4.3. CLASSIFICAÇÃO POR RNA USANDO SOMENTE FOTOS

Nesse tópico serão realizados testes nos cinco recortes/cenas do trecho da LT - Ibicoara/ Brumado. Os resultados serão analisados segundo os erros de Comissão, Omissão e o índice Kappa, como feito na seção anterior. A Tabela 13 mostra as áreas, em hectares, correspondente a cada classe analisada, em cada recorte/cena estudado.

TABELA 13. Áreas (em hectares) das classes obtidas com a classificação por RNA.


	Rec. 1	Rec. 2	Rec. 3	Rec. 4	Rec. 5	Total	%
Mata Ciliar	0,00	2,08	0,00	6,10	0,00	8,18	6
Vegetação Densa	2,12	0,00	1,53	0,00	1,36	5,03	4
Campo Limpo	0,90	2,80	10,6	12,91	0,00	27,25	19
Vegetação de Caatinga/ Vegetação de Transição	17,52	7,97	7,88	4,58	7,72	45,69	33
Solo Exposto	1,47	15,14	2,49	10,38	12,70	42,21	30
Sombra	4,29	2,00	1,69	0,00	0,091	8,08	6
Água	0,00	1,37	0,00	0,00	0,00	1,37	1
Edificação	0,00	0,00	0,00	0,00	1,08	1,08	1

A Tabela 13 apresenta as áreas de cada feição correspondente ao uso, cobertura e ocupação do solo presente nos 5 recortes trabalhados. Tem-se, em nível de importância, a classe “Vegetação de Caatinga/Vegetação de Transição”, com 33 % de ocorrência, representando a maior classe e relatando o relativo aspecto conservacionista do trecho que é cortado pelas linhas de transmissão de energia. Destaca-se, porém a representatividade da classe “Solo exposto” com 30% de ocorrência, relatando uma porcentagem significativa de uso/ocupação, que necessita ser verificada, somadas às áreas que foram possivelmente desnudas devido ações antrópicas, o que pode resultar em impacto ambiental significativo.

Na classe “Campo Limpo” é verificada a presença de talhões de Agricultura, o que permite concluir que trechos da Área Diretamente Afetada possuem sim características antrópicas de ocupação, sendo passível de atenção por parte da empresa CHESF e pelas autoridades envolvidas.

Partindo para análise das classificações, o coeficiente Kappa, referente ao Recorte 1, apresentou valor de 0,7632, o que classifica o mapa temático como uma classificação Substancial. Pode-se observar, visualmente, na Figura 24 que as classes de vegetação deram grande contribuição para os baixos valores de Kappa para esse recorte.

FIGURA 19. Imagem classificada referente ao Recorte 1 (RNA).



Com relação aos erros de Comissão (Tabela 14) para este recorte, tem-se que o maior erro de Comissão trata-se da classe “Vegetação de Caatinga/Vegetação de Transição”, com 47,25% de erro, e o menor erro refere-se à classe “Sombra”, com 0,0%. Em relação aos erros de Omissão, o maior erro está relacionado com a classe “Vegetação Densa”, com 75,47%. Essa classe apresentou o maior erro de Omissão até aqui na pesquisa, demonstrando certa fragilidade em relação aos métodos de classificação utilizados.

TABELA 14. Erros de Comissão e Omissão - Recorte 1 (RNA).

<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Vegetação Densa	38,10	75,47
Campo Limpo	5,65	10,33
Vegetação de Caatinga/ Vegetação de Transição	47,25	17,24
Solo Exposto	13,58	0,00
Sombra	0,00	0,00


Em relação à classe “Vegetação de Caatinga/Vegetação de Transição”, é sabido que se trata de uma classe complexa, caracterizada por vegetação de pequeno e grande porte, além de área mais densa e outras bem esparsas, o que a caracteriza sem um

padrão bem definido. Devido a essa complexa formação da classe “Vegetação de Caatinga/Vegetação de Transição”, torna-se fácil a confusão espectral com a classe “Vegetação Densa”.

A classe “Solo Exposto” foi bem definida no mapa temático resultante, mostrando que a RNA é eficiente na classificação desse tipo de feição. Percebe-se áreas descobertas tanto ao Norte quanto ao Sul da cena/recorte. Os 13,58% de erro de comissão deve-se, provavelmente, à confusão espectral com áreas de pastagem/cultivo, em que alguns *pixels* dessas feições foram inseridos na classe “Solo Exposto”.

Com o Recorte 2, o índice Kappa medido foi de 0,9709; o que classifica o resultado como Excelente. Essa leitura global do resultado demonstra que o mapa temático obtido é preciso. A Figura 25 mostra o resultado desse experimento.

FIGURA 20. Imagem classificada referente ao Recorte 2 (RNA).



Com relação à classificação do Recorte 2, com a utilização do método de RNA, nota-se, visualmente, uma forte segmentação dos alvos analisados. As classes “Solo Exposto” e “Vegetação Nativa” se tornaram de difícil identificação quanto à relação com alvos passíveis de investigação devido ao interesse Ambiental.

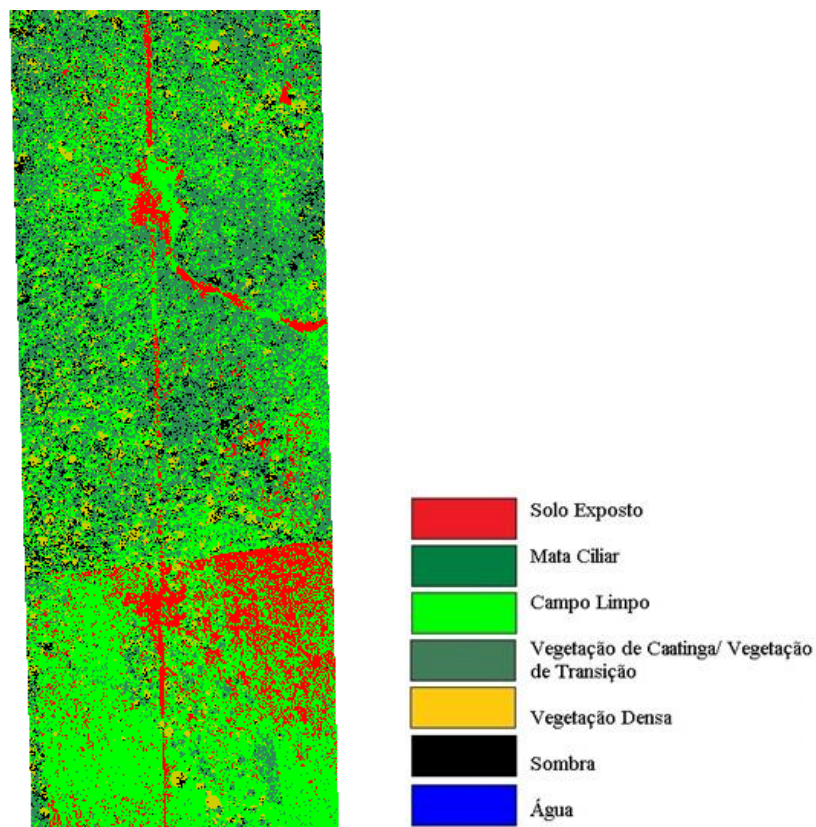
Tratando-se dos índices de Comissão, tem-se com maior índice a classe “Mata Ciliar”, com 15,82% (Tabela 15). Isso demonstra que essa porcentagem de *pixels* foi inserida incorretamente dentro da Classe “Mata Ciliar”. Com relação a Omissão, teve-se como classe predominante a classe “Sombra”, com 47,19%. Essa condição demonstra o quanto de *pixels* foram omitidos, ou seja, não classificados em relação a essa classe em análise. Destaca-se que essa cena/imagem, em específico, possui uma grande complexidade no que se refere às respostas espectrais dos alvos, apresentando diversas tonalidades de cores, tornando a classificação bastante complexa. Houve nessa imagem a não identificação de alguns *pixels*, sendo classificada como classe “não-classificada”, para efeito dessa pesquisa esses dados foram descartados.

