

UNIVERSIDADE FEDERAL DO PARANÁ

ELIZABETE BUGALSKI DE ANDRADE PEIXOTO

MAPEAMENTO DE LINHAS DE TRANSMISSÃO POR SEGMENTAÇÃO
SEMÂNTICA DE NUVENS DE PONTOS OBTIDAS POR LIDAR A BORDO DE
RPAS

Curitiba

2023

ELIZABETE BUGALSKI DE ANDRADE PEIXOTO

MAPEAMENTO DE LINHAS DE TRANSMISSÃO POR SEGMENTAÇÃO
SEMÂNTICA DE NUVENS DE PONTOS OBTIDAS POR LIDAR A BORDO DE
RPAS

Tese apresentada ao Curso de Pós-Graduação em
Ciências Geodésicas, Setor de Ciências da Terra,
Universidade Federal do Paraná, como requisito
parcial à obtenção do Grau de Doutor em Ciências
Geodésicas. Área de Concentração: Fotogrametria
e Sensoriamento Remoto

Orientador: Prof. Dr. Jorge Antonio Silva Centeno.

Curitiba

2023

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Peixoto, Elizabete Bugalski de Andrade

Mapeamento de linhas de transmissão por segmentação semântica de nuvens de pontos obtidas por lidar a bordo de RPAS / Elizabete Bugalski de Andrade Peixoto. – Curitiba, 2023.

1 recurso on-line : PDF.

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas.

Orientador: Jorge Antonio Silva Centeno

1. Energia elétrica. 2. Redes neurais (Computação). I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Ciências Geodésicas. III. Centeno, Jorge Antonio Silva. IV. Título.

Bibliotecário: Leticia Priscila Azevedo de Sousa CRB-9/2029



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS DA TERRA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO CIÊNCIAS
GEODÉSICAS - 40001016002P6

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **ELIZABETE BUGALSKI DE ANDRADE PEIXOTO** intitulada: **Mapeamento de linhas de transmissão por segmentação semântica de nuvens de pontos obtidas por LIDAR a bordo de RPAS**, sob orientação do Prof. Dr. JORGE ANTONIO SILVA CENTENO, que após terem Inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutora está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 30 de Outubro de 2023.

Assinatura Eletrônica

16/11/2023 21:23:57.0

JORGE ANTONIO SILVA CENTENO

Presidente da Banca Examinadora

Assinatura Eletrônica

06/11/2023 13:55:28.0

MARIO ERNESTO JIJÓN PALMA

Avaliador Externo (PESQUISADOR INDEPENDENTE)

Assinatura Eletrônica

06/11/2023 13:11:25.0

HIDEO ARAKI

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

06/11/2023 10:05:36.0

RENATO DE ARRUDA PENTEADO NETO

Avaliador Externo (INSTITUTO DE TECNOLOGIA PARA O DESENVOLVIMENTO)

Centro Politécnico - Caixa Postal 19001 - CURITIBA - Paraná - Brasil

CEP 81531-980 - Tel: (41) 3361-3153 - E-mail: cpqcg@ufpr.br

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.
Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 325636

Para autenticar este documento/assinatura, acesse <https://siga.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp>
e insira o código 325636

Dedico este trabalho a todos aqueles que diretamente ou indiretamente colaboraram para sua realização.

AGRADECIMENTO

Em primeiro lugar, agradeço a Deus, pois sem Sua orientação e força, eu não teria conseguido escrever estas linhas e alcançar esta conquista.

Ao Prof. Jorge Antônio Centeno, meu orientador, expresso minha profunda gratidão. Sua confiança, paciência e dedicação ao longo deste percurso foram essenciais. Foram mais de 10 anos entre disciplinas isoladas, mestrado e doutorado, e sua orientação e incentivo para que eu não desistisse são lições que levarei para a vida toda. Ter um orientador com seu nível de conhecimento e comprometimento foi uma verdadeira bênção.

Agradeço ao Programa de Pós-Graduação em Ciências Geodésicas da UFPR por me acolher, mesmo sem eu ter formação inicial na área. Meu sincero agradecimento ao estimado colega, Prof. Alan Salomão, que generosamente dedicou seu tempo para auxiliar com revisões e sugestões. Sua colaboração exemplifica a verdadeira solidariedade acadêmica e amizade.

Aos meus amigos verdadeiros, expresso minha profunda gratidão. Sua amizade e apoio foram inestimáveis ao longo desta jornada. Às empresas Esteio Engenharia e Instituto Lactec, agradeço o apoio e as horas dedicadas à realização desta tese. Tenho grande respeito e admiração por ambas. Também sou grata a todos os colegas de trabalho que contribuíram com ideias e suporte.

Ao meu marido, Ronald, minha eterna gratidão e amor. Nestes mais de 10 anos de estudo, sua paciência, amor incondicional e dedicação em cuidar da casa e dos compromissos foram fundamentais. Às minhas filhas, Ana Carolina e Gabriele, agradeço por serem minha fonte de inspiração e força. Sua presença em minha vida foi o combustível que me impulsionou a seguir em frente. Meu agradecimento também ao meu genro, Gabriel, que me auxiliou com os códigos, e ao Luan, sempre presente e incentivador.

Agradeço à COPEL-DIS, COPEL-GET e à ANEEL pela cessão de dados, financiamento e infraestrutura para a condução deste projeto de pesquisa.

Ao CNPq, sou grata pelo suporte financeiro, através da bolsa concedida durante dois anos, e pelos subsídios ao Lactec para a importação, nos termos da Lei 8010/90, LI 20/1792326-7 - LiAir S50 e LI 21/3512798-3 - LiAir v70.

Dedico este trabalho a todos vocês que fizeram parte dessa conquista. Obrigada por estarem ao meu lado e por tornarem possível a realização deste sonho.

Não fiz o melhor, mas fiz tudo para
que o melhor fosse feito. Não sou o que
deveria ser, mas não sou o que era antes.
(Martin Luther King).

RESUMO

O progresso da sociedade moderna está intrinsecamente ligado à energia elétrica, impulsionando o constante avanço do setor elétrico para atender às crescentes demandas. No entanto, a integração das redes de distribuição de energia demanda investimentos em automação e monitoramento para garantir sua eficiência e sustentabilidade, enfrentando desafios na implantação e inspeção de ativos, especialmente em locais remotos e de difícil acesso. Nesse cenário, tecnologias como LiDAR e sensores em RPAS têm desempenhado um papel importante ao revolucionar o mapeamento tridimensional, oferecendo alta resolução e precisão. O LiDAR não apenas é utilizado em topografia e monitoramento ambiental, mas também na energia eólica e solar, facilitando a seleção de locais para parques eólicos, otimizando a instalação de aerogeradores e identificando áreas ideais para a instalação de painéis solares, contribuindo para a eficiência energética. A combinação de RPAS com LiDAR tornou viável a coleta de dados em áreas remotas e acidentadas, beneficiando diversos setores, incluindo topografia, planejamento urbano, monitoramento ambiental e a indústria de energia. No entanto, as nuvens de pontos obtidas por RPAS exigem um processo adicional de classificação, envolvendo a atribuição de rótulos com base em características geométricas e aprendizado de máquina, para identificar elementos como torres, postes e cabos. Nesse sentido, a segmentação semântica, aliada ao uso de aprendizado profundo como redes neurais convolucionais, permitiu uma análise mais precisa dessas feições, detectando e classificando cabos e torres em linhas de transmissão de energia de forma automática. Portanto, este estudo desenvolveu uma metodologia para a segmentação semântica de nuvens de pontos, utilizando o algoritmo PointNet++ para detectar e classificar elementos em linhas de transmissão de energia elétrica, com dados provenientes de um sistema LiDAR embarcado em RPAS. Estratégias foram propostas para lidar com a grande quantidade de pontos, permitindo o processamento incremental e eficiente dos dados. Os resultados mostraram uma acurácia média de 86,61%, com destaque para a precisão na classificação de cabos (93,06%). Embora a identificação das torres tenha apresentado um desempenho razoável (F1-score de 72,38%), a classificação dos cabos foi bastante satisfatória (F1-score de 90,09%). Essa metodologia pode oferecer vantagens significativas para o setor elétrico, possibilitando uma gestão mais eficiente das redes de energia, otimizando o planejamento de expansão e reduzindo custos operacionais.

Palavras-chave: energia elétrica; RPAS; LiDAR; segmentação semântica; redes neurais convolucionais.

ABSTRACT

The progress of modern society is inherently linked to electric power, driving the constant advancement of the electrical sector to meet growing demands. However, integrating power distribution networks requires investments in automation and monitoring to ensure their efficiency and sustainability, facing challenges in asset deployment and inspection, especially in remote and inaccessible locations. In this scenario, technologies like LiDAR and RPAS sensors have played a crucial role in revolutionizing three-dimensional mapping, offering high resolution and accuracy. LiDAR is not only used in topography and environmental monitoring but also in wind and solar energy, facilitating site selection for wind farms, optimizing wind turbine installation, and identifying ideal areas for solar panel installation, contributing to energy efficiency. The combination of RPAS with LiDAR has made data collection feasible in remote and rugged areas, benefiting various sectors including topography, urban planning, environmental monitoring, and the energy industry. However, point clouds obtained by RPAS require an additional classification process, involving labeling based on geometric features and machine learning, to identify elements such as towers, poles, and cables. Semantic segmentation, coupled with deep learning techniques like convolutional neural networks, has enabled a more precise analysis of these features, automatically detecting and classifying cables and towers in power transmission lines. Therefore, this study developed a methodology for semantic segmentation of point clouds, using the PointNet++ algorithm to detect and classify elements in electrical transmission lines, with data from a LiDAR system embedded in RPAS. Strategies were proposed to handle the large number of points, allowing for incremental and efficient data processing. The results showed an average accuracy of 86.61%, with a highlight on the precision in cable classification (93.06%). Although tower identification showed reasonable performance (F1-score of 72.38%), cable classification was highly satisfactory (F1-score of 90.09%). This methodology could offer significant advantages for the electrical sector, enabling more efficient management of energy networks, optimizing expansion planning, and reducing operational costs.

Keywords: electric power; RPAS; LiDAR; semantic segmentation; convolutional neural networks.

LISTA DE FIGURAS

FIGURA 1 - RPA MATRICE 600 COM LiDAR.....	32
FIGURA 2 - REPRESENTAÇÃO 3D DE PONTOS	36
FIGURA 3 - TIPOS DE RETORNOS DO VLP-16 DA VELODYNE	39
FIGURA 4 – EXEMPLO DE RETORNO DUPLO DO PULSO LiDAR NUMA ÁRVORE.....	40
FIGURA 5 - SENSOR LIDAR LIVOX AVIA	41
FIGURA 6 - COMPONENTES BÁSICOS DE UMA LINHA DE TRANSMISSÃO AÉREA.....	42
FIGURA 7 - TIPOS DE ISOLADORES PINO, PILAR E DE SUSPENSÃO	45
FIGURA 8 - ESTRUTURAS DE TORRES DE LT'S DO TIPO DELTA, PIRÂMIDE E ESTAIADA	46
FIGURA 9 - ERROS RELATIVOS DOS MODELOS MULTI-LAYERED PERCEPTRON E REDES NEURAS CONVOLUCIONAIS COMO UMA FUNÇÃO DO ERRO MÉDIO QUADRÁTICO DO AGREGADO EM 1 HORA.....	48
FIGURA 10 - DIAGRAMA DE VEN COM A HIERARQUIA DOS TEMAS DENTRO DE CIÊNCIAS DA COMPUTAÇÃO.....	49
FIGURA 11 - ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL	50
FIGURA 12 – VISÃO GERAL DOS MÉTODOS DE APRENDIZAGEM PROFUNDA POR ESTRUTURA DE DADOS.....	53
FIGURA 13 – EXEMPLO DE ORGANIZAÇÃO DOS PONTOS DE UMA NUVEM....	54
FIGURA 14 – ESQUEMA DE UMA REDE CONVOLUCIONAL SIMPLES.....	55
FIGURA 15 – EXEMPLOS DE FILTROS DIRECIONAIS	56
FIGURA 16 – CONVOLUÇÃO USANDO O CONCEITO DE REDE NEURAL	58
FIGURA 17 – EMPILHAMENTO DE CAMADAS EM CNN.....	59
FIGURA 18 – BIBLIOTECAS QUE UTILIZAM AS REDES NEURAS CONVOLUCIONAIS COMO BASE	60
FIGURA 19 – RESULTADO POINTNET++ NUVEM DE PONTOS ORIGINAL (A) SEGMENTAÇÃO(B)	65
FIGURA 20 - ARQUITETURA POINTNET	66
FIGURA 21 - ARQUITETURA POINTNET ++.....	69
FIGURA 22 – MAPA DE DESEMPENHO DOS ALGORITMOS.....	70

FIGURA 23 – DIMENSÃO DOS SENSORES DO SISTEMA LIAIR 50 EM MILÍMETROS.....	73
FIGURA 24 – EQUIPAMENTOS DO VLP-16.....	74
FIGURA 25 - LIVOX AVIA.....	75
FIGURA 26 – FLUXOGRAMA DOS PROCESSOS DE PLANEJAMENTO, CAPTURA DA NUVEM DE PONTOS E DOS PONTOS DE CONTROLE.	78
FIGURA 27 - TRECHO DA LT-230KV FOZ DO CHOPIM - SECCIONAMENTO (CASCABEL - SALTO OSÓRIO C1).....	81
FIGURA 28 - (a) AREA 01 - PERFIL COM A REPRESENTACAO DO TERRENO, DAS TORRES E CABOS (b) DETALHAMENTO DA AREA COM MAIOR VARIAÇÃO ALTIMÉTRICA.	82
FIGURA 29 - FORMAÇÃO ROCHOSA EM RELEVO ACIDENTADO.....	83
FIGURA 30 – VISUALIZAÇÃO DA FORMAÇÃO ROCHOSA NOS DADOS LiDAR (A) E VISUALIZAÇÃO DA FORMAÇÃO ROCHOSA NA MESMA ÁREA NUMA ORTOFOTO (B).	84
FIGURA 31 - CULTURA PRÓXIMO A UMA ESTRUTURA.....	85
FIGURA 32 - EXEMPLO DE ESTRUTUTURA COM INVASÃO DA VEGETAÇÃO NUMA ORTOFOTO.	86
FIGURA 33 - LARGURA DA FAIXA DE PASSAGEM PARA CIRCUITO SIMPLES 230KV	86
FIGURA 34 - CAPOEIRA EM TORNO DAS ESTRUTURAS	88
FIGURA 35 - EXEMPLO DE MATA CILIAR EM TERRENO ACIDENTADO NUMA VISUALIZAÇÃO EM PERFIL NA NUVEM DE PONTOS, INDICANDO 30 METROS PARA CADA LADO DO EIXO DA DIRETRIZ DA LT (A). VISUALIZAÇÃO DA MESMA POSIÇÃO UTILIZANDO UMA ORTOFOTO COMO FUNDO (B).	90
FIGURA 36 – RECORTE DE UMA ÁREA COM RELEVO ACIDENTADO (A). DENSIDADE DE PONTOS NA MESMA ÁREA (B).....	91
FIGURA 37 – LEGENDA DE INTENSIDADE (A) PERFIL DAS FOLHAS FOC_SEC_03 (B) E FOC_SEC_64 (C), COM VISUALIZACAO PELA INTENSIDADE DO PULSO COM HISTOGRAMA.	92
FIGURA 38 – TRECHO DA LT 230 KV CAMPO COMPRIDO – SANTA QUITÉRIA.	94
FIGURA 39 - EXEMPLO DE RELEVO EM UM TRECHO DA ÁREA 02.	95

FIGURA 40 - EXEMPLO DE CULTURA CÍCLICA (A) E PERENE (B) EM UM TRECHO DA ÁREA 02.	96
FIGURA 41 – EXEMPLO DE VEGETAÇÃO PRÓXIMA A UMA ESTRUTURA - CCO_SQT_05.....	97
FIGURA 42 - FLUXOGRAMA DA METODOLOGIA DE SEGMENTAÇÃO DA NUVEM DE PONTOS UTILIZANDO A ARQUITETURA POINTNET++.....	99
FIGURA 43 – (a) VISUALIZAÇÃO DA NUVEM DE PONTOS EM PERFIL, (b) VISUALIZAÇÃO DA NUVEM DE PONTOS EM VISTA DE TOPO (c) VISUALIZAÇÃO DE UM DETALHE DA NUVEM DE PONTOS.	100
FIGURA 44 - ARTICULAÇÃO DE FOLHAS DO CONJUNTO DE FOLHAS 01.....	101
FIGURA 45 - ARTICULAÇÃO DE FOLHAS DO CONJUNTO DE FOLHAS 02.....	102
FIGURA 46 - EXEMPLOS DE ARTEFATOS RUIDOSOS EM NUVEM DE PONTOS NA ÁREA 02	103
FIGURA 47 - NUVEM DE PONTOS COM CLASSIFICAÇÃO MANUAL – VERDADE DE CAMPO	105
FIGURA 48 – REDE NEURAL POINTNET	110
FIGURA 49 - ARQUITETURA POINTNET++ PARA OS CONJUNTOS DE DADOS 01 E 02.....	113
FIGURA 50 – PROCESSO DE TRANSFORMAÇÃO DOS PONTOS BRUTOS EM PONTOS CHAVE.....	116
FIGURA 51 - GRÁFICO DE PROCESSAMENTO DO TREINAMENTO	118
FIGURA 52 - ANTES E DEPOIS DA RECLASSIFICAÇÃO DA CLASSE “TORRE”.	120
FIGURA 53 - CLASSE “TORRE” DA FOLHA FOC_SEC_63 COM OS VETORES PRINCIPAIS.....	121
FIGURA 54 - INTERSEÇÃO SOBRE UNIÃO.....	123
FIGURA 55 – EXEMPLOS DE FALTA DE RETORNO EM REGIÕES DE PAVIMENTO E NO PÉ DA ESTRUTURA DA TORRE.	127
FIGURA 56 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 01	131
FIGURA 57 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 01: FOLHA FOC_SEC_75 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_74 (DIREITA – PIOR RESULTADO)	132

FIGURA 58 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01(T2).....	135
FIGURA 59 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 02: FOLHA FOC_SEC_03 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_14 (DIREITA – PIOR RESULTADO)	136
FIGURA 60 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DOS DADOS DO EXPERIMENTO 03	138
FIGURA 61 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 03: FOLHA FOC_SEC_38 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_75 (DIREITA – PIOR RESULTADO)	139
FIGURA 62 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 04	142
FIGURA 63 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 01: FOLHA FOC_SEC_79 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_81 (DIREITA – PIOR RESULTADO)	142
FIGURA 64 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 04	145
FIGURA 65 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 01: FOLHA CCFOC_SEC_118 (ESQUERDA RESULTADO) E FOLHA CCO_SQT_114 (DIREITA) -RESULTADOS ACEITÁVEIS	146
FIGURA 66 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 – EXPERIMENTO 04	148
FIGURA 67 - NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 02: FOLHA CCO_SQT_81 (ESQUERDA) E FOLHA CCO_SQT_59 (DIREITA)	149
FIGURA 68 - PROGRESSO DE EXPERIMENTO 03 DO CONJUNTO DE DADOS 02	151
FIGURA 69 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 – EXPERIMENTO 03	151

FIGURA 70 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 03: FOLHA CCO_SQT_35 (ESQUERDA – PIOR RESULTADO) E FOLHA CCO_SQT_37 (DIREITA – MELHOR RESULTADO)	152
FIGURA 71 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 – EXPERIMENTO 04	154
FIGURA 72 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 04: FOLHA CCO_SQT_167 (ESQUERDA) E FOLHA CCO_SQT_198 (DIREITA)	155
FIGURA 73 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 04	158
FIGURA 74 – RESULTADO DA FOLHA FOC_SEC_03 DO EXPERIMENTO UNICO	161
FIGURA 75 – CENTROIDES CALCULADOS E VERDADEIROS DAS TORRES DO EXPERIMENTO 01	162
FIGURA 76 – CENTROIDES CALCULADOS E VERDADEIROS DA TORRES DO EXPERIMENTO 02.....	164
FIGURA 77 – CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 01	213
FIGURA 78 - CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 02	214
FIGURA 79 - CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 03	215
FIGURA 80 - CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 04	216
FIGURA 81 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 01	217
FIGURA 82 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 02	218
FIGURA 83 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 03	219
FIGURA 84 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 04	220

FIGURA 85 - CONJUNTO DE DADOS 01 e 02 - PROGRESSO DO TREINAMENTO221

LISTA DE GRÁFICOS

GRÁFICO 1 – QUANTIDADE DE PONTOS POR CLASSE E POR CONJUNTO DE DADOS	126
GRÁFICO 2 - PRECISÃO E FUNÇÃO DE PERDA DO EXPERIMENTO 03	130
GRÁFICO 3 - PRECISÃO E FUNÇÃO DE PERDA DO EXPERIMENTO DO CONJUNTO DE DADOS 01 E 02 COM 3 CLASSES.	159

LISTA DE QUADROS

QUADRO 1 – ESPECIFICAÇÕES TÉCNICAS DO SENSOR VLP-16.....	74
QUADRO 2 – ESPECIFICAÇÕES TÉCNICAS DO SENSOR LIVOX AVIA	76
QUADRO 3 – EXEMPLO DAS FOLHAS AVALIADAS NA VALIDAÇÃO CRUZADA NO CONJUNTO DE DADOS 01 COM 83 FOLHAS.....	107
QUADRO 4 – ELEMENTOS NECESSÁRIOS PARA O EMPREGO DA REDE NEURAL POINTNET++	114
QUADRO 5 - MATRIZ DE CONFUSÃO	122
QUADRO 6 – AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 01.....	163
QUADRO 7 - AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 02.....	164
QUADRO 8 - CENTROIDE CALCULADOS E VERDADEIROS DA TORRES DO EXPERIMENTO 03.....	165
QUADRO 9 - AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 03.....	166
QUADRO 10 - AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 04	167

LISTA DE TABELAS

TABELA 1 – QUANTIDADE DE PONTOS E PERCENTUAL POR INTERVALO DE INTENSIDADE	92
TABELA 2 - INTERVALO DE INTENSIDADE E VISUALIZAÇÃO DA QUANTIDADE DE PONTOS REFERENTES A ESSE INTERVALO, EXEMPLO DA FOLHA 64	93
TABELA 3 - PESOS POR CONJUNTO DE DADOS E ÁREA.....	104
TABELA 4 - HIPERPARÂMETROS UTILIZADOS NOS MODELOS DE TREINAMENTO	108
TABELA 5 - VISÃO GERAL DAS CLASSES DO CONJUNTO DE DADOS 01 EM RELAÇÃO A NÚMERO DE PONTOS DE TREINAMENTO E TESTE.	129
TABELA 6 -VISÃO GERAL DAS CLASSES DO CONJUNTO DE DADOS 02 EM RELAÇÃO A NÚMERO DE PONTOS DE TREINAMENTO E TESTE.	129
TABELA 7 – DESEMPENHO E TEMPO DE DURAÇÃO DOS TREINAMENTOS DOS MODELOS	130
TABELA 8 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01 EXPERIMENTO 01 EM QUANTIDADE DE PONTOS...	133
TABELA 9 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 01 EM PERCENTUAL DECIMAL	133
TABELA 10 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01 EXPERIMENTO 02	136
TABELA 11 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 02 EM PERCENTUAL DECIMAL....	137
TABELA 12 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01 EXPERIMENTO 03	140
TABELA 13 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 03 EM PERCENTUAL DECIMAL....	141
TABELA 14 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01 EXPERIMENTO 04	143
TABELA 15 - CLASSIFICAÇÃO POR CLASSE COM MATRIZ DE CONFUSÃO CONJUNTO DE DADOS 01 EXPERIMENTO 04.....	143

TABELA 16 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 04 EM PERCENTUAL DECIMAL....	144
TABELA 17 – DESEMPENHO, DURAÇÃO E MÉTRICAS DOS EXPERIMENTOS DOS MODELOS DE EXPERIMENTO DO CONJUNTO DE DADOS 02.....	144
TABELA 18 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 01	146
TABELA 19 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E EXPERIMENTO 01 EM PERCENTUAL DECIMAL....	147
TABELA 20 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 02	150
TABELA 21 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E EXPERIMENTO 02	150
TABELA 22 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 03	153
TABELA 23 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E EXPERIMENTO 03	153
TABELA 24 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 04	156
TABELA 25 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E EXPERIMENTO 04	157
TABELA 26 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 04	159
TABELA 27 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 e 02 E EXPERIMENTO UNICO	160
TABELA 28 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 01	162
TABELA 29 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 02	164
TABELA 30 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 03	165
TABELA 31 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 04	167

LISTA DE ABREVIATURAS OU SIGLAS

ANAC	- Agência Nacional de Aviação Civil
APP	- Área de Preservação Permanente
CAVE	- Certificado de Autorização de Voo Experimental
CCO-SQT	- Campo Comprido – Santa Quitéria
CNN	- Convolutional Neural Network
CUDA	- Compute Unified Device Architecture
DECEA	- Departamento de Controle do Espaço Aéreo
FOC-SEC	- Foz do Chopim – Seccionamento Cascavel – Salto Osório
FOV	- Field-of-View
GLONASS	- Globalnaya navigatsionnaya sputnikovaya sistema
GNSS	- Sistema Global de Navegação por Satélite
GPS	- Global Positioning System
IMU	- Unidade de Medição Inercial
IoT	- Internet of Things
IS	- Instrução Suplementar
LiDAR	- Light Detecting and Ranging
LSTM	- Long Short-Term Memory
MLP	- Multi Layer Perceptron
MLS	- Mobile LiDAR Scanning
MTLS	- Mobile Terrestrial LiDAR Scanning
RBAC	- Regulamento Brasileiro de Aviação Civil
ReLU	- Rectified Linear Unit
RNA	- Rede Neural Artificial
RNN	- Recurrent Neural Network
RNN	- Rede Neural Recorrente.
RPA	- Remotely Piloted Aircraft
RPAS	- Remotely Piloted Aircraft System
ToF	- Time of Flight
VANT	- Veículo Aéreo Não Tripulado

SUMÁRIO

INTRODUÇÃO	25
1.1 OBJETIVO GERAL	29
1.2 OBJETIVOS ESPECÍFICOS	30
2 REVISÃO DE LITERATURA	31
2.1 CONCEITOS FUNDAMENTAIS	31
2.1.1 Sistema RPAS.....	31
2.1.1.1 Legislação dos RPAS no Brasil.....	33
2.1.2 Sensor LiDAR.....	33
2.1.2.1 Funcionamento	34
2.1.2.2 Nuvem bruta LAS	35
2.1.2.3 Intensidade	36
2.1.2.4 Aplicações dos Sensores Lidar em RPAS	37
2.1.2.5 Sensor LiDAR VLP-16	38
2.1.2.6 Sensor LiDAR Livox AVIA	41
2.2 ESTADO DA ARTE	42
2.2.1 Linhas de Transmissão	42
2.2.1.1 Componentes das Linhas de Transmissão.....	44
2.2.1.2 Redes Neurais no Setor Elétrico.....	46
2.2.2 Aprendizado Profundo.....	49
2.2.2.1 Aprendizado Profundo em nuvem de pontos.....	52
2.2.2.2 Redes baseadas em pontos	53
2.2.3 Redes Neurais.....	55
2.2.3.1 Convolução.....	55
2.2.3.2 Pooling.....	58
2.2.3.3 Camada Completamente Conectada (<i>Fully Connected Layer</i>)	59
2.2.3.4 Normalização em lote	60
2.2.3.5 Função de ativação ReLU	61
2.2.3.6 Função de ativação Softmax	61
2.2.4 Treinamento de Redes Neurais.....	62
2.2.4.1 Pesos.....	63
2.2.4.2 Hiperparâmetros	63
2.2.4.3 Função de Perda de Entropia Cruzada	64

2.2.4.4 Segmentação Semântica.....	64
2.2.5 PointNet.....	66
2.2.6 PointNet ++	68
3 MATERIAIS E MÉTODOS	71
3.1 MATERIAIS	71
3.1.1 Sistema LiAir 50 UAV LiDAR.....	71
3.1.1.1 VLP-16.....	72
3.1.2 Sistema LiAir 70 UAV LiDAR.....	74
3.1.2.1 Livox AVIA	75
3.1.3 Softwares	76
3.2 COLETA DE DADOS	77
3.2.1 Conjunto de dados 01 – FOC_SEC	80
3.2.1.1 Relevo	81
3.2.1.2 Cultura	84
3.2.1.3 Vegetação	88
3.2.1.4 Atributos de Intensidade	91
3.2.2 Conjunto de dados 02 – CCO_SQT	93
3.2.2.1 Relevo	94
3.2.2.2 Cultura	95
3.2.2.3 Vegetação	96
3.2.2.4 Atributos de Intensidade	97
3.3 MÉTODOS	97
3.3.1 Processamento	98
3.3.2 Pré-processamento	99
3.3.2.1 Agrupamento em blocos.....	101
3.3.2.2 Remoção de ruídos	102
3.3.2.3 Cálculo dos pesos	103
3.3.3 Conjunto de dados de treinamento e teste.....	104
3.3.3.1 Rotulação da Verdade de campo	104
3.3.3.2 Validação Cruzada	106
3.3.4 Definição dos Hiperparâmetros	107
3.3.5 Arquitetura PointNet ++	108
3.3.5.1 Padronização dos dados de entrada	109
3.3.5.2 T-NET	109

3.3.5.3 Normalização.....	110
3.3.5.4 Redução da densidade de pontos	111
3.3.5.5 Definição da arquitetura.....	111
3.3.5.6 Treinamento do modelo.....	117
3.3.5.7 Segmentação semântica	119
3.3.6 Identificação das torres.	120
3.3.7 Métricas de avaliação de desempenho.	122
4 RESULTADOS E DISCUSSÕES.....	126
4.1 CONJUNTO DE DADOS 01 COM 5 CLASSES	130
4.1.1 Experimento 01	131
4.1.2 Experimento 02	134
4.1.3 Experimento 03	138
4.1.4 Experimento 04	141
4.2 CONJUNTO DE DADOS 02 COM 5 CLASSES	144
4.2.1 Experimento 01	145
4.2.2 Experimento 02	148
4.2.3 Experimento 03	150
4.2.4 Experimento 04	154
4.3 INTEGRAÇÃO CONJUNTO DE DADOS 01 E 02 COM 3 CLASSES	157
4.3.1 Treinamento único.....	157
4.4 IDENTIFICAÇÃO DAS TORRES	161
4.4.1 Conjunto de dados 01 com 5 classes.....	161
4.4.1.1 Experimento 01.....	161
4.4.1.2 Experimento 02.....	164
4.4.1.3 Experimento 03.....	165
4.4.1.4 Experimento 04.....	167
5 CONCLUSÕES	168
5.1 CONTRIBUIÇÕES DA TESE	172
REFERÊNCIAS BIBLIOGRÁFICAS	174
APÊNDICE A – RESULTADO DA SEGMENTAÇÃO DA NUVEM DE PONTOS	
CONJUNTO DE DADOS 01 – EXPERIMENTO -5 CLASSES	182
APÊNDICE B – RESULTADO DA SEGMENTAÇÃO DA NUVEM DE PONTOS	
CONJUNTO DE DADOS 02 - 5 CLASSES	189

APÊNDICE C – RESULTADO DA SEGMENTAÇÃO DA NUVEM DE PONTOS CONJUNTO DE DADOS 01 E 02 - 3 CLASSES	196
APÊNDICE D – RESULTADO DA PRECISÃO E IOU POR FOLHA CONJUNTO DE DADOS 01 – EXPERIMENTO 02 - 5 CLASSES	207
APÊNDICE E - RESULTADO DA PRECISÃO E IOU POR FOLHA CONJUNTO DE DADOS 02 – EXPERIMENTO 01 - 5 CLASSES	209
APÊNDICE F - RESULTADO DA PRECISÃO E IOU POR FOLHA CONJUNTO DE DADOS 01 E 02 – EXPERIMENTO ÚNICO.....	210
APÊNDICE G- GRÁFICOS DE MONITORAMENTO DO TREINAMENTO	213
ANEXO 1 – QUADRO DE TERMOS E DEFINIÇÕES UTILIZADOS EM IA	222
ANEXO 2 - RESULTADO ALTIMÉTRICO ÁREA 01 E 02	225
ANEXO 3 – CAMADAS DA REDE POINTNET++	226

INTRODUÇÃO

A energia elétrica é fundamental para o desenvolvimento da sociedade moderna. Por esse motivo, é importante destacar que o setor elétrico necessita de constante reestruturação para atender às crescentes demandas, garantir a segurança e a confiabilidade do fornecimento de energia, promover a eficiência energética e integrar tecnologias emergentes.

Devido ao crescimento populacional e à industrialização, a rede de distribuição de energia elétrica, que antes era isolada, passou a ser integrada em sua totalidade. Há algum tempo, a transmissão de energia elétrica é feita por fios condutores de alta tensão e guiada por subestações, o que demanda altos custos para manutenção. Por isso, é importante investir em pesquisas para automação e monitoramento das redes elétricas, utilizando novas tecnologias que lidam com dados geoespaciais para tornar o processo mais eficiente e sustentável.

As empresas do setor de energia enfrentam inúmeros desafios ao realizar o mapeamento de novas áreas para implantação ou inspeção de seus ativos, especialmente quando se trata das linhas de transmissão de alta tensão. É comum que as torres de transmissão estejam localizadas em regiões de difícil acesso, como terrenos acidentados ou áreas remotas. Através de suas subsidiárias, a Eletrobras atua de forma efetiva nos empreendimentos de implantação de linhas de transmissão.

Nesse contexto, a integração de novos sensores, métodos e avanços da visão computacional tem impulsionado o crescimento da pesquisa em soluções para o setor de energia no Brasil. Dentre os avanços mais significativos nessa área, destacam-se o LiDAR (Light Detection and Ranging), os sistemas de imageamento linear e os sensores embarcados em RPAS (Remotely Piloted Aircraft System). Essas tecnologias permitem a captura de dados 3D, possibilitando o mapeamento tridimensional com alta resolução.

Além das aplicações tradicionais, como mapeamento topográfico, planejamento urbano e monitoramento ambiental, o LiDAR também tem encontrado seu uso na indústria de energia. O uso de sistemas LiDAR tem sido explorado para a avaliação de recursos renováveis, como energia eólica e solar.

No caso da energia eólica, os sistemas LiDAR têm sido empregados para a medição precisa e em tempo real da velocidade e direção do vento em altitudes mais

elevadas. Essas informações são fundamentais para a determinação dos locais ideais para a instalação de parques eólicos, bem como para o dimensionamento e a otimização dos aerogeradores. O uso do LiDAR nesse contexto elimina a necessidade de torres de medição convencionais, reduzindo custos e tempo de instalação.

Já no setor de energia solar, os sistemas LiDAR têm sido utilizados para a avaliação do potencial solar de uma determinada área. Por meio da análise da radiação solar incidente, é possível identificar os locais mais adequados para a instalação de painéis solares, considerando fatores como sombreamento e inclinação ótima. Essa abordagem baseada em LiDAR permite uma análise mais precisa e abrangente do potencial solar, contribuindo para a maximização da eficiência e do aproveitamento da energia.

Dessa forma, os sistemas LiDAR desempenham um papel importante na indústria de energia, permitindo uma avaliação mais precisa e eficiente dos recursos renováveis, como energia eólica e solar. Ao fornecer informações detalhadas sobre o vento e a radiação solar, esses sistemas contribuem para a tomada de decisões estratégicas na implantação de projetos de energia renovável, resultando em maior eficiência e aproveitamento dos recursos disponíveis. Além disso, nos projetos de linhas de transmissão, a velocidade e o sentido preferencial dos ventos são fatores de extrema importância no dimensionamento estrutural das LTs, destacando a relevância das informações fornecidas por meio de RPAS (Sistemas Aéreos Remotamente Pilotados). Assim, o uso integrado de LiDAR, RPAS e dados de geração eólica e solar contribui significativamente para a otimização e a sustentabilidade dos projetos de energia renovável e de infraestrutura elétrica.

Segundo DECEA (2015), a Instrução do Comando da Aeronáutica (ICA) 100-40 que substitui a legislação (Circular de Informações Aeronáuticas AIC N 21/10) esclarece os procedimentos necessários ao voo dos RPAS, bem como os parâmetros, enquadramentos técnicos de cada aeronave e as regras de voo a que estarão expostos. Com isso, após a regulamentação do uso de RPAS no espaço aéreo brasileiro, outras possibilidades foram pesquisadas. A integração do LiDAR com RPAS tornaram-se uma opção mais acessível e viável em termos de manuseio e custo para a realização de mapeamentos específicos, e a utilização de sensores LiDAR oferece vantagens significativas.

A combinação de RPAS e LiDAR permite a coleta de dados precisos e detalhados sobre o ambiente em questão. Os RPAS, pilotados remotamente, têm a

capacidade de voar em áreas de difícil acesso via terrestre, como terrenos acidentados ou regiões remotas, facilitando a captura de informações em locais que anteriormente não seriam mapeados. Ao mesmo tempo, o LiDAR proporciona uma medição precisa de distâncias e uma representação tridimensional detalhada do terreno, objetos e estruturas presentes.

A regulamentação estabelecida por órgãos como a Agência Nacional de Aviação Civil (ANAC), Agência Nacional de Telecomunicações (ANATEL) e Departamento de Controle do Espaço Aéreo (DECEA) impulsionou o uso de RPAS com sensores LiDAR para a coleta de dados em diversos setores, incluindo o mapeamento topográfico, planejamento urbano, monitoramento ambiental e, mais especificamente, na indústria de energia.

Essa combinação de tecnologias não apenas permite a coleta de dados mais eficiente e precisa, mas também estimula o desenvolvimento de novas técnicas de processamento. Com a crescente demanda por soluções de mapeamento e monitoramento mais avançadas, a integração de RPAS com LiDAR está impulsionando a inovação e abrindo novas possibilidades para o setor energético e outros campos de aplicação.

Ao integrar o LiDAR com RPAS, as empresas de energia podem obter um mapeamento mais rápido, preciso e abrangente das áreas de interesse. Os RPAS equipados com sensores LiDAR podem sobrevoar as regiões e coletar dados tridimensionais de forma eficiente, mesmo em terrenos acidentados ou locais remotos. Essas informações permitem uma análise mais detalhada das torres de transmissão, auxiliando na identificação de possíveis problemas, na manutenção preventiva e na tomada de decisões estratégicas para a expansão da infraestrutura elétrica.

Além disso, a utilização de LiDAR e RPAS proporciona benefícios adicionais, como a redução de custos e a minimização de riscos para os trabalhadores. Com a inspeção remota realizada pelos RPAS, não é mais necessário enviar equipes de inspeção física para locais perigosos ou de difícil acesso. Isso resulta em uma economia significativa de recursos e, ao mesmo tempo, garante a segurança dos profissionais envolvidos.

O produto de um levantamento LiDAR é uma nuvem de pontos com coordenadas tridimensionais. O principal problema no uso de dados LiDAR é a modelagem de objetos ou sua identificação, pois a nuvem de pontos, mesmo podendo variar conforme o modelo específico do sensor LiDAR, das configurações de voo e

das necessidades do projeto, fornecem densidades de pontos variando de algumas centenas a vários milhares de pontos por metro quadrado (pontos/m²) e de forma não organizada. Por isso, após a coleta dos dados é necessário seu processamento para a detecção e identificação das feições presentes na nuvem de pontos. Uma etapa nesse processo é a classificação da nuvem de pontos em objetos específicos de interesse. A classificação da nuvem de pontos envolve atribuir rótulos ou categorias a cada ponto com base em suas características e propriedades. Essa classificação permite distinguir diferentes tipos de feições presentes na nuvem de pontos, como edifícios, árvores, veículos, linhas de transmissão, entre outros.