TABELA 15. Erros de Comissão e Omissão - Recorte 2 (RNA).

<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Mata Ciliar	15,82	0,00
Campo Limpo	1,36	0,00
Vegetação de Caatinga/ Vegetação de Transição	0,00	22,73
Solo Exposto	0,00	0,20
Sombra	0,00	47,19
Água	0,30	0,31

O método de classificação por RNA teve muitas dificuldades em diferenciar as classes presentes no Recorte 3. O índice Kappa medido foi de apenas 0,5390, notificando a classificação como Moderada, de acordo com os critérios da Tabela 2. Em uma análise visual, nota-se uma fragmentação exacerbada dos alvos de uso, cobertura e ocupação da superfície terrestre, não sendo bem delimitado, principalmente as categorias relacionadas à vegetação. Os alvos tiveram um aspecto de “pulverizados” em meio a distribuição das classes, o que não necessariamente demonstra classificação errônea, visto a alta resolução espacial e espectral da imagem, salientando a necessidade de visitas de campo como perspectivas futuras da realização desse trabalho. A classificação pode ser verificada na Figura 26.

FIGURA 21. Imagem classificada referente ao Recorte 3 (RNA).



Com relação aos erros de Comissão, embora a a classe “Vegetação Densa” tenha apresentado valor nulo, as outras duas classes relacionadas à vegetação nativa apresentaram altos valores desse erros (Tabela 16): “Campo Limpo” com 77,07% e “Vegetação de Caatinga/Vegetação de Transição” com 23,39%. Essa questão prejudica parcialmente a análise proposta nesse estudo, de verificação das classes correspondentes à vegetação nativa e ao “Solo Exposto”, pois a classe “Solo Exposto” também apresentou alto valor de erro de Comissão (58,10%). Isso significa que as áreas medidas para essas classes não são verdadeiras, dado que muitos *pixels* foram inseridos erroneamente nas referidas classes.

TABELA 16. Erros de Comissão e Omissão - Recorte 3 (RNA).

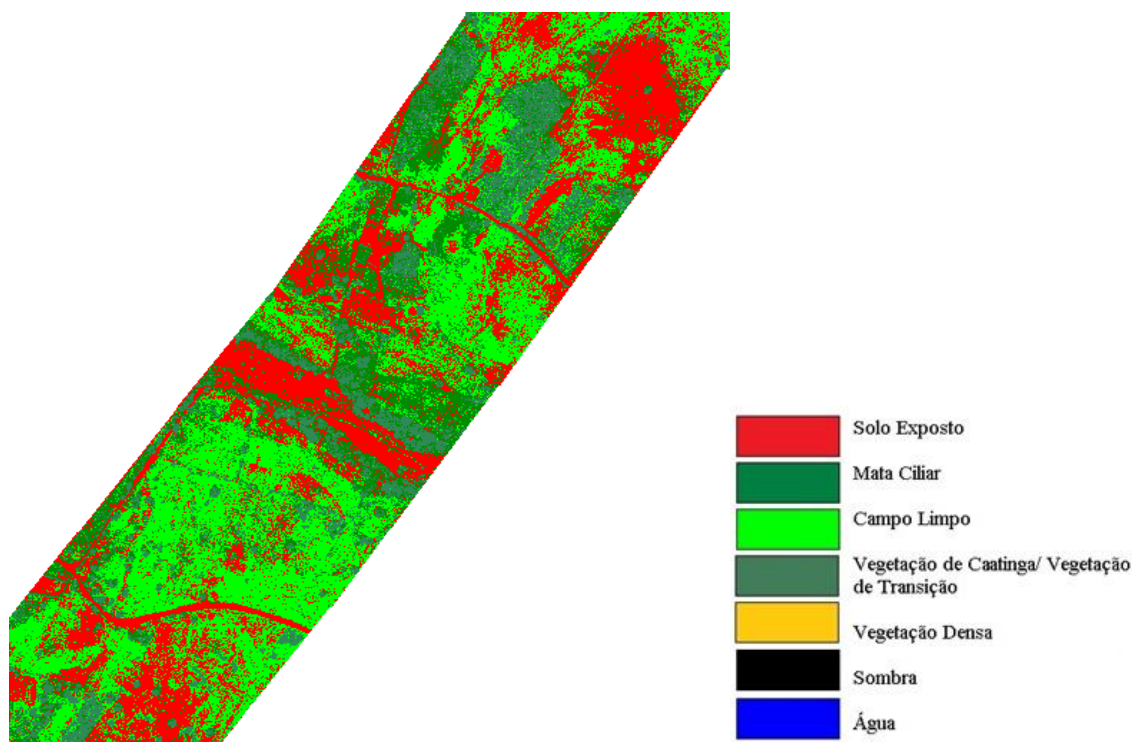
Classes	Comissão (%)	Omissão (%)
Vegetação Densa	0,00	60,50
Campo Limpo	77,07	45,54
Vegetação de Caatinga/ Vegetação de Transição	23,39	6,18
Solo Exposto	58,10	0,00
Sombra	0,00	0,00



Igualmente, os maiores erros de Omissão estão relacionados à classe de vegetação nativa. A classe “Vegetação Densa” foi a mais prejudicada nessa classificação, com erro de 60,50% (Tabela 16). As outras duas classes, referentes à vegetação nativa, “Campo Limpo” e “Vegetação de Caatinga/Vegetação de Transição” apresentaram valores de Omissão iguais a 45,54% e 6,18%, respectivamente. Em vista dos altos valores de erros constatados/medidos e da não acurada inspeção visual, para esse recorte, pode-se inferir que a metodologia apresentou resultados não satisfatórios.

O índice Kappa medido na classificação do Recorte 4 foi 0,9778, o que a classifica como Excelente, segundo a Tabela 2. A imagem classificada é apresentada na Figura 27.

FIGURA 22. Imagem classificada referente ao Recorte 4 (RNA).



Em relação a uma análise visual para identificação dos alvos de interesse, “Solo Exposto” e vegetação nativa, tem-se boas respostas ligadas a essas classes. Os alvos podem ser prontamente identificados na imagem, facilitando a marcação dos pontos/focos de investigação ou intervenção da equipe de campo, no que diz respeito a impactos ambientais. É um resultado interessante, dado que a cena é mais complexa que o Recorte 3 e o método das RNAs mostrou-se mais eficiente no Recorte 4. Esse método demonstra mais eficiência em áreas mais mescladas com solos e vegetação.



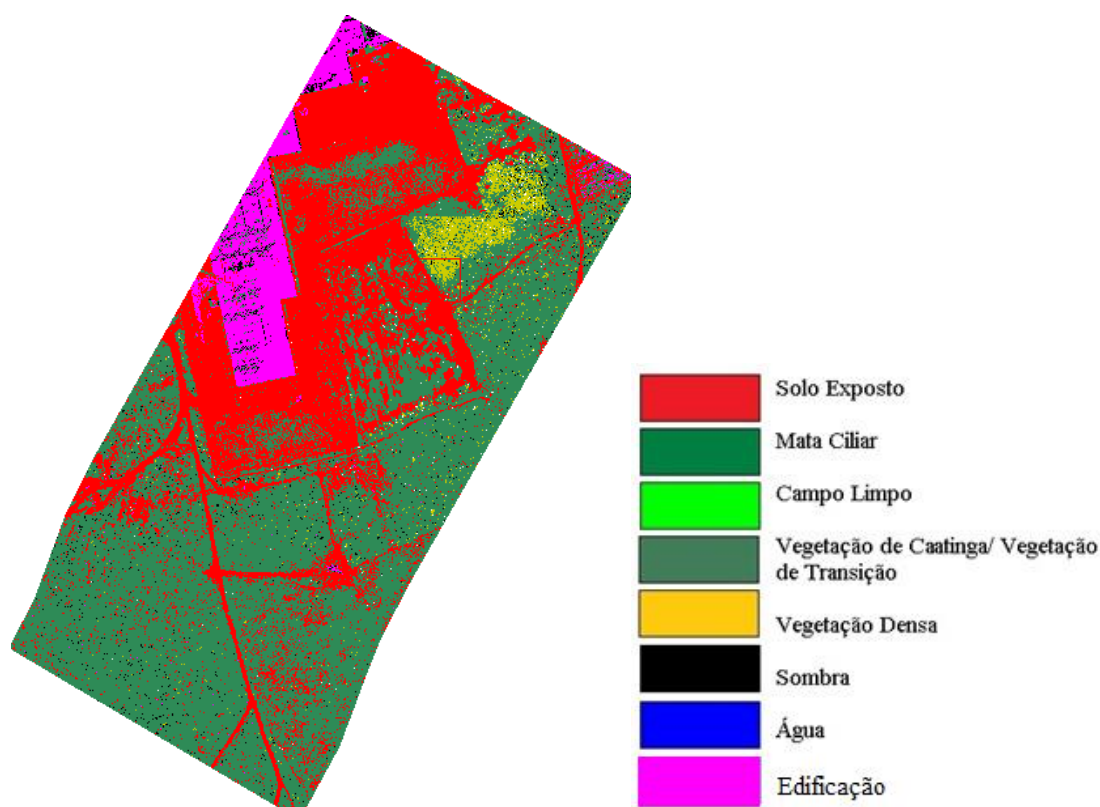
Com relação aos erros de Comissão, o maior valor está relacionado com a classe “Vegetação de Caatinga/Vegetação de Transição”, com 41,86% (Tabela 17). Esse fato é explicado pela variabilidade da vegetação na área em análise, sendo intercalada com árvores de pequeno e grande porte, o que causa a confusão espectral com outras feições de vegetação nativa.

TABELA 17. Erros de Comissão e Omissão - Recorte 4 (RNA).

<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Mata Ciliar	4,17	6,12
Campo Limpo	1,18	0,00
Vegetação de Caatinga/ Vegetação de Transição	41,86	1,32
Solo Exposto	0,00	0,00
Sombra	0,00	0,00

Em relação à Omissão, a classe “Mata Ciliar” apresentou o maior erro. Esse erro ocorre devido à dificuldade do classificador em diferenciar as classes de vegetação nativa presentes na cena. Ainda em relação aos resultados de classificação, destaca-se que a classe “Sombra” não obteve *pixels* classificados, mesmo sendo coletadas amostras na imagem. Diferentemente dos métodos estatísticos, essa é uma característica intrínseca das RNAs, que mesmo fornecendo amostras, pode acontecer de nenhum ou poucos *pixels* serem classificados. Por fim, a classificação do Recorte 5 apresentou valor do índice global Kappa igual a 0,8492, o que a classifica como um resultado Excelente. A Figura 28 mostra o mapa temático obtido com essa classificação.

FIGURA 23. Imagem classificada referente ao Recorte 5 (RNA).



Em relação à classificação do Recorte 5, uma análise visual relata excelente classificação dos alvos de interesse dessa pesquisa. As áreas da classe “Solo Exposto” foram muito bem delimitadas, ficando evidente a degradação ao redor do complexo de edificação, também fica claro as estradas, áreas de solo exposto e de propagação do impacto ambiental. Com relação às áreas de vegetação nativa, as classes “Vegetação de Caatinga/Vegetação de Transição” e “Vegetação Densa” também foram bem identificadas, somente havendo prejuízo na segunda classe citada, que teve sua área reduzida em relação ao alvo original.

No que diz respeito aos erros de Comissão, tem-se como maior erro a classe “Vegetação de Caatinga/Vegetação de Transição”, com 37,32% (Tabela 18). Nota-se que são valores relativamente baixos, se comparados com os resultados dos experimentos anteriores. Com relação à Omissão, tem-se que a classe “Vegetação Densa” apresentou o maior erro, igual a 44,72%. Esses erros específicos das duas classes já citadas estão relacionados com a dificuldade em identificar e diferenciar as duas classes que são muito similares: “Vegetação Densa” e “Vegetação de Caatinga/Vegetação de Transição”.

TABELA 18. Erros de Comissão e Omissão - Recorte 5 (RNA).


<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Vegetação Densa	4,03	44,72
Vegetação de Caatinga/ Vegetação de Transição	37,32	6,01
Solo Exposto	0,17	0,00
Sombra	15,32	0,00
Edificação	0,00	0,00

#### 4.4. CLASSIFICAÇÃO POR RNA USANDO FOTOS E DADOS LiDAR

Nesse tópico foram realizados experimentos em duas cenas (Recorte 2 e Recorte 5) do trecho da LT-Ibicoara/Brumado, com a utilização de ortofotos e dados *Laser Scanner*. Os resultados foram analisados segundo os erros de Comissão, Omissão e índice Kappa. Também foi realizada uma comparação entre os resultados obtidos com as ortofotos sem a utilização dos dados *Laser Scanner*, e com a utilização desses dados.

Usando o Recorte 2 foi obtido um coeficiente Kappa igual a 0,9509, o que qualifica o processo de classificação como Excelente. Esse alto valor do Kappa reflete o aspecto visual de ótima qualidade do mapa temático resultante, como mostra a Figura 29.

FIGURA 24. Imagem classificada referente ao Recorte 2 (RNA – Fotos/LiDAR).



Nota-se visualmente na Figura 29 que nesse resultado é possível identificar os limites da vegetação da classe “Mata Ciliar”, no entorno do corpo d’água principal (rio). É perceptível, também, que os *pixels* azuis da classe “Água” se misturaram, erroneamente, em várias regiões da imagem, dificultando o processo de identificação visual do alvo/feição. As áreas correspondentes ao “Solo Exposto” também ficaram bem destacadas e delimitadas, sendo possível o apontamento de alvos para investigação a respeito de possíveis impactos ambientais causados.

Com relação aos erros de Comissão, tem-se os dois destaques não nulos, referentes às classes “Mata Ciliar” e “Campo Limpo”, com 15,82% e 12,67% (Tabela 19), respectivamente. A similaridade tonal das respostas espectrais dos *pixels* dessas duas classes é a possível causa desses erros. Com relação ao erro de “Omissão”, a classe “Vegetação de Caatinga/ Vegetação de Transição” se destaca, tendo 11,94% de erro.

Tabela 19. Erros de Comissão e Omissão - Recorte 2 (RNA com Foto/LiDAR).


Classes	Comissão (%)	Omissão (%)
Mata Ciliar	15,82	0,00
Campo Limpo	12,67	0,99
Vegetação de Caatinga/ Vegetação de Transição	0,00	11,94
Solo Exposto	0,00	0,04

Sombra	0,00	5,81
Água	0,00	0,00

Pode ser observado, novamente, que os erros referentes à classe “Água”, embora tenham valores nulos, apontam para o cuidado que se deve ter na coleta de amostras de validação e classificação. Isto é, a imagem mostra que ocorreram erros consideráveis com essa classe, enquanto, na validação (Comissão e Omissão), indicam serem erros nulos.