Existem diferentes abordagens e algoritmos para realizar a classificação da nuvem de pontos. Alguns métodos utilizam características geométricas, como a forma e o tamanho dos objetos, enquanto outros utilizam informações de intensidade de retorno do laser ou características espectrais. Além disso, técnicas de aprendizado de máquina, como redes neurais convolucionais (CNNs), podem ser aplicadas para a classificação automatizada da nuvem de pontos.

A classificação da nuvem de pontos permite derivar informações para análise e tomada de decisão no setor de energia. Por exemplo, a identificação de torres, postes e cabos das linhas de transmissão facilita o planejamento de manutenção e inspeção. Da mesma forma, a detecção de outros objetos, como árvores, próximos às linhas de transmissão, ajuda na identificação de potenciais riscos de interferência e quedas de energia elétrica.

No caso específico da análise de nuvens de pontos, a tarefa não consiste apenas em classificar cada ponto com base nas suas coordenadas, mas deve-se analisar seu contexto espacial para decidir de que elemento ele faz parte, ou seja, a nuvem deve ser segmentada e classificada, o que pode ser atingido pela segmentação semântica. Enquanto a classificação da nuvem de pontos atribui rótulos a cada ponto individualmente, a segmentação semântica tem como objetivo agrupar os pontos em regiões ou segmentos que representem objetos ou possuem características semelhantes.

A segmentação semântica busca identificar, na nuvem, regiões de pontos que compartilham propriedades semelhantes, como cor, textura, forma ou contexto espacial. Ao agrupar os pontos em segmentos semânticos, é possível obter uma representação mais rica e detalhada das feições presentes na nuvem de pontos. Por exemplo, em uma nuvem de pontos de uma área urbana com linhas de transmissão,

a segmentação semântica pode ajudar a identificar não apenas as próprias linhas de transmissão, mas também os objetos próximos a elas, como postes, árvores ou edifícios.

O aprendizado profundo, também conhecido como Deep Learning, é uma técnica de aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas para aprender representações complexas dos dados. Essa abordagem tem se mostrado altamente eficaz na segmentação semântica, permitindo que a rede neural aprenda automaticamente as características discriminativas dos objetos de interesse com base nos dados de treinamento.

No contexto da segmentação semântica, uma das aplicações promissoras é a interpretação detalhada do ambiente, identificando e categorizando objetos presentes na nuvem de pontos. Essa técnica, quando combinada com a classificação da nuvem de pontos, oferece uma representação mais completa das feições e objetos na cena. Ao utilizar técnicas avançadas de aprendizado profundo, como as CNNs, é possível alcançar resultados mais precisos e refinados na segmentação semântica, pois as CNNs têm a capacidade de aprender hierarquias de características e identificar padrões e detalhes relevantes em diferentes escalas espaciais.

Essa combinação de técnicas avançadas impulsiona a capacidade de análise e interpretação dos dados coletados. No setor elétrico, aplicando a segmentação semântica ao resultado do mapeamento 3D, espera-se obter uma compreensão mais detalhada do ambiente, identificando obstáculos, feições e estruturas relevantes para a operação das redes elétricas.

Assim, este trabalho propõe o desenvolvimento de um método de segmentação semântica para detectar e classificar cabos e torres ao longo das linhas existentes de transmissão de energia. Para isso, serão utilizadas nuvens de pontos 3D obtidas por sensores LiDAR embarcados em RPAS, explorando técnicas de aprendizado profundo para a análise dos dados.

Adicionalmente, este trabalho proporciona a criação de um banco de dados LiDAR gratuito, acadêmico e específico para a tarefa de segmentação semântica, com o objetivo de fornecer um conjunto de dados representativo e diversificado para o treinamento de modelos de aprendizado profundo.

1.1 OBJETIVO GERAL

O objetivo geral desta pesquisa consiste em desenvolver um método de segmentação semântica baseado em aprendizagem profunda para detecção e classificação de objetos a partir de dados LIDAR embarcado num RPAS.

1.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos para o desenvolvimento da metodologia são:

1. Identificar os principais algoritmos de segmentação semântica para o processamento de nuvens de pontos 3D obtidas por sensores LiDAR embarcados em RPAS.
2. Desenvolver e apresentar estratégias para lidar com alta densidade de pontos em nuvens de pontos 3D, visando otimizar a análise e extração de informações para a entrada de uma rede neural.
3. Analisar o desempenho da rede PointNet++ com as nuvens de pontos aéreas obtida por RPAS com dois conjuntos de dados com características distintas, sendo um de área rural e outro urbana.
4. Desenvolver um método para detectar e segmentar elementos da linha de transmissão, especialmente as torres;
5. Desenvolver um método para classificar os cabos e os tipos de torres conforme suas características e formas;
6. Identificar possíveis desafios e limitações do método proposto e propor estratégias de melhoria e otimização, como o uso de técnicas de pós-processamento ou refinamento.

2 REVISÃO DE LITERATURA

O presente capítulo referente ao embasamento teórico da tese, apresenta os conceitos norteadores da pesquisa e uma reflexão sobre o estado da arte de pesquisas recentes, correlatas aos propostos. Prezou-se por referências recentes sobre os referenciais teórico-conceituais da pesquisa.

2.1 CONCEITOS FUNDAMENTAIS

2.1.1 Sistema RPAS

Os termos "drone", "VANT" e "RPAS" são frequentemente usados para descrever equipamentos remotamente pilotados, que operam no espaço aéreo sem a presença de um ser humano a bordo (DECEA, 2023; GRANSHAW, 2018). Embora o termo "drone" seja uma expressão popular, seu nome deriva do som semelhante a um zangão que alguns desses dispositivos emitem durante o voo (GRANSHAW, 2018). "VANT" é uma sigla para "Veículo Aéreo Não Tripulado", embora tenha sido considerado obsoleto pela Organização da Aviação Civil Internacional (OACI) (DECEA, 2023). Em contraste, "RPAS", ou "*Remotely Piloted Aircraft System*", é um termo técnico e internacionalmente padronizado pela OACI para se referir a sistemas de aeronaves remotamente pilotadas usados principalmente em contextos não recreativos conforme Coelho Eugenio et al., (2021). Portanto, esses termos descrevem essencialmente a mesma categoria de equipamentos, variando em sua popularidade e especificidade técnica.

O RPAS consiste em vários subsistemas, como uma estação de controle, uma aeronave transportando uma câmera, um sistema de comunicação entre a estação de controle e a aeronave e outros equipamentos de suporte. A aeronave, referida como um veículo aéreo não tripulado, o RPA, é operada sem uma tripulação aérea e controlada por um controle remoto ou de forma autônoma por computadores de bordo. Existem muitos tipos diferentes de RPA e, dependendo do próprio veículo aéreo e de seus subsistemas, ele pode ser usado para diferentes tipos de missões (GUSTAFSON, et al., 2017). Entre as vantagens trazidas por esses sistemas estão a possibilidade de coleta de dados em tempo real, a rápida avaliação e mapeamento de recursos na escala espaço-temporal definida pelo usuário, a não necessidade de

utilização de aeroportos para decolagem, flexibilidade da aquisição de dados, além de oferecerem uma resolução espacial mais refinada, pois operam em altitude de voo menor que as plataformas aéreas convencionais (COELHO et al., 2021)

No contexto das aplicações aerolevantamentos e inspeções de linhas de transmissão, os avanços tecnológicos tornam os RPAS soluções acessíveis para observar sistemas de linhas de transmissão de energia a curtas distâncias (GUAN et al., 2021; ZHANG et al., 2017). Os RPAS fornecem vários tipos de dados para inspeções precisas de linhas de energia, por meio de múltiplas tecnologias de sensoriamento remoto, como por exemplo, câmera óptica, LiDAR, câmera infravermelha e câmera ultravioleta (GUAN et al., 2021)

Os sistemas RPAS empregados neste trabalho foram o LiAir50 e o LiAir70, ambos equipados com o RPA Matrice 600, GNSS, IMU, LIDAR e uma câmera RGB, conforme exemplo apresentado na FIGURA 1. A principal distinção entre os sistemas está no sensor LiDAR utilizado. Esses sistemas mostram suas potencialidades para aquisição de dados geoespaciais em trabalhos como os de Józków, Walicka e Borkowski (2021).

FIGURA 1 - RPA MATRICE 600 COM LiDAR



FONTE: GVI (2023).

2.1.1.1 Legislação dos RPAS no Brasil.

O uso do espaço aéreo brasileiro é gerenciado principalmente pelo Departamento de Controle do Espaço Aéreo (DECEA), estando diretamente subordinado ao Ministério da Defesa e ao Comando da Aeronáutica, sendo responsável pelo controle estratégico e sistêmico do espaço aéreo. Também há o papel desempenhado pela Agência Nacional de Aviação Civil (ANAC), vinculada à Secretaria de Aviação Civil da Presidência da República, que tem por objetivos a regulamentação e fiscalização das atividades oriundas da aviação civil, bem como a infraestrutura aeronáutica e aeroportuária brasileiras (DECEA, 2023).

Para realizar qualquer tipo de operação em território nacional, o usuário civil necessita de um Certificado de Autorização de Voo Experimental (CAVE), expedido pela ANAC. A Instrução Suplementar (IS) que orienta tal emissão é a IS nº 21-002A com base no RBAC nº 21. Tal documento discorre sobre a necessidade de autorização de voo, as definições aceitas pela ANAC acerca dos RPAS, dentre outras normativas. Para além do RBAC 21 e o IS nº 21-002A, também é possível tomar como base o Código Brasileiro de Aeronáutica. Cabe citar que até o presente momento a ANAC não autoriza voos comerciais de RPAS, embora venha ensaiando uma liberação de voos de equipamentos de até 25 quilos e teto operacional máximo de 400 pés, ou seja, 120 metros (DECEA, 2023).

2.1.2 Sensor LiDAR

De acordo com a citação de Wehr e Lohr (1999), o termo "LiDAR scanner" refere-se a uma tecnologia de coleta de dados tridimensionais que emprega um sistema de varredura com raios LiDAR. Este sistema segue o princípio de medição de ângulos e distâncias para realizar o posicionamento em três dimensões, semelhante ao funcionamento de uma estação total. A estação total é um instrumento eletrônico que surgiu na década de 1990, muito utilizado para medir ângulos e distâncias. A estação permite o armazenamento de dados internamente o que facilita o trabalho no campo e possibilitando uma sofisticação maior que o teodolito (Carvalho et al., 2017). Portanto, a distinção reside na quantidade de pontos captados e na velocidade de aquisição de dados.

O sistema LiDAR scanner é composto por três componentes essenciais: uma unidade de medição LiDAR, um sistema de varredura optomecânico e uma unidade de registro de medição de apoio (BALTSAVIAS, 1999). Estes sistemas podem ser categorizados como estáticos ou dinâmicos, com exemplos típicos de sistemas estáticos incluindo os terrestres, que são comumente montados em tripés e utilizados para levantamentos minuciosos de objetos a curtas distâncias. Por outro lado, os sistemas móveis tradicionais, como os sistemas aerotransportados, são instalados em aeronaves, como aviões ou helicópteros, e são empregados para cobrir áreas extensas.

Os sistemas de varredura LiDAR móveis, internacionalmente conhecidos como *Mobile LiDAR Scanning* (MLS) ou *Mobile Terrestrial LiDAR Scanning* (MTLS), são classificados como sistemas dinâmicos e são comumente instalados em veículos, especialmente em carros, embora também possam ser adaptados para uso em barcos e trens, conforme destacado por Hoover (2012). Essa tecnologia móvel ingressou no mercado no início dos anos 2000, com o propósito de realizar levantamentos terrestres de alta precisão, superando os limites dos levantamentos aéreos. Uma das principais vantagens dos sistemas móveis LiDAR é a capacidade de coletar uma quantidade substancialmente maior de pontos de dados em comparação com levantamentos aéreos, tornando-os uma ferramenta valiosa para aplicações que demandam alta resolução e detalhamento.

2.1.2.1 Funcionamento

O objetivo básico de um LiDAR scanner é a medição de coordenadas tridimensionais de pontos sobre uma superfície. Para isto, pulsos de LiDAR são emitidos pelo sistema e com auxílio de um espelho de varredura são direcionados, atingindo a superfície dos objetos em vários pontos. Estes objetos refletem o pulso incidente e parte do pulso volta para o sistema. Com isto, a distância entre o sensor e o objeto é determinada através do intervalo de tempo entre a emissão e a reflexão (retorno) do pulso (DALMOLIN e SANTOS, 2003).

Para medir a distância, é registrado o tempo de ida e volta do pulso LiDAR entre o sensor e a superfície. A medição entre a emissão e a captação do pulso deve ser precisa. A distância pode ser medida pela EQUAÇÃO 1.

$$R = \frac{1}{2} \times c \times dt \quad (1)$$

onde:

R=distância (range);

c=velocidade da luz;

dt=intervalo de tempo entre emissão e registro do pulso refletido.

Atualmente os sensores a LiDAR podem ser pulsados ou de onda contínua, e normalmente possuem uma cabeça giratória capaz de coletar pontos em 360 graus. Através do movimento do veículo em conjunto com a varredura do sensor, permite que o perfilamento tenha uma boa área de abrangência (NCHRP, 2013). Os sensores também fornecem um valor de intensidade do sinal, que é o grau de reflectância que os elementos que pertencem a superfície possuem. Ele é importante para distinguir objetos da nuvem de pontos e dependendo do sensor possui características diferentes que resultarão em valores diferentes. Nos casos em que são agrupados levantamentos oriundos de sistemas diferentes será necessário um procedimento de normalização para corrigir essas diferenças. Essa normalização pode ser realizada pelos softwares comerciais de manipulação de dados LiDAR, bem como, através de uma rotina de programação.

2.1.2.2 Nuvem bruta LAS

Sensores 3D típicos utilizam princípios de medição de *line-of-sight* para capturar nuvens de pontos, ou seja, pontos 3D na superfície 2D de um carro ou casa, como apresentado na FIGURA 2. Para armazenar dados bidimensionais em um espaço tridimensional, frequentemente é utilizado um formato de dados esparsos na forma de uma lista de coordenadas. Nesse formato, as coordenadas de cada ponto 3D são armazenadas como números de ponto flutuante, complementados por informações adicionais, como cores RGB, valores de intensidade ou rótulos de classe (TIMO, 2018).


Quando se trata de representar nuvens de pontos, onde cada ponto tem três coordenadas espaciais (x, y e z) para definir sua posição no espaço tridimensional, a organização dessas informações em listas requer uma quantidade considerável de espaço de armazenamento. Isso ocorre porque todas as coordenadas são expressas

como números de ponto flutuante, o que implica que cada coordenada é armazenada com alta precisão para capturar detalhes minuciosos.

Os números de pontos flutuantes são usados para representar números reais que possuem parte inteira e decimal. No entanto, essa representação possui um custo em termos de espaço de armazenamento. Por exemplo, a representação de números flutuantes requer mais espaço do que números inteiros, o que faz com que as coordenadas de cada ponto ocupem uma quantidade significativa de memória. Portanto, a utilização de técnicas de compressão de dados pode ser uma abordagem eficaz para reduzir as necessidades de memória associadas ao armazenamento de grandes conjuntos de nuvens de pontos.

É viável obter uma representação mais eficaz em termos de memória ao depurar ruídos e aplicar funções de compressão fundamentadas em entropia, tal como especificado nos formatos de dados LAS e LAZ (ISENBURG, 2011).

FIGURA 2 - REPRESENTAÇÃO 3D DE PONTOS



FONTE: O autor (2023).

2.1.2.3 Intensidade

A intensidade dos pontos em uma nuvem de pontos LiDAR é uma medida da quantidade de energia refletida pelo objeto-alvo em direção ao sensor LiDAR. Geralmente, essa informação é registrada numericamente, servindo como um indicador da força do retorno do sinal. Em algumas aplicações, a intensidade é útil para inferir características do objeto, como a capacidade de refletir a luz ou a

densidade da vegetação. Além disso, a intensidade é um parâmetro adicional usado na classificação de pontos LiDAR para distinguir diferentes objetos e estruturas. É importante observar que a intensidade é relativa a uma nuvem de pontos específica e não possui um valor absoluto, o que significa que não se pode comparar diretamente valores de intensidade em terrenos ou objetos semelhantes de diferentes áreas de voo ou elevação. Ela varia conforme a distância do objeto, a capacidade de refletir a luz do objeto e o ângulo sob o qual o feixe de laser incide no objeto, conforme detalhado por Schulz (2004). Portanto, a intensidade reflete a qualidade do alcance do sinal emitido pelo sensor LiDAR e é influenciada por esses três principais parâmetros: a distância do objeto, a reflectância do objeto e o ângulo de incidência.

2.1.2.4 Aplicações dos Sensores Lidar em RPAS

Os dados obtidos por sensores LiDAR embarcados em RPA, podem ser georreferenciados em sistemas de coordenadas diversos, e têm uma ampla gama de aplicações, indo desde a esfera do entretenimento até a realização de mapeamentos altamente precisos, abrangendo áreas como levantamentos terrestres, projetos rodoviários, ferroviários e hidrográficos.

No cenário brasileiro, a tecnologia LiDAR vem ganhando relevância, principalmente na agricultura de precisão, onde avanços tecnológicos vêm otimizando processos e recursos, ao mesmo tempo que reduzem os impactos ambientais. A aplicação em projetos rodoviários tem crescido devido à maioria dos sistemas possuir tanto o sensor LiDAR quanto uma câmera digital. A combinação de dados provenientes desses sensores possibilita a aquisição de informações topográficas, planimétricas e altimétricas necessárias para o desenvolvimento de projetos de estradas.

Na perspectiva dos ventos, a tecnologia LiDAR também apresenta potencial no contexto brasileiro, especialmente quando consideramos sua aplicação em projetos de energia eólica. No país, onde as condições geográficas e climáticas favorecem a geração de energia a partir do vento, o uso do LiDAR pode oferecer uma ferramenta precisa para avaliar o potencial de ventos em determinadas regiões, auxiliando na escolha de locais adequados para a instalação de parques eólicos.

Além disso, a utilização do LiDAR na indústria de energia eólica contribui para otimizar o design das plantas e a operação dos parques, permitindo uma melhor

compreensão dos padrões de vento locais e, conseqüentemente, uma maximização da eficiência na geração de energia. Essa abordagem também pode reduzir os custos associados à análise de viabilidade e ao monitoramento da produção de energia, tornando os projetos mais sustentáveis e economicamente viáveis.

2.1.2.5 Sensor LiDAR VLP-16

O sensor LiDAR da Velodyne utiliza a metodologia de tempo de voo (Time of Flight), ToF, que se baseia no princípio de emissão de luz infravermelha para determinar informações de profundidade. Esse sensor emite um pulso de luz, e registra o tempo de disparo e a direção desse pulso. Quando o pulso de luz encontra um obstáculo, parte da energia é refletida e recebida pelo receptor do sensor. Com base no tempo de aquisição e na potência do sinal recebido, é possível calcular a distância e a intensidade do retorno.

Além de determinar informações de profundidade por meio da metodologia de ToF, o sensor LiDAR da Velodyne oferece diversas vantagens na obtenção de dados tridimensionais. Essa tecnologia permite a captura de nuvens de pontos altamente detalhadas e precisas, o que possibilita uma reconstrução fiel do ambiente em que o sensor está operando (VELODYNE, 2018).

Mota (2018) comenta que utilizar luz infravermelha para medir distâncias, o sensor LiDAR é capaz de atingir altos níveis de resolução espacial e temporal. Isso significa que pode detectar pequenas variações de distância entre o sensor e os objetos, resultando em uma representação mais precisa da geometria do ambiente. Portanto, a metodologia ToF oferece uma ampla faixa dinâmica, permitindo que o sensor LiDAR capte tanto objetos próximos quanto distantes com alta precisão. Isso torna o sensor adequado para aplicações em diferentes cenários, desde mapeamento de áreas urbanas até levantamento topográfico de terrenos acidentados.


O sensor LiDAR da Velodyne oferece três tipos de retornos: retorno mais forte, retorno último e retorno duplo. Esses retornos são resultantes da divergência do feixe de luz emitido pelo sensor, que atinge vários objetos dentro do seu campo de visão. O sensor é capaz de determinar a qual objeto cada retorno pertence (VELODYNE, 2018).

Na FIGURA 3 é possível observar que a maior parte do feixe atinge a parede próxima, enquanto uma porção menor do feixe atinge a parede distante. O sensor

VLP-16 registrará ambos os retornos apenas se a distância entre esses dois objetos for maior que 1 metro. Caso o retorno mais forte seja o último detectado, o segundo retorno mais forte também será relatado.

Essa capacidade de distinguir entre os diferentes retornos é importante para a análise e interpretação dos dados coletados pelo sensor LiDAR. Ela permite uma maior precisão na identificação e na localização dos objetos presentes no ambiente, além de fornecer informações sobre a geometria e a estrutura deles (CENTENO, et al., 2007).

FIGURA 3 - TIPOS DE RETORNOS DO VLP-16 DA VELODYNE



FONTE: Adaptado Velodyne (2018).

O retorno duplo é uma modalidade específica de retorno amplamente utilizado em aplicações que exigem a penetração do pulso de luz em múltiplas camadas, principalmente em áreas com cobertura florestal densa ou para obter retorno de cabos para-raios em linhas de transmissão. Essa técnica é particularmente relevante quando o objetivo é obter informações detalhadas sobre a estrutura das árvores presentes na região de interesse ou dos cabos de transmissão, especialmente os cabos para raio. Para realizar essa análise, o sistema de sensoriamento remoto requer a entrada da altura das árvores como um parâmetro fundamental (VELODYNE, 2019).

A FIGURA 4 ilustra um exemplo dessa modalidade de retorno duplo, demonstrando a penetração do pulso de luz na copa das árvores, nos ramos e nas folhas, até alcançar o solo. Essa representação visual exemplifica a capacidade do


sensor LiDAR em capturar informações precisas e detalhadas sobre a estrutura vertical das árvores e o perfil do terreno subjacente.

Ao utilizar o retorno duplo, o sistema de sensoriamento remoto tem a capacidade de registrar não apenas o primeiro retorno do pulso, correspondente à superfície superior da copa das árvores, mas também os retornos subsequentes que podem ocorrer nas partes internas das árvores, como ramos e folhas.

Dessa forma, o uso do retorno duplo amplia significativamente as capacidades do sensor LiDAR na aquisição de dados em áreas florestadas, permitindo uma análise da vegetação e do terreno circundante. Essa modalidade possibilita a obtenção de informações detalhadas sobre a estrutura vertical das árvores, incluindo a detecção de diferentes camadas vegetais e características internas, que são direcionadas para estudos de ecologia florestal, monitoramento ambiental e planejamento sustentável do uso da terra.

Conforme Velodyne (2019), a densidade de pontos por metro quadrado no modo de perfilamento duplo apresenta uma relação inversamente proporcional com a velocidade do RPAS, expressa em metros por segundo. No contexto deste estudo, foram consideradas alturas de voo padrão de 30, 40, e 50 metros, juntamente com um campo de visão (FOV) máximo de 80°.

FIGURA 4 – EXEMPLO DE RETORNO DUPLO DO PULSO LIDAR NUMA ÁRVORE.



FONTE: Adaptado Velodyne (2018).

2.1.2.6 Sensor LiDAR Livox AVIA

O AVIA LIVOX é um sensor superior quando comparado ao VLP-16, mesmo sendo considerados dois notáveis sensores LiDAR. As mesmas características funcionais apresentadas no VLP-16 estão presentes no AVIA LIVOX. As principais distinções são consideráveis tanto em termos de desempenho quanto de design.

Este sensor se destaca pela sua resolução espacial e temporal notavelmente alta, possibilitando uma captura minuciosa e precisa dos detalhes ambientais, enquanto o VLP-16 oferece uma alternativa robusta, com um histórico comprovado de desempenho consistente.

Essas disparidades também se manifestam em suas características físicas, com o AVIA LIVOX concebido para ser compacto, conforme dimensões apresentadas na FIGURA 5 e considerado leve, com apenas 500 gramas, conferindo-lhe uma adaptabilidade ideal para integração em uma variedade de plataformas RPAs, ao passo que o VLP-16, embora mantenha um padrão de qualidade, pode ser ligeiramente maior e mais pesado.

Adicionalmente, embora ambos os dispositivos sejam proficientes em determinar diferentes modalidades de retorno de sinal, tais como retorno mais forte, retorno último e retorno duplo, as nuances da tecnologia de retorno de sinal podem variar entre os modelos, influenciando diretamente na interpretação e utilização dos dados coletados em diversos contextos de aplicação.




FIGURA 5 - SENSOR LIDAR LIVOX AVIA

FONTE: Adaptado Livox (2023).


2.2 ESTADO DA ARTE

2.2.1 Linhas de Transmissão

O transporte da energia gerada nas usinas até as estações transformadoras, bem como a interligação com outros sistemas de transmissão, é realizado através das linhas de transmissão, que operam em alta tensão, permitindo que a energia seja transportada a partir de longas distâncias (ABNT, 2000). Segundo Silva et al., (2016), elas representam maneira mais eficiente de levar energia do ponto de geração aos consumidores finais, que são componentes fundamentais do Sistema Elétrico de Potência.

As linhas de transmissão de energia interligam várias instalações de geração de energia elétrica e distribuidores do sistema de transmissão de eletricidade em massa (GUAN et al., 2021). Segundo a ABNT (2000), no Brasil as linhas de transmissão operam em classes de tensão iguais ou maiores que 230 kV. Linhas de transmissão aéreas apresentam em geral, um cabeamento de condutores nus, suportados por estruturas ou torres, das quais são isolados através de isoladores (ABNT, 2000). De forma resumida, uma linha aérea de transmissão de energia é composta pelos elementos apresentados esquematicamente na FIGURA 6. Um sistema típico de linha aérea de energia na rede elétrica, consiste em milhares de componentes, incluindo condutores, fios terra, isoladores, braçadeiras, emendas, espaçadores e amortecedores (GUAN et al., 2021).

FIGURA 6 - COMPONENTES BÁSICOS DE UMA LINHA DE TRANSMISSÃO AÉREA



FONTE: Silva et al., (2016).

A gestão e a inspeção dos corredores de linhas de transmissão, compreendendo os objetos em suas faixas de domínio, desempenha um papel extremamente importante na gestão de riscos de linhas de energia e, é uma tarefa desafiadora de monitoramento da rotina em uma empresa de energia elétrica (COPEL, 2017). Monitoramentos assertivos empregando soluções robustas para essas redes de transmissão de energia, possibilitam a reengenharia das linhas de transmissão estimando a variação altimétrica na curva de catenária no cabeamento, bem como a identificação de possíveis invasões (vegetação em crescimento danificando as linhas de transmissão, construções irregulares na faixa não edificante etc.) (CHEN et al., 2018; GUAN et al., 2021).

Os níveis elevados de campos eletromagnéticos podem provocar danos a seres humanos, animais ou objetos localizados próximos às linhas de transmissão, sendo necessária também a inspeção de faixas de servidão ao longo das trajetórias das linhas, para a inibição máxima do recebimento dos campos eletromagnéticos (SILVA et al., 2016). Os componentes de linhas transmissão pode ser destruídos ou danificados por desastres naturais como tempestades de vento, raios e incêndios, bem como atividades antrópicas, como vazamentos de poluentes, que resultam em falhas de infraestrutura, como superaquecimento, erosão, quedas, incêndios ou arcos voltaicos (GUAN et al., 2021). Razões pelas quais as linhas de transmissão são prioridade extremamente alta para as empresas de serviços públicos (COPEL, 2017).

Segundo He, Zeng e Hu (2019), a eficiência da inspeção tradicional de linhas de transmissão é baixa, o que indica que métodos de inspeção de linhas de transmissão mais eficientes e automatizados são necessários para manter a segurança da rede elétrica e melhorar a confiabilidade do fornecimento da rede elétrica. Os métodos tradicionais de inspeção da rede de transmissão normalmente dependem de pessoal profissional complementado por telêmetros a laser, teodolitos ópticos, estações totais, termógrafos e outros equipamentos relacionados para completar a inspeção (WANG et al., 2023). Esses métodos têm desvantagens como riscos de segurança e baixa eficiência e não podem atender às necessidades de gestão do sistema de energia ou aos requisitos de desenvolvimento da rede elétrica e reforma institucional (WANG et al., 2023; YANG et al., 2020).

A tecnologia LiDAR embarcada em RPAS é indicada para aerolevantamentos em baixas altitudes de voo, ou mesmo para aquisição de dados tridimensionais a

curtas distâncias. Com o rápido desenvolvimento desses sistemas, alguns sensores de inspeção podem ser integrados à essas aeronaves para aumentar assim sua capacidade de percepção do ambiente de transmissão de energia (YANG et al., 2020). Vantagens notórias devem-se ao seu pequeno tamanho, baixo custo e boa mobilidade. Embarcando a tecnologia de sensoriamento remoto ativo baseada em feixes laser, é possível detectar estruturas finas, como linhas de transmissão aérea, fios elétricos de iluminação pública, cercas, etc. Esta técnica de inspeção de corredores de linhas elétricas oferece uma maneira rápida de obter informações geoespaciais tridimensionais de alta precisão, representadas por nuvens de pontos densas (SHEN et al., 2023; WANG et al., 2023; HARTLING et al., 2021).

2.2.1.1 Componentes das Linhas de Transmissão

O desempenho elétrico das linhas de transmissão depende quase exclusivamente de suas características físicas e da topologia do sistema interligado. Elas não só ditam o seu comportamento em regime normal de operação, definindo seus parâmetros elétricos, como também, quando em condições adversas, como limites no fluxo de energia ao longo das linhas (SILVA et. al., 2017).

Os componentes físicos principais presentes nas linhas de transmissão são os cabos condutores de energia que têm o objetivo de, através dos campos elétricos e magnéticos, transportar a energia. De acordo com Silva (2017) os cabos devem possuir boa durabilidade, alta condutividade, baixo custo, boa resistência mecânica, baixo peso e alta resistência a oxidação e corrosão por agentes químicos poluentes.

As estruturas isolantes têm a função de isolamento elétrica da estrutura e do solo e devido as forças verticais e horizontais que eles suportam devido a condições meteorológicas, precisam também terem boa resistência. Em linhas de transmissão são utilizados os isoladores de pino, tipo pilar e de suspensão, FIGURA 7.

FIGURA 7 - TIPOS DE ISOLADORES PINO, PILAR E DE SUSPENSÃO




FONTE: O autor (2023).

As estruturas em linhas de transmissão desempenham funções específicas de acordo com as cargas a serem suportadas. As estruturas de suspensão suportam cargas verticais, como vento e peso dos cabos e isoladores. As estruturas de ancoragem, divididas em terminais para deflexões grandes e médias para deflexões médias, são empregadas respectivamente no início e fim das linhas e no meio delas, equilibrando trações longitudinais. Estruturas de transposição de fase garantem o equilíbrio magnético da linha, enquanto estruturas de derivação permitem sangrias na linha para alimentar ramais sem a necessidade de pátios de seccionamento.(VELOZO, 2010)

As estruturas de suporte são as torres que sustentam os cabos e isoladores. A disposição e distância dos condutores em linhas de transmissão, seja ela triangular, horizontal ou vertical, desempenha um papel importante na configuração dessas estruturas. Além disso, as dimensões e formas de isolamento são determinadas pela tensão nominal e pelas sobretensões previstas. As flechas dos condutores, a altura de segurança e a função mecânica das estruturas também são considerações essenciais, pois variam de acordo com os tipos de carga que as linhas de transmissão devem suportar. A escolha entre estruturas autoportantes (rígidas, flexíveis, mistas ou semirrígidas) ou estruturas estaiadas é determinada pela análise das necessidades específicas de cada caso. Além disso, os materiais estruturais, como estruturas metálicas, madeira ou concreto, desempenham um papel importante na resistência e durabilidade das linhas de transmissão. Por último, o número de circuitos e outras considerações práticas também influenciam o projeto e a operação dessas linhas de transmissão. Portanto, a arquitetura da estrutura de suporte depende do objetivo e requisitos pré estabelecidos conforme a capacidade da linha a ser implantada. .(SILVA et. al.,2017).

Os tipos de estruturas mais comuns são os apresentados na FIGURA 8. Nesta tese, apenas existem torres do tipo delta e pirâmide, portanto foram nomeadas como torre do tipo 1 e 2.

FIGURA 8 - ESTRUTURAS DE TORRES DE LT'S DO TIPO DELTA, PIRÂMIDE E ESTAIADA



FONTE: Lima (2013).

2.2.1.2 Redes Neurais no Setor Elétrico

A complexidade do sistema elétrico aumentou devido à integração de diferentes fontes de geração de energia, como fotovoltaica, eólica e biomassa. Embora as redes neurais artificiais sejam utilizadas para auxiliar na gestão do sistema elétrico, visando melhorar o planejamento e controle, o aumento no processo de automação também trouxe consigo um desafio: o aumento no volume de informações. Este acréscimo de dados, embora valioso, também pode representar um desafio significativo para os especialistas.


Por um lado, a disponibilidade de mais informações pode enriquecer a análise e fornecer soluções mais precisas. No entanto, é preciso reconhecer que um excesso de informações pode sobrecarregar os especialistas e complicar a tomada de decisões. Lidar com grandes volumes de dados pode exigir recursos computacionais e aumentar os custos operacionais. Além disso, a possibilidade de erros na interpretação ou manipulação dos dados aumenta com a quantidade de informações disponíveis.

Conforme Kopiler, et al.(2019), inúmeros problemas nos Sistemas Elétricos de Potência requerem o conhecimento de um especialista, que usualmente é capaz de resolvê-los bem melhor do que qualquer máquina que seja guiada por algoritmos tradicionais (não inteligentes). Esta característica torna atraente a utilização de técnicas de Inteligência Computacional em sua resolução, pois a forma de pensar do especialista poderia ser então devidamente simulada, auferindo resultados similares àqueles que foram atingidos pelo especialista humano.

Alguns pesquisadores já consolidaram o uso de redes neurais para previsões de sobrecarga do sistema energético, bem como, na detecção de pontos danificados e no planejamento energético. Paralelamente, os estudos sobre mapeamento avançam, especialmente na detecção de vegetação que possa estar invadindo as linhas de alta tensão, graças ao uso de técnicas de aprendizado profundo.

O consumo de energia elétrica das residências e edifícios foi considerado como um dos maiores problemas no futuro. Rahman et al (2018), faz uma predição do consumo de energia de casas e edifícios com resolução de uma hora dentro de 24 horas em uma semana. Esta pesquisa propôs dois modelos de redes neurais convolucionais baseados em *Long Short-Term Memory* (LSTM). São uma combinação de duas arquiteturas de redes neurais profundas: CNNs e Redes Neurais Recorrentes (RNNs). O modelo possui algumas limitações quanto as condições climáticas e quando novos dados são inseridos no conjunto de dados. A FIGURA 9 evidencia que o desempenho do modelo proposto pelo autor foi satisfatório, embora tenha sido inferior em comparação com o modelo Multi-Layered Perceptron (MLP) de 3 camadas. Adicionalmente, o estudo indica que as redes neurais convolucionais possuem um potencial significativo na predição do consumo de energia em residências e edifícios.

FIGURA 9 - ERROS RELATIVOS DOS MODELOS MULTI-LAYERED PERCEPTRON E REDES NEURAIS CONVOLUCIONAIS COMO UMA FUNÇÃO DO ERRO MÉDIO QUADRÁTICO DO AGREGADO EM 1 HORA.



FONTE: Rahman, et al., (2018).


Considerando que o problema da inspeção das linhas elétricas é uma preocupação global, Sikorska-Tukasiewicz (2020) desenvolveu uma metodologia inovadora baseada em aprendizado profundo para detectar a invasão de vegetação nas faixas de alta tensão. Além disso, a autora conduziu uma análise comparativa abrangente de vários tipos de levantamentos realizados com diferentes sistemas e soluções, destacando suas restrições, vantagens e desvantagens individuais.

O estudo utilizou a arquitetura de rede convolucional U-Net, originalmente empregada na segmentação de imagens na área médica. Os dados foram coletados por meio de uma câmera RGB embarcada em um RPA, com os resultados obtidos após a segmentação, demonstrando a eficácia do uso de redes neurais na indústria de energia elétrica."

2.2.2 Aprendizado Profundo

O conceito de “Aprendizado Profundo” ou aprendizado hierárquico é uma subdivisão do Aprendizado de Máquina, definido como o estudo e modelagem de processos de aprendizagem e o uso de algoritmos que permitem aos computadores aprender sem serem explicitamente programados e que aprendem através de um grande volume de dados. É um ramo do campo da Inteligência Artificial. A FIGURA 10 mostra como esses temas estão organizados dentro da área de Ciências da Computação (ZHU, et al., 2017). No ANEXO 01, encontra-se uma tabela contendo os principais termos e suas definições utilizados no campo da Inteligência Artificial.

FIGURA 10 - DIAGRAMA DE VEN COM A HIERARQUIA DOS TEMAS DENTRO DE CIÊNCIAS DA COMPUTAÇÃO




FONTE: O autor (2023).

Os métodos de aprendizado profundo se baseiam em Redes Neurais Artificiais, organizadas em camadas de entrada, intermediárias e saída, do que decorre o conceito de profundidade e cada camada tem um peso, conforme exemplo da FIGURA 11. Conforme Hidalgo, 2022, em um problema de classificação, a camada de saída de uma rede neural artificial geralmente consiste em tantos neurônios quantos rótulos de classe houver com um neurônio dedicado a cada classe de saída

potencial. Por exemplo, se você estivesse construindo uma rede neural artificial para classificar diferentes categorias, como "aeroportos," "desmatamento," "floresta," "mineração ilegal," "cultivos ilícitos" e "água" a partir de um conjunto de dados criado com imagens de satélite, a camada de saída teria seis neurônios, cada um representando e correspondendo a uma classe específica. Nos últimos anos, os algoritmos do Aprendizado profundo estão ganhando aplicações em sensoriamento remoto, como mostram publicações recentes como (ZHANG, et al., 2017), (ZHU, et al., 2017), (SHEN, et al., 2019), (SHRESTHA, et al., 2017), (WU, et al., 2020), (SAIFULLAHI, et al., 2019).

FIGURA 11 - ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL



FONTE: Peixoto (2016).

Neste sentido, o Aprendizado Profundo é um tipo de aprendizado de representação, o que significa que, ao contrário do aprendizado de máquina clássico, não requer a criação manual de características. Em outras palavras, especialistas em um determinado domínio não precisam especificar quais características são importantes nos dados e, em seguida, extrair essas características. Ao invés disso, os modelos de aprendizado de máquina aprendem essas características definindo representações dos dados de maneira hierárquica, ou seja, as representações consistem em outras representações mais simples. Essas representações são adquiridas ao passar os dados por camadas sucessivas. Com o Aprendizado Profundo, é possível aprender conceitos complexos, e a necessidade de decidir quais

características são importantes para resolver a tarefa em questão é reduzida. (GOODFELLOW & BENGIO, 2016).

Em termos mais simples, o grande diferencial dos métodos de aprendizagem profunda se encontra no seu processo de aprendizagem. Enquanto tradicionalmente um programador, ou analista, parametriza o problema e propõe o uso de feições ou variáveis para a solução, em algoritmos de aprendizado profundo, a solução é encontrada pelo computador com base em amostras apresentadas ao sistema. Portanto o sistema é responsável por identificar e parametrizar as características mais relevantes das classes de objetos em função dos dados de entrada e, eventualmente, da classificação esperada para cada amostra. No processo de aprendizagem, os descritores mais relevantes são automaticamente extraídos do conjunto de dados pelo sistema. É possível que muito dos descritores ou variáveis obtidas pelo sistema não façam sentido para o usuário descrever a classe com base em seus conhecimentos do meio ambiente, mas sim para a solução do problema no ambiente digital. ANDRADE (2003).

Como os algoritmos de aprendizagem profunda podem encontrar uma solução com base nos dados a eles fornecidos, seu desempenho depende muito da qualidade e quantidade da informação usada na fase de treinamento. Em geral, são necessários grandes conjuntos de dados de referência, ou mais conhecidos como amostras de treinamento para encontrar uma solução adequada (SERRA, 2020).