Na classificação corresponde ao Recorte 5, o índice Kappa calculado foi de 0,8492, mostrando um a classificação de nível Excelente. O resultado referente a esse experimento pode ser verificado na Figura 30.

FIGURA 25. Imagem classificada referente ao Recorte 5 (RNA – Fotos/LiDAR).



Com relação a análise visual da classificação, pode-se observar em destaque uma confusão no que diz respeito a classificação da classe “Edificação”, sendo classificados *pixels* de “Vegetação de Caatinga/Vegetação de Transição” como “Edificação”. A degradação, em virtude da presença da edificação de apoio das linhas

de energia, fica claramente demonstrada. Ao redor dessa estrutura há uma forte ocorrência da classe “Solo Exposto”. Com relação à detecção da classe “Vegetação Densa”, nota-se que há uma falha na classificação, ficando essa categoria reduzida em 44,72% (Tabela 20) se comparada à verdade de campo. O mesmo fenômeno ocorre quando essa feição é comparada com a mesma imagem classificada sem a presença de dados Laser.

TABELA 20. Erros de Comissão e Omissão - Recorte 5 (RNA com Foto/LiDAR).

<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Vegetação Densa	4,03	44,72
Solo Exposto	0,17	0,00
Vegetação de Caatinga/ Vegetação de Transição	37,32	06,01
Sombra	15,32	0,00
Edificação	0,00	0,00

Tratando-se dos erros de Comissão, tem-se que o maior valor de erro refere-se à classe de “Vegetação de Caatinga/Vegetação de Transição”, com 37,32%. A menor Comissão corresponde à classe “Edificação”, com erro nulo. Por outro lado, a classe “Vegetação Densa” apresentou o maior valor de erro de Omissão, com 44,72%. Esse é um resultado esperado após a discussão tratada na identificação visual.

#### 4.5. SEGMENTAÇÃO E CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO COM FOTO E COM FOTO INTEGRADA AO DADO LiDAR

No processo de classificação, após a segmentação, foram coletadas as seguintes amostras para as feições de uso, cobertura e ocupação do solo: “Solo Exposto”, “Vegetação de Caatinga/Vegetação de Transição”, “Vegetação de Mata Ciliar”, “Edificação”, “Água” e “Sombreamento”. Ressalta-se que foram coletadas dezenas de amostras, com centenas de *pixels* cada uma, tanto para treinamento quanto para verificação de erros (Kappa, Comissão e Omissão).

Os testes foram realizados no recorte 2, devido ao fato de não se ter imagem/fotos e dados *Laser Scanner* de todas as cenas. Para cada recorte/cena foram realizados dois experimentos: o primeiro teste foi realizado com a segmentação e classificação da imagem/foto, utilizando o classificador vizinho mais próximo, para rotular os segmentos, e o segundo teste foi realizado com a segmentação e classificação

da imagem/foto integrada com dados LiDAR. Na análise, foi definido como Recorte 2a, a cena sem Laser, e como Recorte 2b, a imagem integrada com dado LiDAR.

Os resultados obtidos com os recortes 2a e 2b estão ilustrados nas Figuras 31 e 32, respectivamente.

FIGURA 26. Imagem classificada referente ao Recorte 2a (Segmentação – Foto).

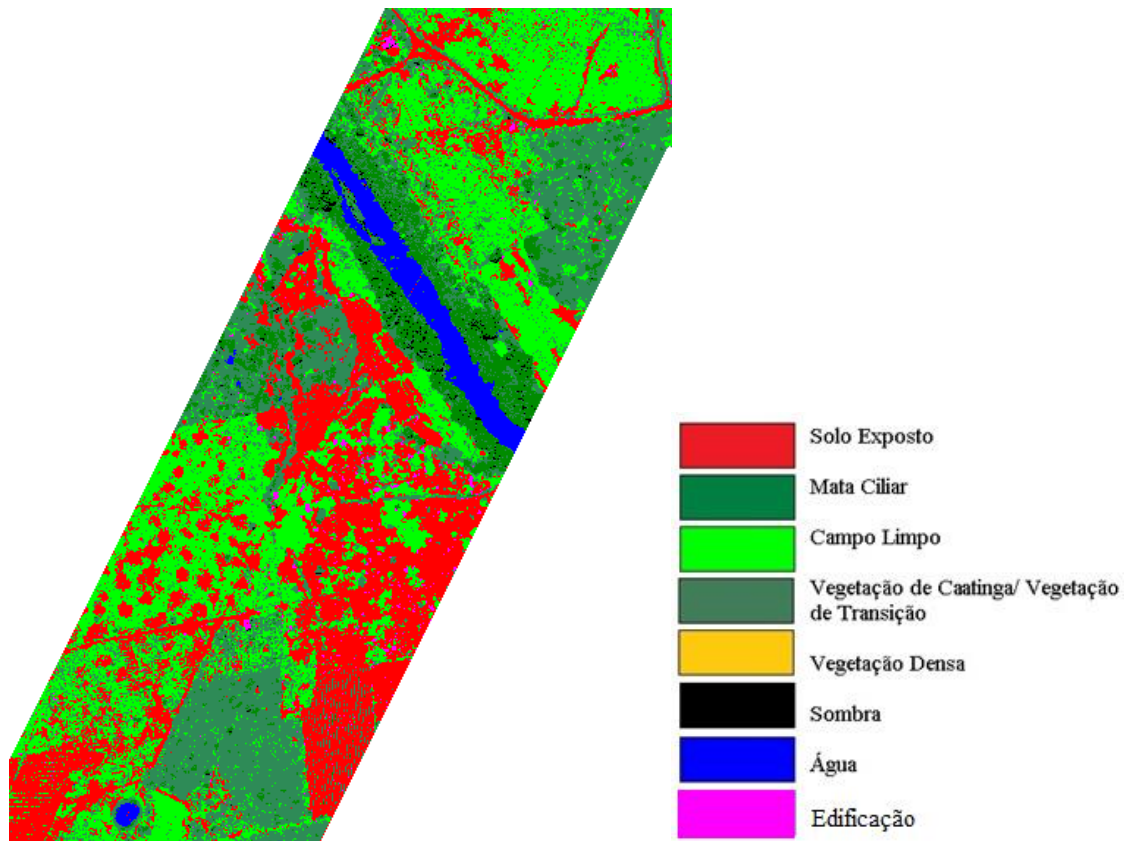
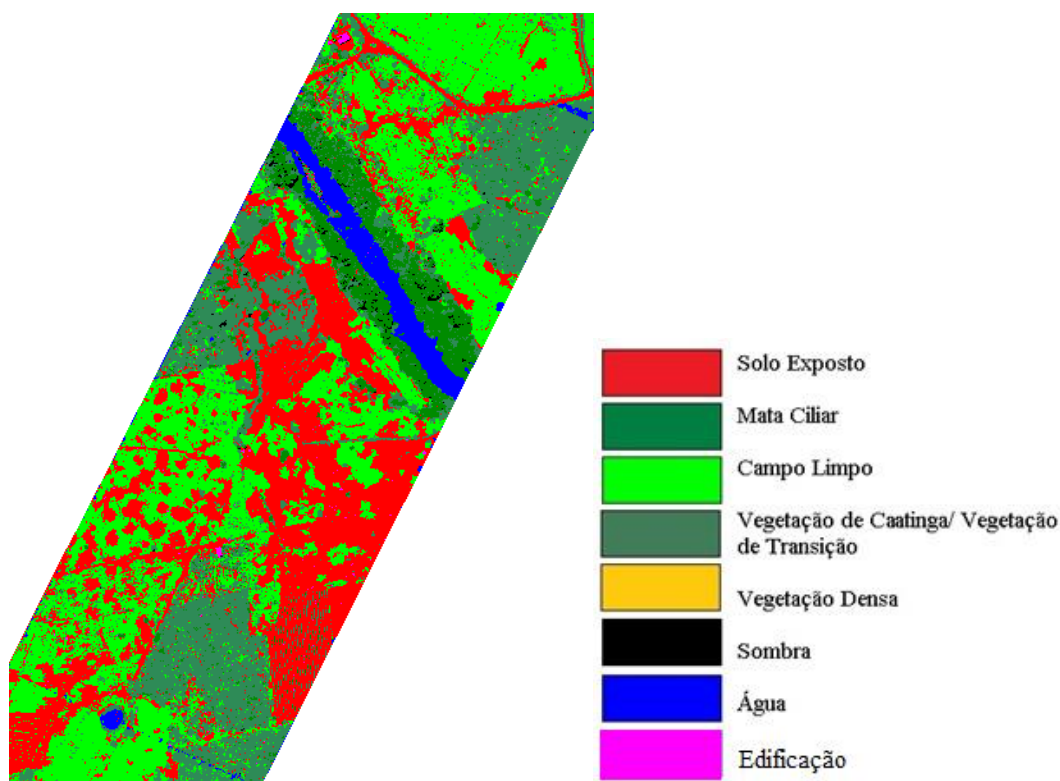


FIGURA 27. Imagem classificada referente ao Recorte 2b (Segmentação – Foto/LiDAR).



No resultado obtido com o Recorte 2a, o índice Kappa medido foi de 0,9674, o que classifica a segmentação como “Excelente”, segundo a tabela de concordância (Tabela 2). As feições “Edificação” e “Mata Ciliar” apresentaram maiores erros de Comissão (Tabela 21), indicando que pouco mais de 15% de suas áreas foram afetadas/somadas, erroneamente, com *pixels* de outras classes. Por outro lado, a classe “Solo Exposto” apresentou baixo valor de erro de Comissão (0.1%), apontando que poucos *pixels* de outras classes tenham sido inseridos nessa feição. Todas as classes apresentaram relativamente baixos valores de erros de Omissão. A feição “Mata Ciliar” apresentou maior erro (8.88%), enquanto a classe “Edificação” exibiu o menor, com um erro de apenas 0.74%.

TABELA 21. Erros de Comissão e Omissão - Recorte 2 (Segmentação com Foto).

Classes	Comissão (%)	Omissão (%)
Água	0,00	0,00
Mata Ciliar	15,11	8,88
Edificação	15,56	0,74
Campo Limpo	4,01	3,45
Vegetação de Caatinga/ Vegetação de Transição	4,62	4,39
Solo Exposto	0,10	2,63



No recorte 2b, o índice Kappa medido foi 0,9949, classificando a segmentação como “Excelente”, segundo a tabela de concordância (Tabela 2). Em comparação com o resultado obtido com o Recorte 2a, houve um melhor resultado na classificação, mostrando, portanto, um bom desempenho na utilização de dados LiDAR integrados com fotografias aéreas.

A Tabela 22 mostra que os valores de erros de Comissão e Omissão também são inferiores aos erros apresentados na classificação com a imagem isolada (Tabela 21), com exceção da feição “Solo Exposto”, que apresenta erro de Comissão levemente superior (0.02%), com a integração imagem/LiDAR. Isso pode ser explicado pelo fato de a feição “Solo Exposto” não apresentar grandes destaques nos dados LiDAR, isto é, não sofre alterações altimétricas bruscas, como é o caso de construções e árvores. Outra feição que merece destaque é a “Mata Ciliar”, que apresenta erro de Omissão similar em ambos os testes. Esse caso é facilmente explicado devido a existência de árvores de grande porte, com características de “Mata Ciliar”, mas presentes em regiões afastadas dos corpos d’água.

Destaca-se também, com relação a detecção dos alvos, nota-se que nos dois recorte analisados houve confusão inerente a classe “Edificação”, nota-se que essa classe foi confundida pelo software em alguns trechos, com a classe “Vegetação de Caatinga/ Vegetação de Transição”.

TABELA 22. Erros de Comissão e Omissão - Recorte 2 (Segmentação com Foto/LiDAR).

<b>Classes</b>	<b>Comissão (%)</b>	<b>Omissão (%)</b>
Água	0.00	0.00
Mata Ciliar	0.00	8.77
Edificação	4.62	0.43
Campo Limpo	0.18	0.14
Vegetação de Caatinga/ Vegetação de Transição	0.00	0.00
Solo Exposto	0.12	0.58

Visando a diminuição dos impactos causados pelo setor de produção de energia elétrica no Brasil, em específico nos biomas Cerrado e Caatinga, busca-se através do desenvolvimento de métodos de análises com uso de geotecnologias, a simplificação dos processos de obtenção de diagnósticos ambientais e sociais. Em se tratando de esforços iniciais, a utilização de imagens e dados LiDAR, com alta resolução espacial, aliada às técnicas consagradas como a classificação MaxVer e segmentação de imagens,

e outras técnicas de inovação, como a RNA, podem apresentar resultados satisfatórios no que diz respeito à identificação de alvos de interesse, que apontam os processos ambientais para tomada de decisão, comprovado nesse estudo para o caso de projeto de LT.

#### 4.6. COMPARAÇÃO ENTRE OS MÉTODOS DE CLASSIFICAÇÃO UTILIZADOS

Comparando as classificações, utilizando a mesma metodologia, porém com a adição ou não de dados *Laser scanner*, tem-se, através do índice Kappa, um indício de que os dados LiDAR aumentam a eficiência de classificação, considerando que nos três métodos utilizados apenas Rede Neural não obedeceu a essa regra (Tabela 23). Porém há dois destaques a serem comentados: O primeiro é que visualmente, os resultados com a utilização dos dados LiDAR aparentam estar mais “pulverizados” dentro dos polígonos de classes formados, dificultando uma leitura técnica para análise de Campo, salientando novamente que esse aspecto não demonstra necessariamente um processo de classificação errônea, visto a alta resolução espacial e espectral da imagem. O segundo é que apesar de ocorrer essa “pulverização”, a borda dos alvos é delimitada com exatidão.

TABELA 23. Índices Kappa obtidos em todos os recortes e métodos testados.

<b>Método</b>	<b>Rec. 1</b>	<b>Rec. 2</b>	<b>Rec. 3</b>	<b>Rec. 4</b>	<b>Rec. 5</b>
Max Ver sem Laser	0,8422	0,9583	0,8156	0,9935	0,985
Max Ver com Laser	x	0,9735	x	x	0,9498
Rede Neural com Laser	x	0,9509	x	x	0,8492
Rede Neural sem Laser	0,7632	0,9709	0,539	0,9778	0,8492
Segmentação sem Laser	x	0,9674	x	x	x
Segmentação com Laser	x	0,9949	x	x	x

Fazendo uma comparação entre os métodos testados, mas com a utilização dos dados LiDAR (Recorte 2), pode-se afirmar que o melhor desempenho, de acordo com os valores do Kappa (Tabela 23), foi do método da Segmentação/classificação pelo Vizinho Mais Próximo, que apresentou resultado superior ao MaxVer em 2,2% e à RNA em 4,42%.

Analizados os resultados das classificações sem a utilização dos dados *Laser Scanner*, tem-se que os métodos se alternaram muito com relação à apresentação do melhor resultado (Tabela 23). Esse comportamento sugere a não indicação de um método mais eficiente, mais sim a elaboração de testes quanto à tipologia do alvo a se identificar.