Conforme Shrestha, et al., (2017), o problema da segmentação de imagens ganhou uma nova perspectiva com a popularização da aprendizagem profunda. Estes algoritmos são vastamente usados na atualidade para reconhecer objetos em imagens, como rostos, veículos ou pedestres e está amplamente sendo estudado na área de medicina, reconhecimento de voz e outras.

Entre os algoritmos de aprendizado profundo mais populares se encontram as CNNs. Em geral, as CNNs têm um desempenho melhor do que outros algoritmos, e seu sucesso se justifica no uso de feições derivadas pelo próprio algoritmo em lugar de feições propostas pelo usuário. Desta forma, os algoritmos de redes profundas podem detectar padrões que, muitas vezes, são invisíveis ao ser humano, devido a sua complexidade. (SERRA, 2020)

Na área de medicina, Shen, et al., (2019) desenvolveram um algoritmo de aprendizado profundo que detecta o câncer em exames de mamografias. Utilizam uma abordagem de treinamento de ponta a ponta que aproveita de forma eficiente as

anotações clínicas como rótulos na parte inicial. O método de rede é totalmente convolucional e apresentou excelentes resultados comparados aos métodos anteriores.

No setor elétrico, um grupo de pesquisadores está desenvolvendo uma rede para detectar fraudes de consumo de energia. Como a base de dados e estudos científicos nessa área são escassos, os estudos estão sendo realizados com a base de dados fornecidos pela *State Grid China*. Eles instalaram medidos IoT (*Internet of Things*) que captam em tempo real o consumo e a energia fornecida pelo transformador. (TERRA, 2020)

Em se tratando de nuvens de pontos, os mesmos conceitos podem ser aplicados, porém, a abordagem deve ser adaptada à natureza dos dados. A opção mais imediata é a projeção da nuvem de pontos a uma grade regular e aplicar técnicas tradicionalmente usadas no processamento de imagens. A outra opção é tratar os dados na sua forma vetorial. (TIMO, 2018)

Algumas experiências já comprovam a viabilidade do uso de aprendizagem profunda para segmentar nuvens de pontos, apontando suas vantagens e desvantagens. Por exemplo, Ciçek, et al.(2016) implementaram a U-Net 3D com base em redes convolucionais para a segmentação de imagens microscópicas de tecidos renais, no campo da medicina. Outros exemplos, mais recentes, podem ser encontrados na medicina, como (ALALWAN, et al., 2020).

Um estudo comparativo entre diferentes métodos de segmentação de nuvens de pontos, que incluem o uso de redes profundas, é apresentado em Poux, et al., (2019). Estes autores compararam diferentes níveis de generalização de feições e métodos de segmentação, começando com a estrutura mais simples de dados tridimensionais (XYZ), voxels, e derivando estruturas topológicas mais complexas.

2.2.2.1 Aprendizado Profundo em nuvem de pontos

Nos últimos anos, o tema do aprendizado profundo para nuvens de pontos 3D tem ganhado bastante popularidade. Atualmente, é uma área de pesquisa muito ativa, com novos artigos sendo publicados mensalmente. Os modelos citados no conjunto de dados incluem o RangeNet++, o RandLa-Net e o LatticeNet. Os métodos de aprendizado profundo atuais para segmentação semântica de nuvens de pontos 3D

podem ser divididos em duas categorias: redes baseadas em projeção e redes baseadas em pontos (SERRA, 2020).


2.2.2.2 Redes baseadas em pontos

As redes baseadas em pontos operam diretamente nas nuvens de pontos. Uma das arquiteturas mais conhecidas e precursoras nesse estudo é o PointNet que utiliza um método MLP ponto a ponto (QI, SU, MO e GUIBAS, 2017). No entanto, existem diversas outras abordagens, como métodos de convolução de pontos, métodos baseados em RNN e métodos baseados em grafos.

Atualmente, as redes baseadas em pontos são a abordagem mais popular para o aprendizado profundo em nuvens de pontos 3D e o RandLa-Net, por exemplo, é um método MLP baseado em pontos (HU, et al., 2020). O principal desafio desses métodos é não possuírem informações explícitas sobre a estrutura de vizinhança da nuvem de pontos 3D e precisam realizar buscas dispendiosas de vizinhos, como o KNN (SERRA, 2020).

A FIGURA 12 apresenta os métodos de aprendizado profundo dividido por suas respectivas estruturas de dados de 2017 até 2020 (SAIFULLAHI, et al., 2019).

FIGURA 12 – VISÃO GERAL DOS MÉTODOS DE APRENDIZAGEM PROFUNDA POR ESTRUTURA DE DADOS.



FONTE: Adaptado Saifullahi, et al., (2019)

Conforme Saifullahi, et al.(2019), a irregularidade significa que os pontos não são amostrados uniformemente em uma determinada região ou cena, então algumas regiões podem ter pontos densos, enquanto outras têm pontos esparsos. Não estruturado quer dizer que os dados da nuvem de pontos não são colocados em uma grade regular. Cada ponto é escaneado de forma independente, e sua distância aos pontos vizinhos não é fixa. Em contraste, pixels das imagens são representadas em uma grade bidimensional, e o espaçamento entre dois pixels adjacentes é sempre igual. E desordenamento é quando uma nuvem de pontos de uma cena é o conjunto de pontos obtido em torno dos objetos na cena, e geralmente são armazenados como uma lista em um arquivo. Como um conjunto, a ordem em que os pontos são armazenados não altera a cena representada; portanto, é invariante. A FIGURA 13 apresenta os exemplos das propriedades de irregularidade, desestruturação e desorganização dos pontos de uma nuvem de pontos 3D.

FIGURA 13 – EXEMPLO DE ORGANIZAÇÃO DOS PONTOS DE UMA NUVEM



FONTE: Adaptado Saifullahi, et al.(2019).

As propriedades de nuvens de pontos são muito desafiadoras para o aprendizado profundo, especialmente para as CNNs, por isso, algumas abordagens convertem as nuvens de pontos em malha regulares. Isso ocorre porque os CNNs são baseados na operação de convolução, que é realizada em dados ordenados, regulares e em uma malha estruturada. No entanto, pesquisadores têm desenvolvido recentemente abordagens que usam diretamente o poder da aprendizagem profunda para a nuvem de pontos brutas, sem a necessidade de conversão para uma malha estruturada (SAIFULLAHI, et al., 2019).


Os autores Osdemir, et al.(2019) registraram uma pesquisa em andamento para a reconstrução de edifícios 3D com base na classificação de nuvens de pontos aéreas sem dados auxiliares fornecidos. O trabalho inclui uma abordagem de aprendizagem profunda com base em características geométricas específicas extraídas da nuvem de pontos e a metodologia foi testada no ISPRS 3D *Semantic Labeling Contest*.

2.2.3 Redes Neurais

2.2.3.1 Convolução

Redes Convolucionais, também conhecidas como CNN ou RNC, são basicamente um arranjo de neurônios artificiais, com uma estrutura mais complexa do que as redes neurais artificiais convencionais. O esquema da FIGURA 14 representa as diferentes camadas de uma rede convolucional. Basicamente ela é composta de três elementos principais: a camada de convolução, a camada de pooling e a camada de saída.

FIGURA 14 – ESQUEMA DE UMA REDE CONVOLUCIONAL SIMPLES



FONTE: Barcellos, Shitara, Ferraz e Vieira (2019).

Nas primeiras camadas, convolucionais, os dados são processados usando-se o conceito de convolução. As redes convolucionais foram concebidas para o processamento de imagens baseado na análise de regiões, ou da variação local dos valores digitais da imagem. Por este motivo, o processo se baseia na convolução de funções e a imagem. O conceito de convolução não é novo no processamento de imagens. Ele é usado, por exemplo, nos métodos de filtragem espacial. Um exemplo são os filtros de bordas ou direcionais que, com base em janelas móveis que usam

pesos pré-definidos, podem detectar fronteiras ou alinhamentos em direções específicas (RAMALHO, 2022).

O processo de convolução de uma imagem I com a janela H é formalmente descrito na EQUAÇÃO 2.

$$I'(u, v) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} I(u - i, v - j) \times H(i, j) \quad (2)$$

Em termos práticos, isto equivale a deslocar a função H ao longo de toda a imagem e, em cada posição possível, calcular um resultado pela multiplicação dos valores digitais da imagem com o “peso” definido pela função H . Este processo pode ser usado para filtrar a imagem e suavizar a mesma, usando o filtro passa-baixas da média, ou salientar diferenças específicas, como no caso de filtros lineares. Basta, para isto, definir os “pesos” ou valores da janela móvel. Alguns exemplos de filtros lineares (3x3), conhecidos como filtros direcionais, frequentemente usados no processamento de imagens para salientar diferenças em algumas direções são mostrados na FIGURA 15 (GONZALEZ E WOODS, 2000).

FIGURA 15 – EXEMPLOS DE FILTROS DIRECIONAIS

NORTE-SUL			NORDESTE-SUDOESTE			LESTE-OESTE			NOROESTE-SUDESTE		
1	2	1	0	1	2	-1	0	1	-2	-1	0
0	0	0	-1	0	1	-2	0	2	-1	0	1
-1	-2	-1	-2	-1	0	-1	0	1	0	1	2

FONTE: Adaptado Gonzalez e Woods (2000).

No caso de filtros 3x3, nove multiplicações são efetuadas e a convolução pode ser descrita como um polinômio, conforme apresentado na EQUAÇÃO 3.

$$C(i, j) = I(u - 1, v - 1) * H(1, 1) + I(u - i, v) * H(1, 2) + \dots + I(u + 1, v + 1) * H(3, 3) \quad (3)$$

onde:

O resultado depende dos pesos definidos pela função H , escolhidos pelo usuário, onde:

I é a matriz de entrada, também chamada de imagem de entrada.

H é a matriz do kernel, também conhecida como máscara de convolução ou filtro.

$I(u-i,v-j)$ representa o pixel da matriz de entrada na posição $(u-i,v-j)$.

$H(k,l)$ representa o valor do elemento na posição (k,l) do kernel.

A operação de convolução discreta é comumente usada em processamento de imagens e processamento de sinais para diversos fins, incluindo filtragem de imagem, detecção de bordas, suavização, entre outros.

A fórmula descreve a operação de convolução de uma região (u,v) da matriz de entrada I com o kernel H . Cada elemento da matriz resultante C ($C(i,j)$) é calculado multiplicando cada elemento da vizinhança de (u,v) na matriz de entrada com o elemento correspondente na matriz do kernel, e somando esses produtos.

Portanto, a fórmula está realizando uma soma ponderada dos pixels vizinhos de (u,v) na matriz de entrada, onde os pesos são determinados pelos valores no kernel. Essa operação é repetida para cada posição (i,j) na matriz resultante C .


Uma rede convolucional se baseia neste princípio para detectar feições relevantes na imagem. Porém, no caso de uma rede convolucional, o usuário não determina quais filtros serão utilizados, mas o próprio sistema detecta as variações mais frequentes e propõe os filtros mais adequados para resolver o problema da identificação/descrição, do objeto procurado. Por este motivo, se diz que a rede convolucional utiliza filtros.

A convolução, na sua definição formal, é muito similar à equação usada para processar as entradas em um neurônio artificial, a soma dos elementos multiplicados por um peso. Sendo assim, nas redes convolucionais usam-se neurônios para obter os filtros mais adequados. Como, a princípio, não se conhece quantos e quais filtros são necessários, uma grande quantidade de filtros é utilizada.

Assim sendo, a entrada em uma rede convolucional é uma região da imagem, uma janela móvel que se desloca ao longo da imagem para analisar cada possível região usando uma matriz retangular (ou quadrada). Esquemáticamente, isso pode ser representado de acordo com a FIGURA 16. O valor digital de cada pixel na imagem é lido e usado como entrada na matriz bidimensional de neurônios representados pela matriz vermelha na FIGURA 16. Cada entrada é ponderada utilizando-se um peso (p_1 ,

$p_2, \dots, p_n$), inicialmente desconhecido e depois ajustado durante o processo iterativo, e "viés", um valor constante é adicionado à soma ponderada dos insumos.

FIGURA 16 – CONVOLUÇÃO USANDO O CONCEITO DE REDE NEURAL



FONTE: Adaptado Barcellos, Shitara, Ferraz e Vieira (2019)

Para cada posição possível na imagem, os mesmos pesos e bias são usados, do que resulta uma nova imagem para cada filtro. Isto significa que todos os neurônios da primeira camada escondida detectam exatamente o mesmo recurso apenas em locais diferentes na imagem de entrada. Assim, as redes convolucionais são invariantes à translação.

Portanto, conforme a FIGURA 17 e citado anteriormente, a camada convolucional é responsável pelo aprendizado dos filtros independentes que irão representar as características do objeto de entrada. Para que a camada de convolução funcione corretamente é necessário determinar como se dá o deslocamento do *kernel* do filtro a ser aprendido, em outras palavras, qual será o tamanho da passada do *kernel*, ou *stride*. Também é necessário determinar qual será o tratamento das bordas da imagem. A técnica de preenchimento, chamada de *padding*, é a normalmente usada. Essa técnica, acrescenta bordas a imagem de entrada visando manter coerente a saída da convolução. Essas duas técnicas, *stride* e *padding*, determinam o tamanho da camada de saída. (FERRUGEM, 2022)

2.2.3.2 Pooling


A camada de pooling consiste em resumir a imagem filtrada, reduzindo seu tamanho. Para isto, a imagem é dividida em regiões e dentro de cada uma delas apenas um valor significativo e representativo é selecionado. Este valor é armazenado em uma nova matriz preservando, desta forma, a relação espacial original da imagem.

Uma opção muito usada é a seleção do valor máximo da região (*max-pooling*) ou a média dos valores (*average-pooling*).

2.2.3.3 Camada Completamente Conectada (*Fully Connected Layer*)

Finalmente, uma camada completamente conectada (*Fully Connected Layer*), representada por FC na FIGURA 17, se encarrega de interpretar as representações das feições geradas a partir de camadas anteriores e executam a função de raciocínio de alto nível. É nelas que a classificação se processa, selecionando a classe mais provável ou estimando a probabilidade ou função de pertinência que associa a região a cada classe.

Este esquema básico pode ainda ser multiplicado para configurar uma rede mais profunda pelo “empilhamento” de camadas, conforme mostra a FIGURA 17.




FONTE: Adaptado Clark (2018).

Uma vez definida a arquitetura da rede, a mesma deve ser treinada. Para isto, uma grande quantidade de amostras é necessária, visto o elevado número de parâmetros a serem estimados. O treinamento supervisionado é o mais frequentemente usado, porém estratégias não supervisionadas também são possíveis.

Na atualidade, não é necessário programar uma rede convolucional desde a estaca zero, pois existem diferentes bibliotecas que podem ser aproveitadas para esta finalidade, muitas delas de código aberto. A FIGURA 18 mostra uma avaliação de algumas delas, classificando-as quanto o número de usuários que participam de seu desenvolvimento e sua idade. As cores dos círculos representam a idade em dias que a biblioteca foi publicada no *Github*, bem como, a relação ao número de colaboradores

e pontuação dada no repositório. Destacam-se as bibliotecas Tensorflow e Keras, muito populares e ainda disponíveis na plataforma pública do Google Colab (CLARK, 2018).

FIGURA 18 – BIBLIOTECAS QUE UTILIZAM AS REDES NEURAIS CONVOLUCIONAIS COMO BASE



FONTE: Adaptado Clark (2018)

2.2.3.4 Normalização em lote

A normalização em lotes é uma técnica usada para estabilizar o processo de aprendizado e reduzir o número de épocas necessárias para treinar uma rede neural. Proposta por Ioffe e Szegedy (2015), a normalização em lote, ou *Batch Normalization*, é um método de otimização indicado para acelerar e estabilizar treinamentos de redes neurais profundas. Neste processo, a normalização ocorre por lotes, nos quais a rede é previamente dividida. Em cada iteração de treinamento, as entradas são normalizadas, o que envolve a subtração da média e a divisão pelo desvio padrão, sendo ambos estimados com base nas estatísticas do *mini-batch* atual. Posteriormente, um coeficiente de escala e um deslocamento de escala são

aplicados. É o uso dessa normalização baseada em estatísticas de lotes que dá à técnica o nome de "normalização em lote". Esta normalização é feita pela média e desvio padrão, como descrito na EQUAÇÃO 4;

$$BN = \frac{BN - \hat{\mu}}{\hat{\sigma}} \quad (4)$$

Onde $\hat{\mu}$ é a média da amostra e $\hat{\sigma}$ é o desvio padrão da amostra e BN a normalização.

2.2.3.5 Função de ativação ReLU

Atualmente, a Unidade Linear Retificada (ReLU) é recomendada como a função de ativação padrão. As ReLUs são semelhantes às unidades lineares e são fáceis de otimizar. A diferença entre unidades lineares e ReLU é que as ReLUs produzem saídas zero em metade do seu domínio. Uma desvantagem da ReLU simples é que, quando uma unidade ReLU se torna zero, seu gradiente também se torna zero. Portanto, se for usado um método de otimização baseado em gradiente, uma unidade ReLU que se torne zero não poderá mais ser atualizada e permanecerá em zero. Portanto a ReLU fornece uma transformação não linear muito simples. Dado um elemento x a função é definida como o máximo desse elemento e 0, conforme a EQUAÇÃO 5 (SERRA, 2020).

$$ReLU(x) = \max(x, 0) \quad (5)$$

2.2.3.6 Função de ativação Softmax

A função de ativação Softmax é normalmente utilizada nas camadas de classificação das redes neurais e é responsável converter o espaço de saída da rede neural em um espaço probabilístico. Nesse espaço, os valores são normalizados para estarem no intervalo de 0 a 1, e a soma de todos os valores resulta em 1 (GOODFELLOW, et.al.(2016).

A Softmax pode ser descrita pela seguinte EQUAÇÃO 6:

$$\sigma(z) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (6)$$

Onde: em que $i = 1, \dots, K$ e $z_i = (z_1, \dots, z_k) \in \mathbb{R}^K$, sendo K a quantidade de classes do problema e z_i é a saída do neurônio i da última camada da rede.

2.2.4 Treinamento de Redes Neurais

A utilização eficaz de uma rede neural artificial envolve a tarefa de determinação dos pesos e bias associados a cada neurônio. Este desafio torna-se complexo à medida que se adotam arquiteturas mais sofisticadas, caracterizadas por múltiplas camadas e um maior número de neurônios. A alocação manual de valores para esses parâmetros se torna rapidamente impraticável, havendo a necessidade de recorrer a métodos matemáticos para a definição adequada desses valores. Esse processo é comumente denominado de treinamento da rede, no qual a rede adquire conhecimento a partir de um conjunto de dados de treinamento (JIANG, LU, & CHEN, 2022).

O processo de aprendizado pode ser categorizado em três abordagens principais: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. No aprendizado supervisionado, a rede se beneficia do conhecimento prévio do erro, permitindo a avaliação e posterior ajuste dos pesos com base no erro calculado em relação aos dados de entrada. Já o aprendizado não supervisionado pressupõe que os pesos da rede são determinados com base em estatísticas derivadas dos dados de entrada, sem depender de informações explícitas sobre os erros. O aprendizado por reforço, por sua vez, constitui uma abordagem híbrida que combina elementos do aprendizado supervisionado e não supervisionado. (SOUZA P. H., 2022)

Conforme destacado por Andrade (2003), uma vez determinados o tipo e a arquitetura da rede a ser utilizada na construção do modelo, bem como os parâmetros de entrada e as saídas desejadas, e após a coleta dos dados referentes ao fenômeno a ser modelado, inicia-se o processo de treinamento da rede neural. O treinamento é um procedimento iterativo, no qual os dados de entrada são processados repetidamente até que o algoritmo convirja e os erros atinjam níveis aceitáveis. O principal objetivo do treinamento é ajustar os pesos da rede da melhor maneira possível, a fim de otimizar sua capacidade de realizar as tarefas específicas para as quais foi projetada.

2.2.4.1 Pesos

Os pesos são utilizados no treinamento e no ajuste de modelos de aprendizado de máquina. Eles influenciam como o modelo atribui importância a diferentes amostras de dados durante o treinamento e como ele busca otimizar sua performance em relação às metas definidas. A importância dos pesos varia dependendo do tipo de modelo e do problema em questão. Neste trabalho, é utilizado como um equilíbrio de classes para mitigar problemas onde uma classe tem muito mais amostras do que outras. Essa atribuição de pesos distintos às diferentes classes contribuiu para a capacidade de generalização do modelo (PEIXOTO, 2016).

2.2.4.2 Hiperparâmetros

Hiperparâmetros fazem parte da configuração do treinamento de uma rede neural e especificam como a rede deve ser treinada. Eles não são aprendidos pela rede durante o treinamento, mas geralmente são configurados manualmente antes do início do processo de treinamento. Eles desempenham criticidade na arquitetura e no desempenho final do modelo, influenciando como o algoritmo de aprendizado opera e como os pesos dos parâmetros são ajustados ao longo do treinamento (YOSHUA, 2012).

Esses hiperparâmetros direcionam o processo de otimização, afetando aspectos como a convergência do modelo, sua capacidade de generalização, o tempo de treinamento e a possibilidade de ocorrer sobreajuste (*overfitting*) ou subajuste (*underfitting*). Dessa forma, a escolha dos hiperparâmetros tem como objetivo alcançar um desempenho ótimo do modelo (YOSHUA, 2012).

As variáveis utilizadas como hiperparâmetros, incluem a taxa de aprendizado, a regularização L2, número de épocas, o número de camadas ocultas e o número de neurônios em cada camada, o tamanho do minilote, fator de redução da taxa de aprendizado, período de redução da taxa de aprendizado, fator de redução do gradiente, fator de decaimento quadrado do gradiente e as funções de ativação (YOSHUA, 2012).

2.2.4.3 Função de Perda de Entropia Cruzada

É uma função que quantifica o quão bem as previsões do modelo correspondem aos valores reais. A operação de entropia cruzada calcula a perda de entropia cruzada entre as previsões da rede e os valores alvo para tarefas de classificação de rótulo único e classificação de rótulo múltiplo. No contexto de classificação de rótulo múltiplo, como é o caso da segmentação semântica, é frequente a adoção da função de perda de entropia cruzada. A perda de entropia cruzada, denotada como L , é calculada conforme a EQUAÇÃO 7 (PyT, 2020).

$$L = - \sum_{c=1}^C w_c y_c \log(\hat{y}_c) \quad (7)$$

Onde C é o número de classes, y_c é 1 se c for a classe correta e 0 caso contrário, e $\hat{y}_c$ é a probabilidade prevista de que a observação seja da classe c . A variável w_c é um fator de ponderação. Se w_c for maior que 1, então L é chamado de perda de entropia cruzada ponderada (PyT, 2020).

2.2.4.4 Segmentação Semântica


Compreender os ambientes computacionalmente é um dos desafios que a visão computacional tem todos os dias. A segmentação semântica é uma técnica do campo de visão computacional que tem aplicações que vão desde a segmentação de imagens biomédicas e sensoriamento remoto até robótica de campo, com o objetivo de categorizar cada elemento seja pixel da imagem ou ponto da nuvem, em uma classe apropriada (TAHER, 2019).

A classificação semântica de grandes conjuntos de pontos apresenta um desafio computacionalmente complexo. O principal obstáculo reside na computação dos vizinhos dos pontos, essencial para o cálculo das características geométricas. Para contornar esse problema, são utilizadas pirâmides multiescala para aproximar os vizinhos, permitindo descrever volumes pequenos com poucos vizinhos em uma escala detalhada e volumes grandes com poucos vizinhos em uma escala mais ampla. (TIMO, 2018)

A FIGURA 19 apresenta um exemplo de uma segmentação realizada com o PointNET++, com legenda apresentando as classes. A FIGURA 19A é uma nuvem de

pontos sem nenhuma classificação, antes do processo de segmentação. A FIGURA 19B é uma nuvem de pontos segmentada nas classes LT representado na cor magenta, Torre na cor amarela, a superfície na cor verde e o terreno na cor azul.

FIGURA 19 – RESULTADO POINTNET++ NUVEM DE PONTOS ORIGINAL (A) SEGMENTAÇÃO(B)



FONTE: O autor (2023).

Trabalhos mais recentes adotaram uma abordagem genérica, usando algoritmos de aprendizado discriminativo para inferir informações semânticas para cada ponto individualmente. Essa abordagem permitiu a aplicação de classificação de alta qualidade a dados de ponto nível, e não se limitava apenas à extração de edifícios. Essas técnicas se mostraram úteis em várias aplicações, incluindo mapeamento móvel, navegação autônoma e detecção de danos causados por desastres. Em resumo, a segmentação semântica 3D é uma técnica importante com aplicações em diversas áreas e continua evoluindo (TAHER, 2019).

A nuvem de pontos 3D possui características 3D que codificam propriedades geométricas, como variações de superfície, curvatura, orientação normal ou altura em relação a um plano de referência. A codificação dessas características é chamada de descritores, que apesar de serem computacionalmente exigentes, são normalmente projetados para trabalhar na nuvem de pontos esparsa. Recentemente, as CNNs mostraram eficiência na segmentação de nuvens de pontos. Para reduzir a demanda computacional da rede convolucional, uma representação 2D semelhante a imagem pode ser gerada a partir de representações 3D por meio de kernels (BERNSTALE & LIND, 2022).


2.2.5 PointNet

Antes do desenvolvimento do PointNet++, o PointNet serviu como base para aprimoramentos na arquitetura. Em seu estudo de 2016, os autores Qi, Su, Mo e Guibas (2016) destacaram a importância das nuvens de pontos como uma estrutura de dados geométricos significativa. Devido à natureza irregular dessas nuvens, muitos pesquisadores tradicionalmente as transformam em grades 3D regulares ou coleções de imagens. No entanto, essa abordagem tende a gerar dados excessivamente volumosos e acarretar problemas.

Nesse contexto, os autores propuseram um avanço ao projetar uma nova classe de redes neurais capazes de processar diretamente nuvens de pontos, levando em consideração a invariância à permutação das informações de entrada. O PointNet oferece uma arquitetura unificada direcionada a diversas aplicações, desde a classificação de objetos até a segmentação de partes e a análise semântica de cenas.

A FIGURA 20 mostra a arquitetura do PointNet, onde a rede de classificação recebe n pontos como entrada, aplica transformações de entrada e características e, em seguida, agrega as características dos pontos por meio do máximo (max pooling). A saída são os escores de classificação para k classes. A rede de segmentação é uma extensão da rede de classificação. Ela concatena características globais e locais e gera escores por ponto. O MLP representa um perceptron de múltiplas camadas e os números entre parênteses indicam os tamanhos das camadas. A normalização em lote é usada em todas as camadas com ativação ReLU. Camadas de dropout são usadas na última camada MLP da rede de classificação.

FIGURA 20 - ARQUITETURA POINTNET



Fonte: Qi, Su, Mo e Guibas (2016).

A PointNet possui três módulos-chave: a camada de agrupamento máximo, que atua como uma função simétrica para agregar informações de todos os pontos; uma estrutura de combinação de informações locais e globais; e duas redes de alinhamento conjuntas que alinham tanto os pontos de entrada quanto as características dos pontos (QI, SU, MO E GUIBAS, 2016).

A estrutura de aprendizado profundo consome conjuntos de pontos não ordenados como entrada, sem nenhuma interação separada. Como entrada é utilizada somente uma nuvem de pontos representada como um conjunto de pontos tridimensionais $\{P_i \mid i = 1, \dots, n\}$, onde cada ponto P_i é um vetor com suas coordenadas (x, y, z) e um vetor de características que são os canais adicionais, como cor, normais, intensidade (QI, SU, MO E GUIBAS, 2016).

No contexto da tarefa de classificação de objetos, a nuvem de pontos de entrada pode ser obtida diretamente a partir de uma forma ou pré-segmentada a partir de uma nuvem de pontos de cena. A rede profunda gera k pontuações para todas as k classes candidatas. Para a segmentação semântica, a entrada pode ser um único objeto para segmentação de região de partes ou um subvolume de uma cena 3D para segmentação de região de objetos. Nosso modelo produzirá $n \times m$ pontuações para cada um dos n pontos e cada uma das m subcategorias semânticas (QI, SU, MO E GUIBAS, 2016).

Embora tenha demonstrado eficácia em tarefas de processamento de nuvens de pontos, o PointNet apresentou algumas limitações. Ele é invariante à permutação, mas não à rotação, o que pode ser problemático em cenários onde a orientação é importante. Além disso, o tratamento de pontos como conjuntos independentes pode resultar em cálculos redundantes e consumo de memória elevado, especialmente em conjuntos de dados grandes. A falta de consideração direta ao contexto espacial e a dependência de pré-processamento adequado também são desafios conhecidos. Mesmo sendo o precursor, pesquisas subsequentes, como o PointNet++, buscaram melhorar essas limitações e melhorar o desempenho em tarefas específicas (QI, SU, MO E GUIBAS, 2017).

2.2.6 PointNet ++


Conforme mencionado anteriormente, o PointNet, embora pioneiro no processamento de conjuntos de pontos, tinha limitações em capturar estruturas locais relacionadas à métrica espacial, o que o impedia de reconhecer detalhes e de lidar com cenas complexas. Por seu design, o PointNet não captura a estrutura local induzida pela métrica. No entanto, explorar a estrutura local tem se mostrado importante para o sucesso das arquiteturas convolucionais. Uma CNN (Rede Neural Convolucional) toma dados definidos em grades regulares como entrada e é capaz de capturar progressivamente características em escalas cada vez maiores ao longo de uma hierarquia de várias resoluções. Nos níveis mais baixos, os neurônios têm campos receptivos menores, enquanto nos níveis mais altos eles têm campos receptivos maiores. A capacidade de abstrair padrões locais ao longo da hierarquia permite uma melhor generalização para casos não vistos (QI, SU, MO E GUIBAS, 2017).

Para superar essas limitações, Qi, Su, Mo e Guibas (2016) introduziram uma rede neural hierárquica denominada PointNet++, projetada para processar de maneira hierárquica um conjunto de pontos amostrados em um espaço métrico. A ideia fundamental do PointNet++ é bastante simples: inicialmente, subdividem o conjunto de pontos em regiões locais que se sobrepõem, com base na métrica de distância do espaço subjacente. De forma semelhante às CNNs, eles extraem características locais que capturam estruturas geométricas detalhadas de pequenos agrupamentos de pontos. Posteriormente, essas características locais são combinadas em unidades maiores e processadas para gerar características de nível superior. Esse processo é repetido até que tenham obtido as características que representam todo o conjunto de pontos de forma eficiente em várias escalas, lidando com desafios de densidade variável. Em cada nível, um conjunto de pontos é processado e abstraído para produzir um novo conjunto com menos elementos.

Conforme apresentado na FIGURA 21, o nível de abstração de conjuntos é composto por três camadas principais: camada de amostragem e agrupamento, camada PointNet e Max Pooling. A camada de amostragem seleciona um conjunto de pontos a partir dos pontos de entrada, o que define os centroides das regiões locais. A camada de agrupamento então constrói conjuntos de regiões locais encontrando

pontos "vizinhos" ao redor dos centroides. Cada camada PointNet usa um mini-PointNet para codificar padrões de regiões locais em vetores de características.

FIGURA 21 - ARQUITETURA POINTNET ++




FONTE: O autor (2023).

Na etapa final, características locais são extraídas de cada subconjunto de pontos dentro de uma esfera, por meio de um pequeno módulo PointNet. Os pontos são inicialmente traduzidos para um sistema de coordenadas local, com o ponto central como origem. Da mesma forma como um filtro convolucional é aplicado a uma imagem, o mesmo pequeno PointNet é usado para codificar as características de cada esfera em uma camada (BERNSTALE E LIND, 2022).

Em resumo, o PointNet++ é uma arquitetura de rede neural projetada para tarefas de processamento de nuvens de pontos tridimensionais, como segmentação semântica ou classificação. Ele foi desenvolvido com o objetivo de fornecer melhorias em comparação ao PointNet original, permitindo a extração de informações contextuais em diferentes escalas e hierarquias, ser invariante à permutação e rotação e mais otimizado (QI, SU, MO E GUIBAS, 2017).

A FIGURA 22 mostra o desempenho do algoritmo PointNet++ quando comparado com os principais algoritmos com publicação e metodologia comprovada. A partir dele foi possível visualizar que o KPConv possui um resultado melhor em relação ao PointNet++. O KPConv apresentou um desempenho forte nos conjuntos de dados disponíveis no mercado, os benchmarks conhecidos como SemanticKITTI, Semantic 3D, ISPRS, entre outros. Porém como o KPConv é um algoritmo que não possui caixa delimitadora, um processo em lote torna-se difícil de ser realizado pois se a caixa for muito pequena, muitos objetos não serão detectados e se a caixa for

muito grande, haverá um custo computacional elevado. Por isso, optou-se pelo PointNet++



FONTE: Adaptado Varney et.al (2020).

Em resumo, o PointNet e o PointNet++ são dois modelos de aprendizado profundo desenvolvidos para processar dados de nuvens de pontos 3D. O PointNet, pioneiro nesse campo, abordou diretamente tarefas de classificação e segmentação sem a necessidade de converter os dados para outros formatos. No entanto, enfrentou limitações ao lidar com nuvens de pontos complexas devido à sua capacidade limitada de capturar informações contextuais e hierárquicas. Como uma evolução do PointNet, o PointNet++ introduziu uma estrutura de agrupamento hierárquica, permitindo que os pontos fossem agrupados em subconjuntos menores para aplicar operações de convolução em diferentes níveis de resolução. Isso possibilitou uma melhor modelagem de informações em múltiplas escalas, resultando em um desempenho aprimorado em tarefas de classificação e segmentação de nuvens de pontos 3D, tornando o PointNet++ uma escolha mais indicada para lidar com dados mais complexos e detalhados.

3 MATERIAIS E MÉTODOS

Neste capítulo, serão apresentados os principais equipamentos que compõem o sistema LiAir 50 UAV LiDAR e o LiAir 70 UAV LiDAR, juntamente com a metodologia aplicada para a classificação da nuvem de pontos e da segmentação semântica dos dados desse estudo.

3.1 MATERIAIS

3.1.1 Sistema LiAir 50 UAV LiDAR

O LiAir V50 é um sistema de levantamento LiDAR embarcado em RPAS. Este sistema foi projetado e produzido pela GreenValley International, com o objetivo de realizar levantamentos aéreos capazes de gerar nuvens de pontos tridimensionais com um alto nível de detalhamento. A carga útil foi projetada para as plataformas DJI Matrice 600 Pro ou DJI M300 RTK e possui a flexibilidade de ser equipado com uma câmera de alta definição para fotogrametria e geração de nuvens de pontos 3D coloridas (GVI, 2023)

O componente central deste sistema é o sensor LiDAR, baseado na tecnologia de detecção e varredura a laser, permitindo medições precisas da distância entre o sensor e os objetos presentes em sua área de cobertura. No caso específico do LiAir 50 UAV LiDAR, utiliza-se o sensor 3D LiDAR VLP-16, fabricado pela empresa Velodyne.

O sensor LiDAR é integrado a um RPA, que neste projeto foi ao modelo DJI Matrice 600 Pro, que é uma plataforma de voo robusta e confiável. A utilização deste RPA como plataforma de transporte e estabilização viabiliza a operação eficiente do sensor LiDAR, permitindo a aquisição eficaz de dados em diversas áreas e tipos de terrenos.

O sistema LiAir 50 UAV LiDAR apresenta a incorporação de um sistema inercial capaz de resolver as ambiguidades posicionais durante a coleta dos dados, garantindo uma precisão em torno de 8 centímetros. Além disso, através da integração do Sistema Global de Navegação por Satélite (GNSS) com a Unidade de Medição Inercial (IMU), é possível obter dados com uma precisão centimétrica durante o processo de pós-processamento dos dados coletados (VELODYNE, 2018)

Nesta pesquisa, a densidade de pontos foi superior a 100 pontos por metro quadrado, revelando-se suficiente para permitir uma classificação detalhada das feições em análise. É importante destacar que ambos os sistemas utilizados possuem a capacidade de realizar levantamentos com densidades de pontos variando de 0 a 3000 pontos por metro quadrado. Essa variação é determinada por diferentes combinações de velocidades, que variam de 1 a 5 metros por segundo, alturas de voo de 30, 40 e 50 metros, e um campo de visão (FOV) de abertura de 80°.

Em geral, independente do sistema LiAir utilizado, os levantamentos foram conduzidos a uma velocidade de 5 metros por segundo e altura de voo de 50 metros, resultando em uma densidade nominal superior a 250 pontos por metro quadrado. Devido à baixa altitude dos voos, essa alta densidade de pontos viabiliza um delineamento mais preciso das feições em análise, contribuindo para a obtenção de resultados de maior acurácia.

Dessa forma, neste projeto específico, a densidade de pontos adotada foi considerada adequada para permitir uma classificação detalhada das feições. A possibilidade de ajustar a densidade de pontos de acordo com os requisitos específicos permite uma cobertura mais minuciosa e precisa do terreno, contribuindo para a obtenção de resultados confiáveis e de alta qualidade.


3.1.1.1 VLP-16

O sensor VLP-16, fabricado pela Velodyne, utiliza uma matriz de 16 lasers infravermelhos (IR) emparelhados com detectores IR para medir distâncias até objetos. Este dispositivo é instalado de forma segura em uma caixa compacta, projetada para resistir às condições climáticas adversas. A matriz de pares laser/detector gira dentro da estrutura fixa para escanear o ambiente circundante. Cada laser dispara aproximadamente 18.000 vezes por segundo, proporcionando em tempo real um conjunto de até 300.000 pontos por segundo de dados tridimensionais. Essa taxa pode ser dobrada se o modo de duplo retorno estiver ativado (VELODYNE, 2019)

Conforme apresentado na FIGURA 23, as dimensões do sensor LiDAR são de 181 mm de largura e 197 mm de altura. Ele é montado em um braço com largura de 1170 mm, que oferece ajuste para o centro de gravidade do sensor. Além disso, o

conjunto do sensor LiDAR também inclui uma câmera fotográfica, que permite a integração da informação RGB de cada ponto capturado (VELODYNE, 2019)

FIGURA 23 – DIMENSÃO DOS SENSORES DO SISTEMA LIAIR 50 EM MILÍMETROS.



FONTE: Velodyne (2018).

Na FIGURA 24 está apresentado o sistema 3D da Velodyne e no QUADRO 1 as especificações técnicas do sensor VLP-16. Esse sistema é conectado à interface da Velodyne e envolve os seguintes equipamentos: (1) um computador, que deve ser conectado via Ethernet; (2) GNSS/IMU (Sistema Global de Navegação por Satélite/Unidade de Medição Inercial); (3) Caixa de interface da Velodyne (4) o sensor LiDAR; e (5) uma bateria com a fonte de alimentação. Essa configuração permite o funcionamento integrado do sistema de sensoriamento da Velodyne (VELODYNE, 2019).

FIGURA 24 – EQUIPAMENTOS DO VLP-16



FONTE: Velodyne (2018)

QUADRO 1 – ESPECIFICAÇÕES TÉCNICAS DO SENSOR VLP-16

Sensor LiDAR	Velodyne VLP-16	
Precisão do Range	+-3 cm	
Alcance máximo	100 m	
Precisão relativa do sistema	+- 5 cm	
POS System Performance	Atitude:0.1° (1 sigma)	S 50
	Azimuth: 0.1° (1 sigma)	
	Atitude:0.015° (1 sigma)	P50
	Azimuth: 0.08° (1 sigma)	
Onboard Storage	128GB	
Portas disponíveis	Ethernet&USB 3.0	
Peso	3.4 kg (excluindo baterias e câmera)	
Dimensões	1170x181x197	
Max tempo de voo	21 minutos	
Voltagem de operação	9-30v	
Vertical FOV	-15° a 15°	
Horizontal FOV	360°	
Software de planejamento de voo	LiPlan	
Software de aquisição e PPK	LiAcquire	
RGB Camera	Sonya6000	

FONTE: Velodyne (2018)

3.1.2 Sistema LiAir 70 UAV LiDAR

O LiAir V70 é um sistema de levantamento LiDAR embarcado em RPAS, também projetado e produzido pela (GVI). Diferentemente do LiAir 50, este sistema apresenta um scanner a laser Livox AVIA, fabricado pela empresa Livox Technology Company. Essa carga útil leve para mapeamento e levantamento 3D foi projetada para as plataformas DJI Matrice 600 Pro, DJI M300 RTK e DJI Matrice 210 e possui a

flexibilidade de ser equipado com uma câmera de alta definição para fotogrametria e geração de nuvens de pontos 3D coloridas (GVI, 2023).