Fazendo uma análise das cenas e dos respectivos métodos de classificação usados tem-se que, no Recorte 1, classificado com o método Max Ver e Rede Neural, os *pixels* da classe “Solo Exposto” são identificados de forma semelhante. A diferença destoante diz respeito a determinação das classes de vegetação. Foi encontrada na classificação Max Ver um alto índice de “Vegetação Densa”, o que não ocorreu nas Redes Neurais. Nas Redes Neurais houve a classificação dessa mesma classe em “Vegetação de Caatinga ou Transição”. Aos olhos do observador, se aproximou mais da realidade a classificação Max Ver, apontando esse método mais eficiente para identificação de classes de vegetação ao invés do uso de Redes Neurais.

Com relação ao Recorte 2 tem-se os três métodos aplicados, com a utilização ou não de dados Lidar. Ao se analisar os pares e as correlações tem-se que para a classificação Max Ver fica evidente como a presença de dados Lidar assume o papel de refinador de resultado, delimitando principalmente as classes que são diferenciadas em campo por fatores de altimetria, nota-se que a imagem ganha bordas de transições entre as classes, apesar do aumento de ruídos já comentado nesse trabalho. No que diz respeito à classificação de Redes Neurais, houve erroneamente atribuição de *pixels* a classes, para as quais eles não pertenciam. Na classificação sem a utilização de dados LiDAR, a classe solo exposto foi predominante na imagem, trazendo um falso resultado da realidade. Já com a classificação em Redes Neurais, com a utilização de dados LiDAR, a veracidade das informações é retomada, sendo as classes corretamente classificadas e delimitadas. Para esse método, houve a necessidade clara de inclusão dos dados LiDAR para o melhor resultado na classificação.

Com relação à Segmentação, visualmente houve uma diferença mínima na classificação com a utilização ou não dos dados Lidar, porém observa-se o mesmo fenômeno já relatado em outras imagens, a melhor distinção de classes, com um efeito de criar bordas. Destaca-se que a classificação utilizando esse método ficou extremamente fiel a realidade da imagem. Em relação ao Recorte 2, nota-se que o melhor resultado obtido a olho nu foi o método da Segmentação seguida da classificação do Vizinho Mais Próximo, com a utilização dos dados LiDAR,

concordando também com a Tabela 23, que aponta o maior valor do índice Kappa 0,9949 para esse método.

Com relação ao Recorte 3, esse foi classificado com a utilização dos métodos de Max Ver e Redes Neurais; Em uma análise a olho nu não houveram diferenças significativas na diferenciação de classes.


Com relação ao Recorte 4, esse foi classificado com a utilização dos métodos de Max Ver e Redes Neurais. Destaca-se que a classificação de Máxima Verossimilhança define melhor o uso e ocupação do solo do recorte, sendo mais fiel a imagem real. O método foi capaz de definir com precisão os locais onde se encontram as classes relacionadas à vegetação.

Com relação ao Recorte 5, foram utilizados os métodos de classificação Max Ver e Redes Neurais com e sem dados LiDAR. Comprando-se par a par tem-se um resultado antagônico as demais imagens, sendo que a classificação em Max Ver, sem os dados Laser, aparenta um melhor resultado ao olho nu do que com a utilização dos dados LiDAR, isso se tratando em específico do classe “Vegetação Densa”, que é delimitada com menor precisão. Com relação às demais classes encontradas, o resultado é semelhante. Tratando das Redes Neurais, a presença dos dados LiDAR aumenta a densidade da classe “Vegetação Densa”, refinando o resultado nessa classe, as demais classes também se assemelham e não há destaque na classificação.

Com relação aos erros de Comissão e Omissão, esses também se alternaram incisivamente dentre os resultados obtidos nos diferentes métodos, sendo improvável a verificação estatística para os melhores e os piores resultados. Com relação ao que foi testado, acredita-se que esse fator ocorre principalmente devido a complexidade de *pixels* e alvos nas imagens.

No que se refere às áreas, a diferença das áreas das classes analisadas referentes às classificações por Máxima Verossimilhança e por RNA, sem a utilização dos dados LiDAR, demonstrou uma baixa variabilidade entre os métodos. Analisando o gráfico da Figura 31, nota-se a pequena diferença entre os resultados dos dois métodos supracitados. Destaca-se a classe “Solo Exposto”, que obteve porcentagem igualada, bem como as classes “Edificação” e “Água”, que apresentaram diferença de apenas 1%. Com essa análise, pode-se concluir que os métodos analisados nesse estudo possuem pouca variabilidade com relação aos resultados encontrados. Contudo, ambos apresentam bons resultados, validados pelo índice Kappa.

FIGURA 28. Comparação entre as áreas medidas com os métodos MaxVer e RNA.



## 5. CONCLUSÕES

Essa dissertação foi realizada no intuito de investigar métodos de identificação automática (e/ou semiautomática) de feições para a observação e diagnóstico de pontos propícios à ocorrência de impactos ambientais em LT.

Os três métodos estudados mostraram-se satisfatórios e válidos perante os resultados obtidos, validados pela análise dos índices Kappa. Esses três métodos (classificação por Máxima Verossimilhança, classificação usando Redes Neurais Artificiais e Segmentação seguida pela classificação pelo Vizinho Mais Próximo) apresentaram comportamentos semelhantes, não podendo ser enfatizado um em relação ao outro. Nesse contexto, como se trata de dados de cenas/recortes de trechos de uma LT, com características particulares, recomenda-se investigações futuras, com mesma metodologia, mas em áreas com outros Biomas e novas condições de uso, cobertura e ocupação da superfície terrestre.

A integração das ortofotos com os dados *Laser Scanner* demonstrou um refinamento dos resultados, quando analisados com o índice Kappa. Contudo, em uma análise visual os resultados com dados LiDAR “pulverizaram” os alvos de interesse, trazendo um aspecto de desfragmentação dos objetos. O que pode trazer uma dificuldade na interpretações dos dados, apesar de não ser necessariamente um indicativo de erro na classificação se levado em consideração a alta qualidade de resolução das imagens trabalhadas. Ressalta-se que para o uso do dado LiDAR, em

uma questão ambiental, deve ser levado em consideração a viabilidade econômica, uma vez que a aquisição desses dados ainda envolve um custo relativamente alto.

No que diz respeito ao diagnóstico ambiental encontrado na Área Diretamente Afetada da linha de transmissão de energia elétrica (Ibicoara/Brumado), usando o classificador MaxVer, nota-se que o trecho, de forma amostral, indicou um elevado índice antrópico de uso/ocupação, destacando as classes “Campo Limpo” e “Solo Exposto”. Essa revelação de forte ocupação antrópica pode ser verificada com a razão entre as áreas dos dois parâmetros analisados nessa pesquisa (vegetação nativa e “Solo Exposto”), que são praticamente iguais, a vegetação nativa com 43% (soma das classes: “Mata Ciliar”, “Vegetação Densa” e “Vegetação de Caatinga /Vegetação de Transição”) e o “Solo Exposto” (Soma das classes: “Solo Exposto” e “Campo Limpo”) com 47% da área total.

Com a classificação por Redes Neurais Artificiais, os valores percentuais de áreas continuam similares para as classes de vegetação nativa e “Solo Exposto”, com 45% e 51%, respectivamente. No que diz respeito à classe puramente de “Solo Exposto”, um dos focos dessa pesquisa, a percentagem de área encontrada para ambos os métodos (MaxVer e RNA) foi de 28%, relatando a real necessidade de atenção nessas áreas que apontam possível degradação e/ou impacto ambiental.

Á área diretamente afetada do empreendimento necessita de atenção quanto a recomposição vegetal das áreas aqui identificadas, especialmente nas APPs. Ressalta-se que esse estudo é um primeiro esforço de diagnóstico e investigação, sendo necessária visitas a campo para confirmação do diagnóstico e o planejamento de metas.