Adicionalmente, o sistema é considerado uma evolução em relação ao LiAir V50, incorporando avanços em relação ao sistema.

3.1.2.1 Livox AVIA

De acordo com as especificações do fabricante, o Livox Avia é mais compacto e leve quando comparado ao VPL-16, concomitantemente à expansão das capacidades de detecção e eficiência, evidenciando um campo de visão (FOV) que ultrapassa a marca dos 70° (FIGURA 25). Seus modos de funcionamento, que englobam retornos triplos e varredura dupla, revelam-se particularmente adequados para contextos de aplicação que abrangem desde mapeamento cartográfico até direção autônoma em baixas velocidades (LIVOX, 2023)

FIGURA 25 - LIVOX AVIA



FONTE: Livox (2023)

Conforme (LIVOX, 2023), o escaneamento da Livox oferece dois padrões de nuvem de pontos de escaneamento: padrões de escaneamento não repetitivos e padrões de escaneamento repetitivos. Quando o escaneamento é não repetitivo, a densidade de escaneamento é maior no centro do campo de visão (FOV) em comparação com a área circundante. Para padrões de nuvem de pontos de escaneamento não repetitivos, o Avia tem um FOV de 77,2° verticalmente e 70,4° horizontalmente. No centro do FOV em um raio de 10°, a densidade de nuvem de pontos é comparável aos sensores LiDAR tradicionais de 32 linhas em 0,1 segundo e

aos sensores LiDAR tradicionais de 64 linhas em 0,2 segundos. A densidade de nuvem de pontos no restante do FOV é comparável aos sensores LiDAR tradicionais de 32 linhas em 0,2 segundos. O desempenho do método de escaneamento é definido pela cobertura do campo de visão (FOV), que é calculada como a fração do FOV iluminada pelos feixes de laser. A cobertura do FOV (C) pode ser calculada com a EQUAÇÃO 8:

$$C = \frac{\text{TOTAL DE ÁREA ILUMINADA PELO FEIXE LASER}}{\text{TOTAL DE ÁREA NO FOV}} \times 100\% \quad (8)$$

As especificações técnicas do AVIA estão apresentadas no QUADRO 2.

QUADRO 2 – ESPECIFICAÇÕES TÉCNICAS DO SENSOR LIVOX AVIA

Sensor LiDAR	LIVOX AVIA
Precisão do Range	+2 cm
Alcance máximo	320 m
Precisão relativa do sistema	+5 cm
POS System Performance	Atitude: 0.008° (1 sigma) Azimute: 0.038° (1 sigma)
Onboard Storage	128GB
Portas disponíveis	Ethernet&USB 3.0
Peso	0.9 kg (excluindo baterias e câmera)
Dimensões	1780x81.6x140.2 mm
Max tempo de voo	21 minutos
Voltagem de operação	9-30v
Vertical FOV	-15° a 15°
Horizontal FOV	360°
Software de planejamento de voo	LiAcquire Web
Software de aquisição e PPK	LiGeoreference
RGB Camera	Sony A5100

FONTE: GVI (2023)

3.1.3 Softwares

Para as capturas e processamentos de voo foram utilizados softwares proprietários da GreenValley, o LiPLan®, o Li Acquire® e o LiGeoreference®. O LiPLan® é o software desenvolvido pela Green Valley utilizado para o planejamento de voos com drones. Ele possui ferramentas para definir rotas de voo, configurar parâmetros de captura de imagens e otimizar a cobertura da área a ser mapeada. O LiGeoreference® também é um software desenvolvido pela Green Valley voltado

para a georreferenciação de imagens capturadas por drones, que foi uma atualização do LiPlan®. Ele oferece ferramentas avançadas para associar as imagens coletadas com coordenadas geoespaciais precisas, permitindo uma integração dos dados com sistemas de referência terrestre. Já o LiAcquire®, também desenvolvido pela Green Valley, é um software utilizado para o processamento dos dados capturados durante o voo. Ele oferece ferramentas para importar, visualizar e processar as imagens coletadas pelo drone, além de realizar a reconstrução tridimensional do ambiente mapeado.


A linguagem de programação utilizada foi o Matlab®. Conforme (MATHWORKS, 2020), o MATLAB® é uma linguagem de programação de alto desempenho utilizada para computação técnica. Para a metodologia proposta foram utilizados pacotes como *Deep Learning Toolbox*, *LiDAR Toolbox*, *LiDAR Labeler* que são ferramentas e funções especializadas para o pré-processamento e preparação de dados, interfaces de treinamento, ferramentas de avaliação e exemplos de referência. Para a classificação manual, ou rotulagem da nuvem de pontos foram utilizados o *LiDAR Labeler* do Matlab e o TerraScan da Terrasolid

O hardware utilizado foi um computador AMD Ryzen 5 com 64 GB de RAM, 4 TB de armazenamento interno e placa de vídeo do fornecedor NVIDIA RTX 3060 12GB, que auxiliou para otimizar os cálculos. Foi empregada uma Unidade de Processamento Gráfico (GPU) que se utiliza da plataforma de computação paralela CUDA, tanto para treinamento quanto para predições. É importante destacar que, para o processamento de Aprendizado de Máquina, no Matlab, apenas as placas do fabricante NVIDIA são compatíveis devido a arquitetura CUDA, que é amplamente utilizada por várias bibliotecas de aprendizado profundo, como o TensorFlow e o PyTorch. (MATHWORKS, GPU Computing Requirements, 2023).

3.2 COLETA DE DADOS

Inicialmente, será apresentado na FIGURA 26 o fluxograma que descreve o processo de aquisição dos dados, desde o planejamento até os produtos gerados. Além disso, serão introduzidos os conjuntos de dados 01 e 02 utilizados nesta pesquisa, destacando suas principais características e a região a que estão associados.

FIGURA 26 – FLUXOGRAMA DOS PROCESSOS DE PLANEJAMENTO, CAPTURA DA NUVEM DE PONTOS E DOS PONTOS DE CONTROLE.



FONTE: O autor (2023).

O processo de geração dos produtos que servirão de entrada para a rede neural possui algumas etapas, conforme ilustrado na FIGURA 26. Inicialmente, foram definidos os parâmetros para o planejamento do voo com LiDAR, que normalmente são:

- Altura de voo:** Refere-se à altitude do RPA em relação ao terreno durante a aquisição dos dados. Esta altura é importante para garantir a resolução e a cobertura desejadas para o mapeamento. Em ambos os conjuntos de dados a altura de voo configurada foi aproximadamente 100 metros.
- Sobreposição lateral:** É a sobreposição entre as faixas adjacentes percorridas pelo LiDAR durante o voo. Essa sobreposição lateral ajuda a garantir uma cobertura completa e uniforme do terreno, minimizando lacunas nos dados coletados. Em ambos os conjuntos de dados a sobreposição lateral configurada foi aproximadamente trinta por cento (30%).

- c) Sobreposição longitudinal: Refere-se à sobreposição entre os pontos adjacentes ao longo da trajetória de voo. Essa sobreposição é importante para garantir uma densidade adequada de pontos e uma boa qualidade dos dados capturados. Em ambos os conjuntos de dados a sobreposição lateral configurada foi aproximadamente oitenta por cento (80%).
- d) Velocidade de voo: É a velocidade com que o RPA se move durante o levantamento com LiDAR. Esta velocidade é ajustada para garantir uma taxa de amostragem adequada e um tempo de resposta rápido, sem comprometer a qualidade dos dados. A velocidade configurada para ambos os levantamentos foi de 10 metros por segundo.

Segundo De Oliveira, et al (2017), atualmente, há uma grande incerteza sobre como especificar, de forma minimamente confiável, a combinação de um RPA e de sensores para se obter dados úteis para a sua finalidade. Informações como altura e velocidade de voo, densidade de pontos, posição do objeto imageado, e, no caso particular de linhas de alta tensão, se pode ser mais seguro voar mais alto ou lateralmente ao corredor determinado pela linha de transmissão.

Juntamente com o levantamento dos pontos de controle, a escolha adequada dos parâmetros de voo, visam garantir que a captura dos elementos cabos e torres, atendam de maneira adequada aos objetivos estabelecidos.

Simultaneamente, foram elaborados os planos para a distribuição estratégica dos pontos de controle, recomendando-se que sejam dispostos de maneira uniforme, em locais desobstruídos e livres de interferências de sinal, a fim de minimizar problemas como o multicaminhamento e garantir que sejam facilmente identificáveis na nuvem de pontos.

Cada uma das sub-etapas passou por avaliações durante todo o processo de planejamento, captura e controle de qualidade dos dados, a fim de evitar custos que possam ter impacto financeiro na realização de uma nova coleta de dados em campo. Caso algum dos critérios estabelecidos não fosse atendido, o fluxo de trabalho retorna à etapa correspondente, conforme indicado na FIGURA 26.

Após a conclusão do voo e a coleta dos pontos de controle, foi realizada uma avaliação da integridade dos dados. Em seguida, a nuvem de pontos bruta foi gerada e comparada com os pontos de controle previamente coletados em campo, seguindo o fluxo sem a ocorrência de problemas.

É importante destacar que, neste estudo, foi considerada a discrepância máxima tolerável de 0,15 metros, conforme especificação técnica do cliente, levando em conta a altura máxima de voo de 100 metros e a precisão nominal do equipamento LiDAR foi estabelecida em 0,08 metros. Se o resultado não atendesse aos critérios de aceitação, os dados seriam reexaminados, e os parâmetros de desalinhamento do sensor em relação ao sistema em uso seriam recalculados.


Os resultados da validação altimétrica dos dois trechos estão disponibilizados no ANEXO 2. A seguir, serão apresentados os dois trechos de linhas de alta tensão utilizados nesta pesquisa.

3.2.1 Conjunto de dados 01 – FOC_SEC

Nesta pesquisa, foram empregados dois conjuntos de dados, ambos disponibilizados pela Copel Geração e Transmissão, com o processo de coleta e processamento sendo conduzido pelo Lactec. A coleta de dados foi realizada por meio da aplicação de tecnologias incluindo perfilamento a laser e imageamento, usando sensores embarcados em drones para aquisição de informações detalhadas.

Ambas as áreas utilizaram dados LiDAR coletados por meio de RPAS. No entanto, é importante destacar que no primeiro trecho, considerado uma área rural, foi adotada uma tecnologia mais avançada, o Sistema LiAir 70, enquanto no segundo trecho, considerado uma área urbana, foi utilizado o Sistema LiAir 50. Esses sistemas empregam sensores distintos e equipamentos mais sofisticados em comparação, como é citado no item 3.1.

FIGURA 27 - TRECHO DA LT-230KV FOZ DO CHOPIM - SECCIONAMENTO (CASCAVEL - SALTO OSÓRIO C1)



FONTE: Adaptado Google Earth (2023)

A primeira área estudada foi a LT 230 kV Foz do Chopim - Seccionamento Cascavel - Salto Osório C1, compreendendo as coordenadas geográficas 25°30'32.95"S, 53°05'19.78"W e 25°30'56.94"S, 53°06'06.73"W; situada no município de Três Barras do Paraná, estado do Paraná. Esta área abrange aproximadamente 20,5 hectares. O levantamento foi realizado no período de 15/05/2023 a 30/05/2023. Conforme ilustrado na FIGURA 27, o segmento representa a área onde tem uma linha existente e por isso foi selecionada como conjunto de dados 01.

O conjunto de dados da Área 01 contém um total de 112.395.007 pontos. A área foi dividida de acordo com o procedimento apresentado no item 3.2.5.1, passando por uma classificação inicial em 5 classes (Superfície, Terreno, Edificações, Torres e LTs) e posteriormente em 3 classes (Superfície, Torres e LTs). Durante esse processo, a área exibiu características distintas que auxiliaram na determinação do número de classes a serem aplicadas. Essa classificação foi baseada nos elementos principais utilizados em um projeto de uma nova linha de transmissão.


3.2.1.1 Relevo

Uma representação do relevo do terreno está ilustrada na FIGURA 28, onde é possível visualizar na FIGURA 28(a) a extensão completa do conjunto de dados 01

em perfil. Na FIGURA 28(b) é um detalhe da FIGURA 28(a) ilustrando um vale com 30 metros de altura. No conjunto de dados 01 a variação altimétrica é de 90 metros em 1,2 quilômetros de extensão, resultando que em alguns trechos consistem principalmente em vales.

Essa variação altimétrica apresentou dificuldades no processo de classificação para a classe de vegetação e causou impacto nas características dos pontos na nuvem de dados. A inclinação do terreno e as mudanças abruptas de elevação causaram variações significativas na distribuição espacial dos pontos, afetando não apenas a interpretação e classificação dos objetos presentes na área, mas também o cálculo dos pesos atribuídos aos diferentes elementos.

FIGURA 28 - (a) AREA 01 - PERFIL COM A REPRESENTACAO DO TERRENO, DAS TORRES E CABOS (b) DETALHAMENTO DA AREA COM MAIOR VARIAÇÃO ALTIMÉTRICA.




FONTE: O autor (2023).

Adicionalmente, o relevo acidentado com formações rochosas dificulta o processo porque as pedras devem ser classificadas como parte do terreno, no entanto, devido à sua complexidade geométrica, a classificação automática frequentemente exclui esses elementos devido a ângulos acentuados em distâncias curtas.

As FIGURA 29 e FIGURA 30 apresentam exemplos do tipo de formação rochosa em relevo acidentado encontrado no conjunto de dados 01. Devido às características singulares dessas formações rochosas, caracterizadas por ângulos

acentuados e reduzidas distâncias entre elementos, a classificação automática pode, por vezes, não capturar com precisão esses elementos. Tal fenômeno decorre da interpretação incorreta ou da exclusão dessas complexas características pelo algoritmo em uso. A FIGURA 29 destaca essa problemática, na qual, sob condições visuais, a distinção nítida entre as entidades rochosas e vegetativas torna-se impraticável, particularmente quando as características altimétricas são semelhantes.

FIGURA 29 - FORMAÇÃO ROCHOSA EM RELEVO ACIDENTADO



FONTE: O autor (2023).

No entanto, a FIGURA 30, dividida em duas imagens, apresenta em (A) a visualização da formação rochosa, indicada por setas, por meio de um modelo de superfície colorido conforme as cotas altimétricas derivado de uma nuvem de pontos LiDAR, destacando a complexidade na interpretação desse tipo de característica de feição, e em (B) a mesma formação rochosa em uma ortofoto. Mesmo sendo uma imagem, sua interpretação não é imediata.

FIGURA 30 – VISUALIZAÇÃO DA FORMAÇÃO ROCHOSA NOS DADOS LiDAR (A) E VISUALIZAÇÃO DA FORMAÇÃO ROCHOSA NA MESMA ÁREA NUMA ORTOFOTO (B).



FONTE: O autor (2023).

Nestas circunstâncias, somente a variável cromática poderia ser considerada um fator diferenciador, ainda assim, tal recurso não se mostra infalível em todas as instâncias. Para garantir uma identificação e classificação precisas das formações rochosas, um procedimento de categorização manual se torna imperativo, no qual um observador humano empreende uma avaliação crítica e confere a categoria apropriada a esses elementos.

Diversas estratégias foram exploradas para enfrentar os desafios decorrentes da significativa variação altimétrica da área. As abordagens consideradas abrangeram ajustes nos algoritmos de classificação, a implementação de técnicas de pré-processamento projetadas para abordar a variação altimétrica e a avaliação de potenciais integrações de dados de imagem RGB com o objetivo de aprimorar a precisão da classificação. A incorporação de dados de imagem RGB permitiu que informações visuais complementares fossem combinadas com os dados LiDAR, fornecendo uma visão mais completa das características da área.


3.2.1.2 Cultura

A presença de culturas agrícolas em áreas próximas às estruturas adiciona uma camada de complexidade ao processo de análise de dados geoespaciais. Essa interação entre vegetação e infraestrutura pode levar a desafios distintos que afetam tanto a precisão da modelagem do terreno quanto a classificação das torres.

Neste sentido, as culturas nas imediações das estruturas podem, de fato, resultar em representações enganosas do terreno. Isso ocorre devido à densidade e altura das plantas, que podem ser interpretadas como partes elevadas do terreno na captura de dados LiDAR. Esse fenômeno, conhecido como "falso terreno", pode afetar a modelagem topográfica, resultando em elevações incorretamente estimadas.

Conforme apresentado nas FIGURA 31 e FIGURA 32, a cultura impede que alguns pontos atinjam o solo, dificultando a formação da classe de terreno. Neste caso, a cultura apresenta uma altura de 2 metros em relação ao terreno e causou um erro na classificação da verdade de campo (*Ground Truth*) bem como, os erros de classificação próximo da estrutura. A FIGURA 31 ilustra que os pés da torre não estão visíveis devido à invasão da cultura na faixa de passagem da torre. Isso é um indicativo de que a cultura cresceu além dos limites estabelecidos para a passagem segura em torno da torre, que deve ficar livre para sua manutenção.

FIGURA 31 - CULTURA PRÓXIMO A UMA ESTRUTURA



FONTE: O autor (2023).


FIGURA 32 - EXEMPLO DE ESTRUTUTURA COM INVASÃO DA VEGETAÇÃO NUMA ORTOFOTO.



FONTE: O autor (2023).

A presença de vegetação invadindo a faixa de passagem das torres de transmissão pode representar riscos para a integridade da estrutura e para a segurança das operações. Essas faixas são estabelecidas com base em diretrizes de segurança e regulamentos técnicos para garantir que haja espaço adequado para inspeções, manutenções e evitar interferências com os componentes das torres e linhas de transmissão (CUCCO, 2011).

FIGURA 33 - LARGURA DA FAIXA DE PASSAGEM PARA CIRCUITO SIMPLES 230KV



FONTE: O autor (2023).

Como observado no exemplo da FIGURA 33, existe um raio de 25 metros em torno da estrutura que não deveria estar obstruído, ou seja, a faixa de passagem precisa ter 50 metros. É importante ressaltar que a faixa de passagem está sujeita a áreas de restrições conforme as normas técnicas e de segurança (CUCCO, 2011).

Os aerolevantamentos com RPAS têm a capacidade de sobrevoar áreas específicas e capturar dados de alta resolução permitindo identificar potenciais problemas, como invasões de vegetação, danos nas estruturas, fios desgastados ou qualquer outra anomalia, de maneira mais detalhada do que outros métodos tradicionais. Além disso, a coleta de dados com RPAS reduz consideravelmente o tempo necessário para a inspeção em comparação com outros meios convencionais.

Porém se for considerada a questão de classificação presente neste estudo, foi viável atenuar esse desafio da cultura devido à densidade de amostragem que superou 100 pontos por metro quadrado. Caso essa densidade fosse muito menor, a vegetação poderia ser erroneamente interpretada como parte do terreno, uma vez que a quantidade insuficiente de pontos no terreno prejudicaria a distinção entre essas duas características.

Para mitigar esses desafios, estratégias específicas foram consideradas. O pré-processamento dos dados por envolver filtragem para remover pontos relacionados à vegetação, especialmente aquela muito próxima às estruturas. E técnicas de segmentação e classificação aplicadas para melhor discernir entre vegetação e torres utilizando informações de imagem RGB em conjunto com os dados LiDAR para proporcionar uma visão mais abrangente, auxiliando na identificação das estruturas.



Entretanto, a necessidade de reduzir a resolução da nuvem de pontos, ou seja, realizar uma reamostragem da nuvem de pontos para tornar o processamento viável, pode impactar a precisão da classificação. Por isso, foi necessário realizar um equilíbrio entre a densidade da nuvem de pontos e a viabilidade do processamento. A reamostragem pode levar à perda de detalhes finos e à suavização das características, o que, por sua vez, pode afetar a capacidade de discernimento entre objetos próximos, como vegetação e torres. Para enfrentar esse desafio, uma análise da taxa de reamostragem foi conduzida, considerando a importância da manutenção das características distintas enquanto se alcança um nível de processamento viável.

3.2.1.3 Vegetação

Assim como mencionado anteriormente no item 3.2.1.2 referente a cultura, a vegetação também apresenta características específicas que podem representar desafios no processo de classificação. A complexidade da vegetação, com suas formas variadas, densidade e altura variáveis, pode dificultar a interpretação automática e precisa dos dados.

Neste estudo, um dos problemas encontrados foi a presença de capoeira em torno das estruturas. Conforme, (SOUZA, et al., 2014), a capoeira ou pasto sujo em geral está associada a áreas onde foram desenvolvidas atividades causando alteração da vegetação natural, ou mesmo a ocorrência de degradação natural. Após o abandono destas áreas a vegetação natural começa a se restabelecer apresentando-se em vários estágios de crescimento, o que torna difícil estabelecer um padrão único de resposta espectral. Neste caso, é uma área próxima a estrutura que animais não conseguiam acessar e por isso seu crescimento que dificultou inclusive medições do centro da estrutura para validações, conforme é possível visualizar na FIGURA 34.

FIGURA 34 - CAPOEIRA EM TORNO DAS ESTRUTURAS



FONTE: O autor (2023).


Outro tipo de vegetação encontrada na área de estudo, foi a mata ciliar formada nos fundos de vale. A mata ciliar se desenvolve às margens dos rios, riachos, córregos, lagoas e é uma barreira natural de proteção aos recursos hídricos. Além de preservar os fundos de vale, diminui a ocorrência de erosões, reduz os assoreamentos e melhoram a paisagem local (BAHIA, 2007).

Uma representação visual por diferentes sensores de captura de dados, apresentada na FIGURA 35, mostra o relevo acidentado tanto pela ortofoto como pela nuvem de pontos. No perfil, é possível observar a nuvem de pontos LiDAR, que destaca a topografia do terreno e evidencia o fundo de vale, representado pelos pontos A e B. Adicionalmente, a FIGURA 35 demarca a área designada como Área de Preservação Permanente (APP), mostrando a delimitação espacial das restrições legais impostas nessa região pelo tamanho do corpo d'água, ou seja, 30 metros para cada lado. Na mesma figura, a visualização em topo é uma ortofoto RGB da mesma área, que adiciona informações visuais dos pontos A e B para a interpretação do perfil.

Para estudos de linhas de transmissão, a identificação desse tipo de vegetação é de extrema importância devido ao fato de que essas áreas são consideradas Áreas de Preservação Permanente (APP) e possuem restrições rigorosas quanto à intervenção e uso. As APPs, incluindo os fundos de vale, são protegidas por lei para preservar a integridade ambiental, a biodiversidade e os recursos hídricos. A compreensão dessas áreas protegidas é importante para o planejamento e a gestão de atividades nas proximidades das linhas de transmissão, garantindo a conformidade legal e a sustentabilidade ambiental.

Em áreas de relevo acidentado, conforme apresentado na FIGURA 35, a distribuição espacial de pontos na nuvem LiDAR tende a ser menos densa e irregular em comparação com terrenos planos, devido à variação na incidência dos raios LiDAR em objetos e superfícies com ângulos mais acentuados. Isso pode resultar em lacunas na captura de pontos em áreas de sombra ou com ângulos de incidência desfavoráveis, impactando a qualidade e densidade dos dados coletados. No entanto, sistemas LiDAR embarcados em RPAS tendem a mitigar esses problemas. Isso ocorre porque eles permitem a coleta de dados com ângulos mais fechados de incidência dos raios LiDAR, o que ajuda a capturar mais pontos mesmo em áreas com ângulos desfavoráveis e sombras, minimizando as lacunas e melhorando a qualidade geral da nuvem de pontos.


FIGURA 35 - EXEMPLO DE MATA CILIAR EM TERRENO ACIDENTADO NUMA VISUALIZAÇÃO EM PERFIL NA NUVEM DE PONTOS, INDICANDO 30 METROS PARA CADA LADO DO EIXO DA DIRETRIZ DA LT (A). VISUALIZAÇÃO DA MESMA POSIÇÃO UTILIZANDO UMA ORTOFOTO COMO FUNDO (B).



FONTE: O autor (2023).

A FIGURA 36(A) e (B) retratam a mesma área, porém representadas de maneiras distintas. A FIGURA 36(A) a altimetria do recorte é mostrada por meio de cores, destacando o fundo de vale na cor azul. Já na FIGURA 36(B), o mesmo recorte é apresentado com base na densidade de pontos. Observa-se que, mesmo em áreas com declives superiores a 32 metros, a densidade de pontos não diminuiu abruptamente. Esse resultado indica uma vantagem do uso do sistema RPAS com LiDAR. O sistema RPAS, devido à sua capacidade de coletar dados com ângulos mais fechados e em áreas de difícil acesso, parece ter superado os desafios associados ao relevo acidentado, mantendo uma coleta eficaz de pontos em terrenos íngremes. Esse resultado destaca a importância do sistema RPAS no contexto de levantamentos topográficos.

FIGURA 36 – RECORTE DE UMA ÁREA COM RELEVO ACIDENTADO (A). DENSIDADE DE PONTOS NA MESMA ÁREA (B)



FONTE: O autor (2023).

3.2.1.4 Atributos de Intensidade


Neste estudo, a incorporação da intensidade do pulso laser como uma camada na rede neural teve importância na modelagem da área. O potencial de melhoria pode ser explorado através da otimização dos hiperparâmetros da camada de intensidade e da aplicação de técnicas de regularização para aprimorar a capacidade do modelo em aprender padrões complexos, o que resultou em avanços na precisão e na robustez das previsões.

No conjunto de dados da área 01 foi realizado um procedimento para avaliar a influência dos valores de intensidade no treinamento de um modelo. Para realizar essa avaliação, foram considerados os valores de intensidade dos pontos de duas folhas, juntamente com seus respectivos histogramas. Essa análise teve como objetivo compreender se essa afeta o desempenho ou comportamento do modelo durante o treinamento. Os histogramas podem ser usados para visualizar a distribuição dos valores de intensidade e identificar padrões ou características importantes que podem impactar o processo de treinamento do modelo.

Foi realizada uma avaliação das folhas 03 e 64, com a criação de uma legenda de cores de acordo com os intervalos de valores, conforme ilustrado na parte A da FIGURA 37. A parte B da FIGURA 37 exibe o histograma e o perfil da folha FOC_SEC_03, evidenciando baixa reflectância nos dados. Enquanto isso, a FIGURA

37 parte C mostra o histograma e o perfil da FOC_SEC_64, onde os dados demonstram maior reflectância. A diferença de refletância é visível nos dois exemplos, mesmo fazendo parte do mesmo levantamento e serem áreas parecidas, apresentam uma média de intensidade diferente. Porém, se forem analisados apenas os pontos com maior percentual de valores de intensidade, conforme FIGURA 37 é possível visualizar que os maiores percentuais se concentram nos valores de baixas intensidades nas duas folhas. A TABELA 2 evidencia que a estrutura pode ser filtrada apenas nas intensidades bem baixas, ou seja, sendo uma vantagem seu uso no treinamento do modelo e na predição de torres e cabos.

FIGURA 37 – LEGENDA DE INTENSIDADE (A) PERFIL DAS FOLHAS FOC_SEC_03 (B) E FOC_SEC_64 (C), COM VISUALIZAÇÃO PELA INTENSIDADE DO PULSO COM HISTOGRAMA.






FONTE: O autor (2023).

TABELA 1 – QUANTIDADE DE PONTOS E PERCENTUAL POR INTERVALO DE INTENSIDADE

FOLHA	INTERVALO INTENSIDADE	QDE DE PONTOS	%
FOC_SEC_03 809.959 pontos 34 média	0-0	107.053	13,2
	1-35	324.907	40,1
	36-49	197.470	24,4
	50-62	89.357	11,0
	63-76	66.359	8,2
	77-89	21.843	2,7
FOC_SEC_64 1.993.915 pontos 57 média	90-150	2.970	0,4
	0-0	81.616	4,1
	1-35	275.136	13,8
	36-49	405.880	20,4
	50-62	393.126	19,7
	63-76	416.949	20,9
	77-89	269.603	13,5
	90-150	151.605	7,6

FONTE: O autor (2023).

TABELA 2 - INTERVALO DE INTENSIDADE E VISUALIZAÇÃO DA QUANTIDADE DE PONTOS REFERENTES A ESSE INTERVALO, EXEMPLO DA FOLHA 64


Intervalo	Pontos com intensidade
0-0	
1-35	
36-49	
50-62	
63-76	
77-89	
90-150	

FONTE: O autor (2023).

3.2.2 Conjunto de dados 02 – CCO_SQT

A segunda área estudada foi a LT 230 kV Campo Comprido – Santa Quitéria – CCO-SQT, compreendendo as coordenadas geográficas 25°25'45.34"S, 49°22'22.23"W e 25°28'49.54"S, 49°20'28.20"W, localizada no município de Curitiba, no estado do Paraná. Esta área abrange aproximadamente 23,5 hectares. O levantamento foi realizado no período de 02/06/2021 a 14/06/2021. Como mostrado na FIGURA 38, o segmento A-B delimita a extensão da linha existente, indicando seu início e término.

FIGURA 38 – TRECHO DA LT 230 KV CAMPO COMPRIDO – SANTA QUITÉRIA.



FONTE: Adaptado Google Earth (2023).


Esta área contém um total de 116.219.794 pontos, dividida de acordo com o procedimento apresentado no item 3.2.5.1, passando por uma classificação inicial em 5 classes (Superfície, Terreno, Edificações, Torres e LTs) e posteriormente em 3 classes (Superfície, Torres e LTs). Durante esse processo, a área exibiu características distintas que auxiliaram na determinação do número de classes a serem aplicadas. Essa classificação foi baseada nos elementos principais utilizados em um projeto de uma nova linha de transmissão.

3.2.2.1 Relevo

A área 02 possui uma variação altimétrica de 74 metros em 6 quilômetros lineares. Ao contrário da área 01, a área 02 não apresenta a presença de vales ao

longo da faixa. Uma representação do terreno na FIGURA 39 mostra que não há variação altimétrica considerável em trechos próximos, apenas considerando a extensão completa da área.

FIGURA 39 - EXEMPLO DE RELEVO EM UM TRECHO DA ÁREA 02.



FONTE: O autor (2023).

3.2.2.2 Cultura

Na área 02 é possível visualizar que, por se tratar de uma área urbana, predominam os espaços destinados a pastos e áreas arborizadas. Essa configuração reflete não apenas a presença de vegetação, mas também a integração de elementos naturais dentro da área urbana, promovendo um ambiente sustentável.

Nesta região, conforme apresentado na FIGURA 41A, a cultura local é caracterizada por uma abordagem cíclica. Isso é possível visualizar em práticas agrícolas sazonais que seguem o ciclo das estações ou até mesmo em iniciativas de conservação ambiental que buscam manter o equilíbrio entre o desenvolvimento urbano e a preservação dos recursos naturais, conforme apresentado.

Na FIGURA 41B é apresentado um exemplo de cultura perene que se desenvolve de forma baixa e está situada a uma distância considerável das torres de alta tensão. Isso sugere uma conscientização e planejamento cuidadosos em relação à localização e à escolha das culturas na área. Optar por culturas perenes de baixo porte nessas proximidades pode ser uma estratégia para minimizar o risco de interferência com as linhas de transmissão de alta tensão, garantindo assim a segurança e a eficiência do fornecimento de energia elétrica.

Essa sinergia entre a urbanidade e a natureza não apenas define a identidade dessa área, mas também influencia na questão do cuidado da conservação das torres em conjunto com o estilo de vida dos seus habitantes em seu entorno.

FIGURA 40 - EXEMPLO DE CULTURA CÍCLICA (A) E PERENE (B) EM UM TRECHO DA ÁREA 02.



FONTE: O autor (2023).


3.2.2.3 Vegetação

Na área 02, observa-se que a vegetação predominante é composta por espécies nativas, conforme indicado nos mapas CCO_SQT_52, CCO_SQT_53, CCO_SQT_142 e CCO_SQT_143, conforme descrito no item 3.3.2.1. Essa vegetação nativa geralmente consiste em espécies adaptadas ao ambiente local e desempenha um papel crucial na manutenção da biodiversidade e na estabilidade do ecossistema.

No entanto, próxima à estrutura, identificada na CCO_SQT_005, é observada a presença de capoeira, conforme ilustrado na FIGURA 41. A capoeira é uma formação vegetal típica de áreas abandonadas ou em processo de regeneração, caracterizada pelo crescimento de vegetação secundária, como arbustos e árvores de porte menor, após a retirada ou perturbação da vegetação original.

A presença de capoeira próxima à estrutura pode indicar um processo natural de regeneração ou um estágio de transição na paisagem. É importante monitorar essa vegetação de perto para compreender seu desenvolvimento e avaliar se são necessárias intervenções para garantir a segurança das estruturas próximas e promover a conservação da biodiversidade local.

FIGURA 41 – EXEMPLO DE VEGETAÇÃO PRÓXIMA A UMA ESTRUTURA - CCO_SQT_05.



FONTE: O autor (2023).

3.2.2.4 Atributos de Intensidade

Os atributos de intensidade no conjunto de dados 02 são idênticos aos do conjunto de dados 01, pois ambos foram selecionados levando em consideração o objetivo do estudo, que é a análise das torres e cabos. Essa consistência nos atributos permite uma comparação direta entre os conjuntos de dados e facilita a aplicação das técnicas e dos modelos.

3.3 MÉTODOS

Neste capítulo, são abordados os aspectos relacionados à captura e processamento de dados, bem como o treinamento e a validação de um modelo para a segmentação semântica de nuvens de pontos provenientes de RPAS, com foco nas classes 'Torres' e 'LTs' (Cabos condutores das Linhas de Transmissão). Realizaram-se testes em dois conjuntos de dados de regiões distintas, coletados com sensores diferentes, com o propósito de compreender as redes neurais na tarefa de classificação.


Nas próximas subseções, são detalhadas as etapas relacionadas à coleta de dados, áreas de estudo, parametrização e tratamento dos dados. Essencialmente, estas subseções da metodologia explicam as fases do processamento de dados no método proposto. Inicialmente, é explicado o algoritmo utilizado para preparar os dados antes de serem introduzidos nas entradas da rede neural. Posteriormente, a arquitetura PointNet++ é discutida, visto que ela é responsável pela classificação dos

pontos analisados. Por fim, o objetivo é apresentar uma metodologia abrangente com as etapas envolvidas nesse processo, oferecendo estratégias para uma compreensão mais aprofundada do escopo deste estudo.

3.3.1 Processamento

O fluxograma apresentado na FIGURA 42 fornece uma visão esquemática e estruturada das diferentes fases que compõem o processo de construção de uma rede de aprendizado profundo, utilizando a arquitetura PointNet++, para segmentação de torres e cabos condutores de LT's a partir de dados LiDAR de RPAS. Cada elemento dentro deste fluxograma possui uma função específica, contribuindo para a formação e otimização da rede. Está apresentado desde a fase inicial de aquisição de dados até a etapa de treinamento, ajuste do modelo, segmentação semântica, avaliação e as inter-relações entre elas.

FIGURA 42 - FLUXOGRAMA DA METODOLOGIA DE SEGMENTAÇÃO DA NUVEM DE PONTOS UTILIZANDO A ARQUITETURA POINTNET++.



FONTE: O autor (2023).

3.3.2 Pré-processamento

Em uma nuvem de pontos, cada ponto tem três coordenadas espaciais (x, y e z), e estas coordenadas são armazenadas como números de ponto flutuante. Essa representação demanda alto custo em termos de espaço de armazenamento. Portanto, a utilização de técnicas de compressão de dados é geralmente aplicada para reduzir as necessidades de memória associadas ao armazenamento de grandes


conjuntos de nuvens de pontos. Uma opção é aplicar funções de compressão fundamentadas em entropia, tal como especificado nos formatos de dados LAS e LAZ (ISENBURG, 2011).

Para efetivamente explorar a utilidade da nuvem de pontos 3D e viabilizar a aplicação de técnicas baseadas em redes neurais e outros métodos de processamento avançado, é necessária a realização de uma série de etapas de pré-processamento, descritas a seguir. Um dos problemas a ser contornado, por exemplo, é a falta de organização dos dados.

A desordem diz respeito à ausência de organização dos pontos em uma estrutura regular, como é verificado no caso de imagens que usam a estrutura matricial (KHARROUBI et al., 2022). A falta de estrutura aponta para a inexistência de informações semânticas ou categorização nos dados brutos da nuvem de pontos. Na FIGURA 43 são apresentadas diferentes visualizações de uma nuvem de pontos.

A primeira imagem (a) mostra uma nuvem de pontos numa visualização em perfil, evidenciando que, mesmo sem classificação, os pontos formam a representação de uma árvore. Na segunda imagem (b), tem-se uma visualização de topo, na qual não é possível identificar claramente o elemento em questão, evidenciando a característica de falta de estrutura. Por fim, na última imagem (c), têm-se um recorte da área delimitado pelo quadrado da imagem (b), destacando as características de irregularidade e desordem na distribuição dos pontos.

FIGURA 43 – (a) VISUALIZAÇÃO DA NUVEM DE PONTOS EM PERFIL, (b) VISUALIZAÇÃO DA NUVEM DE PONTOS EM VISTA DE TOPO (c) VISUALIZAÇÃO DE UM DETALHE DA NUVEM DE PONTOS.



FONTE: O autor (2023).

As etapas do pré-processamento da nuvem de pontos incluem o agrupamento de pontos em blocos, a análise da presença de ruído e sua remoção, bem como o cálculo dos pesos associados a cada ponto. Essas etapas visam garantir a qualidade


e a consistência dos dados antes de serem introduzidos nas etapas subsequentes do processo de análise e classificação.

3.3.2.1 Agrupamento em blocos

A seção 01 deste estudo abrange uma área total de 73.051 m², compreendendo um conjunto de 67.209.295 pontos de dados. Esta extensão foi dividida em 82 folhas, cada uma com dimensões de 30 metros por 30 metros, resultando em uma área de 900 m² por folha. Com esse arranjo, a densidade média fica em aproximadamente 500.000 pontos por metro quadrado por folha. Essa configuração ressalta a importância da fase inicial de cálculo das dimensões das folhas no contexto da definição das proporções do modelo.


É importante destacar que a nuvem de pontos foi subdividida em folhas, cada uma organizada de forma sequencial, sem sobreposição, conforme ilustrado nas FIGURA 44 e FIGURA 45. Além disso, cada folha foi devidamente identificada por meio de um atributo, como seu nome, a fim de facilitar a organização e a identificação das informações contidas em cada uma delas. Foram atribuídas nomenclaturas específicas para cada área, sendo a área 01 denominada como FOC_SEC e a área 02 como CCO_SQT, conforme os trechos indicados nos itens 3.2.1 e 3.2.2.

FIGURA 44 - ARTICULAÇÃO DE FOLHAS DO CONJUNTO DE FOLHAS 01.



FONTE: O autor (2023).

FIGURA 45 - ARTICULAÇÃO DE FOLHAS DO CONJUNTO DE FOLHAS 02



FONTE: O autor (2023).

Além da estruturação em blocos, outra estratégia adotada para manipular grande quantidade de pontos foi a utilização de funções para gerenciar e acessar informações relacionadas à nuvem de pontos em arquivos bloqueados. A nuvem de pontos é dividida em pequenos blocos. Cada bloco contém um subconjunto dos pontos. Esses blocos são unidades de armazenamento, o que facilita o gerenciamento e o acesso a partes específicas da nuvem de pontos.

A estruturação em blocos ajuda a reduzir a carga de trabalho do software ao lidar com grandes volumes de dados, tornando o processo mais eficiente. Em vez de manter todos os pontos diretamente na memória do computador ou em arquivos internos ao software, os pontos utilizados são os mesmos que estão armazenados em arquivos externos. Isso significa que os dados da nuvem de pontos residem fora do software principal. Isso economiza memória RAM, pois apenas os blocos relevantes precisam ser carregados na memória quando necessário, em vez de toda a nuvem de pontos. Também economiza espaço em disco, uma vez que os dados são mantidos de forma mais compacta e organizada em arquivos.


3.3.2.2 Remoção de ruídos

Após a articulação da nuvem de pontos bruta em folhas, é iniciado um procedimento de manipulação que objetiva a depuração do conjunto, visando a supressão de valores discrepantes e dados incongruentes. Esta operação tem como

objetivo preservar a integridade dos dados destinados à análise subsequente. A presença de artefatos ruidosos pode exercer interferência no processo de treinamento da rede. Para esta atividade foram utilizados algoritmos de classificação automática de ruídos e após uma verificação com ferramentas de edição manual no software TerraScan® da Terrasolid.

Uma vez finalizada a fase de manipulação, a nuvem de pontos é submetida a um processo de categorização por intermédio do mesmo software. Tal categorização é empreendida mediante uma consideração das propriedades intrínsecas dos pontos individuais, viabilizando, desse modo, a identificação acurada e a classificação apropriada dos elementos contidos na referida nuvem de pontos. Na FIGURA 46 observa-se um exemplo de ruído que pode ocorrer numa nuvem de pontos LiDAR. Esses pontos considerados ruídos devem ser eliminados ou classificados para uma categoria específica para não interferir nos resultados.

FIGURA 46 - EXEMPLOS DE ARTEFATOS RUIDOSOS EM NUVEM DE PONTOS NA ÁREA 02



FONTE: O autor (2023).

3.3.2.3 Cálculo dos pesos

O cálculo foi realizado de forma iterativa utilizando como base a quantidade de pontos por classe. Portanto, a fórmula dos pesos foi atribuída por classe e considera o maior número total de pontos considerando todas as classes e o número de pontos da classe em estudo.

Portanto, no método adotado neste trabalho, os pesos são determinados individualmente para cada classe. Esses pesos são calculados considerando duas

variáveis: o maior número total de pontos entre todas as classes e o número de pontos pertencentes à classe específica que está sendo estudada, conforme apresentado na EQUAÇÃO 9. Esses valores são armazenados em variáveis para referência durante o processo de treinamento. A TABELA 3 apresenta os pesos utilizados por área.

$$Peso = \sqrt{\frac{\text{Maior número de pontos entre todas as classes}}{\text{Número de pontos da classe}}} \quad (9)$$

TABELA 3 - PESOS POR CONJUNTO DE DADOS E ÁREA

Classes	Terreno	Superfície	Edificação	Torres	LT's
Área 01	1	3.2122	22.8879	19.1385	20.7419
Área 02	1.2463	1	35.6998	12.4551	8.1090
Area 01 e 02	-	1	-	5.1217	4.8537

FONTE: O autor (2023).

Dada a extrema desigualdade na distribuição de categorias em nuvens de pontos obtidas por meio de RPAS, a utilização de uma matriz de pesos foi importante para a eficiência do treinamento. Com isso, essa abordagem atribuiu pesos mais elevados às classes com menos amostras, garantindo que o modelo concedesse maior importância a essas classes minoritárias durante o processo de treinamento.

3.3.3 Conjunto de dados de treinamento e teste

3.3.3.1 Rotulação da Verdade de campo

Após a conclusão do pré-processamento, a próxima etapa envolve a preparação dos conjuntos de dados de treinamento e teste, que inclui a criação da verdade de campo por meio de rotulagem. A construção da verdade de campo para imagens é realizada usando algoritmos específicos de anotação. No entanto, no caso de nuvens de pontos, esse processo envolve a aplicação de técnicas de classificação.

Na classificação de nuvens de pontos, cada elemento individual na nuvem de pontos recebe uma identificação específica por meio de intervenção manual, seguindo critérios predefinidos. É importante observar que essa tarefa é uma atividade demorada e depende da intervenção de um operador humano. Portanto, existe a possibilidade de ocorrerem eventuais imprecisões devido à natureza manual do processo.


A verdade de campo (*Ground Truth*) é o termo que descreve os dados do mundo real usados para treinar e testar as saídas de modelos de Inteligência Artificial. Dados de verdade de campo são necessários para muitas aplicações de Inteligência Artificial, incluindo direção automatizada e reconhecimento de áudio ou fala, conforme citado em (MATHWORKS, 2020).

A categorização da nuvem de pontos ocorre para a geração da verdade de campo que constitui uma das etapas de pré-processamento dos dados antes do treinamento da rede neural. Este procedimento implica na criação de um conjunto de dados de referência que captura a classificação correta, ou seja, a verdade das características e categorias contidas na nuvem de pontos.

Os dados de verdade de campo são basicamente para duas etapas, no treinamento e na validação. No desenvolvimento de algoritmos de IA que se refere ao treinamento do modelo, a verdade de campo é usada para que o algoritmo aprenda quais características são apropriadas para aquela folha e para o teste do modelo, quando após o algoritmo estar treinado ser utilizado para validar a precisão do modelo.

A FIGURA 47 apresenta um exemplo de nuvem de pontos que foi submetida a um processo de classificação manual utilizando o software TerraScan®, sendo essa classificação considerada como a verdade de campo. No contexto da anotação de imagens, a utilização de programas dedicados a essa finalidade é prática comum. Contudo, para o domínio das nuvens de pontos, a seleção de programas distintos pode ser mais apropriada, dada a natureza singular desses dados.

FIGURA 47 - NUVEM DE PONTOS COM CLASSIFICAÇÃO MANUAL – VERDADE DE CAMPO



FONTE: O autor (2023).

Inicialmente, a classificação foi executada com 5 (cinco) classes distintas, (superfície, terreno, torres, cabos LT's e edificações) abordando diferentes características presentes na nuvem de pontos. Posteriormente, devido ao foco específico na categorização de torres e cabos, a classificação foi refinada para abranger somente 3 classes relevantes (superfície, torres e cabos LT's).

3.3.3.2 Validação Cruzada

A próxima etapa envolveu a seleção das amostras para treinamento e teste, utilizando a técnica de validação cruzada. Inicialmente, o conjunto de dados foi dividido em duas partes: treinamento e teste, visto que todas as folhas testadas foram validadas. Dentro do conjunto de dados, foi aplicada a técnica de validação cruzada K-Fold.

A validação cruzada é uma abordagem amplamente empregada para avaliar a capacidade de generalização de modelos preditivos em diferentes cenários, usando conjuntos de dados distintos. Essa técnica desempenha um papel importante na fase de avaliação e ajuste de modelos de aprendizado de máquina e aprendizado profundo. Além disso, é fundamental na escolha dos hiperparâmetros ideais para o modelo, contribuindo significativamente para o processo de desenvolvimento e otimização. (BERRAR, 2019)

Nesse estudo, o QUADRO 3 mostra o conjunto de dados 01 com 83 folhas. O conjunto de treinamento foi subdividido em 4 partições K de tamanho similar, conforme apresentado em cada iteração. O modelo foi treinado k vezes, utilizando k-1 partições para treinamento e 1 partição para teste a cada iteração. Isso permitiu avaliar o modelo em diferentes conjuntos de dados e evitar a influência excessiva de um único conjunto de validação.

QUADRO 3 – EXEMPLO DAS FOLHAS AVALIADAS NA VALIDAÇÃO CRUZADA NO CONJUNTO DE DADOS 01 COM 83 FOLHAS.

ID	Tipo / número de folhas			
Iteração 1	Teste 20	Treinamento 20	Treinamento 20	Treinamento 23
Iteração 2	Treinamento 23	Teste 20	Treinamento 20	Treinamento 20
Iteração 3	Treinamento 20	Treinamento 20	Teste 20	Treinamento 23
Iteração 4	Treinamento 20	Treinamento 20	Treinamento 20	Teste 20

FONTE: O autor (2023).

Já para o conjunto de dados 02 que possui 198 folhas, foram utilizadas aproximadamente 80 folhas para treinamento e 20 para teste, escolhidas de forma sequencial ou aleatória. O conjunto de treinamento também foi subdividido em 4 partições K de tamanho similar, ou seja, aproximadamente 80 folhas para cada iteração. Ao final das iterações, os conjuntos de métricas de avaliação, proporcionaram uma compreensão mais sólida da performance do modelo, auxiliando na prevenção de sobreajuste e uma avaliação mais confiável do modelo.

3.3.4 Definição dos Hiperparâmetros

No início do processo, os pesos foram calculados conforme o item 3.3.2.3 e durante o treinamento foram recalculados conforme o gradiente da função de perda, visando sua redução. A taxa de aprendizado determinou o tamanho dos passos que o algoritmo de otimização fez em direção ao mínimo da função de perda, portanto é uma taxa de convergência. Uma taxa de aprendizado maior que 0.0002 resulta em passos maiores, enquanto uma taxa de aprendizado menor resulta em passos menores, porém se a taxa de aprendizado for muito superior a esse valor, a convergência será mais rápida, mas poderá ocorrer sobreajuste e um resultado de predição com muitos falsos positivos.

Nesse sentido, foram necessários vários treinamentos para a escolha de uma taxa de aprendizado adequando ao modelo. A busca pelos hiperparâmetros adequados envolveu experimentação e ajuste iterativo. Técnicas como busca em grade, busca aleatória e otimização bayesiana são frequentemente utilizadas para explorar o espaço de hiperparâmetros em busca da configuração que maximize o

desempenho do modelo de acordo com uma métrica específica, como a acurácia ou a perda nos dados de validação. A TABELA 4 apresenta os hiperparâmetros utilizados nos treinamentos das áreas 01 e 02.

TABELA 4 - HIPERPARÂMETROS UTILIZADOS NOS MODELOS DE TREINAMENTO

Hiperparâmetro	Valor
Taxa de aprendizado	0.0002;
Regularização L2	0.01;
Número de épocas	60;
Tamanho do minibatch	64;
Fator de redução da taxa de aprendizado	0.1;
Intervalo de redução da taxa de aprendizado	40;
Fator de queda do gradiente	0.9;
Fator de queda do gradiente ao quadrado	0.999;

FONTE: O autor (2023).

3.3.5 Arquitetura PointNet ++

Após a preparação dos dados de treinamento e teste, o próximo passo foi a escolha da arquitetura que tivesse o melhor desempenho com nuvem de pontos 3D. A escolha do PointNet++ foi motivada por algumas razões, mas a principal é que foi projetada para lidar com conjuntos de pontos 3D irregulares, tornando-a adequada para tarefas que envolvem nuvens de pontos desorganizadas e não estruturadas. Outros fatores relevantes foram a invariância a permutação, o agrupamento hierárquico, a redução da dimensionalidade e a possibilidade de treinamento eficiente mesmo com volumes de dados menores, se comparados com outras abordagens. Essas comparações estão apresentadas no item 2.2.6, comprovando que apesar do PointNet++ não ter apresentado os melhores resultados, ele é mais adequado para a segmentação de nuvem de pontos densa, devido as caixas delimitadoras do KPConv.(VARNEY, et.al, 2020)

O PointNet++ é baseado no PointNet, ambos desenvolvidos na Universidade de Stanford e utiliza uma estratégia hierárquica para capturar as informações locais em diferentes escalas de contexto, tornando-o mais eficiente e robusto na análise de conjuntos de pontos 3D irregulares. Alcançou resultados significativamente superior em comparação com abordagens de ponta em benchmarks que envolvem nuvens de pontos 3D (QI, YI, SU, & GUIBAS, 2017).

3.3.5.1 Padronização dos dados de entrada

3.3.5.2 T-NET


A Transform-Net consiste em camadas de redes neurais que estimam a matriz de transformação afim necessária para realizar a rotação, translação e escala dos pontos no espaço tridimensional. Essa matriz é então aplicada aos pontos de entrada para realizar a transformação. É necessário utilizar nas nuvens de pontos ou dados 3D, onde a orientação ou a posição dos pontos pode variar.

Diferentemente das redes convolucionais que processam imagens, a entrada neste caso é um conjunto de pontos no espaço 3D Euclidiano. As nuvens de pontos possuem características próprias, que devem ser consideradas:

- a) Os pontos são desorganizados. Uma nuvem pode ser resultado de várias varreduras e, mesmo em uma única varredura, não se pode facilmente identificar os pontos vizinhos, pois eles não são armazenados como voxels ou em uma estrutura matricial. Por isso, é necessário que o processamento seja invariante à ordem de entrada dos dados.
- b) A nuvem de pontos pode ser adquirida de diferentes pontos de vista, então o processo deve ser invariante a rotações. Por ser uma nuvem no espaço Euclidiano, apenas transformações de corpo rígido devem ser consideradas, desconsiderando mudança de escala e cisalhamento.
- c) O modelo deve ser capaz de detectar e entender estruturas locais, pois os pontos não ocorrem de forma isolada. Eles geralmente são o resultado do reflexo do pulso laser em estruturas existentes, objetos, com forma e tamanho definidos.

Com base nessas considerações, a entrada que é um conjunto de coordenadas 3D é modificada aplicando-se uma transformação de corpo rígido, com base na rede T-Net, conforme apresentado na FIGURA 48. Ele alinha a nuvem de pontos de entrada a um espaço canônico antes da extração de descritores, com a finalidade de minimizar o efeito da rotação. Uma matriz de transformação 3×3 é calculada usando uma rede convolucional.

FIGURA 48 – REDE NEURAL POINTNET



FONTE: Hu et. Al, 2022

Para cada ponto de entrada são calculados 64 atributos usando um MLP. Esta nova série é usada como entrada em novas camadas convolucionais expandido o vetor até 1024. Nesta primeira fase uma grande quantidade de atributos é calculada. A seguir, o vetor de atributos é reduzido sistematicamente, usando uma camada de *max pooling* e camadas totalmente conectada. Na última etapa deste processo, é obtido um vetor 1x9, que resume os elementos da matriz de rotação e que é transformado em uma matriz 3x3 (Hu et.al, 2022)

Uma das vantagens do uso de T-NET é que o resultado é invariante à ordem de entrada dos dados e sua principal característica é que mapeia as coordenadas, mesmo que obtidas desde diferentes pontos de vista, para o mesmo sistema 3D.

3.3.5.3 Normalização

A etapa de normalização de dados, envolveu a transformação dos valores X, Y, Z da nuvem de pontos em dados dentro do intervalo entre 0 e 1 para que eles permanecessem em uma escala comum e numa distribuição específica. O cálculo para a normalização deu-se pelo mínimo e máximo dos valores encontrados de X, Y e Z de cada folha. A EQUAÇÃO 10 apresenta a fórmula para calcular o valor normalizado de X, onde x representa o valor original de X, xmin é o valor mínimo de X encontrado na folha e xmax é o valor máximo de X encontrado na folha:

$$X_{normalizado} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (10)$$

A EQUAÇÃO 10 calcula o valor normalizado de X, garantindo que ele esteja dentro do intervalo de 0 a 1, com base nos valores mínimos e máximos encontrados na folha específica da nuvem de pontos. Esse processo é então repetido para os valores de Y e Z, garantindo que todos os dados estejam na mesma escala e distribuição, facilitando análises posteriores.

3.3.5.4 Redução da densidade de pontos

Uma estratégia viável para otimização do processamento de nuvem de pontos densa é a redução da densidade dos pontos, mediante a preservação apenas de uma fração dos pontos originais. Cada bloco ficou com 8000 pontos para viabilizar o treinamento e tornar os dados compatíveis com os dados da camada de entrada da rede neural.

Ao longo da investigação, uma série de alternativas de valores foi submetida a testes empíricos, visando a identificar a configuração mais adequada na questão de melhor eficiência e menor tempo. Foram realizados 26 treinamentos, que serviram para avaliar esses parâmetros escolhidos. Portanto, 8000 pontos foi a alternativa escolhida em que o resultado foi satisfatório, não ultrapassou 3 horas de treinamento e foi capaz de proporcionar o equilíbrio entre a redução da quantidade de pontos e a preservação das informações essenciais contidas na nuvem de pontos.

3.3.5.5 Definição da arquitetura

Essa rede pode ser dividida em dois módulos principais, o primeiro módulo, chamado de módulo de abstração do conjunto de dados, que recebe os dados de entrada, normalmente são as coordenadas brutas XYZ da nuvem de pontos, realiza transformações nos dados e ao mesmo tempo, calcula descritores espaciais com base nessas coordenadas. Em seguida, as características mais relevantes são agregadas na camada de *pooling* usando a técnica de *max-pooling*. O resultado é uma série de descritores globais relevantes, que capturam as variações na nuvem de pontos.

No segundo módulo, conhecido como módulo de propagação de características, os descritores globais são combinados com descritores locais para

tomar decisões sobre a classe mais apropriada para cada ponto de dados. A saída da rede é expressa por meio de índices que representam cada uma das classes consideradas.

Para empregar a arquitetura PointNet++, é necessário definir tanto a estrutura do codificador quanto a do decodificador, incorporando camadas de convolução 2D, normalização e ativação ReLU, camadas de agrupamento e amostragem, e uma camada de *pooling*, conforme apresentado na FIGURA 49. O codificador é encarregado de receber as coordenadas brutas XYZ da nuvem de pontos, aplicar transformações e extrair características, enquanto o decodificador é adaptado para a tarefa específica, como classificação ou segmentação. As camadas de convolução 2D aprendem representações locais, normalização e ReLU introduzem não-linearidades. As camadas de agrupamento e amostragem agregam informações em diferentes escalas, e a camada de pooling resume informações globais.

O QUADRO 4 apresenta os elementos necessários para o emprego da rede neural com arquitetura PointNet++ e que serão detalhados nos itens subsequentes. O total de camadas da rede foi de 79 e o cálculo está apresentado na EQUAÇÃO 11, onde SA refere-se à fase de agrupamento espacial, que inclui camadas de convolução (CONV), normalização (NORM), função de ativação ReLU e operação de MaxPool. Enquanto isso, FP representa a fase de agrupamento final, que consiste em camadas de convolução (CONV), normalização (NORM) e função de ativação ReLU.

$$TOTAL\ CAMADAS = SA\ (CONV + NORM + ReLU + MaxPool) + FP\ (CONV + NORM + RELU) \quad (11)$$

QUADRO 4 – ELEMENTOS NECESSÁRIOS PARA O EMPREGO DA REDE NEURAL POINTNET++

Tipo	Valor
Número de pontos	8000
Dimensão do ponto	3
Número de classes	5
Tipo de normalização	lote
Número de módulos de abstração	4
Número de agrupamentos	1024
Raio do agrupamento	0.1
Tamanho do agrupamento	32

FONTE: O autor (2023).

Na arquitetura da rede, os módulos de abstração de conjunto de dados são representados pela sigla SA (*Set Abstraction*), e sua quantidade é determinada pela configuração específica da rede, neste caso, conforme apresentado no QUADRO 4, foram estabelecidos quatro desses módulos que são identificados como SA-01 a SA-04. Esses módulos são responsáveis por capacitar a arquitetura a aprender representações hierárquicas dos dados de entrada.

Cada módulo de abstração de conjunto é composto por uma camada de amostragem e agrupamento, seguida por uma mini-rede PointNet composta por uma convolução 2D, uma normalização e uma ativação ReLU (SA-Conv, SA-Norm, SA-ReLU) e concluída com uma camada de max pooling (SA-Maxpool). Esses componentes atuam em conjunto para permitir que a rede realize a extração de características pertinentes a partir dos dados de entrada, contribuindo para o processo de aprendizado e a representação de informações complexas.

Na arquitetura da rede, os módulos de propagação de características são representados pela sigla FP (*Feature Propagation*) e estão numerados de FP-01 a FP-04. Cada um desses módulos SA (*Set Abstraction*) é composto por três operações de convolução 2-D, três operações de normalização e três operações ReLU. Esses componentes atuam no processamento das informações nos módulos de propagação de características, contribuindo para a extração e transformação das representações dos dados.

Cada módulo de propagação de características segue uma estrutura padronizada que compreende uma camada de interpolação (*FP-Interpolation*) seguida por uma mini-rede PointNet (FP-Conv, FP-Norm, FP-ReLU). A mini-rede PointNet, por sua vez, consiste em uma sequência de camadas que englobam operações de convolução, normalização e ativação ReLU. O número de filtros empregados nas camadas de convolução da mini-rede PointNet é calculado dinamicamente com base no valor especificado em PointNetLayerSize (S), conforme apresentado no QUADRO 4.

Dado o conhecimento prévio sobre as configurações para os módulos de abstração e propagação, a próxima etapa envolverá a apresentação da arquitetura completa da rede, conforme apresentada na FIGURA 49. É possível observar, conforme citado anteriormente, que a rede possui 4 módulos de abstração de dados e 4 módulos de propagação de características.


Inicialmente a entrada de dados é realizada a partir das variáveis de entrada da rede que são o número de pontos por bloco e dimensão. Esses dados foram armazenados numa matriz numérica S por C, onde S é o valor de número de pontos por bloco, ou seja, 8000 e C é o valor da dimensão, ou seja, as coordenadas X, Y e Z (3).

A etapa subsequente consiste na amostragem e agrupamento, na qual os pontos de entrada são divididos em grupos. Nessa fase, 1024 agrupamentos são gerados com um raio de 0,1 e um tamanho de 32 pontos por agrupamento. A primeira etapa desse processo envolve a seleção de um subconjunto de pontos de entrada usando a técnica do ponto mais distante. O propósito dessa etapa inicial é escolher pontos iniciais que estejam espacialmente distantes uns dos outros, os centroides, visando a representar de maneira eficaz os primeiros grupos na formação da rede.

Com os pontos iniciais selecionados, a próxima etapa é agrupar os pontos de entrada em grupos com base na proximidade espacial em relação aos pontos iniciais.

Portanto, a camada de agrupamento constrói conjuntos de pontos de regiões locais encontrando os pontos "vizinhos" ao redor dos centroides. Isso envolve encontrar os pontos mais próximos de cada ponto inicial e atribuí-los ao mesmo grupo. A operação de agrupamento foi realizada usando um algoritmo de consulta por bola, conforme FIGURA 50 .

FIGURA 50 – PROCESSO DE TRANSFORMAÇÃO DOS PONTOS BRUTOS EM PONTOS CHAVE.



FONTE: Adaptado Jiang, Lu e Chen (2022)

Após a etapa de amostragem e agrupamento, vem a etapa de uma mini rede. A rede mini-PointNet contém uma rede MLP compartilhada com uma série de camadas de convolução, normalização e ativação ReLU, seguidas por uma camada de max pooling. Isso permite que a rede codifique padrões locais da região em vetores de características e extraia as características das nuvens de pontos durante a etapa de amostragem e agrupamento desses grupos.

A camada de convolução 2-D consistiu em 32 filtros ou convoluções com tamanho da janela $[1 \ 1 \ 3]$ com um deslocamento da janela de $[1 \ 1]$ e um preenchimento de $[0 \ 0 \ 0 \ 0]$. Além disso, o argumento de preenchimento foi definido como 'same', o que significa que durante o treinamento, o software calculou e ajustou automaticamente o tamanho do preenchimento de forma a garantir que a saída da camada tenha as mesmas dimensões que a entrada.

A camada de normalização teve a função de normalizar as ativações da camada anterior, que teve por objetivo para estabilizar o treinamento da rede e melhorar seu desempenho.

A função de ativação ReLU *reluLayer*, realizou a operação de limiar, definindo todos os valores em X que são menores que zero como zero, enquanto deixam os

valores maiores ou iguais a zero inalterados. Essa função de ativação é utilizada em redes neurais para introduzir não linearidade e ajudar os modelos a aprender relações complexas nos dados.

3.3.5.6 Treinamento do modelo

Para assegurar a obtenção dos resultados desejados no treinamento do modelo gerado pela arquitetura da rede neural PointNet++, foi necessário o ajuste dos itens 3.3.4., 3.3.5.1 e 3.3.5.5 apresentados anteriormente. Com isso, foi possível treinar a rede de forma otimizada.

Os modelos foram treinados usando o otimizador Adam. O Adam é um algoritmo de otimização usado para ajustar os pesos de uma rede neural durante o treinamento. Ele combina técnicas de otimização do Gradiente Descendente Estocástico e momentos, o que o torna eficaz para encontrar os mínimos locais de uma função de perda. É uma abordagem iterativa, o Adam adapta automaticamente a taxa de aprendizado com base na história dos gradientes da função de perda calculados, tornando-o adequado para diferentes partes do espaço de parâmetros. Essa configuração de treinamento utilizou pesos de classe ponderados com base na frequência das classes, conforme apresentado no item 3.3.2.3 e considerou informações tridimensionais das medições do LiDAR.


A taxa de aprendizado é um hiperparâmetro que controla o tamanho dos passos que o otimizador dá durante o processo de treinamento. Uma taxa de aprendizado mais alta pode levar a convergência mais rápida, mas também pode tornar o treinamento instável. Uma taxa de aprendizado muito baixa pode fazer com que o treinamento seja lento ou pare de convergir. Portanto, encontrar a taxa de aprendizado adequada é crítico para treinar uma rede neural (BERNSTALE e LIND, 2022)

Já a regularização L2 é uma técnica que ajuda a evitar o sobreajuste em modelos de aprendizado de máquina, incluindo redes neurais. Ela funciona adicionando um termo de penalização à função de perda durante o treinamento, que incentiva os pesos dos neurônios a permanecerem pequenos. Isso ajuda a melhorar a capacidade de generalização do modelo, o que significa que o modelo se ajustará melhor a dados não vistos (GOODFELLOW e BENGIO, 2016).

Durante o treinamento de uma rede neural, os dados são frequentemente divididos em minilotes, que são pequenos conjuntos de exemplos de treinamento. Em cada iteração de treinamento, o otimizador ajusta os pesos da rede com base em um minilote de dados ao invés de usar o conjunto de dados completo. O tamanho do minilote é um hiperparâmetro importante, pois afeta a eficiência do treinamento e a utilização de recursos de hardware. Portanto, o otimizador Adam controla como os pesos são atualizados. A taxa de aprendizado determina o tamanho dos passos de atualização, a regularização L2 ajuda a evitar o sobreajuste e o tamanho do minilote influencia a eficiência e a convergência do treinamento. A configuração correta desses elementos é essencial para obter um modelo de aprendizado de máquina eficaz.

O treinamento é acompanhado por um gráfico que atualiza automaticamente as informações de precisão e função de perda a cada iteração e época, bem como, o tempo gasto no treinamento do modelo. A FIGURA 51 apresenta um exemplo de um gráfico de acompanhamento do treinamento de um modelo. A curva na cor azul representa a porcentagem de precisão que o modelo está alcançando a cada época e iteração e a curva na cor azul a função de perda. Ambas são atualizadas simultaneamente.

FIGURA 51 - GRÁFICO DE PROCESSAMENTO DO TREINAMENTO



FONTE: O autor (2023).

Como o objetivo desse estudo foi classificar torres e cabos, no primeiro treinamento utilizou-se apenas 3 classes e nos treinamentos subsequentes foi aumentado o número de classes para 5, visando abranger um número maior de camadas que interessam num projeto de linha de transmissão. Neste sentido, a opção de utilizar menos classes simplifica o processo de anotação, mas restringe seu uso. Portanto, foi realizado um experimento para investigar se a resultados poderiam melhorar agrupando as classes. O experimento foi conduzido com a utilização dos modelos gerados nos treinamentos com os conjuntos de dados da área 01 e área 02, com três classes, agrupando as classes que fossem diferentes de torres e cabos para superfície e em cinco classes agrupando as classes diferentes de torres, cabos, edificações, terreno e superfície para a classe superfície.

3.3.5.7 Segmentação semântica

A segmentação em nuvens de pontos de teste envolveu a aplicação de um processo de pré-processamento, semelhante ao utilizado no treinamento, para extrair rótulos e normalizar os dados. Foi a última etapa da rede antes da validação, conforme apresentado na FIGURA 49.

Em seguida, foram definidos os números de vizinhos mais próximos e o raio de busca para encontrar os pontos mais próximos na nuvem de pontos com resolução reduzida em relação a cada ponto na nuvem de pontos densa, a fim de realizar a interpolação. Os rótulos preditos foram calculados em toda a nuvem de pontos densa, usando rótulos previstos da nuvem de pontos com resolução reduzida. Esse processo ocorre de forma iterativa, considerando blocos não sobrepostos da nuvem de pontos.

No processo de segmentação da nuvem de pontos de teste, a interpolação foi importante para atribuir rótulos a todos os pontos na nuvem de pontos densa com base nas informações obtidas na nuvem de pontos com resolução reduzida. Isso permitiu que a segmentação fosse aplicada de maneira satisfatória em toda a nuvem de pontos densa, mesmo quando os pontos estão próximos uns dos outros.

Além disso, o processo iterativo em blocos não sobrepostos apresentou a escalabilidade dessa abordagem. Permitindo que a segmentação fosse aplicada em grandes conjuntos de dados de nuvem de pontos, tornando-a adequada para lidar com cenários extensos.


Resumidamente, inicialmente o algoritmo recebeu a nuvem de pontos 3D e a rede neural profunda treinada capaz de realizar a segmentação semântica. A entrada foi uma matriz numérica e a saída uma matriz categórica contendo rótulos de segmentação. Foi possível personalizar o comportamento da função com argumentos adicionais, como tipo de saída, tamanho de minilote, ambiente de execução (CPU ou GPU) e classes personalizadas. Permitindo também controlar a gravação dos resultados individuais utilizando um processo iterativo, conforme apresentado no APENDICE A.

3.3.6 Identificação das torres.

Para identificar as 'Torres', foi desenvolvido um algoritmo projetado para processar todas as folhas contendo a nuvem de pontos obtida após a segmentação semântica. Nesse algoritmo foi inserida a condição de abertura apenas de folhas com mais de 2500 pontos na classe “Torre”, com o objetivo de exclusão de ruídos que tenham sido classificados incorretamente.

Após esse processo, foi realizada uma reclassificação dos pontos da classe “Torre” para a classe “Superfície”, dos pontos mais baixos, ou seja, do Z mínimo até 4 metros. Com isso, os pontos de “Superfície” equivocadamente classificados como “Torre” não influenciarão na PCA. A partir da FIGURA 52 é possível visualizar a classe “Torre” antes e após reclassificação.

FIGURA 52 - ANTES E DEPOIS DA RECLASSIFICAÇÃO DA CLASSE “TORRE”.



FONTE: O autor (2023).


Posteriormente, o algoritmo calcula o centro das torres através das médias das coordenadas X, Y e Z, conforme apresentado na EQUAÇÃO 12. O centro da classe “Torre” é uma informação importante para os projetos de linhas de transmissão.

$$média(\tilde{x}) = \frac{\text{Soma de todos os valores } (\sum x)}{\text{Número de valores } (n)} \quad (12)$$

Além do cálculo do centro e da altura das torres, também foi realizada a determinação do tipo de torre. Nos conjuntos de dados 01 e 02, apenas dois tipos de torre foram identificados a partir da matriz dos autovetores. Os coeficientes que representam os principais eixos, ou seja, as direções que permitiram a extração de características significativas e distintivas que facilitaram a classificação das torres em seus respectivos tipos. As diferenças entre os autovetores estão nas relações relativas entre as variáveis (X, Y e Z) em cada direção principal de variação. A FIGURA 53 mostra a torre da folha FOC_SEC_63 com as principais direções indicadas pelas setas na cor branca (Z), amarela (Y) e azul (X).

Os autovetores representam as direções de maior importância. A combinação específica das três variáveis em cada autovetor refletem como essas variáveis estão relacionadas em cada direção principal. Dessa forma, a análise dos autovetores ocorreu para a identificação do atributo tipo das torres presentes na nuvem de pontos.

FIGURA 53 - CLASSE “TORRE” DA FOLHA FOC_SEC_63 COM OS VETORES PRINCIPAIS



FONTE: O autor (2023).

3.3.7 Métricas de avaliação de desempenho.

Dentro do contexto da avaliação do desempenho dos modelos treinados para a classificação da nuvem de pontos, a medição e validação foram conduzidas para garantir que atendessem aos requisitos de um processo sem intervenção. As métricas de avaliação foram derivadas da matriz de confusão, permitindo a quantificação precisa do quão bem os modelos estão classificando os pontos, conforme apresentado no QUADRO 5 e desenvolvidas dentro do ambiente do Matlab®.

Foram calculadas as métricas de acurácia, precisão, interseção sobre a união, sensibilidade, especificidade e F1score nos quatro conjuntos de dados formados pela combinação dos dois conjuntos de dados.

QUADRO 5 - MATRIZ DE CONFUSÃO

		Classe Desejada	
		Verdadeiro	Falso
Classe verdadeira	Positivo	VP - Representa os casos em que o modelo previu corretamente a classe positiva e o valor real também pertencem a essa classe	FP - Indica os casos em que o modelo previu incorretamente a classe positiva, mas o valor real pertence a outra classe
	Negativo	FN - Indica os casos em que o modelo previu incorretamente a classe negativa, mas o valor real pertence à classe positiva	VN - Refere-se aos casos em que o modelo previu corretamente a classe negativa e o valor real também pertencem a essa classe.

FONTE: O autor (2023).


A precisão foi utilizada especialmente para analisar os problemas em trabalhar com várias classes. Ela calcula a precisão para cada classe individualmente. No final foi calculada uma precisão média, permitindo a identificação de classes específicas que poderiam estar sendo mal classificadas pelo modelo.

A precisão global forneceu uma medida geral do desempenho do modelo em relação a todo o conjunto de dados, ou seja, a proporção de pontos classificados corretamente em relação ao total de pontos, independentemente da classe (MATHWORKS , 2023). Essa métrica é particularmente útil para avaliar a capacidade do modelo de classificar corretamente todos os exemplos do conjunto de dados. No

entanto, a precisão global pode ser enganosa em situações de desequilíbrio de classes, onde uma classe domina as outras em termos de número de amostras.

A interseção sobre união, IoU, é uma métrica comumente usada em tarefas de detecção de objetos e segmentação de imagens para avaliar o desempenho de algoritmos de visão computacional. Neste estudo foi utilizada para medir a sobreposição entre a área prevista pelo modelo e a área verdadeira do objeto. O cálculo do IoU é realizado pela divisão da área de interseção entre a previsão e a verdade verdadeira pela área de união dessas duas regiões. O resultado desse cálculo é um valor variando de 0 a 1, onde um IoU de 0 indica ausência de sobreposição entre a previsão e a verdade verdadeira, enquanto um IoU de 1 representa uma sobreposição perfeita, ou seja, a previsão é idêntica à verdade verdadeira, conforme apresentado na FIGURA 54.

FIGURA 54 - INTERSEÇÃO SOBRE UNIÃO



FONTE: O autor (2023).

Outra métrica utilizada foi a média da interseção sobre a união e interseção sobre a união ponderada. Em tarefas de segmentação de imagens, onde a precisão nas bordas das regiões segmentadas é crítica, a média da interseção sobre união (IoU) é orientada a ser empregada. A média IoU mede a sobreposição entre as máscaras segmentadas previstas e as máscaras de verdade de campo para cada classe. Essa métrica fornece uma avaliação mais detalhada da qualidade das previsões de segmentação.

Em cenários onde o desequilíbrio entre as classes é acentuado, o IoU Ponderado é uma extensão da média IoU que leva em consideração a representatividade das classes no conjunto de dados. O IoU Ponderado atribui pesos

diferentes às classes com base em sua frequência, garantindo que classes menos frequentes também sejam consideradas na avaliação.

A precisão e a sensibilidade são consideradas como medidas de consistência e completude da informação. A consistência verifica se os dados foram classificados corretamente e a completude verifica se todos os dados foram classificados. No entanto, o F1Score é a média harmônica entre a precisão e a sensibilidade.

As EQUAÇÕES 13 a 18 foram empregadas para o cálculo do desempenho do modelo e da predição e são:

$$IoU = \frac{\text{ÁREA DE INTERSEÇÃO}}{\text{ÁREA DE UNIÃO}} \quad (13)$$

$$\text{Acurácia} = \frac{VP+VN}{VP+FP+VN+FP} \quad (14)$$

$$\text{Precisão} = \frac{VP}{VP+FP} \quad (15)$$

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad (16)$$

$$\text{Especificidade} = \frac{VN}{VN+FP} \quad (17)$$

$$\text{F1Score} = 2 * \frac{\text{Precisão} * \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (18)$$

Essas métricas são algumas das ferramentas disponíveis para avaliar o desempenho de modelos de aprendizado de máquina. A escolha das métricas adequadas depende do contexto da tarefa e dos objetivos específicos do projeto, que neste caso é medir o resultado da predição.

A escolha da melhor métrica para analisar a nuvem de pontos depende dos objetivos específicos da análise. A acurácia é útil quando as classes estão balanceadas, enquanto a precisão é importante para minimizar falsos positivos. A Interseção sobre a União (IoU) é comumente usada em problemas de segmentação, enquanto a sensibilidade destaca-se na minimização de falsos negativos. A especificidade é relevante para avaliar a capacidade do modelo em identificar

verdadeiros negativos. A escolha depende das prioridades de avaliação em relação aos tipos de erros e ao equilíbrio entre classes na nuvem de pontos, ou seja, todas as métricas auxiliam na medição de desempenho do modelo.


4 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados obtidos e respectivas análises para cada experimento descrito no item 3.3.

Conforme citado no item 3.3.3.2, a validação cruzada foi gerada a partir da divisão do conjunto de dados de treino e teste em quatro partes. Com isso, foi avaliada a capacidade de generalização dos modelos.


Através do GRÁFICO 1, é possível observar a discrepância na quantidade de pontos entre o conjunto de dados 01 representado pela cor azul e o conjunto de dados 02 representado pela cor laranja. O conjunto de dados 02, contém um número maior de pontos, e essa diferença não se deve apenas à extensão da área mapeada. Isso ocorre também porque o sensor de captura utilizado no conjunto de dados 02 era uma tecnologia em fase de desenvolvimento, resultando na acumulação de mais pontos no primeiro retorno, especialmente perceptível nos elementos com determinada refletância, conforme é possível visualizar na FIGURA 55 que apresenta duas situações de ausência de retorno, uma ocorrendo em uma rua bem definida e a outra na base da estrutura da torre.

GRÁFICO 1 – QUANTIDADE DE PONTOS POR CLASSE E POR CONJUNTO DE DADOS



FONTE: O autor (2023).

FIGURA 55 – EXEMPLOS DE FALTA DE RETORNO EM REGIÕES DE PAVIMENTO E NO PÉ DA ESTRUTURA DA TORRE.



FONTE: O autor (2023).

Além disso, devido à um problema intrínseco do sistema LiAir 50 em relação a falta de retorno em superfícies com determinada cor, não foi possível obter uma captura adequada das informações do solo, o que resultou em uma desigualdade na distribuição de pontos entre as classes. No entanto, é importante observar que esse problema não faz parte do escopo desta pesquisa.

As TABELA 5 e TABELA 6 fornecem uma visão geral da distribuição dos dados por classe nos conjuntos de treinamento e validação. Embora o conjunto de dados 02 seja maior em termos de quantidade total de pontos, com um total de 116.219.794 pontos em comparação com os 64.223.230 pontos do conjunto de dados 01, é importante destacar que as classes de interesse, ou seja, "Torres" e "LT," apresentam uma quantidade menor de pontos no conjunto de dados 02, conforme evidenciado no GRÁFICO 01.