## REFERÊNCIAS

- ANEEL. **Atlas de energia elétrica no Brasil- Parte I- Energia no Brasil e no Mundo**. Brasília 2012. Disponível em:  
<[http://www.aneel.gov.br/arquivos/pdf/atlas\\_par1\\_cap1.pdf](http://www.aneel.gov.br/arquivos/pdf/atlas_par1_cap1.pdf)>. Acesso em: 05 Jan. 2011.
- ANEEL. **Atlas de Energia Elétrica no Brasil**. Brasília. 2012. Disponível em:  
<[http://www.aneel.gov.br/arquivos/pdf/livro\\_atlas.pdf](http://www.aneel.gov.br/arquivos/pdf/livro_atlas.pdf)>. Acesso em: 16 Dez. 2015.
- ANELL. **Aspectos Institucionais**. Sistema Interligado Nacional. Disponível em:  
<[http://www.aneel.gov.br/aplicacoes/atlas/aspectos\\_institucionais/2\\_1\\_1.htm](http://www.aneel.gov.br/aplicacoes/atlas/aspectos_institucionais/2_1_1.htm)>. Acesso em: 05 de Jan. 2016.
- BRASIL. MINISTÉRIO DO MEIO AMBIENTE. **Áreas Prioritárias para Conservação, Uso Sustentável e Repartição de Benefícios da Biodiversidade Brasileira: Atualização - Portaria MMA nº9, de 23 de janeiro de 2007**. Ministério do Meio Ambiente, Secretaria de Biodiversidade e Florestas. Brasília, 2007.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5422\1985**: Projetos de Linhas de transmissão de energia elétrica: Procedimento. Rio de Janeiro, 1985.
- BEIRÃO, C.C.B. **O potencial do Laser Scanner terrestre para o inventário do patrimônio Arquitetônico**. Dissertação (Mestrado). 2011. 79f. Universidade Federal de Santa Catarina. Florianópolis, 2011. Disponível em:  
<<https://repositorio.ufsc.br/bitstream/handle/123456789/95470/300159.pdf?sequence=1>>. Acesso em: 06 Jan. 2016.
- BEZERRA, M. E. U. **Métodos baseados na regra do Vizinho Mais Próximo para reconhecimento de imagens**. 2006. 22f. Trabalho de Conclusão de Curso. Departamento de Ciências Computacionais da Escola Politécnica de Pernambuco. Recife. 2006.
- BOTELHO, M. F.; SILVA, C.R.; SCHOENINGER, E. R.; CENTENO, J. A. S. **Comparação dos resultados de interpoladores “Vizinho mais próximo” e “Inverso de uma distância” no cálculo de volume a partir de dados do laser scanner**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia. **Anais**. Inpe, 2005 p. 731-736.
- BRANDALIZE, M. C. B. A. **Qualidade Cartográfica dos Resultados do Lasercanner Aerotransportado**. Tese (Doutorado em Engenharia Civil) – Universidade Federal de Santa Catarina, Florianópolis, 2004.
- BRASIL. **Código Florestal**. Lei nº 12.651 de 25 de maio de 2012.
- CARVALHO, P.L.F. **Backpropagation**. 2016. Disponível em:  
<<http://www.icmc.usp.br/~andre/research/neural/MLP.htm>> Acesso em: 05 Jan. 2016.
- CASTROS, P.H.C. **Comparação de interpoladores para geração de superfícies mde, mdt e mds a partir de dados laser scanner aerotransportado**. Trabalho desenvolvido na disciplina TCC1 do curso de Engenharia Cartográfica- UFU. Monte Carmelo. 2015.

CENTENO, J. A. S. **Sensoriamento remoto e processamento de imagens digitais**. 1. ed. Curitiba: UFPR.2004.

CENTENO, J. A. S.; MITISHITA, E. A. Laser scanner aerotransportado no estudo de áreas urbanas: A experiência da UFPR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Inpe, 2007 p. 3645-3652.

COLOMBO, F. **A Produção de energia no Brasil**. Disponível em: <http://f1colombo-geografando.blogspot.com.br/2013/06/10-producao-de-energia-no-brasil.html>. Acesso em: 01 Dez. 2015.

CONAMA. Conselho Nacional do Meio Ambiente. Resolução Conama nº 349, de 16 de Agosto de 2004. **Dispõe sobre o licenciamento ambiental de empreendimentos ferroviários de pequeno potencial de impacto ambiental e a regularização dos empreendimentos em Operação**. Disponível em: <<http://www.mma.gov.br/port/conama/legiabre.cfm?codlegi=450>>. Acesso em: 19 Jul. 2014.

CONAMA. Conselho Nacional do Meio Ambiente. **Resolução Conama nº 305, de 12 de Junho de 2002**. Disponível em: <<http://www.mma.gov.br/port/conama/legiabre.cfm?codlegi=300>>. Acesso em: 19 Jul. 2014.

CONAMA. Conselho Nacional do Meio Ambiente. **Resolução CONAMA nº001 de 23, de Janeiro de 1986**. Disponível em: <<http://www.mma.gov.br/port/conama/res/res86/res0186.html>>. Acesso em: 21 Jan. 2016

COSTA, D. T., et al. Grandes Impactos Ambientais no Mundo. **Caderno de Meio Ambiente e Sustentabilidade**. Curitiba, v, 01(nº), p. 56-73, 2012. Disponível em:<<http://webcache.googleusercontent.com/search?q=cache:YuRnfRmhgJJJ:www.gru>

DALMOLIN, Q.; SANTOS, D, R. **Sistema Laserscanner: conceitos e princípios de funcionamento**. 3. Ed. Curitiba: UFPR, 2004, 97p.

**ENVI EX - User's Guide**. 2009. Disponível em: <[http://www.exelisvis.com/portals/0/pdfs/enviex/ENVI\\_EX\\_User\\_Guide.pdf](http://www.exelisvis.com/portals/0/pdfs/enviex/ENVI_EX_User_Guide.pdf)>. Acesso em: 09 Nov. 2015

ERTHAL., et al. Um Sistema de Classificação de Satélites. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS, 6.. 2012. São Paulo. **Anais...** Inpe, 2012 p . 237-240.

EXELIS VISUAL INFORMATION SOLUTIONS. **Rede Neural**. Disponível em: <http://www.exelisvis.com/docs/NeuralNet.html>. Acesso em: 22 Set. 2015.

GUIMARÃES, L. T. **Utilização do sistema de informação geográfica (SIG) para identificação de áreas potenciais para disposição de resíduos na bacia do Paquequer, município de Teresópolis – RJ**. 2000. 163f. Dissertação (Mestrado em Engenharia Civil) –Universidade Federal do Rio de Janeiro , Rio de Janeiro, Brasil, 2000.



IBAMA. **Licenciamento Ambiental Federal**. Disponível em:  
<http://www.ibama.gov.br/licenciamento/>. Acesso em: 16 Dez.2015.

INPE – Instituto de Pesquisas Espaciais. **Classificação de imagens**. Disponível em:  
<http://www.dpi.inpe.br/spring/portugues/tutorial/classific.html>. Acesso em: 23 Jan. 2014.

INPE – Instituto de Pesquisas Espaciais. **Segmentação de imagens**. Disponível em:  
<http://www.dpi.inpe.br/spring/portugues/tutorial/segmentacao.html>. Acesso em 23 Jan. 2014.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied Geostatistics**. 1. ed. Oxford University Press, 1989, 561 p.

LABEGALINI, P. R., et al. **Projetos mecânicos das linhas Aéreas de transmissão**. Editora Edgard Blücher Ltda. São Paulo. 1992.