Apesar do conjunto de dados 02 conter um total de 198 folhas, aproximadamente 100 folhas foram selecionadas para compor os conjuntos de treinamento e teste. Isso foi de acordo com as diretrizes mencionadas no 3.3.3.2, onde foi destacado que o número de folhas tem um impacto significativo no tempo total de treinamento. A escolha de utilizar uma quantidade semelhante de folhas às aquelas presentes no conjunto de dados 01 é feita com o objetivo de garantir uma comparação equilibrada entre os conjuntos de dados. Isso significa que ao manter uma quantidade

similar de folhas em diferentes conjuntos de dados, minimiza-se o viés que poderia surgir devido a diferenças no tamanho ou na complexidade dos conjuntos de dados.

TABELA 5 - VISÃO GERAL DAS CLASSES DO CONJUNTO DE DADOS 01 EM RELAÇÃO A NÚMERO DE PONTOS DE TREINAMENTO E TESTE.

Classes	Quantidade de pontos									
	Geral	Treinamento (número – folha)					Teste (número – folha)			
		1-59	2-48	3-35	4-60	1-21	2-20	3-45	4-20	
Terreno	27.505.309	17.877.393	14.606.438	13.622.090	21.432.860	9.627.916	15.336.153	13.883.219	6.072.449	
Superfície	35.727.806	27.772.218	20.768.732	17.993.776	26.137.479	7.955.588	17.906.788	17.734.030	9.590.328	
Edificações	21.791	21.791	0	21.791	21.791	0	21.791	0	0	
Torres	345.928	179.026	345.928	98.412	193.783	166.902	204.352	247.516	152.145	
LT	622.396	422.348	368.676	283.000	468.677	200.048	352.013	339.396	153.719	

FONTE: O autor (2023).

TABELA 6 - VISÃO GERAL DAS CLASSES DO CONJUNTO DE DADOS 02 EM RELAÇÃO A NÚMERO DE PONTOS DE TREINAMENTO E TESTE.

Classes	Quantidade de pontos									
	Geral	Treinamento (número – folha)					Teste (número – folha)			
		1 -84	2 -85	3 - 79	4-81	1-21	2-30	3-17	4-21	
Terreno	107.678.335	52.857.136	43.697.761	36.301.721	48.254.589	14.170.018	16.275.703	26.585.200	6.072.449	
Superfície	8.003.714	2.968.966	4.234.880	2.432.439	21.432.860	1.275.527	1.142.751	502.011	9.590.328	
Edificações	145.248	29.497	83.415	62.406	21.791	26.866	16.576	106	0	
Torres	165.926	130.295	119.300	142.242	193.783	18.563	118.297	19.808	152.145	
LT	226.571	135.910	101.569	43.891	468.677	26.586	32.355	85.936	153.719	

FONTE: O autor (2023).

4.1 CONJUNTO DE DADOS 01 COM 5 CLASSES

A TABELA 7 exibe os resultados dos quatro treinamentos em relação ao número de folhas, com um padrão de 60 épocas e a taxa de aprendizado de 0.02% para o processamento. Ela fornece informações sobre o tempo gasto no processamento, bem como, a acurácia e as perdas obtidas em cada treinamento. Esses dados são para avaliar o desempenho dos modelos treinados e entender como diferentes quantidades de folhas afetam o processo de treinamento.


TABELA 7 – DESEMPENHO E TEMPO DE DURAÇÃO DOS TREINAMENTOS DOS MODELOS

Treinamento	Folhas	Época	Iteração	Duração	Acurácia	Perdas	Taxa de aprendizado
1	59	60	60	01:38:37	87.30%	0.5161	0.0002
2	48	60	60	01:51:36	88.16%	0.4536	0.0002
3	35	60	60	01:39:41	96.87%	0.4051	0.0002
4	60	60	60	01:35:13	90,10%	0.6010	0.0002

FONTE: O autor (2023).

O GRÁFICO 2 apresenta de progresso de treinamento do modelo 03 que apresentou o melhor resultado. O modelo que alcançou o melhor resultado foi o treinamento 3, configurado com 35 folhas, alcançando 96,87% na métrica de acurácia, porém no processo de segmentação foi o modelo do treinamento 2 que obteve um melhor resultado nas métricas de forma equânime.

GRÁFICO 2 - PRECISÃO E FUNÇÃO DE PERDA DO EXPERIMENTO 03



FONTE: O autor (2023).


O monitoramento do progresso do treinamento foi realizado com o objetivo de identificar quando um modelo estava apresentando de desempenho satisfatório, permitindo a detecção de sinais de superajustamento da rede, ou até mesmo, interrompimento antecipado do processamento. Os gráficos de monitoramento estão apresentados no APENDICE G.

4.1.1 Experimento 01

No treinamento 01 do conjunto de dados 01, composto por 59 folhas, conforme apresentado na TABELA 7, foi observado um desempenho relativamente mais baixo em termos de métricas de desempenho e perda do modelo quando comparado aos outros treinamentos. No entanto, durante a execução da etapa de segmentação do modelo de treinamento, conforme descrito na seção 3.3, considerando visualmente o número de pontos classificados corretamente, o resultado foi satisfatório, apresentado na FIGURA 56.


A FIGURA 56 apresenta o perfil das folhas resultantes após a etapa de processamento da segmentação da nuvem de pontos, destacando com setas os pontos que exibem maior quantidade de erros. Informações adicionais sobre os erros na extração dos objetos estão disponíveis na FIGURA 57.

FIGURA 56 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 01



FONTE: O autor (2023).

FIGURA 57 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 01: FOLHA FOC_SEC_75 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_74 (DIREITA – PIOR RESULTADO)



FONTE: O autor (2023).

No resultado à esquerda, conforme apresentado na FIGURA 57, o melhor desempenho, onde as linhas de transmissão estão nitidamente bem definidas, assim como a representação do terreno é bem evidenciada. Já na imagem da direita, é perceptível que as bordas da linha de transmissão (LT) estão se confundindo com a superfície. Essa confusão pode ser atribuída a duas possíveis causas. A primeira causa provável é a insuficiência de dados de treinamento para que o modelo aprenda a distinguir adequadamente as bordas, como fora relatado nos estudos de Jhaldiyal e Chaudhary (2023) e Langer et al., (2020). A segunda, e mais provável razão, discutida em trabalhos como os de Kölle et al., (2021), é o desbalanceamento de quantidade de pontos entre as classes, uma vez que a classe “Superfície” possui a maioria dos pontos da nuvem de pontos. Adicionalmente, a insuficiência de dados de treinamento com esse tipo de torre para que o modelo aprenda a distinguir adequadamente as bordas, também pode ter influenciado o resultado insatisfatório.

Com base na matriz de confusão apresentada na TABELA 8, é possível observar que o modelo de classificação alcançou um grau de acerto aceitável na classificação das classes “Terreno” e “LT”. Isto fora evidenciado pelos valores da matriz de confusão para essas classes. No entanto, também são evidenciados erros substanciais na classificação das outras classes, especialmente entre as classes “Superfície” e “Edificações,” onde as confusões foram mais proeminentes. Isso sugere

que o modelo pode precisar de melhorias específicas, em estudos futuros, para distinguir os objetos tipificado nessas categorias.

TABELA 8 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01
EXPERIMENTO 01 EM QUANTIDADE DE PONTOS

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	9 499 300	144 402	NaN	422	0
Superfície	4 479 887	4 553 915	NaN	28 954	4
Edificações	0	0	NaN	0	0
Torre	846	40 569	NaN	125 487	0
LT	13 624	12 928	NaN	11 743	174 209

FONTE: O AUTOR (2023).

Os dados que estão considerando as métricas de desempenho de acurácia, precisão, sensibilidade, especificidade e F1-score, estão apresentados na TABELA 9 para avaliar o desempenho global do modelo e identificar áreas específicas que requerem ajustes para aprimorar sua capacidade de classificação (DONG et al., 2022; ZHOU et al., 2021). Para obter essas métricas, os valores dos Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN), foram contabilizados a partir da TABELA 8.

Com base na tabela de métricas apresentadas na TABELA 9, é possível analisar o desempenho do modelo de classificação para cada uma das classes de objetos. A acurácia global do modelo varia significativamente entre as classes, aproximadamente 66,65% a 99,43%, o que indica que a acurácia do modelo difere entre as classes propostas. Considerando todas as classes, a média da acurácia ficou em 85,35%.

TABELA 9 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E
EXPERIMENTO 01 EM PERCENTUAL DECIMAL

Métrica	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	75.57%	66.65%	NaN	99.43%	99.73%	85.35%
Precisão	98.50%	50.25%	NaN	75.19%	81.98%	76.48%
Sensibilidade	67.88%	95.84%	NaN	75.32%	100.00%	84.76%
Especificidade	97.10%	51.84%	NaN	99.71%	99.73%	87.10%
F1score	80.37%	65.93%	NaN	75.25%	90.10%	77.91%

FONTE: O autor (2023).

Em termos de precisão, o modelo apresenta precisão nas classes "Terreno," "Torre," e "LT," sugerindo que quando o modelo classifica uma instância como

pertencente a essas classes, geralmente está correto. Entretanto, para as classes "Superfície" a precisão é significativamente menor, 50,24%, o que indica que o modelo tende a cometer erros de classificação nessas classes e como não teve nenhuma edificação no treinamento, ela ficou com 0%. Essa confusão se deve ao fato de muitos pontos que foram considerados como terreno, são pontos de superfície, principalmente os referentes a cultura.

A sensibilidade, que mede a capacidade do modelo em identificar instâncias positivas reais, (ZHOU et al., 2021), varia amplamente entre as classes. As classes "Superfície" e "LT" têm alta sensibilidade, indicando que o modelo é eficaz em identificar a maioria das instâncias verdadeiramente positivas nessas classes. Por outro lado, a sensibilidade é baixa para a classe "Edificações," por não possuir elemento nessa classe.

No que diz respeito à especificidade, ela identificou o quanto o classificador é eficaz em reconhecer corretamente áreas que não pertencem verdadeiramente a cada classe (COSTA, 2022). O experimento apresenta resultado relativamente alto para a maioria das classes, o que sugere que o modelo é capaz de identificar corretamente a maioria das instâncias verdadeiramente negativas.

Finalmente, o F1-score, que combina precisão e sensibilidade em uma única métrica conforme Amisse; Jijón-Palma e Centeno (2021), mostra que as classes "Terreno" e "LT" têm F1-scores mais altos, indicando um bom equilíbrio entre precisão e sensibilidade. Por outro lado, a classe "Superfície" tem um F1-score baixo, sugerindo um desequilíbrio entre essas duas métricas. Quando comparadas à literatura, as métricas que propõe experimentos semelhantes as apresentadas possuem resultados satisfatórios (JHALDIYAL; CHAUDHARY, 2023; SHEN et Al., 2023; SHINOHARA; XIU; MATSUOKA, 2020).


4.1.2 Experimento 02

No experimento 02 do conjunto de dados 01, composto por 48 folhas, observou-se o desempenho mais alto que o experimento 01 e 04 em termos de precisão e perda do modelo. Igualmente ao experimento 01, o resultado das métricas do modelo foram consideradas satisfatórias.

A FIGURA 58 apresenta o perfil das folhas resultantes após a etapa de processamento da segmentação da nuvem de pontos, destacando com setas os

pontos que exibem os maiores erros. O perfil apresenta uma região de vale com vegetação e uma porção de cabos não classificados corretamente. O detalhamento dos erros está apresentado na FIGURA 59.

FIGURA 58 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01(T2).




FONTE: O autor (2023).

A análise da imagem da folha "FOC_SEC_03" apresentada no lado esquerdo da FIGURA 59 sugere que, em termos gerais, a classificação realizada foi satisfatória. A classe "Torre" e as "Linhas de Transmissão (LTs)" foram identificadas de forma precisa, refletindo um desempenho adequado do modelo nesses aspectos. No entanto, há um desafio que está relacionado aos cabos que se estendem a partir da estrutura da torre. Isso deve-se ao fato desses terem sido erroneamente classificados como pertencentes a classe "Torre". Assim, evidencia-se uma limitação na capacidade do modelo em distinguir esses elementos.

Por outro lado, a análise da folha "FOC_SEC_14" revela que os cabos foram incorretamente categorizados como "Superfície". No entanto, é notável que o modelo conseguiu fazer uma distinção satisfatória entre "Superfície" e "Terreno". Essa observação ressalta a complexidade da tarefa de classificação dos cabos e a necessidade de melhorar a precisão global da classificação dos pontos.

FIGURA 59 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 02: FOLHA FOC_SEC_03 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_14 (DIREITA – PIOR RESULTADO)



FONTE: O autor (2023).

A partir da matriz de confusão apresentada na TABELA 10, é possível observar que o modelo de classificação alcançou um grau de acerto aceitável na classificação geral. A média de acurácia ficou com 88,92%. As classes "Terreno" e "Superfície," continuam sendo as classes com maior confusão. A classe "Superfície" como evidenciado pelos valores na linha principal, mostra que essa classe teve FP em todas as classes. No entanto, também são evidenciados erros substanciais na classificação das outras classes, onde as confusões foram menos proeminentes.

TABELA 10 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01 EXPERIMENTO 02

Classes	Terreno	Superfície	Edificações	Torre	LT
Terreno	6 348 353	402 149	NaN	0	0
Superfície	3 439 067	6 830 323	NaN	3 184	21
Edificações	0	21 791	NaN	0	0
Torre	0	4 807	NaN	32 643	0
LT	0	5 479	NaN	2 319	157 617

FONTE: O AUTOR (2023).

As métricas de desempenho de precisão, sensibilidade, especificidade e F1-score do modelo de classificação do experimento 02 nas cinco classes, estão apresentadas na TABELA 11. Os dados tabulares servem para avaliar o desempenho global do modelo e identificar áreas específicas que requerem ajustes para aprimorar sua capacidade de classificação.

É possível perceber que as categorias "Torre" e "LT" exibem um desempenho globalmente satisfatórios, com altos valores de acurácia, precisão, sensibilidade, especificidade e F1 Score. Em contraste, a categoria "Edificações" permanece com um valor "NaN" por não ter nenhum elemento nessa classe.

As classes "Terreno" e "LT" têm valores de precisão relativamente altos, indicando que o modelo é eficaz em identificar corretamente essas classes. No entanto, a classe "Superfície" tem uma precisão mais baixa, sugerindo que o modelo tende a classificar alguns pontos incorretamente. A classe "Edificações" tem um valor "NaN," indicando uma falta de exemplos de treinamento. As classes "Superfície" e "LT" têm alta sensibilidade, o que significa que o modelo é eficaz em identificar a maioria das instâncias verdadeiramente positivas nessas classes. Adicionalmente, a especificidade é relativamente alta para a maioria das classes, sugerindo que o modelo é capaz de identificar corretamente a maioria das classes verdadeiramente negativas (COSTA, 2020). As classes "Terreno" e "LT" têm F1-scores mais altos, indicando um bom equilíbrio entre precisão e sensibilidade. A classe "Superfície" tem um F1-score satisfatório, enquanto a classe "Edificações" permanece com um valor "NaN" por não ter nenhum elemento nessa classe.

TABELA 11 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 02 EM PERCENTUAL DECIMAL

Métrica	Terreno	Superfície	Edificações	Torre	LT	Média
Acurácia	77,68%	78,13%	NaN	99,92%	99,94%	88,92%
Precisão	94,04%	66,49%	NaN	87,16%	95,29%	85,75%
Sensibilidade	64,86%	94,02%	NaN	85,57%	99,99%	86,11%
Especificidade	94,58%	67,10%	NaN	99,96%	99,94%	90,40%
F1score	76,77%	77,90%	NaN	86,36%	97,58%	84,65%

FONTE: O autor (2023).

O modelo do experimento 02 apresentou um desempenho geral consistente e satisfatório, tendo um equilíbrio nos resultados das métricas, com destaque para as classes "Terreno," "Torre," e "LT." No entanto, seria importante, em estudos futuros, coletar mais dados ou ajustar o modelo para melhorar o desempenho nas classes com resultados menos satisfatórios, a exemplo do que fora realizado em Liu et al., (2023).


4.1.3 Experimento 03

A TABELA 7 evidenciou que o experimento 3, mesmo possuindo menos folhas, obteve o melhor resultado entre os treinamentos do conjunto de dados 01. Isso confirma a importância do equilíbrio entre as classes no conjunto de dados, indicando que conjuntos de dados com uma distribuição mais equilibrada das classes tendem a produzir resultados melhores.

Outra característica do experimento 3 é que a escolha foram folhas sequenciais. Isso pode contribuir de várias maneiras, incluindo a consistência espacial e temporal, a redução da variabilidade, a eficiência computacional e a facilidade na criação de regiões contíguas em análises geográficas. Adicionalmente é possível melhorar a interpretação dos dados e a eficácia das análises, mas é fundamental considerar o potencial viés que pode ser introduzido por essa escolha, portanto na validação dos dados é que será avaliado a sua eficiência (Cano-Solis; Ballesteros; Branch-Bedoya, 2023; Liu Et Al., 2023).

Por meio da interpretação visual da FIGURA 60, torna-se evidente que a maioria das regiões apresenta um desempenho satisfatório em relação ao modelo de classificação. No entanto, é possível identificar uma única região com erros mais notáveis, conforme apontado nas indicações sinalizadas na FIGURA 60. Isso sugere que o modelo pode estar enfrentando desafios específicos nessa região em particular, exigindo uma atenção mais detalhada para melhorar seu resultado. A análise visual das regiões com erros pode ser valiosa para aprimorar o desempenho geral do modelo e direcionar os esforços de ajuste e refinamento.


FIGURA 60 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DOS DADOS DO EXPERIMENTO 03



FONTE: O autor (2023).

A análise da imagem da folha "FOC_SEC_38" da FIGURA 61 apresenta que, a classificação realizada foi satisfatória. A classe "Torre" e as "Linhas de Transmissão (LTs)" foram identificadas de forma precisa, inclusive classificando corretamente a vegetação na base da estrutura, refletindo um desempenho adequado do modelo. No entanto, continua o desafio em relação aos cabos que se estendem a partir da estrutura da torre, que foram erroneamente classificados como parte da categoria "Torre", indicando uma limitação na capacidade do modelo em distinguir esses elementos. Por outro lado, a análise da folha "FOC_SEC_75" revela que os cabos foram incorretamente categorizados como "Superfície" nas bordas dessa folha.

FIGURA 61 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 03: FOLHA FOC_SEC_38 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_75 (DIREITA – PIOR RESULTADO)



FONTE: O autor (2023).

A TABELA 12 apresenta a matriz de confusão para descrever o desempenho do modelo de classificação usando o conjunto de dados 01 no experimento 03. Inicialmente, é evidente que as categorias "Terreno" e "Superfície" possuem um grande número de pontos que foram classificadas corretamente, com 13.145.557 e 11.203.486, respectivamente. Além disso, a classe "Torre" também teve um número significativo de classificações corretas, totalizando 214.522 pontos. No entanto, um aspecto preocupante é a classe "Edificações", que registra valores "NaN" em todas as células da linha, sugerindo que essa categoria não foi identificada ou classificada corretamente pelo modelo. Isso aponta para um desafio, para estudos futuros na

identificação de "Edificações" nos modelos por serem pouco representativos dentro dos conjuntos de dados.

Além das classificações corretas, a matriz de confusão também revela erros de classificação, como a classe "Superfície" sendo incorretamente classificada como "Terreno" em 822.387 pontos. É importante considerar que a interpretação final depende dos objetivos específicos do problema e da importância relativa de cada classe, que neste caso, o objetivo é a análise do desempenho das "LTs" e "Torres". A ausência de classificações para "Edificações" causa um desequilíbrio, porém não possui importância.

TABELA 12 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01
EXPERIMENTO 03

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	13.145.557	813.559	NaN	7.078	1.750
Superfície	7.640.029	11.203.486	NaN	99.407	27
Edificações	0	0	NaN	0	0
Torre	1.073	31.921	NaN	214.522	0
LT	1.680	18.145	NaN	24.282	307.779

FONTE: O autor (2023).

A TABELA 13 fornece as métricas de desempenho onde a acurácia média do modelo é de 86,62%. Considera-se que o modelo faz previsões corretas em uma quantidade significativa de dados.

Considerando a precisão, que mede a proporção de verdadeiros positivos em relação ao total de positivos previstos, para a classe "Terreno", a precisão é de 94,11%, o que indica que a maioria das previsões positivas para "Terreno" está correta. No entanto, a categoria "Superfície" tem uma precisão mais baixa de 59,14%, sugerindo que o modelo gera um número significativo de falsos positivos para essa classe.

A classe "Superfície" tem uma sensibilidade alta de 92,84%, o que indica que o modelo identifica bem os exemplos reais dessa classe. No entanto, a categoria "Terreno" tem uma sensibilidade mais baixa de 63,23%, sugerindo que o modelo pode estar perdendo alguns exemplos dessa classe. A categoria "Torre" tem uma alta especificidade de 99,87%, o que significa que o modelo identifica bem os negativos reais para essa classe.

E por fim, a métrica F1 Score, apresenta a classe "LT" com um F1 Score de 93,06%, indicando um bom equilíbrio entre precisão e sensibilidade para essa classe. Haja vista que, para um projeto de engenharia na área de inspeção de linhas de transmissão, essa vem a ser a principal classe de interesse (CANO-SOLIS; BALLESTEROS; BRANCH-BEDOYA, 2023).

TABELA 13 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 03 EM PERCENTUAL DECIMAL

Métrica	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	74,61%	72,72%	NaN	99,35%	99,82%	86,62%
Precisão	94,11%	59,14%	NaN	86,67%	87,47%	81,85%
Sensibilidade	63,24%	92,84%	NaN	62,13%	99,43%	79,41%
Especificidade	93,45%	60,24%	NaN	99,87%	99,82%	88,34%
F1score	75,64%	72,26%	NaN	72,38%	93,06%	78,34%

FONTE: O autor (2023).

4.1.4 Experimento 04


Esse experimento teve um resultado de acurácia no treinamento do modelo de 90,10%, com 60 folhas. Uma das características desse experimento é que a escolha das folhas foi aleatória e não sequencial.

Neste sentido, apesar dessa escolha introduzir desafios de representatividade e variabilidade nos resultados, um dos fatores positivos é que ela pode acelerar o processo de treinamento inicial, especialmente em conjuntos de dados muito grandes. Exemplos similares são discutidos por Cano-Solis, Ballesteros e Branch-Bedoya, (2023) e Ballouch et al., (2022), que apontam como essa complexidade e descontinuidade do conjunto de dados com nuvens de pontos pode conferir maior robustez ao modelo. Com isso, é possível uma visão inicial do desempenho do modelo antes de realizar seleções mais ponderadas de exemplos de experimento, bem como, no processo treinamento geral, apresentando o menor tempo de processamento com o maior número de folhas, conforme TABELA 7.

A FIGURA 62 apresenta essa aleatoriedade das folhas selecionadas para a segmentação e a FIGURA 63 com o melhor do conjunto de dados à esquerda e pior resultado do conjunto de dados à direita. É possível identificar que a folha FOLHA FOC_SEC_79 teve um resultado bem satisfatório, conforme apresentado no APENDICE A, separando bem as classes. Enquanto na folha FOLHA FOC_SEC_81,


houve confusão das classes tanto na “Torre” como nas “LT’s”, porém mesmo assim, o número de pontos classificados como “Torre” foi satisfatório para sua detecção.

FIGURA 62 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 04



FONTE: O autor (2023).

FIGURA 63 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 - EXPERIMENTO 01: FOLHA FOC_SEC_79 (ESQUERDA – MELHOR RESULTADO) E FOLHA FOC_SEC_81 (DIREITA – PIOR RESULTADO)



FONTE: O autor (2023).

A TABELA 14 apresenta a matriz de confusão do experimento 04 do conjunto de dados 01. A partir dela é possível verificar que houve confusão entre as classes “Terreno” e “Superfície”. Com base nessa TABELA 14, a TABELA 15 mostra que os valores de Verdadeiros Positivos (VP) e Verdadeiros Negativos (VN), é possível

identificar que o modelo conseguiu um resultado satisfatório em classificar corretamente as classes "Terreno," "Superfície," "Torre," e "LT.", evidenciado pelos altos números de VP e VN nessas classes, porém também é possível verificar que existe confusão entre as classes "Terreno" e "Superfície," o que sugere que apesar do modelo ter apresentado um bom resultado no treinamento, sua segmentação pode ser melhorada.

TABELA 14 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 01 EXPERIMENTO 04

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	5 640 608	488 272	NaN	1	0
Superfície	3 459 913	7 168 850	NaN	60 189	0
Edificações	0	0	NaN	0	0
Torre	622	41 123	NaN	153 594	0
LT	2 922	8 441	NaN	13 959	141 351

FONTE: O autor (2023).

TABELA 15 - CLASSIFICAÇÃO POR CLASSE COM MATRIZ DE CONFUSÃO CONJUNTO DE DADOS 01 EXPERIMENTO 04

Classe	Terreno	Superfície	Edificações	Torre	LT
VP	5 640 608	7 168 850	NaN	153 594	141 351
VN	7 463 795	7 463 795	NaN	12 950 809	12 963 052
FP	488 273	3 520 102	NaN	41 745	25 322
FN	3 463 457	537 836	NaN	74 149	0

FONTE: O autor (2023).

O modelo de classificação do experimento 04 apresenta um desempenho satisfatório em praticamente todas as classes. A média da acurácia ficou em 88,51%, destacando com a classe "Torre" e "LT" com 99%. A precisão e sensibilidade tiveram bons resultados na classe "LT". No entanto, enfrenta desafios na classificação da classe "Superfície," onde a precisão é mais baixa. Embora a acurácia global seja de aproximadamente 88.51%, a análise detalhada das métricas revela a necessidade de melhorias, particularmente na precisão da classe "Superfície."

TABELA 16 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 E EXPERIMENTO 04 EM PERCENTUAL DECIMAL

Métrica	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	76,83%	78,29%	NaN	99,12%	99,81%	88,51%
Precisão	92,03%	67,07%	NaN	78,63%	84,81%	80,63%
Sensibilidade	61,96%	93,02%	NaN	67,44%	100,00%	80,61%
Especificidade	93,86%	67,95%	NaN	99,68%	99,81%	90,32%
F1score	74,06%	77,94%	NaN	72,61%	91,78%	79,10%

FONTE: O autor (2023).

4.2 CONJUNTO DE DADOS 02 COM 5 CLASSES

Os resultados de desempenho dos quatro treinamentos estão apresentados na TABELA 17. O número de épocas foi o mesmo utilizado no conjunto de dados 01, porém o número de iterações dobrou em relação ao anterior. Os modelos de treinamento tiveram as métricas de acurácia e função de perda com valores satisfatórios, porém o experimento 03 demorou 12 horas para finalizar. Todos os modelos de treinamento atingiram precisão superior a 90%.

Os gráficos de progresso do treinamento estão apresentados no APENDICE G. Esse monitoramento do progresso do treinamento foi realizado com o objetivo de identificar o desenvolvimento de aprendizagem e quando um modelo não estava apresentando desempenho satisfatório, permitindo a detecção de sinais de superajustamento da rede, ou até mesmo, possibilitando o interrompimento antecipado do processo.

Conforme apresentado na TABELA 17, o modelo que alcançou o melhor resultado foi o treinamento 1, treinado com 84 folhas, alcançando 96,7%.

TABELA 17 – DESEMPENHO, DURAÇÃO E MÉTRICAS DOS EXPERIMENTOS DOS MODELOS DE EXPERIMENTO DO CONJUNTO DE DADOS 02.


Treinamento	Folhas	Época	Iteração	Duração	Acurácia	Perda	Taxa de aprendizado
1	84	60	120	3:10:55	98,7%	0,253	0.0002
2	85	60	60	1:39:41	96,3%	0,401	0.0002
3	79	60	120	12:31:31	94,5%	0,226	0.0002
4	81	60	120	2:38:58	98,4%	0,297	0.0002

FONTE: O autor (2023).

4.2.1 Experimento 01

Esse treinamento teve o melhor resultado de acurácia no treinamento do modelo de 98,7%, com 84 folhas. Uma das características desse treinamento é que a escolha das folhas foi sequencial, conforme apresentado na FIGURA 64. Com isso, a representatividade e variabilidade nos resultados ficaram preservadas.


FIGURA 64 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 04



FONTE: O autor (2023).

A FIGURA 65 apresenta dois resultados considerados aceitáveis. A imagem da esquerda apresenta uma quantidade de vegetação que foi classificada corretamente e na imagem da direita a estrutura da torre, mesmo que incompleta, também classificada em quase sua totalidade corretamente, possibilitando a detecção e a identificação em etapa posterior.

FIGURA 65 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 01: FOLHA CCFOC_SEC_118 (ESQUERDA RESULTADO) E FOLHA CCO_SQT_114 (DIREITA) - RESULTADOS ACEITÁVEIS



FONTE: O autor (2023).

Com base na matriz de confusão apresentada na TABELA 18 é possível verificar que a confusão entre as classes “Terreno” e “Superfície” foi menor quando comparado ao experimento 01, e as classes “Torre” e “LT” tiveram resultado satisfatório. A classe “Edificações” continuou apresentando nenhum resultado.

TABELA 18 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 01

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	15 924 653	160 170	NaN	0	0
Superfície	204 148	1 081 866	NaN	3 490	0
Edificações	16 691	10 175	NaN	0	0
Torre	1 198	1 392	NaN	15 973	0
LT	75	0	NaN	2 503	25 576

FONTE: O autor (2023).

Quanto as médias das métricas apresentadas na TABELA 18, pode-se concluir que a acurácia e a precisão são altas, a média ficou em 95,77% e 89,95%, o que indica que a grande maioria dos pontos classificados pelo modelo realmente pertence a essa classe. A sensibilidade também é aceitável, cerca de 89.95%, indicando que o modelo identificou a maioria dos pontos que realmente estavam naquelas classes. E o F1-score também ficou satisfatório, aproximadamente 89,48%, sugerindo um bom equilíbrio entre precisão e recall para as classes.

Para a classe “Terreno”, a precisão foi alta, atingindo aproximadamente 98.9%, o que indica que a grande maioria dos pontos classificados como "Terreno" pelo modelo realmente pertence a essa categoria. A sensibilidade também foi alta para essa classe, cerca de 98.6%, indicando que o modelo identificou a maioria dos pontos que realmente eram "Terreno". O F1-score foi elevado, aproximadamente 98.7%, sugerindo um bom equilíbrio entre precisão e recall para esta categoria.

Para a classe “Superfície”, a precisão foi razoável, cerca de 83.9%, o que significa que uma parte significativa dos pontos classificados como "Superfície" pelo modelo pertence a essa categoria. A sensibilidade também é razoável, aproximadamente 86.3%, indicando que o modelo conseguiu identificar uma boa parte dos pontos que realmente eram "Superfície". O F1-score para essa classe é aceitável, aproximadamente 85.1%, mostrando um equilíbrio razoável entre precisão e recall para esta categoria.

Para a classe “Torre”, a precisão foi razoável, aproximadamente 86.1%, o que sugere que o modelo classificou uma parte significativa dos pontos corretamente como "Torre". A sensibilidade foi mais baixa, cerca de 72.7%, indicando que o modelo identificou uma porção menor dos pontos que eram realmente "Torre". O F1-score foi razoável, aproximadamente 78.6%, mostrando um equilíbrio geral razoável entre precisão e recall para esta categoria de objetos.

Para a classe “LT”, a precisão foi alta, cerca de 90.8%, indicando que a grande maioria dos pontos classificados como "LT" pelo modelo realmente pertence a essa categoria. A sensibilidade foi muito alta, 100%, o que significa que o modelo identificou todos os pontos que eram realmente "LT". O F1-score foi também elevado, aproximadamente 95.1%, indicando um excelente desempenho para esta categoria de objetos.

TABELA 19 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E EXPERIMENTO 01 EM PERCENTUAL DECIMAL

Métrica	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	97.81%	85.32%	NaN	99.95%	99.99%	95.77%
Precisão	99.00%	83.90%	NaN	86.05%	90.84%	89.95%
Sensibilidade	98.62%	86.30%	NaN	72.72%	100.00%	89.41%
Especificidade	87.52%	84.40%	NaN	99.99%	99.99%	92.97%
F1score	98.81%	85.08%	NaN	78.82%	95.20%	89.48%

FONTE: O autor (2023).


Em geral, o modelo no experimento 01 parece ter um bom desempenho na identificação das categorias de objetos em “Terreno” e “LT”, com acurácia, precisão, especificidade e sensibilidade muito altos. No entanto, as classes “Superfície” e “Torre” têm um desempenho um pouco menos consistente, com precisões e recalls um pouco mais baixos.

4.2.2 Experimento 02

Apesar da obtenção de uma acurácia elevada de 96,3%, com 85 folhas, destaca-se que este treinamento registrou a maior função de perda, atingindo o valor de 0,004. Se for comparado com os outros quatro treinamentos, conforme documentado na TABELA 17 e FIGURA 82, foi o pior resultado.

A função de perda é uma métrica fundamental que avalia a distância entre as previsões do modelo e os valores reais ou rótulos de treinamento (LANGER et al., 2020; DAVIES, 2012). Quanto maior a perda, maior a discrepância entre as previsões do modelo e os valores reais, evidências que podem ser discutidas com base nos experimentos de Jameela e Sohn (2020), onde a função de perda é empregada para verificar a consistência do layout espacial dos objetos reais sobre os produtos da segmentação de objetos 3D. Este resultado pode ser atribuído a vários fatores, incluindo a possibilidade de influência da aleatoriedade da seleção das amostras de treinamento ou à complexidade intrínseca dos dados e do problema em análise.


FIGURA 66 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 – EXPERIMENTO 04



FONTE: O autor (2023).

A FIGURA 66 apresenta as 85 folhas selecionadas para o treinamento, bem como, a sua aleatoriedade de seleção. Porém os resultados não foram satisfatórios. A FIGURA 67 apresenta a folha CCO_SQT_81 com um desempenho satisfatório, enquanto a folha CCO_SQT_59 exibe um desempenho deficiente dada a mistura de objetos distintos na classe “Superfície” e um notório problema na extração de feições 3D na classe “Torre”. Observa-se que, na folha CCO_SQT_59, houve uma confusão generalizada entre a torre e a vegetação em praticamente todas as instâncias. Os resultados individuais podem ser avaliados no APENDICE C.

FIGURA 67 - NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 02: FOLHA CCO_SQT_81 (ESQUERDA) E FOLHA CCO_SQT_59 (DIREITA)



FONTE: O autor (2023).

A TABELA 20 exibe a matriz de confusão, que detalha como o modelo classificou as diferentes categorias, como Terreno, Superfície, Edificações, Torre e LT, em comparação com os rótulos reais do conjunto de dados. A partir disso, foi possível analisar que teve confusão entre todas as classes, com ênfase na classe “Superfície” e “Terreno”.

TABELA 20 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02
EXPERIMENTO 02

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	17.540.571	262.083	NaN	127.898	4.518
Superfície	106.422	1.030.419	NaN	6.969	402
Edificações	2.002	14.574	NaN	0	0
Torre	2.053	34.266	NaN	79.614	2.364
LT	1.581	3.189	NaN	8.230	20.443

FONTE: O autor (2023).

A TABELA 21 apresenta uma análise do desempenho de um modelo de classificação aplicado ao conjunto de dados 02 durante o experimento 02. Destaca-se que o modelo alcançou uma acurácia de aproximadamente 94,9%, o que sugere um desempenho amplamente satisfatório. As classes "Terreno" e "LT" se destacam com pontuações elevadas em precisão, sensibilidade e F1-score. A classe "Torre" também apresenta uma precisão razoável (63,3%), embora com uma sensibilidade mais baixa, indicando que o modelo pode perder alguns casos positivos. A classe "Superfície" apresenta uma precisão e sensibilidade razoáveis, embora seu F1-score seja ligeiramente inferior, sugerindo um equilíbrio menos ideal entre precisão e sensibilidade. É relevante mencionar que não há dados disponíveis para a classe "Edificações". O modelo do experimento 02 do conjunto 02 teve o pior resultado da classificação, precisando de aprimoramento em experimentos futuros.

TABELA 21 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E
EXPERIMENTO 02

Métricas	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	97,36%	83,47%	NaN	99,04%	99,89%	94,94%
Precisão	97,80%	90,06%	NaN	67,30%	61,13%	79,07%
Sensibilidade	99,37%	76,64%	NaN	35,75%	73,73%	71,37%
Especificidade	74,13%	90,86%	NaN	99,79%	99,93%	91,18%
F1score	98,58%	82,81%	NaN	46,69%	66,84%	73,73%


FONTE: O autor (2023).

4.2.3 Experimento 03

Apesar da obtenção de uma precisão satisfatória de 94,5%, com 79 folhas, destaca-se que este treinamento registrou o maior tempo de aprendizagem, demorando aproximadamente 12 horas. Os ruídos na curva de aprendizagem mostram que o modelo teve dificuldades com os alguns minilotes individuais. Para

estabilizar a curva de aprendizado foram necessárias 20 iterações e para a função de perda 80 iterações, conforme indicações na FIGURA 68.


FIGURA 68 - PROGRESSO DE EXPERIMENTO 03 DO CONJUNTO DE DADOS 02



FONTE: O autor (2023).

A função de perda auxiliou na identificação do porquê do tempo excessivo de aprendizado, e considerando que a área selecionada possui características bem diferentes das anteriores, conforme apresentado na FIGURA 69. Com a complexidade inerente dos dados, é normal que tenha um aumento de tempo para o modelo se ajustar aos dados. Todos os gráficos de monitoramento de treinamento estão apresentados no APENDICE G.


FIGURA 69 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 – EXPERIMENTO 03



FONTE: O autor (2023).

A FIGURA 70 apresenta dois exemplos de resultado da segmentação. A imagem da esquerda mostra que alguns pontos de vegetação não foram classificados corretamente e a imagem da direita apresenta uma classificação satisfatória, com poucos pontos classificados erroneamente. Apesar do resultado insatisfatório da classificação da classe “Superfície” que poderá ser interpretado visualmente pela imagem da FIGURA 70 no item do Experimento 04, as “LT’s” e “Torres” tiveram resultado satisfatório.

FIGURA 70 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 03: FOLHA CCO_SQT_35 (ESQUERDA – PIOR RESULTADO) E FOLHA CCO_SQT_37 (DIREITA – MELHOR RESULTADO)



FONTE: O autor (2023).

A matriz de confusão mostra como o modelo, classificou diferentes categorias (Terreno, Superfície, Edificações, Torre e LT) em comparação com os rótulos reais do conjunto de dados. É perceptível que classificou principalmente a classe "Torres" e "LT's" corretamente, com muitos verdadeiros positivos e poucos falsos negativos, conforme apresentado na TABELA 22.

TABELA 22 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02
EXPERIMENTO 03

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	29 422 689	0	NaN	0	0
Superfície	684 965	42 924	NaN	0	0
Edificações	106	0	NaN	0	0
Torre	1 879	0	NaN	17 929	0
LT	1 300	0	NaN	2 705	89 607

FONTE: O autor (2023).

As métricas de desempenho, apresentada na TABELA 23, mostram a acurácia geral do modelo com aproximadamente 79,9%, indicando um desempenho razoável, mas não excelente. A categoria "Terreno" tem uma precisão perfeita, mas a categoria "Superfície" tem uma precisão muito baixa, sugerindo problemas na identificação dessa classe. A sensibilidade da categoria "Superfície" é alta, mas sua precisão é baixa, o que indica um grande número de falsos positivos. As categorias "Edificações" e "LT" têm um F1-score razoável, enquanto a categoria "Superfície" tem um F1-score muito baixo, refletindo o desequilíbrio entre precisão e sensibilidade.

TABELA 23 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E
EXPERIMENTO 03

Métrica	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	97,73%	22,02%	0,00%	99,99%	99,99%	79,93%
Precisão	100,00%	5,90%	0,00%	90,51%	95,72%	73,03%
Sensibilidade	97,71%	100,00%	0,00%	86,89%	100,00%	96,15%
Especificidade	100,00%	18,01%	0,00%	99,99%	99,99%	79,50%
F1score	98,84%	11,14%	0,00%	88,67%	97,81%	74,12%

FONTE: O autor (2023).

Em resumo, o modelo parece ter um desempenho aceitável em algumas categorias, como "Terreno" e "LT", mas enfrenta desafios significativos na identificação da categoria "Superfície", com muitos falsos positivos e baixa precisão. É importante considerar que o objetivo principal é uma boa classificação das LTs e Torres, portanto nessas classes o treinamento e segmentação apresentaram resultados satisfatórios.

A acurácia para a classe "Torre" é alta, com um valor de 99,985%. Isso indica que a maioria das previsões para esta classe está correta. A precisão, que mede a proporção de verdadeiros positivos em relação ao total de previsões positivas, é de 90,514%. Evidenciando que a maioria dos pontos classificados como "Torre" estão corretos, mas ainda existe alguma margem para falsos positivos. A sensibilidade da

classe "Torre," é de 86,891%. Indicando que o modelo não identifica todas as torres, o que pode resultar em falsos negativos. E a especificidade é alta, com um valor de 99,994%, mostrando que o modelo é eficaz em evitar falsos positivos para a classe "Torre."

A acurácia para a classe "LT" é muito alta, com um valor de 99,986%. Indicando que a maioria das previsões para esta classe está correta. A precisão é de 95,722%, o que sugere que a maioria das classes classificadas como "LT" está correta, mas ainda existe alguma margem para falsos positivos. A sensibilidade é de 100%, o que significa que o modelo identifica todas as instâncias reais da classe "LT." A especificidade é alta, com um valor de 99,986%, indicando que o modelo é eficaz em evitar falsos positivos para a classe "LT."

4.2.4 Experimento 04

O resultado do experimento 04 com 81 folhas, foi satisfatória com 98,4% de acurácia e 0,297 de perda. Destaca-se que este treinamento possuiu seleção aleatória de folhas, conforme visualização da FIGURA 71. Essa seleção foi realizada para retirar qualquer tipo de viés nos dados de treinamento, que afetasse a capacidade do modelo de LiDAR com variações e situações não consideradas durante o treinamento.


FIGURA 71 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 – EXPERIMENTO 04



FONTE: O autor (2023).

A FIGURA 72 indicou dois resultados de classificações problemáticas. Na imagem da esquerda, a folha foi classificada erroneamente em todas as classes, exceto na classe "Terreno." Por outro lado, na imagem da folha à direita, todas as classes estão incorretas. Isso indica um desempenho substancialmente deficiente do modelo de classificação, com falhas em identificar corretamente as classes das folhas, o que pode ser um desafio significativo para a aplicação prática desse modelo em cenários reais. Esses problemas destacam, que em estudos futuros, a necessidade de uma análise mais aprofundada e melhorias no algoritmo de classificação, aquisição de dados ou pré-processamento das imagens para aprimorar a precisão do modelo.

FIGURA 72 – NUVEM DE PONTOS RESULTANTES DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 02 - EXPERIMENTO 04: FOLHA CCO_SQT_167 (ESQUERDA) E FOLHA CCO_SQT_198 (DIREITA)



FONTE: O autor (2023).

A TABELA 24 , que representa a matriz de confusão para a classificação no Conjunto de Dados 02 durante o Experimento 04, revela o desempenho do modelo de classificação. Destacam-se observações como a eficácia na identificação da classe "Terreno" com um alto número de verdadeiros negativos, desafios na distinção entre as classes "Superfície" e "Edificações" com um número significativo de falsos positivos em "Superfície," e notáveis confusões entre as classes "Torre" e "LT" com falsos positivos e falsos negativos. Além disso, a presença de valores "NaN" denota a falta de previsões ou instâncias reais em algumas classes. Essa análise da matriz de confusão foi para orientar a otimização do modelo, considerando estratégias como balanceamento de classes, ajuste de hiperparâmetros e validação cruzada.

TABELA 24 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02
EXPERIMENTO 04

Classe	Terreno	Superfície	Edificações	Torre	LT
Terreno	12.452.873	946.654	NaN	0	2
Superfície	136.107	670.239	NaN	13	0
Edificações	17.331	15.601	NaN	0	0
Torre	1.259	1.219	NaN	9.129	9
LT	551	525	NaN	1.494	28.518

FONTE: O autor (2023).

A TABELA 25 apresenta as várias métricas de desempenho para cada classe específica e uma média total das métricas. Estão sendo discutidas as métricas de acurácia, precisão, sensibilidade, especificidade e F1-score.

A classe “Terreno” possui precisão de 92,93%, o que indica que o modelo fez um bom trabalho ao evitar falsos positivos para esta classe. A sensibilidade com 98,76% indica que o modelo é bom em identificar instâncias reais desta classe. A acurácia geral ficou com 92,27%.

A classe “Superfície” possui precisão moderada de 83,11%, sugerindo que o modelo evita falsos positivos, mas pode cometer alguns erros. A sensibilidade é baixa 41,01% indicando que o modelo não é tão bom em identificar instâncias reais desta classe, bem como, a acurácia que está com 55,61%

A classe “Torre” possui precisão moderada 78,59%, o que sugere que o modelo evita alguns falsos positivos, mas não todos. A sensibilidade é alta 85,83%, indicando que o modelo é eficaz em identificar instâncias reais desta classe. A acurácia geral para esta classe é muito alta 99,97%.

Para a classe “LT (Linha de Transmissão)”, a precisão ficou alta 91,73, indicando que o modelo faz um bom trabalho ao evitar falsos positivos para esta classe. A sensibilidade é muito alta 99,96%, indicando que o modelo é altamente eficaz em identificar instâncias reais desta classe e a acurácia geral para esta classe é muito alta 99,98.

TABELA 25 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 02 E EXPERIMENTO 04

Métrica	Terreno	Superfície	Edificações	Torre	LT	Total
Acurácia	92.27%	55.61%	NaN	99.97%	99.98%	86.96%
Precisão	92.94%	83.12%	NaN	78.59%	91.73%	86.59%
Sensibilidade	98.77%	41.01%	NaN	85.83%	99.96%	81.39%
Especificidade	42.78%	83.87%	NaN	99.98%	99.98%	81.66%
F1score	95.76%	54.92%	NaN	82.05%	95.67%	82.10%

FONTE: O autor (2023).

O modelo apresentou um bom desempenho, especialmente para as classes "Torre" e "LT". No entanto, para a classe "Superfície", a sensibilidade é relativamente baixa, sendo inferior a 50% de assertividade (aproximadamente 41%), o que significa que o modelo pode estar perdendo alguns casos reais dessa classe.

4.3 INTEGRAÇÃO CONJUNTO DE DADOS 01 E 02 COM 3 CLASSES


Após realizar uma análise detalhada dos conjuntos de dados 01 e 02, bem como avaliar os quatro resultados de treinamento, foi identificado que algumas classes tiveram desempenho menos satisfatório no processo de classificação. Com base nessa análise, decidiu-se excluir essas classes menos satisfatórias para um novo treinamento e teste de generalização do modelo. Essa abordagem de refinamento do conjunto de classes visa melhorar a eficácia geral do modelo, concentrando-se nas classes onde o desempenho é mais robusto.

Ao excluir as classes menos satisfatórias, o novo treinamento foi direcionado para as classes restantes, permitindo que o modelo se especialize em distinguir essas categorias com maior precisão. Essa estratégia tem o potencial de aumentar a qualidade das previsões para as classes retidas, uma vez que o modelo terá mais recursos para aprender e se adaptar a essas categorias específicas.

4.3.1 Treinamento único

O perfil dos resultados da classificação das três classes "Superfície", "Torre" e "LTs" está apresentado na FIGURA 73. A partir dessa imagem é possível ter uma representação visual do desempenho do modelo. Os resultados mostram que o desempenho foi considerado satisfatório, indicando que o modelo é capaz de distinguir e classificar com precisão essas três classes de interesse específicas.

FIGURA 73 – PERFIL DO RESULTADO DA SEGMENTAÇÃO DO CONJUNTO DE DADOS 01 – EXPERIMENTO 04




FONTE: O autor (2023).

De acordo com o GRÁFICO 3, o monitoramento do processo de treinamento, teve início com uma taxa de precisão de aproximadamente 40%. Ressalta-se que esse valor é frequentemente observado em cenários de transferência de aprendizado, nos quais um modelo pré-treinado é adaptado e refinado para uma tarefa específica.

Na transferência de aprendizado, um modelo que já foi treinado em um conjunto de dados amplo e diversificado é reutilizado como ponto de partida, porém isso não foi utilizado nessa pesquisa. Neste sentido, o monitoramento indica que o modelo vai convergir com menos iterações.

Ao longo do treinamento, foi possível perceber que o modelo melhorou gradualmente e finalizou em 30 épocas e 30 iterações com resultado de 99,43%. Com isso, espera-se que o modelo gerado se adapte aos dados específicos da tarefa.

GRÁFICO 3 - PRECISÃO E FUNÇÃO DE PERDA DO EXPERIMENTO DO CONJUNTO DE DADOS 01 E 02 COM 3 CLASSES.



FONTE: O autor (2023).

A TABELA 26 é uma matriz de confusão que revela o desempenho da classificação no Conjunto de Dados 02 durante o Experimento 04 para as classes "Superfície," "Torre" e "LT." Ela indica que o modelo tem um desempenho satisfatório na identificação das classes "Superfície" e "LT," com altas contagens de verdadeiros positivos e baixos falsos positivos. No entanto, a classe "Torre" também é identificada corretamente, mas com alguns falsos positivos.

As principais confusões, conforme é possível verificar na folha FOC-SEC_64 do APENDICE C, são referentes às conexões dos cabos às estruturas. Isso se deve à classe mais próxima do ponto classificado incorretamente. Como é um algoritmo de busca das características dos centroides de uma nuvem esparsa para posteriormente ser aplicado numa nuvem densa, há uma confusão nesses limites. Porém, os resultados apresentados ficaram superiores ao anterior com 5 classes.

TABELA 26 – MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO CONJUNTO DE DADOS 02 EXPERIMENTO 04

Classe	Superfície	Torre	LT
Superfície	3.278.981	12.817	951
Torre	0	134.498	523
LT	1	6.097	161.545

FONTE: O autor (2023).

A TABELA 27, formada a partir dos dados das tabelas anteriores, apresenta métricas de desempenho para cada classe específica e uma média total das métricas. As métricas incluem acurácia, precisão, sensibilidade, especificidade, F1score e IoU. O IoU que mede a sobreposição entre as máscaras previstas e reais (JHALDIYAL; CHAUDHARY, 2023). Dessa forma, quanto maior o valor de IoU, melhor o modelo está em prever as áreas corretas da classe em relação às áreas reais (AMISSE; JIJÓN-PALMA; CENTENO, 2021).

A classe “Superfície” possui a precisão de 98,52%, considerada satisfatória, indicando que o modelo faz um bom trabalho em evitar falsos positivos para esta classe. A sensibilidade é 1,0, o que significa que o modelo identifica todas as instâncias reais desta classe e com acurácia geral de 99,616%. A classe “Torre” também apresenta valores de precisão, sensibilidade, acurácia bem satisfatórios, com 99,54%, 87,67% e 99,49% respectivamente. A classe “LT” com 97,73%, 99,09%, 99,79% para os valores de precisão, sensibilidade, acurácia, também foram considerados satisfatórios.

Todos os resultados indicam que o modelo é capaz de realizar classificações assertivas e identificar instâncias das classes com eficácia, considerando as métricas de F1score com 99,79%, 93,26% e 97,71%, mostram que o modelo possui um equilíbrio entre sensibilidade e precisão e minimiza os falsos positivos.

Para a classe "Superfície", o IoU é de 98,52%, o que indica uma boa correspondência entre as áreas previstas e reais da classe. Para a classe "Torre", o IoU é de 87,78%, sugerindo uma sobreposição adequada entre as áreas previstas e reais da classe, embora seja um pouco menor em comparação com "Superfície". Para a classe "LT", o IoU é com um valor de 97,14%, indica uma excelente correspondência entre as áreas previstas e reais da classe "LT".


TABELA 27 - MÉTRICAS DE DESEMPENHO POR CLASSE CONJUNTO DE DADOS 01 e 02 E EXPERIMENTO UNICO

Métrica	Superfície	Torre	LT	Total
Acurácia	99.62%	99.46%	99.79%	99.62%
Precisão	99.58%	99.61%	96.36%	98.52%
Sensibilidade	100.00%	87.67%	99.10%	95.59%
Especificidade	95.56%	99.99%	99.82%	98.45%
F1score	99.79%	93.26%	97.71%	96.92%
IoU	98.52%	87.78%	97.15%	94.48%

FONTE: O autor (2023).

A Figura 72 apresenta o resultado da análise da folha "FOC_SEC_03" e destaca os pontos onde ocorreram confusões entre as classes. A imagem mostra que as características geométricas dos "Cabos" próximos às "Torres" são a fonte desse erro de classificação. No entanto, é observado que a classe "Superfície" foi bem definida e os pontos de "Torre" próximos à "Superfície" foram classificados de forma assertiva. Essas observações indicam que o modelo está demonstrando uma capacidade satisfatória de distinguir a classe "Superfície," mas está tendo dificuldade em separar efetivamente os "Cabos" das "Torres" devido à sua proximidade e características semelhantes.

FIGURA 74 – RESULTADO DA FOLHA FOC_SEC_03 DO EXPERIMENTO UNICO



FONTE: O autor (2023).

4.4 IDENTIFICAÇÃO DAS TORRES

4.4.1 Conjunto de dados 01 com 5 classes.

4.4.1.1 Experimento 01

Neste estudo, foram conduzidas análises para identificação e caracterização das torres no experimento 01. O primeiro resultado dessa análise trata-se da identificação das torres, com ênfase na determinação do número de torres existentes. Conforme 3.3.6, apenas a classe "Torre" com mais de 2500 pontos foi analisada.

Verificou-se que nenhuma torre deixou de ser classificada no experimento 01. Adicionalmente, foram obtidas informações detalhadas sobre a posição bidimensional dos centroides das torres e calculada a diferença pontual entre as posições calculadas e as verdadeiras. A TABELA 28 apresenta as coordenadas das torres do experimento 01 com as posições X e Y calculadas e as verdadeiras e suas respectivas diferenças.

TABELA 28 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 01


Folha	X calculado	Y calculado	X verdadeiro	Y verdadeiro	Dif (m)
FOC_SEC_63	289 460.18	7 176 608.61	289 460.39	7 176 608.41	0.29
FOC_SEC_74	289 753.17	7 176 472.93	289 752.53	7 176 472.32	0.87
FOC_SEC_81	289 933.76	7 176 388.37	289 933.68	7 176 387.99	0.38

FONTE: O autor (2023).

Apesar da classificação insatisfatória na folha FOC_SEC_74, conforme evidenciado pelos resultados apresentados na FIGURA 57, é notável que os poucos pontos classificados como "Torre" conseguiram detectar e posicionar essa torre específica com um erro de apenas 0,87 metros. As folhas FOC_SEC_63, e FOC_SEC_81 tiveram um desempenho satisfatório, visto que, apresentaram diferenças inferiores a 0,50 metros quando comparadas com os valores verdadeiros.

Este desempenho é particularmente significativo para projetos de linhas de transmissão, onde apesar da precisão da localização das torres ser importante, existe uma margem de até 1 metro que pode ser atingida. A FIGURA 75 apresenta as torres identificadas com suas localizações calculadas e verdadeiras.

FIGURA 75 – CENTROIDES CALCULADOS E VERDADEIROS DAS TORRES DO EXPERIMENTO 01






FONTE: O autor (2023).

Para diferenciar os dois tipos de torres existentes nessa pesquisa, foram utilizadas as matrizes de autovetores. Os resultados apresentando os autovetores constam no QUADRO 6. A partir dele é possível verificar que a partir da direção dos vetores, consegue-se diferenciar as torres em todos os casos. Como a torre FOC_SEC_74 teve um resultado insatisfatório na segmentação, para o cálculo dos autovetores não foi possível distinguir o tipo de torre.

No QUADRO 6 ainda é possível observar a questão das conexões dos cabos às estruturas. Em trabalhos futuros, há a possibilidade de aprofundar a análise do ponto de conexão, denominado "Cabo na Cadeia", que também desempenha um papel significativo na caracterização das torres.

QUADRO 6 – AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 01.

Folha/Tipo	Autovetores	Imagem
FOC_SEC_63 1	-0.0686 0.4247 0.9027 -0.1031 0.8970 -0.4298 0.9923 0.1225 0.0178	
FOC_SEC_74 Erro	Menos que 3000 pontos, não tem como distinguir.	
FOC_SEC_81 1	0.0130 0.4417 0.8970 0.0090 0.8970 -0.4419 0.9999 -0.0138 -0.0077	

FONTE: O autor (2023).

4.4.1.2 Experimento 02


A TABELA 29 apresenta as coordenadas X e Y das torres do experimento 02 com a posição X e Y calculada e a verdadeira. O resultado foi considerado satisfatório, visto que a diferença posicional foi de 0,14 metros.

TABELA 29 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 02

Folha	X calculado	Y calculado	X verdadeiro	Y verdadeiro	Dif (m)
FOC_SEC_03	288944.924	7176887.066	288944.845	7176886.948	0.14

FONTE: O autor (2023).

FIGURA 76 – CENTROIDES CALCULADOS E VERDADEIROS DA TORRES DO EXPERIMENTO 02.



FONTE: O autor (2023).

Neste experimento, os autovetores também convergiram para o tipo de torre1. O resultado apresentando os autovetores está apresentado no QUADRO 7 e nas marcações na cor laranja.

QUADRO 7 - AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 02.

Folha/Tipo	Autovetores			Imagem
FOC_SEC_03 1	0.0036 -0.0133 0.9999	0.5047 0.8633 0.0097	0.8633 -0.5046 -0.0098	

FONTE: O autor (2023).

4.4.1.3 Experimento 03






Esta tabela apresenta as coordenadas X e Y das torres identificadas no Experimento 03, bem como as coordenadas verdadeiras correspondentes. A coluna "Dif (m)" representa a diferença em metros entre as coordenadas calculadas e as coordenadas verdadeiras das torres. Esses dados são referentes às folhas FOC_SEC_38, FOC_SEC_44, FOC_SEC_63, FOC_SEC_74 e FOC_SEC_81. Nesse treinamento das 5 torres existentes, todas foram identificadas e a diferença máxima do centroide calculado em relação ao verdadeiro foi de 0,51 metros, evidenciando assim, conforme apresentado na TABELA 30 o resultado satisfatório na detecção.

TABELA 30 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 03

Folha	X calculado	Y calculado	X verdadeiro	Y verdadeiro	Dif (m)
FOC_SEC_38	289 905,07	7 176 440,23	289 904,84	7 176 440,03	0.31
FOC_SEC_44	288 936,71	7 176 852,15	288 936,72	7 176 852,17	0.10
FOC_SEC_63	289 460,38	7 176 608,28	289 460,56	7 176 608,24	0.19
FOC_SEC_74	289 752,00	7 176 472,52	289 752,49	7 176 472,45	0.51
FOC_SEC_81	289 933,66	7 176 388,22	289 933,63	7 176 388,05	0.17

FONTE: O autor (2023).






QUADRO 8 - CENTROIDE CALCULADOS E VERDADEIROS DA TORRES DO EXPERIMENTO 03.

FOC_SEC_38	FOC_SEC_44	FOC_SEC_63	FOC_SEC_81	FOC_SEC_74
				

FONTE: O autor (2023).

No QUADRO 9 estão apresentados os tipos das torres obtidos a partir da matriz de autovetores das folhas. Além de todas as torres terem sido detectadas, todas foram identificadas com o tipo correto. As folhas FOC_SEC_44, FOC_SEC_63 e FOC_SEC_81 possuem a mesma descrição em relação as direções, ou seja, fortemente alinhadas com os eixos X e Z com exceção da folha FOC_SEC_74 que está fortemente alinhada com os eixos X e Y.

QUADRO 9 - AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 03

Folha/Tipo	Autovetores	Imagem
FOC_SEC_38 1	0.0116 0.5220 0.8529 -0.0164 0.8529 -0.5218 0.9998 0.0079 -0.0185	
FOC_SEC_44 1	-0.0157 0.3691 0.9293 -0.0562 0.9276 -0.3694 0.9983 0.0580 -0.0062	
FOC_SEC_63 1	-0.0638 0.4313 0.9000 -0.1027 0.8942 -0.4358 0.9927 0.1202 0.0127	
FOC_SEC_74 2	0.0152 0.9957 0.0917 -0.0144 -0.0915 0.9957 0.9998 -0.0165 0.0130	
FOC_SEC_81 1	0.0084 0.4398 0.8981 -0.0105 0.8981 -0.4397 0.9999 0.0058 -0.0122	

FONTE: O autor (2023).

4.4.1.4 Experimento 04




A TABELA 31 apresenta dados relativos à identificação de torres em três locais diferentes. Ela inclui coordenadas calculadas (X e Y) das torres, bem como as coordenadas verdadeiras e a diferença em metros entre elas, permitindo avaliar a precisão da identificação das torres em relação às posições reais. A partir dessa, é possível visualizar que a folha FOC_SEC_81 apresentou uma diferença de 1.81 metros, que a visualizando o QUADRO 10 é possível ver que a torre está incompleta.

TABELA 31 - CARACTERÍSTICAS DAS TORRES IDENTIFICADAS NO EXPERIMENTO 04

Folha	X calculado	Y calculado	X verdadeiro	Y verdadeiro	Dif (m)
FOC_SEC_44	288 936,83	7 176 852,36	288 936,72	7 176 852,17	0.21
FOC_SEC_63	289 460,30	7 176 608,18	289 460,56	7 176 608,24	0.26
FOC_SEC_81	289 934,07	7 176 389,32	289 933,63	7 176 388,05	1.31

FONTE: O autor (2023).

QUADRO 10 - AUTOVETORES DAS FOLHAS DO CONJUNTO 01 - EXPERIMENTO 04

Folha/Tipo	Autovetores			Imagem
FOC_SEC_44 1	0.0301 0.0508 0.9983	0.4413 0.8954 -0.0589	0.8968 -0.4423 -0.0046	
FOC_SEC_63 1	-0.0669 -0.0894 0.9937	0.4237 0.8992 0.1094	0.9033 -0.4284 0.0223	
FOC_SEC_81 1	0.1035 0.1218 0.9871	0.4009 0.9032 -0.1535	0.9103 -0.4116 -0.0447	

FONTE: O autor (2023).

5 CONCLUSÕES

Durante o desenvolvimento dessa pesquisa, foram apresentadas todas as etapas desde o levantamento a laser com um Sistema LiDAR até a detecção e identificação das torres. O estudo foi realizado ao longo de linhas de transmissão no estado do Paraná, principalmente cobrindo áreas rurais, utilizando dados obtidos em projetos de transmissão de energia.

As áreas mapeadas durante o levantamento a laser apresentam uma ampla gama de características geoespaciais, como variações na elevação, tipos de vegetação, distâncias entre torres e diferentes configurações de linha de transmissão. Essa diversidade ajuda a compreensão da eficácia dos métodos de classificação, detecção e identificação em diferentes contextos.

Levantamentos realizados com LiDAR embarcados em RPAS, apesar de possuírem uma cobertura limitada e serem direcionados para aplicações específicas, apresentam uma densidade de pontos 10 vezes superior àquela obtida por sistemas LiDAR instalados em aeronaves, possibilitando a aquisição de mais detalhes geométricos. Foram utilizados dois sistemas LiDAR, o LiAiR V50 e o LiAir V70. Percebeu-se uma melhora significativa na transição entre as versões, uma delas sendo a inclusão de mais um retorno de pulso no LiAir V70, o que corrigiu problemas de absorção do pulso em superfícies escuras, como o asfalto, e a penetração do pulso até o solo quando há obstáculos, como vegetação e estruturas, como torres. Para o setor de energia, o uso de LiDAR a bordo de RPAS permite mapear as estruturas de suporte das linhas de transmissão e os cabos com maior precisão.

Embora, o LiDAR apresente muitas vantagens, ele também possui desafios, sendo o principal manipular nuvens de pontos com alta densidade. Este trabalho apresentou uma metodologia para segmentação semântica de nuvem de pontos com o algoritmo PointNet++ direcionado para detectar e classificar elementos de linhas transmissão de energia elétrica, utilizando dados oriundos de um sistema LiDAR embarcado em RPAS.

Para contornar o problema da grande quantidade de pontos obtidos na varredura da área de domínio de linhas de transmissão, foi proposta uma estratégia de criação de blocos com densidade de pontos padrão para gerenciar memória e espaço em disco. Essas estratégias, aplicadas tanto na entrada quanto na saída de dados na rede neural, permitem o processamento de forma incremental. Enquanto os

blocos podem ser processados separadamente no início, a operação interna esparsa das redes neurais, como a PointNet++, contribui para economizar recursos computacionais. No entanto, na saída, transformar os resultados de volta em uma nuvem de pontos densa não foi uma tarefa simples, pois exigiu um desempenho computacional significativo. Portanto, destaca-se que para esta pesquisa foi utilizado um computador AMD Ryzen 5 com 64 GB de RAM, 4 TB de armazenamento interno e placa de vídeo NVIDIA RTX 3060 12GB, esta configuração foi suficiente para a obtenção dos resultados apresentados.

Com as estratégias e recursos computacionais apresentados anteriormente, foram realizados 26 treinamentos para definição de hiperparâmetros que tivessem o melhor custo-benefício, ou seja, que fosse possível obter um desempenho satisfatório da segmentação semântica e o treinamento não fosse extremamente demorado. Alguns treinamentos demoraram 3 dias e esses foram descartados. Além dos diferentes hiperparâmetros, foram testadas algumas configurações de raio e número de vizinhos mais próximos para a predição. Constatou-se que, mesmo pequenas variações dos parâmetros tiveram grande influência nos resultados. Os pesos também representaram um elemento importante dentro do processo de segmentação e classificação. A escolha de pesos iniciais apropriados acelera a etapa de aprendizado, bem como, diminui a chance de sobreajuste.

A escolha da rede neural PointNet++ foi justificada pelo fato de ser uma rede consolidada para o processamento de nuvens de pontos 3D, sem a necessidade de converter esses pontos em imagens ou voxels. Com origem em 2017, o uso desta rede acumulou um volume considerável de trabalhos na literatura. Embora os experimentos relatados na literatura se concentrem na análise de objetos mais simples e isolados, neste trabalho foi constatado que a PointNet++ pode ser usada para processar e analisar uma nuvem de pontos oriunda de levantamentos LiDAR desde RPAS por terem uma alta densidade de pontos. Adicionalmente, a invariância à permutação, o agrupamento hierárquico, a redução da dimensionalidade torna uma rede viável, mesmo tendo outras redes, como o KPConv apresentando resultados melhores. Por ser uma rede conhecida, muitos algoritmos de otimização já estão disponíveis para parametrização.

As classes empregadas neste estudo foram escolhidas com base em projetos de linhas de transmissão, compreendendo as classes de terreno, edificações, cabos e torres, juntamente com uma classe denominada "superfície," que englobou todas as

outras classes, com exceção das já mencionadas. Experimentos foram realizados usando dois tipos diferentes de sensores, varrendo diferentes áreas, com densidade de pontos diferentes e com capacidade diferente de coleta de pontos próximos do chão. Para avaliação dos resultados foi usada a validação cruzada usando um conjunto de verificação em cada caso. A validação desempenhou um papel importante na avaliação e escolha do grupo de dados que melhor se adequava à generalização do problema.

As métricas empregadas nos treinamentos com 5 classes incluíram: precisão, acurácia, especificidade, sensibilidade e F1-score. Com base nessas métricas, constatou-se que melhores resultados podem ser obtidos com o sensor Sistema LiAir 70, e que é importante o balanceamento do número de amostras por classe. A acurácia teve uma média de 86,61%, a precisão 81,85%, a sensibilidade de 79,41%, a especificidade de 88,34% e o F1-score de 78,34%.

Por outro lado, se forem analisadas apenas as classes de interesse que são cabos e torres separadamente, o F1-score das torres é razoável, com 72,38%, porém dos cabos é bem satisfatória, com 93,06%. O menor desempenho no caso de torres se deve à confusão da base da torre com a classe superfície, principalmente quando ocorre vegetação na base da torre. Considerando estas duas classes, o melhor resultado tem acurácia de 99,43%, precisão de 75,18%, sensibilidade de 75,32%, especificidade de 99,71% e F1-score de 75,25% para as torres e acurácia de 99,73%, precisão de 81,97%, sensibilidade de 99,98%, especificidade de 99,73% e F1-score de 90,09% para os cabos. Destacando que os cabos tiveram um bom desempenho pela não conexão posicional em relação as outras classes. É importante ressaltar que, embora as classes de maior interesse sejam cabos e torres, todas as classes foram avaliadas de forma abrangente, garantindo uma análise completa do modelo em diversos contextos.

Considerando todos os experimentos realizados de maneira geral, o principal desafio em relação ao treinamento foi a questão do desbalanceamento do número de pontos por classe. Neste sentido, o PointNet++ ofereceu mais flexibilidade para abordar esse desafio. Com sua capacidade de agrupar hierarquicamente e processar subgrupos de pontos, o PointNet++ ajudou a dar maior ênfase a áreas de interesse e classes menos representadas. Além disso, o ajuste de pesos inicial baseado no número de pontos por classe, conseguiu fazer com que o treinamento fosse mais

rápido e equilibrado, melhorando assim a capacidade do modelo de lidar com classes desbalanceadas de maneira satisfatória.

A classificação do tipo de torre é relevante num projeto de linhas de transmissão de energia, pois influencia na capacidade de carga das torres, no dimensionamento dos cabos, na resistência a condições climáticas e na eficiência energética. Em virtude disso, após a segmentação da nuvem de pontos, a detecção do centroide e a classificação do tipo da estrutura foram realizados a partir de ferramentas estatísticas aplicadas diretamente aos pontos. Nos quatro experimentos do conjunto de dados 01, os resultados foram satisfatórios, com 100% na detecção e 91,66% na identificação.

Para trabalhos futuros e superação de desafios encontrados, há diversas direções de pesquisa que podem ser consideradas. Uma delas é o aprimoramento das arquiteturas de redes neurais, baseadas no PointNet++, com a incorporação de técnicas de aprendizado profundo mais recentes e o desenvolvimento de modelos personalizados que possam lidar com o desbalanceamento de classes de forma mais eficaz.

Além disso, estratégias de customização em pós-processamento dos dados LiDAR em softwares proprietários antes dos treinamentos, bem como, o próprio refinamento dos resultados nesses softwares, podem ser exploradas para melhorar a precisão das classificações. Adicionalmente, o estudo da segmentação dos componentes da estrutura da torre é um assunto que deve ser explorado. Este foco mais específico na segmentação dos componentes individuais das torres pode proporcionar uma compreensão mais detalhada da sua geometria e construção, contribuindo assim para uma análise mais precisa das estruturas de transmissão de energia elétrica.

Este estudo oferece uma série de vantagens significativas para o setor elétrico. Ao aprimorar a detecção e identificação de torres e cabos em linhas de transmissão de energia elétrica através do uso de tecnologias avançadas como o LiDAR e técnicas de segmentação semântica, as empresas do setor podem obter uma compreensão mais precisa e abrangente da infraestrutura de suas redes de energia. Isso permite uma melhor gestão do sistema elétrico, incluindo a identificação precoce de possíveis problemas de manutenção, a otimização do planejamento de expansão da rede e a melhoria da eficiência operacional. Além disso, a aplicação dessas metodologias pode contribuir para a redução de custos operacionais e de manutenção, bem como para o aumento da segurança e confiabilidade do

fornecimento de energia elétrica para a população. Em última análise, essas melhorias resultam em um setor elétrico mais resiliente, sustentável e preparado para enfrentar os desafios do futuro.

A expansão e compartilhamento desse conhecimento entre pesquisadores e profissionais da área deve ser contínuo para impulsionar o avanço contínuo do setor elétrico. Ao compartilhar as metodologias desenvolvidas e os resultados obtidos, abre-se espaço para a colaboração interdisciplinar e o avanço do conhecimento científico. Essa troca de informações e experiências não apenas enriquece o corpo de conhecimento existente, mas também inspira novas pesquisas e descobertas. Além disso, ao estabelecer parcerias entre universidades e empresas do setor elétrico, a academia pode se beneficiar do acesso a dados e recursos reais, permitindo a realização de estudos mais aplicados e relevantes. Dessa forma, a colaboração entre academia e indústria impulsiona a inovação e o progresso científico, contribuindo para o avanço não só do setor elétrico, mas também de diversas áreas do conhecimento.

5.1 CONTRIBUIÇÕES DA TESE

A importância para a pesquisa científica se dá com o avanço da indústria de energia, especialmente no que se refere à inovação em metodologias que aumentem o conhecimento em processos automatizados e auxiliem no monitoramento das redes elétricas. A necessidade de otimizar a infraestrutura elétrica é uma preocupação crescente e este tema possui poucos estudos publicados.

Esta tese servirá de incentivo para que outros pesquisadores aprimorem os resultados existentes e desenvolvam novas abordagens com base nos estudos e descobertas apresentados. Esse compartilhamento de informações contribuirá para o avanço contínuo da pesquisa e promoverá a inovação dentro do campo.

No campo do aprendizado profundo, combinando tecnologias como LiDAR e RPAS, os desafios persistem, mas à medida que mais estudiosos se dedicam a esse tópico, soluções emergem com maior rapidez. A colaboração e a disseminação do conhecimento são importantes no desvendamento desses desafios complexos. À medida que a comunidade de pesquisadores e profissionais cresce nessa área, são esperados avanços significativos em eficiência, precisão e aplicação dessas tecnologias na indústria de energia e em diversos outros setores. A pesquisa

colaborativa e o compartilhamento de resultados são a chave para desbloquear o potencial total dessas tecnologias e beneficiar a todos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALALWAN, N., ABOZEID, A. e ELHABSHY, A. **A Efficient 3D Deep Learning Model for Medical Image Semantic Segmentation**. Arábia Saudita. Elsevier, 2020.vol. 60.
- AMISSE, C; JIJÓN-PALMA, M. E.; CENTENO, J.A.S. **Pedestrian Segmentation from Complex Background Based On Predefined Pose Fields and Probabilistic Relaxation**. Boletim de Ciências Geodésicas, v. 27, n.3, 2021.
- ANDRADE, A.F. **Integração de Variáveis Espectrais e Forma na Classificação de Imagens de Alta Resolução Utilizando Redes Neurais**. Curitiba, 2003.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Sistemas Elétricos de Potência**. ABNT NBR 5460: 2000.
- AXELSSON, P. **Processing of laser scanner data-methods and algorithms**. ISPRS Journal of Photogrammetry and Remote Sensing, v. 53, p. 1-6, 1998
- BAHIA Secretaria do Meio Ambiente e Recursos Hídricos. SEMARH **Recomposição florestal de Matas Ciliares**. Salvador.Gráfica Print Folhes, 2007. 3. vol. 1.
- BALLOUCH, Z.; HAJJI, R.; POUX, F.; KHARROUBI, A.; BILLEN, R. **A Prior Level Fusion Approach for the Semantic Segmentation of 3D Point Clouds Using Deep Learning**. *Remote Sensing*, v. 14, n. 14, p. 3415, 2022.
- BALTSAVIAS, E.P. **Airbone Laser Scanning Basic Relations and Formulas** ISPRS Journal of Photogrammetry and Sensing. - 1999. - n-2-3p : Vol. 54.
- BARCELLOS, W.; SHITARA, N. H.; FERRAZ, C.; VIEIRA, R. **Evaluation of Fine Tuning and Feature Extraction methods in Biometric Periocular Recognition**. In: **Anais do Workshop de Visão Computacional**, 2019. Disponível em: https://pdfs.semanticscholar.org/cd16/cf81fd2bdc905061a291bd20655fad999e8d.pdf?_ga=2.254205515.239857574.1612065072-1883552835.1611434736. Acesso em: 10 de jan. 2023.
- BERNSTALE, R.; LIND, H. **Segmentation, Classification and Tracking of objects in LiDAR Point Cloud Data Using Deep Learning**. 2022. Dissertação de Mestrado em Ciências Matemáticas, Faculdade de Engenharia, Universidade de Lund, Suécia. Disponível em: <http://lup.lub.lu.se/student-papers/record/9072762>. Acesso em: 12 de jan. 2023.
- BERRAR, D. **Cross-Validation**. Data Science Laboratory, Tokyo Institute of Technology, 542-545. 2019. Disponível em: https://www.researchgate.net/publication/324701535_Cross-Validation/citations#fullTextFileContent Acesso em: 15 jan.2023.
- CANO-SOLIS, M.; BALLESTEROS, J. R.; BRANCH-BEDOYA, J. W. **VEPL Dataset: A Vegetation Encroachment in Power Line Corridors Dataset for Semantic Segmentation of Drone Aerial Orthomosaics**. *Data*, v. 8, n. 8, p. 128, 2023.

CARVALHO, R.F. et al. **Mapeamento Planialtimétrico com Receptores GNSS, Estação Total e Aeronaves Remotamente Pilotáveis**. In: VIII SEAGRUS–Semana de Agronomia da UESB, v. 5, 2017.

CENTENO, J. A. S.; MITISHITA, E. A. **Laser scanner aerotransportado no estudo de áreas urbanas**: A experiência da UFPR. XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, v. 4, p. 3645-3652, 2007.

CHEN, C.; YANG, B.; SONG, S.; PENG, X.; HUANG, R. **Automatic clearance anomaly detection for transmission line corridors utilizing UAV-Borne LIDAR data**. Remote Sensing, v. 10, n. 4, p. 613, 2018.

CIÇEK, O; ABDULKADIR,A e LIENKAMP,S **U-Net 3D** International Conference on Medical Image Computing and Computer-Assisted Intervention. 2016.p.424–432. Springer, 2016

CLARK,D. **Kdnuggets**. 2018. Disponível em:<https://www.kdnuggets.com/2018/04/top-16-open-source-deep-learning-libraries.html>. Acesso em: 10 de dez. 2022.

COELHO, E, F. et al., **Remotely Piloted Aircraft Systems (RPAS) and machine learning: A review in the context of forest science**. International Journal of Remote Sensing, v. 42, n. 21, p. 8207-8235, 2021.

COPEL, **Relatório Anual e de Sustentabilidade**, 2017.

COSTA, F. C. **Segmentação semântica de áreas desmatadas utilizando Redes Neurais Convolucionais no sul da Amazônia Legal**. Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, 2020.

COSTA, F.A.L.e MITISHITA, E. A. **An approach to improve direct sensor orientation using the integration of photogrammetric and lidar datasets**. International Journal of Remote Sensing, v. 40, n. 14, p. 5651-5672, 2019.

CUCCO, J. **Gestão territorial em faixas de servidão de linhas de transmissão** Dissertação. - Florianópolis : Universidade Federal de Santa, 2011.

DALMOLIN, Q., e SANTOS, D. **Sistema Laserscanner: Conceitos e Princípios de Funcionamento**. p. 111p. 2003. Curitiba: UFPR.

DE OLIVEIRA LAGE, Mariana et al., **Modelagem De Parâmetros De Um Vant Equipado Com Lidar Em Aplicações De Monitoramento De Linhas De Transmissão De Energia Elétrica**. Cep, v. 81531, p. 990.

DECEA. **Qual a diferença entre drone, VANT e RPAS?**. Disponível em: <https://ajuda.decea.mil.br/base-de-conhecimento/qual-a-diferenca-entre-drone-vant-e-rpas/#:~:text=VANT%20%C3%A9%20a%20sigla%20de,um%20ser%20humano%20a%20bordo>. Acesso em: 15 de out.2023

DONG, Y.; MA, Z., XU, F., & CHEN, F. **Unsupervised Semantic Segmenting TLS Data of Individual Tree Based on Smoothness Constraint Using Open-Source Datasets**. IEEE Transactions on Geoscience and Remote Sensing, v. 60, p. 1-15, 2022.