LANDIS, J. R; KOCH, G. G. **The measurement of observer agreement for categorical data**. Biometrics. Washington. 1977. Disponível em:  
<[http://www.jstor.org/stable/2529310?seq=1#page\\_scan\\_tab\\_contents](http://www.jstor.org/stable/2529310?seq=1#page_scan_tab_contents)>. Acesso em: 05 Nov. 2015.

LANHELLAS, R. **Devmedia- Redes Neurais Artificiais: Algoritmo Backpropagation**. 2016. Disponível em: <http://www.devmedia.com.br/redes-neurais-artificiais-algoritmo-backpropagation/28559>. Acesso em: 05 Jan. 2016.

MAZZINI, P. L. F. SCHETTINI, C. A. F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase- sinóticos. **Rev. Braz. J. Aquat. Sci. Technol**, Brasil, v. 13, n. 1, 2009.

MENDES, C. A.; SILVA, H. J. **Introdução às linhas de transmissão de energia**. Lisboa Editora: Departamento de Engenharia Eletrônica, de Telecomunicações e de Computadores, 2005.

MENESES, P. R; ALMEIDA, T. **Introdução ao processamento de imagens e ao Sensoriamento Remoto**. Brasília. 2012. Disponível em:<  
<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 09 Nov. 2015

MINISTÉRIO DO MEIO AMBIENTE. **Biomass**. Disponível em:  
<http://www.mma.gov.br/informma/itemlist/category/12-biomass?start=42>. Acesso em: 05 Jan. 2016.

MINISTÉRIO DOS TRANSPORTES. DNER – Departamento Nacional de Estradas de Rodagem. Diretoria de Engenharia Rodoviária. **Corpo normativo ambiental para empreendimentos rodoviários**. Rio de Janeiro, 1996.

MORAES, F. C. de. **Avaliação temática das imagens rapideye na classificação do uso e cobertura do solo em estudos de empreendimentos energéticos**. 2011. 56f. Monografia (Especialização em Geoprocessamento). Universidade Estadual da Paraíba, Campina Grande, 2011. Disponível em:  
<<http://dspace.bc.uepb.edu.br/jspui/handle/123456789/717>>. Acesso em: 05 de Janeiro de 2016.

MORAIS, A. M., et al. **Tomada de Decisão aplicada à Inteligência Artificial em Serious Games voltados para Saúde**. In IX Encontro Regional de Matemática Aplicada e Computacional. João Pessoa, 2009. ALIXANDRINI JÚNIOR, M. J. **Estimativa da altura da vegetação utilizando dados Airborne Laser Scanner**. Dissertação (Mestrado). 2005. 68 p. - Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Civil. Florianópolis, 2005.

MOREIRA, E.S. **Protótipo de um sistema inteligente para a medição de dureza em peças de ferro fundido**. 2009. 89f. Trabalho de conclusão de Estágio apresentado ao Curso de Bacharel em Sistemas de Informação. Universidade da Região de Joinville – UNIVILLE. Joinville 2009. Disponível em: [http://www.eduardomoreira.eng.br/teoria/Monografia\\_Eduardo.pdf](http://www.eduardomoreira.eng.br/teoria/Monografia_Eduardo.pdf). Acesso em: 05 Jan. 2016.

MOREIRA, M.A. **Fundamentos do sensoriamento remoto e metodologia de aplicação**. 2ed. Viçosa: UFV, 2003.

MUNICÍPIA. **Lidar**. Disponível em: <http://www.municipia.pt/gca/?id=156>. Acesso em: 06 Jan. 2016.

OLIVEIRA, B. N. H. **Segmentação e classificação de imagens Land Sat Tm**. Dissertação (Mestrado). 1999. 97f. Universidade Federal do Paraná. Curitiba. 1999. Disponível em: <http://dspace.c3sl.ufpr.br/dspace/bitstream/handle/1884/24745/D%20-%20OLIVEIRA,%20HEMERSON%20NOBREGA%20BARROS%20DE.pdf?sequence=1>. Acesso em: 06 Jan. 2016.

OLIVEIRA, J. C; SILVA, J.M. F. Influência da Segmentação no processo de classificação por região. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12.. 2005, Goiânia. **Anais...** INPE, 2005 p. 4209-4216.

QUEIROZ, R. B., et al. Redes Neurais: Um comparativo com Máxima Verossimilhança Gaussiana na Classificação de Imagens CBERS 1. In: Workshop de Tecnologia da Informação aplicado ao Meio Ambiente. 3.. 2004, Itajaí. **Anais...** UFRGS, 2004 p. 746-749.

RIBEIRO, R. J.C; BAPTISTA, G. M. M; BIAS, S. E. Comparação dos métodos de classificação supervisionada de imagem Máxima Verossimilhança e Redes Neurais em ambiente urbano. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO. 8.. 2007. Florianópolis, **Anais...** Inpe, 2007 p . 5471- 5478.

RIBEIRO, S. R. A; CENTENO, J.S. Classificação do Solo Utilizando Redes Neurais e o Algoritmo MAX VER. In: In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10.. 2001, Foz do Iguaçu. **Anais...** Inpe, 2001 p, 1341-1348.

RICHARDS, J.A. Remote Sensing Digital Image Analysis. Springer-Verlag, Berlin. 1999.

ROSS, J. L. S. **Análise empírica da fragilidade dos ambientes naturais e antropizados**. Revista do Departamento de Geografia. 1994.

RIMA - **Relatório de Impacto Ambiental LT 230 Kv Ibicoara/ Brumado II C1 e SE** Ibicoara 230/138. Salvador. 2009.

SANO, E. E., et al. Notas Científicas: Mapeamento sem detalhado do uso da Terra do Bioma Cerrado. **Base de dados da Pesquisa Agropecuária Embrapa**. Brasília. 2008. Disponível em: <<http://www.scielo.br/pdf/pab/v43n1/a20v43n1.pdf>>. Acesso em: 06 Jan. 2016.

SEMA. **Seia-** sistema estadual de informações ambientais e de recursos hídricos. 2016. Disponível em:< <http://www.meioambiente.ba.gov.br/2015/08/10560/SEIA-.html>>. Acesso em: 05 Jan. 2016.

SILVA, C. C, S; VIANNA, R. P, T; MORAES, R.M. Sistema de Apoio a Decisão: a Segurança Alimentar e o Modelo em Rede Neural. **Revista Brasileira de ciência da saúde**, São Caetano do Sul, v.nº45,p. 79-84, 2012.

SOUZA, C. J. **Determinação da largura de faixa de segurança de linhas de transmissão: um estudo paramétrico**. 2012. 86 f. Dissertação de Mestrado- Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, Belo Horizonte, 2012.

TAFNER, M.A. **O que são as redes neurais artificiais**. Revista “Cérebro & Mente”. Universidade Estadual de Campinas. Campinas, 1998. Disponível em: <http://www.cerebromente.org.br/n05/tecnologia/rna.htm>. Acesso: 21 Jan. 2016.

VASCONCELOS, C. H; NOVO, E. M. L. M. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens – fração solo, sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do sensor TM/Landsat5, na região do reservatório de Tucuruí - PA. **Acta Amazônica**. Manaus. 2004. Disponível em:< <http://www.scielo.br/pdf/aa/v34n3/v34n3a14.pdf>>. Acesso em: 06 Jan. 2016.

WOSNY, G.C; OLIVEIRA, F. H; DEL SANTO, A.M. **Geotecnologias como Subsídio ao Gerenciamento das Linhas de Transmissão de Energia Elétrica**. Laboratório de Geoprocessamento (Geolab-UDESC).2006. Disponível em: [http://www.geolab.faed.udesc.br/publicacoes/Guilherme/CBC2005\\_.pdf](http://www.geolab.faed.udesc.br/publicacoes/Guilherme/CBC2005_.pdf). Acesso em: 05 Jan. 2016.