ESTEIO LIDAR <https://www.lidar.com.br/index.php/tecnologia/principio-de-funcionamento-de-um-lidar-aereo/intensidade-do-pulso-laser/>, Acesso em 10 de jan. 2023.

FERRUGEM, A. P. **Extração de Mapas de Profundidades de Dense Light Fields usando Deep Learning**. Tese de doutorado, 2022.

GONZALEZ, R., & WOODS, R. **Processamento de Imagens Digitais**. Sao Paulo: Edgard Blucher. 2000.

GOODFELLOW, I., & BENGIO, Y. C. **Deep Learning**. 2016, Disponível em: <http://www.deeplearningbook.org>. Acesso em: 12 de jan. 2023.

GOOGLE COLAB, 2020.

GOOGLE EARTH. 2023.

GRANSHAW, S. I. **RPV, UAV, UAS, RPAS... or just drone?**. The Photogrammetric Record, v. 33, n. 162, p. 160-170. 2018.

GRATTAROLA, D. e ALIPPI, C. **Graph Neural Networks in TensorFlow and Keras with Spektral** Switzerland. IEEE, 2021. vols. 1556-603X.

GUAN, H.; SUN, X.; SU, Y.; HU, T.; WANG, H.; WANG, H.; PENG, C.; GUO, Q. **UAV-lidar aids automatic intelligent powerline inspection**. International Journal of Electrical Power & Energy Systems, v. 130, p. 106987, 2021.

GUSTAFSON, H ;ZUNA L. **Unmanned Aerial Vehicles for Geographic Data Capture: A Review** . Stockolmo , 2017.

GVI. **LiAir V70**. - Berkeley : Green Valley International, USA. 2023 Disponível em: <https://greenvalleyintl.com/LiAirV70/>, Acesso em 30 de set. 2023.

GVI. **LiAir50** - Berkeley : Green Valley International, USA. 2010 Disponível em: <https://geo-matching.com/products/liair-50n>, Acesso em 13 de jan. 2023.

HE, T.; ZENG, Y.; HU, Z. **Research of multi-rotor UAVs detailed autonomous inspection technology of transmission lines based on route planning**. IEEE Access, v. 7, p. 114955-114965, 2019.

HIDALGO, J.J.P. **Detection of geospatial objects linked to drug trafficking organizations: an approach based on geospatial Intelligence and Artificial Intelligence**. Tese de doutorado. UFPR. Curitiba. 2022.

HOOVER, R. **3D Laser Scanner History**. 2012.

HU, Q. et al. **RandLA-Net: Efficient Semantic Segmentation of Large-Scale Point Clouds**. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020.

HU, H. et al. **Multi-information PointNet++ fusion method for DEM construction from airborne LiDAR data**. Geocarto International, 2023.

IOFFE, S.; SZEGEDY, C. **Batch normalization: Accelerating deep network training by reducing internal covariate shift**. In: International Conference on Machine Learning. Mountain View, CA, 2015.

ISENBURG, M. **Laszip: lossless compression of lidar data**. European LiDAR Mapping Forum, 2011

JAMEELA, M.; SOHN, G. **Spatial layout consistency for 3d semantic segmentation**. In: **International Conference on Pattern Recognition**. Cham: Springer Nature Switzerland, p. 386-400, 2022.

JHALDIYAL, A.; CHAUDHARY, N. **Semantic segmentation of 3D LiDAR data using deep learning: a review of projection-based methods**. Applied Intelligence, v. 53, n. 6, p. 6844-6855, 2023.

JIANG, H., LU, Y., & CHEN, S. **Research on 3D Point Cloud Object Detection Algorithm for Autonomous Driving**. Hindawi, 2022.

JÓŹKÓW, G., WALICKA, A., and BORKOWSKI, A.: Monitoring Terrain Deformations Caused By Underground Mining Using Uav Data, Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLIII-B2-2021, 737–744, 2021. Disponível em: <https://doi.org/10.5194/isprs-archives-XLIII-B2-2021-737-2021>. Acesso em: 11 de jan. 2023.

KHARROUBI, A;POUX, F;BALLOUCH, Z; HAJJI, R;BILLEN, R. **Three Dimensional Change Detection Using Point Clouds: A Review**. **Geomatics**. pg. 457-486. 2022.

KID, J. R. **Performance Evaluation of the Velodyne VLP-16 System for Surface Feature Surveying**. Dissertação de Mestrado, Universidade de New Hampshire, New Hampshire, 2017.

KOPIER, A; NAVARRO, V. e OLIVEIRA, L. A. **Redes Neurais Artificiais e suas aplicações no setor elétrico**.Revista de Engenharias da Faculdade Salesiana. 2019.

LANGER, F.; MILIOTO, A., HAAG, A., BEHLEY, J., E STACHNISS, C. **Domain transfer for semantic segmentation of LiDAR data using deep neural networks**. In: 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems p. 8263-8270, 2020.

LIMA, G. F. **Aula 05 - Apresentação da disciplina Instalações Elétricas de Alta Tensão - Transmissão em Alta Tensão**. Natal: Instituto Federal do Rio Grande do Norte, 2013.

LIU, X.; SHUANG, F.; LI, Y.; ZHANG, L.; HUANG, X.; QIN, J. **SS-IPLE: Semantic segmentation of electric power corridor scene and individual power lines extraction from UAV-based Lidar point cloud**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023.

LIVOX. **New AVIA**. Livox Technology Company. China. Disponível em: <https://livox-wiki-en.readthedocs.io/en/latest/introduction/production.html#new-avia>. Acesso em: 20 de mar. 2023.

MATHWORKS, D. **Lidar Point Cloud Semantic Segmentation using PointSEG Deep Learning Network**, 2020. Disponível em: <https://la.mathworks.com/help/deeplearning/ug/lidar-semantic-segmentation-using-pointseg.html>. Acesso em 01 de nov. 2022.

MATHWORKS **What Is Ground Truth?**. Acesso em 07 de 07 de 2023, Disponível em <https://www.mathworks.com/discovery/ground-truth.html>. Acesso em: 20 de mar. 2023.

MATHWORKS. Disponível em: <https://www.mathworks.com/help/lidar/ug/get-started-pointnetplus.html> . Acesso em 08 de mar. 2023.

MATHWORKS. GPU Computing Requirements. 2023 Disponível em: <https://www.mathworks.com/help/parallel-computing/gpu-computing-requirements.html>. Acesso em 08 de mar. 2023.

MILIOTO, A, VIZZO, I. BEHLEY, J. Range NET++: Fast and Accurate LIDAR,

MOTA, R. F.S. **Sensor de distância por infravermelhos para a caracterização do espaço de trabalho**. Tese de Doutorado. Curso de Engenharia Eletrica, Faculdade Ciencia e Tecnologia de Nova Lisboa, Nova Lisboa, 2018. Cap. 2.

NCHRP **Guidelines for the Use of Mobile LIDAR in Transportation Applications**. : National Cooperative Highway Research Program, 2013. - Vol. Report 748.

NEGNEVITSKY, M. **Artificial Intelligence** Pearson, 2002.

OSDEMIR, E.; REMONDINO, F. Classification of Aerial Point Clouds with Deep Learning. Nova Zelândia, vols. XLII-2/W13, 2019.

PEIXOTO, E. B. **Deteção e identificação automática de postes utilizando nuvem de pontos do sistema laser terrestre móvel**. Dissertação. Curitiba, Paraná: UFPR, 2016.

PEREIRA, M. M. **Aprendizado profundo: redes LSTM**. 2017. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) – Faculdade de Ciências Exatas e Tecnologias, Universidade Federal da Grande Dourados, Dourados, MS, 2017.

POUX,F ; BILLEN,R. **Voxel-based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods**. Liège. ISPRS, 2019.

PyT, Master Documentation — torch.nn, Loss functions. Disponível em <https://pytorch.org/docs/stable/nn.html#crossentropyloss>. Acesso em 05 de nov.de 2020.

QI, C., SU, H., MO, K.; GUIBAS, L. J. **PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation**. Computer Vision Foundation. IEEE. 2016.

QI, C.; SU, H.; MO, K.; GUIBAS, L. J. **PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space**. 2017.

RAHMAN, A; SRIKUMAR,V.; SMITH, A. **Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks** Research Gate. Utah, 2018. p. 31.

RAMALHO, G. L. **Deteção e rastreamento de múltiplos objetos utilizando redes profundas no contexto de mapeamento de formigueiros em plantação de eucaliptos**. Dissertação . Campo Grande, MS: UFMS. 2022.

RAMOS, H. F. **Aeronaves Remotamente Pilotadas como Efeito Multiplicador nas Forças na Manutenção da Soberania Nacional: Popularização da Ferramenta Enquanto Agente Transformador do Cenário Geopolítico**. In: Anais do I Congresso Brasileiro de Geografia Política e Gestão do Território. REBRAGEO, 2014, UERJ, p. 1221-1231.

SAIFULLAHI,B; SHANGSHU, Y; WANG, C. **Review: Deep Learning on 3D Point Clouds**. Remote Sensing, 2019. vol. 12.

SALDANHA, M. F.S.; FREITAS, C.C.**Segmentação de Imagens Digitais: Uma revisão**. INPE.2010. Disponível em:<http://mtc-m16c.sid.inpe.br/col/sid.inpe.br/mtc-m18@80/2010/06.22.18.13/doc/106003.pdf?metadataarepository=sid.inpe.br/mtc-m18@80/2010/06.22.18.13.06&mirror=sid.inpe.br/mtc-m18@80/2008/03.17.15.17.24>. Acesso em 05 de nov.de 2020,

SCHULZ, W. **Landslides mapped using LIDAR imagery**. U.S. Geological Survey Open-File Report . Washington, Seattle. 2004.

SERRA, S. Deep Learning for Semantic Segmentation of 3D Clouds from Airborne LiDAR. Dissertação de mestrado. Linköping: Linköping University, 2020.

SHEN, Li; et al. **Deep Learning to Improve Breast Cancer Detection on Screening Mammography**: Nature Research journals, 2019. - Vol. 9.

SHEN, Y.; HUANG, J.; CHEN, D.; WANG, J.; LI, J.; FERREIRA, V. **An automatic framework for pylon detection by a hierarchical coarse-to-fine segmentation of powerline corridors from UAV LiDAR point clouds**. International Journal of Applied Earth Observation and Geoinformation, v. 118, p. 103263, 2023.

SHRESTHA,A.e MAHMOOD,A. **Review of Deep Learning Algorithms and Architectures**. Briggeport, IEE, 2017.

SIKORSKA-TUKASIEWICZ, K **Methods of automatic vegetation encroachment detection for high voltage power lines** SPIE, 2020.

SILVA, C. A.; CAMPOS, G. L.; DOS SANTOS, M. G.; OLIVEIRA, M. L. R.; DA NOBREGA, R. V. T. **Análise conceitual de linhas de transmissão operando em regime permanente senoidal**. ForScience, v. 4, n. 2, e00206, 2016.

SOUSA, P.H. **Lidar3dnet - Abordagem Inteligente Para Classificar Objetos 3D** Fortaleza : Tese de doutorado, 2022.

SOUZA, E.M.F.; CRUZ, C. B. M. e VICENS, R.S. **Estágios de Conservação da Vegetação em Área de Mata Atlântica a partir de Imagem Hiperespectral** Ensaios De Geografia. Rio de Janeiro.Universidade Federal Fluminense, 2014.

TAHER, J. **Deep Learning for road area semantic segmentation in multispectral LiDAR data**. Dissertação de mestrado. Helsinque, Finlândia: Universidade Alto, 2019.

TERRA, Notícias **Projeto aplica técnicas avançadas em Inteligência Artificial para detectar fraudes no setor elétrico**. São Paulo.2020.

TIMO, H. **Large-scale Machine Learning for Point Cloud Processing**. Institute of Geodesy and Photogrammetry, Zurich, Alemanha: ETH ZURICH. 2018.

VARNEY, N; ASARI, V K.; GRAEHLING, Q. **DALES: A large-scale aerial LiDAR data set for semantic segmentation**. In: Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops. 2020. p. 186-187.

VELODYNE VLP-16 User Manual.San Jose, 2018.

VELOZO, Liliane Tojeira. **Metodização do estudo das fundações para suportes de linhas de transmissão**. Rio de Janeiro, Rio de Janeiro, Brasil. 2010.

WANG, G.; WANG, L.; WU, S.; ZU, S.; SONG, B. **Semantic Segmentation of Transmission Corridor 3D Point Clouds Based on CA-PointNet++**. Electronics, v. 12, n. 13, p. 2829, 2023.

WANG, Y et al. **PointSeg: Real-Time Semantic Segmentation Based on 3D LiDAR Point Cloud** China, 2018 vol.807.06288.

WEHR, A.; LOHR, U. **Airborne laser scanning - an introduction and overview**. In: ISPRS Journal of Photogrammetry and Remote Sensing, p. 68-82, 1999.

WU, B. et al. **SqueezeSeg: Convolutional Neural Nets with Recurrent CRF for Real-Time Road-Object Segmentation from LiDAR Point Cloud**. 2020.

YANG, L.; FAN, J.; LIU, Y.; LI, E.; PENG, J.; LIANG, Z. **A review on state-of-the-art power line inspection techniques**. IEEE Transactions on Instrumentation and Measurement, v. 69, n. 12, p. 9350-9365, 2020.

YOSHUA, B. **Practical recommendations for gradient-based training of deep architectures**. Neural networks. Springer, 2012. - pp. 437–478.

YUN-JOU, L et al. **Comparative Analysis of Potential Calibration Alternatives for a Multi-Unit LiDAR System**. 2017.



ZHANG, C; BENGIO,S; e HARDT,M. **Understanding Deep Learning Requires Rethinking Generalization**. 5th International Conference on Learning Representations. Toulon, France, 2017.



ZHANG, X.; LI, X.; AN, J.; GAO, L.; HOU, B.; LI, C. **Natural language description of remote sensing images based on deep learning**. In: 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, 2017. p. 4798-4801.




ZHOU, J.; GANDOMI, A. H., CHEN, F., & HOLZINGER, A. **Evaluating the quality of machine learning explanations: A survey on methods and metrics**. Electronics, v. 10, n. 5, p. 593, 2021.




ZHU, X et al. **Deep learning in remote sensing: a review**. IEEE Geoscience and Remote Sensing Magazine.Munich., 2017.




APÊNDICE A – RESULTADO DA SEGMENTAÇÃO DA NUVEM DE PONTOS
CONJUNTO DE DADOS 01 – EXPERIMENTO -5 CLASSES




Folha	Nuvem de Pontos
FOC_SEC_01	Nuvem de pontos com classificação semântica 
FOC_SEC_02	Nuvem de pontos com classificação semântica 
FOC_SEC_03	Nuvem de pontos com classificação semântica 



FOC_SEC_04		Nuvem de pontos com classificação semântica 	
FOC_SEC_05		Nuvem de pontos com classificação semântica 	
FOC_SEC_06		Nuvem de pontos com classificação semântica 	

FOC_SEC_07		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
FOC_SEC_08		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
FOC_SEC_09		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	




FOC_SEC_10		Nuvem de pontos com classificação semântica  	
FOC_SEC_11		Nuvem de pontos com classificação semântica  	
FOC_SEC_12		Nuvem de pontos com classificação semântica  	




FOC_SEC_13		Nuvem de pontos com classificação semântica 	
FOC_SEC_14		Nuvem de pontos com classificação semântica 	
FOC_SEC_15		Nuvem de pontos com classificação semântica 	




FOC_SEC_16		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie	
FOC_SEC_17		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
FOC_SEC_18		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	




FOC_SEC_19		Nuvem de pontos com classificação semântica  	
FOC_SEC_20		Nuvem de pontos com classificação semântica  	




APÊNDICE B – RESULTADO DA SEGMENTAÇÃO DA NUVEM DE PONTOS
CONJUNTO DE DADOS 02 - 5 CLASSES




Folha	Nuvem de Pontos	
CCO_SQT_100		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno
CCO_SQT_101		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno
CCO_SQT_102		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno




CCO_SQT_103		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
CCO_SQT_104		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
CCO_SQT_105		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	

CCO_SQT_106		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
CCO_SQT_107		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
CCO_SQT_108		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	




CCO_SQT_109		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superfície Terreno	
CCO_SQT_110		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superfície Terreno	
CCO_SQT_111		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superfície Terreno	




CCO_SQT_112	Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
CCO_SQT_113	Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	
CCO_SQT_114	Nuvem de pontos com classificação semântica  LT Torres Edificacao Superficie Terreno	



CCO_SQT_115		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superfície Terreno	
CCO_SQT_116		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superfície Terreno	
CCO_SQT_17		Nuvem de pontos com classificação semântica  LT Torres Edificacao Superfície Terreno	




CCO_SQT_118		Nuvem de pontos com classificação semântica 	
CCO_SQT_119		Nuvem de pontos com classificação semântica 	
CCO_SQT_120		Nuvem de pontos com classificação semântica 	

APÊNDICE C – RESULTADO DA SEGMENTAÇÃO DA NUVEM DE PONTOS
CONJUNTO DE DADOS 01 E 02 - 3 CLASSES

Folha	Nuvem de Pontos	
FOC_SEC_01		Nuvem de pontos com classificação semântica  LT Torres Superfície
FOC_SEC_02		Nuvem de pontos com classificação semântica  LT Torres Superfície
FOC_SEC_03		Nuvem de pontos com classificação semântica  LT Torres Superfície




FOC_SEC_04		Nuvem de pontos com classificação semântica  LT Torres Superfície	
FOC_SEC_05		Nuvem de pontos com classificação semântica  LT Torres Superfície	
FOC_SEC_06		Nuvem de pontos com classificação semântica  LT Torres Superfície	




FOC_SEC_07		Nuvem de pontos com classificação semântica  LT Torres Superfície	
FOC_SEC_08		Nuvem de pontos com classificação semântica  LT Torres Superfície	
FOC_SEC_09		Nuvem de pontos com classificação semântica  LT Torres Superfície	

FOC_SEC_10		Nuvem de pontos com classificação semântica 	
FOC_SEC_11		Nuvem de pontos com classificação semântica 	
FOC_SEC_12		Nuvem de pontos com classificação semântica 	




FOC_SEC_13		Nuvem de pontos com classificação semântica  LT Torres Superfície	
FOC_SEC_14		Nuvem de pontos com classificação semântica  LT Torres Superfície	
FOC_SEC_15		Nuvem de pontos com classificação semântica  LT Torres Superfície	


FOC_SEC_16		Nuvem de pontos com classificação semântica LT Torres Superfície	
FOC_SEC_17		Nuvem de pontos com classificação semântica LT Torres Superfície	
FOC_SEC_18		Nuvem de pontos com classificação semântica LT Torres Superfície	

FOC_SEC_19		Nuvem de pontos com classificação semântica 	
FOC_SEC_64		Nuvem de pontos com classificação semântica 	
CCO_SQT_12		Nuvem de pontos com classificação semântica 	

CCO_SQT_22		Nuvem de pontos com classificação semântica 	
CCO_SQT_38		Nuvem de pontos com classificação semântica 	
CCO_SQT_56		Nuvem de pontos com classificação semântica 	

CCO_SQT_68		Nuvem de pontos com classificação semântica  LT Torres Superfície	
CCO_SQT_90		Nuvem de pontos com classificação semântica  LT Torres Superfície	
CCO_SQT_101		Nuvem de pontos com classificação semântica  LT Torres Superfície	

CCO_SQT_151		Nuvem de pontos com classificação semântica  LT Torres Superfície	
CCO_SQT_158		Nuvem de pontos com classificação semântica  LT Torres Superfície	
CCO_SQT_181		Nuvem de pontos com classificação semântica  LT Torres Superfície	



APÊNDICE D – RESULTADO DA PRECISÃO E IOU POR FOLHA CONJUNTO DE

DADOS 01 – EXPERIMENTO 02 - 5 CLASSES

Nome da Folha	Classe	Accuracy	IoU
FOC_SEC_01.xls	Terreno	0,000000	0,000000
FOC_SEC_01.xls	Superfície	1,000000	0,955284
FOC_SEC_01.xls	Edificações		
FOC_SEC_01.xls	Torre		
FOC_SEC_01.xls	LT	1,000000	1,000000
FOC_SEC_02.xls	Terreno	0,000000	0,000000
FOC_SEC_02.xls	Superfície	1,000000	0,945684
FOC_SEC_02.xls	Edificações		
FOC_SEC_02.xls	Torre		
FOC_SEC_02.xls	LT	1,000000	1,000000
FOC_SEC_03.xls	Terreno	0,000000	0,000000
FOC_SEC_03.xls	Superfície	1,000000	0,888225
FOC_SEC_03.xls	Edificações		
FOC_SEC_03.xls	Torre	0,871642	0,820815
FOC_SEC_03.xls	LT	0,664788	0,664788
FOC_SEC_04.xls	Terreno	0,330335	0,257859
FOC_SEC_04.xls	Superfície	0,941207	0,804046
FOC_SEC_04.xls	Edificações	0,000000	0,000000
FOC_SEC_04.xls	Torre		
FOC_SEC_04.xls	LT	1,000000	1,000000
FOC_SEC_05.xls	Terreno	0,979346	0,561051
FOC_SEC_05.xls	Superfície	0,667496	0,661404
FOC_SEC_05.xls	Edificações		
FOC_SEC_05.xls	Torre		
FOC_SEC_05.xls	LT	1,000000	1,000000
FOC_SEC_06.xls	Terreno	0,987674	0,528899
FOC_SEC_06.xls	Superfície	0,652551	0,649289
FOC_SEC_06.xls	Edificações		
FOC_SEC_06.xls	Torre		
FOC_SEC_06.xls	LT	0,993824	0,993824
FOC_SEC_07.xls	Terreno	0,971528	0,513526
FOC_SEC_07.xls	Superfície	0,575179	0,567444
FOC_SEC_07.xls	Edificações		
FOC_SEC_07.xls	Torre		
FOC_SEC_07.xls	LT	0,995673	0,995673
FOC_SEC_08.xls	Terreno	0,985050	0,510900
FOC_SEC_08.xls	Superfície	0,212889	0,210243
FOC_SEC_08.xls	Edificações		
FOC_SEC_08.xls	Torre		0,000000
FOC_SEC_08.xls	LT	1,000000	1,000000
FOC_SEC_09.xls	Terreno	0,998935	0,738248
FOC_SEC_09.xls	Superfície	0,057533	0,057370
FOC_SEC_09.xls	Edificações		
FOC_SEC_09.xls	Torre		
FOC_SEC_09.xls	LT	1,000000	1,000000
FOC_SEC_10.xls	Terreno	1,000000	0,766804
FOC_SEC_10.xls	Superfície	0,013777	0,013777
FOC_SEC_10.xls	Edificações		
FOC_SEC_10.xls	Torre		
FOC_SEC_10.xls	LT	0,999851	0,999554
FOC_SEC_11.xls	Terreno	1,000000	0,698724
FOC_SEC_11.xls	Superfície	0,021061	0,021058
FOC_SEC_11.xls	Edificações		

FOC_SEC_11.xls	Torre		
FOC_SEC_11.xls	LT	0,996007	0,995732
FOC_SEC_12.xls	Terreno	0,964881	0,639531
FOC_SEC_12.xls	Superfície	0,583654	0,567368
FOC_SEC_12.xls	Edificações		
FOC_SEC_12.xls	Torre		0,000000
FOC_SEC_12.xls	LT	1,000000	0,998263
FOC_SEC_13.xls	Terreno	0,000000	0,000000
FOC_SEC_13.xls	Superfície	1,000000	0,991829
FOC_SEC_13.xls	Edificações		
FOC_SEC_13.xls	Torre		
FOC_SEC_13.xls	LT	1,000000	1,000000
FOC_SEC_14.xls	Terreno	0,835224	0,020290
FOC_SEC_14.xls	Superfície	0,656222	0,647974
FOC_SEC_14.xls	Edificações		
FOC_SEC_14.xls	Torre		
FOC_SEC_14.xls	LT	0,284532	0,284532
FOC_SEC_15.xls	Terreno	0,000000	0,000000
FOC_SEC_15.xls	Superfície	1,000000	0,993190
FOC_SEC_15.xls	Edificações		
FOC_SEC_15.xls	Torre		
FOC_SEC_15.xls	LT	1,000000	1,000000
FOC_SEC_16.xls	Terreno	0,000000	0,000000
FOC_SEC_16.xls	Superfície	1,000000	0,990313
FOC_SEC_16.xls	Edificações		
FOC_SEC_16.xls	Torre		
FOC_SEC_16.xls	LT	1,000000	1,000000
FOC_SEC_17.xls	Terreno	0,614728	0,420780
FOC_SEC_17.xls	Superfície	0,757223	0,629483
FOC_SEC_17.xls	Edificações		
FOC_SEC_17.xls	Torre		
FOC_SEC_17.xls	LT	1,000000	1,000000
FOC_SEC_18.xls	Terreno	1,000000	0,605603
FOC_SEC_18.xls	Superfície	0,137082	0,137082
FOC_SEC_18.xls	Edificações		
FOC_SEC_18.xls	Torre		
FOC_SEC_18.xls	LT	1,000000	1,000000
FOC_SEC_19.xls	Terreno	1,000000	0,633487
FOC_SEC_19.xls	Superfície	0,008474	0,008474
FOC_SEC_19.xls	Edificações		
FOC_SEC_19.xls	Torre		0,000000
FOC_SEC_19.xls	LT	1,000000	1,000000
FOC_SEC_20.xls	Terreno	1,000000	0,694477
FOC_SEC_20.xls	Superfície	0,000000	0,000000
FOC_SEC_20.xls	Edificações		
FOC_SEC_20.xls	Torre		
FOC_SEC_20.xls	LT	1,000000	1,000000

**APÊNDICE E - RESULTADO DA PRECISÃO E IOU POR FOLHA CONJUNTO DE
DADOS 02 – EXPERIMENTO 01 - 5 CLASSES**

Nome da Folha	Classe	Precisão	IoU
CCO_SQT_100.xls	Terreno	1	0,995690041
CCO_SQT_100.xls	Superfície	0,173462214	0,173462214
CCO_SQT_100.xls	Edificações		
CCO_SQT_100.xls	Torre		0
CCO_SQT_100.xls	LT	1	1
CCO_SQT_101.xls	Terreno	0,983512607	0,971416856
CCO_SQT_101.xls	Superfície	0,862541928	0,729724794
CCO_SQT_101.xls	Edificações		
CCO_SQT_101.xls	Torre		
CCO_SQT_101.xls	LT	1	1
CCO_SQT_102.xls	Terreno	0,989532517	0,977634961
CCO_SQT_102.xls	Superfície	0,806053977	0,676846716
CCO_SQT_102.xls	Edificações		
CCO_SQT_102.xls	Torre	0,822602431	0,703865417
CCO_SQT_102.xls	LT	0,265359477	0,265359477
CCO_SQT_103.xls	Terreno	0,995110523	0,991055263
CCO_SQT_103.xls	Superfície	0,881758123	0,772570214
CCO_SQT_103.xls	Edificações		
CCO_SQT_103.xls	Torre		
CCO_SQT_103.xls	LT	0,999038462	0,999038462
CCO_SQT_104.xls	Terreno	1	0,988483421
CCO_SQT_104.xls	Superfície	0,420714236	0,420714236
CCO_SQT_104.xls	Edificações		
CCO_SQT_104.xls	Torre		
CCO_SQT_104.xls	LT	1	1
CCO_SQT_105.xls	Terreno	1	0,982159379
CCO_SQT_105.xls	Superfície	0,456464821	0,456464821
CCO_SQT_105.xls	Edificações		
CCO_SQT_105.xls	Torre		
CCO_SQT_105.xls	LT	1	1
CCO_SQT_106.xls	Terreno	0,993684271	0,985418912
CCO_SQT_106.xls	Superfície	0,675660755	0,543039379
CCO_SQT_106.xls	Edificações		
CCO_SQT_106.xls	Torre		
CCO_SQT_106.xls	LT	1	1
CCO_SQT_107.xls	Terreno	0,996405372	0,962377139
CCO_SQT_107.xls	Superfície	0,715433415	0,696689088
CCO_SQT_107.xls	Edificações		
CCO_SQT_107.xls	Torre		0
CCO_SQT_107.xls	LT	1	1
CCO_SQT_108.xls	Terreno	0,958196275	0,934794733
CCO_SQT_108.xls	Superfície	0,65147629	0,411168277
CCO_SQT_108.xls	Edificações		
CCO_SQT_108.xls	Torre		
CCO_SQT_108.xls	LT	0,881410256	0,881410256
CCO_SQT_109.xls	Terreno	0,9903113	0,986417779
CCO_SQT_109.xls	Superfície	0,459293175	0,197356287
CCO_SQT_109.xls	Edificações		
CCO_SQT_109.xls	Torre		
CCO_SQT_109.xls	LT	1	1
CCO_SQT_110.xls	Terreno	1	0,989281845
CCO_SQT_110.xls	Superfície	0,740771938	0,740771938
CCO_SQT_110.xls	Edificações		

CCO_SQT_110.xls	Torre		
CCO_SQT_110.xls	LT	1	1
CCO_SQT_111.xls	Terreno	0,989071551	0,962094872
CCO_SQT_111.xls	Superfície	0,31266811	0,152575471
CCO_SQT_111.xls	Edificações	0	0
CCO_SQT_111.xls	Torre		
CCO_SQT_111.xls	LT	1	1
CCO_SQT_112.xls	Terreno	0,992855883	0,944710846
CCO_SQT_112.xls	Superfície	0,618701086	0,587308451
CCO_SQT_112.xls	Edificações		
CCO_SQT_112.xls	Torre		
CCO_SQT_112.xls	LT	1	1
CCO_SQT_113.xls	Terreno	0,987721254	0,957151828
CCO_SQT_113.xls	Superfície	0,365393117	0,262260901
CCO_SQT_113.xls	Edificações	0	0
CCO_SQT_113.xls	Torre		
CCO_SQT_113.xls	LT	1	1
CCO_SQT_114.xls	Terreno	1	0,999059441
CCO_SQT_114.xls	Superfície	0	0
CCO_SQT_114.xls	Edificações		
CCO_SQT_114.xls	Torre	0,881680672	0,790119738
CCO_SQT_114.xls	LT	0,393045775	0,393045775
CCO_SQT_115.xls	Terreno	1	0,99330841
CCO_SQT_115.xls	Superfície	0,215884801	0,215884801
CCO_SQT_115.xls	Edificações		
CCO_SQT_115.xls	Torre		
CCO_SQT_115.xls	LT	1	1
CCO_SQT_116.xls	Terreno	1	0,999498438
CCO_SQT_116.xls	Superfície	0	0
CCO_SQT_116.xls	Edificações		
CCO_SQT_116.xls	Torre		
CCO_SQT_116.xls	LT	1	1
CCO_SQT_117.xls	Terreno	0,991143965	0,964741505
CCO_SQT_117.xls	Superfície	0,862374011	0,825605266
CCO_SQT_117.xls	Edificações		
CCO_SQT_117.xls	Torre		
CCO_SQT_117.xls	LT	1	1
CCO_SQT_118.xls	Terreno	0,946667092	0,939119752
CCO_SQT_118.xls	Superfície	0,993041814	0,949210846
CCO_SQT_118.xls	Edificações		
CCO_SQT_118.xls	Torre		
CCO_SQT_118.xls	LT	1	1
CCO_SQT_119.xls	Terreno	0,335599387	0,334917943
CCO_SQT_119.xls	Superfície	0,999687914	0,907232846
CCO_SQT_119.xls	Edificações		
CCO_SQT_119.xls	Torre		
CCO_SQT_119.xls	LT	1	1
CCO_SQT_120.xls	Terreno	0,954931821	0,895962102
CCO_SQT_120.xls	Superfície	0,930023731	0,887498282
CCO_SQT_120.xls	Edificações		
CCO_SQT_120.xls	Torre		
CCO_SQT_120.xls	LT	1	1

APÊNDICE F - RESULTADO DA PRECISÃO E IOU POR FOLHA CONJUNTO DE

DADOS 01 E 02 – EXPERIMENTO ÚNICO


Nome da Folha	Classe	Precisão	IoU
FOC_SEC_01.xls	Superfície	1,00000	1,00000

FOC_SEC_01.xls	Torre		
FOC_SEC_01.xls	LT	1,00000	1,00000
FOC_SEC_02.xls	Superfície	1,00000	1,00000
FOC_SEC_02.xls	Torre		
FOC_SEC_02.xls	LT	1,00000	1,00000
FOC_SEC_03.xls	Superfície	0,78532	0,78532
FOC_SEC_03.xls	Torre	0,99148	0,73799
FOC_SEC_03.xls	LT	0,90923	0,76844
FOC_SEC_04.xls	Superfície	1,00000	1,00000
FOC_SEC_04.xls	Torre		
FOC_SEC_04.xls	LT	1,00000	1,00000
FOC_SEC_05.xls	Superfície	1,00000	1,00000
FOC_SEC_05.xls	Torre		
FOC_SEC_05.xls	LT	1,00000	1,00000
FOC_SEC_06.xls	Superfície	1,00000	1,00000
FOC_SEC_06.xls	Torre		
FOC_SEC_06.xls	LT	1,00000	1,00000
FOC_SEC_07.xls	Superfície	1,00000	1,00000
FOC_SEC_07.xls	Torre		
FOC_SEC_07.xls	LT	1,00000	1,00000
FOC_SEC_08.xls	Superfície	1,00000	1,00000
FOC_SEC_08.xls	Torre		
FOC_SEC_08.xls	LT	1,00000	1,00000
FOC_SEC_09.xls	Superfície	1,00000	1,00000
FOC_SEC_09.xls	Torre		
FOC_SEC_09.xls	LT	1,00000	1,00000
FOC_SEC_10.xls	Superfície	1,00000	1,00000
FOC_SEC_10.xls	Torre		
FOC_SEC_10.xls	LT	1,00000	1,00000
FOC_SEC_11.xls	Superfície	1,00000	1,00000
FOC_SEC_11.xls	Torre		
FOC_SEC_11.xls	LT	1,00000	1,00000
FOC_SEC_12.xls	Superfície	1,00000	1,00000
FOC_SEC_12.xls	Torre		
FOC_SEC_12.xls	LT	1,00000	1,00000
FOC_SEC_13.xls	Superfície	1,00000	1,00000
FOC_SEC_13.xls	Torre		
FOC_SEC_13.xls	LT	1,00000	1,00000
FOC_SEC_14.xls	Superfície	0,96760	0,96760
FOC_SEC_14.xls	Torre		
FOC_SEC_14.xls	LT	1,00000	0,99322
FOC_SEC_15.xls	Superfície	1,00000	1,00000
FOC_SEC_15.xls	Torre		
FOC_SEC_15.xls	LT	1,00000	1,00000
FOC_SEC_16.xls	Superfície	0,99323	0,99323
FOC_SEC_16.xls	Torre		
FOC_SEC_16.xls	LT	1,00000	0,99870
FOC_SEC_17.xls	Superfície	1,00000	1,00000
FOC_SEC_17.xls	Torre		
FOC_SEC_17.xls	LT	1,00000	1,00000
FOC_SEC_18.xls	Superfície	1,00000	1,00000
FOC_SEC_18.xls	Torre		
FOC_SEC_18.xls	LT	1,00000	1,00000
FOC_SEC_19.xls	Superfície	1,00000	1,00000
FOC_SEC_19.xls	Torre		
FOC_SEC_19.xls	LT	1,00000	1,00000
FOC_SEC_64.xls	Superfície	1,00000	1,00000
FOC_SEC_64.xls	Torre	1,00000	0,94708

FOC_SEC_64.xls	LT	0,78124	0,78124
CCO_SQT_101.xls	Superfície	1,00000	1,00000
CCO_SQT_101.xls	Torre		
CCO_SQT_101.xls	LT	1,00000	1,00000
CCO_SQT_12.xls	Superfície	1,00000	1,00000
CCO_SQT_12.xls	Torre		
CCO_SQT_12.xls	LT	1,00000	1,00000
CCO_SQT_151.xls	Superfície	0,96705	0,96705
CCO_SQT_151.xls	Torre		0,00000
CCO_SQT_151.xls	LT	1,00000	1,00000
CCO_SQT_158.xls	Superfície	1,00000	1,00000
CCO_SQT_158.xls	Torre		
CCO_SQT_158.xls	LT	1,00000	1,00000
CCO_SQT_181.xls	Superfície	1,00000	1,00000
CCO_SQT_181.xls	Torre		
CCO_SQT_181.xls	LT	1,00000	1,00000
CCO_SQT_187.xls	Superfície	1,00000	0,99965
CCO_SQT_187.xls	Torre		
CCO_SQT_187.xls	LT	0,98936	0,98936
CCO_SQT_22.xls	Superfície	0,99862	0,99862
CCO_SQT_22.xls	Torre		0,00000
CCO_SQT_22.xls	LT	1,00000	1,00000
CCO_SQT_38.xls	Superfície	0,88838	0,88838
CCO_SQT_38.xls	Torre	0,99973	0,89941
CCO_SQT_38.xls	LT	0,94017	0,93957
CCO_SQT_56.xls	Superfície	1,00000	1,00000
CCO_SQT_56.xls	Torre		
CCO_SQT_56.xls	LT	1,00000	1,00000
CCO_SQT_68.xls	Superfície	1,00000	1,00000
CCO_SQT_68.xls	Torre		
CCO_SQT_68.xls	LT	1,00000	1,00000
CCO_SQT_90.xls	Superfície	0,94266	0,94266
CCO_SQT_90.xls	Torre	0,99032	0,92674
CCO_SQT_90.xls	LT	0,67680	0,64496


APÊNDICE G- GRÁFICOS DE MONITORAMENTO DO TREINAMENTO

FIGURA 77 – CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 01




FONTE: O autor (2023).

FIGURA 78 - CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 02




FONTE: O autor (2023).

FIGURA 79 - CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 03




FONTE: O autor (2023).

FIGURA 80 - CONJUNTO DE DADOS 01 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 04




FONTE: O autor (2023).

FIGURA 81 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 01




FONTE: O autor (2023).

FIGURA 82 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 02




FONTE: O autor (2023).

FIGURA 83 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 03




FONTE: O autor (2023).

FIGURA 84 - CONJUNTO DE DADOS 02 - PROGRESSO DO TREINAMENTO DO EXPERIMENTO 04



FONTE: O autor (2023).

FIGURA 85 - CONJUNTO DE DADOS 01 e 02 - PROGRESSO DO TREINAMENTO



FONTE: O autor (2023)

ANEXO 1 – QUADRO DE TERMOS E DEFINIÇÕES UTILIZADOS EM IA

Termo	Definição
Generalização (Generalization)	Refere-se à capacidade do modelo de se adaptar e fazer previsões de uma maneira apropriada para novos dados nunca vistos antes.
Regularização (Regularization)	É um conjunto de técnicas que podem prevenir overfitting em redes neurais e, assim, melhorar a precisão de um modelo de aprendizado profundo quando confrontado com dados completamente novos. Exemplo: L1, L2, Dropout
Subajuste (Underfitting)	Ocorre quando o modelo não consegue alcançar uma perda suficientemente baixa no conjunto de treinamento. Nesse caso, o modelo não aprende os padrões subjacentes nos dados de treinamento, resultando em um erro elevado tanto nos dados de treinamento quanto nos de teste.
Superajuste (Overfitting)	Ocorre quando a rede neural modela muito bem os dados de treinamento, mas não generaliza bem para os dados de validação. Nesse caso, o modelo é adequado apenas para os dados de treinamento e não é capaz de generalizar para outros dados que nunca viu antes.
Forma de entrada (Input shape)	Este é o hiperparâmetro que indica como os dados de entrada são; é o tensor inicial na primeira camada. Este tensor deve ter a mesma forma que os dados de treinamento. Por exemplo, se as imagens tiverem 256 x 256 pixels em RGB (3 canais), a forma de entrada seria (256 x 256 x 3).
Rótulo (Label)	Refere-se ao que um modelo é destinado a prever.
Aumento de dados (Data augmentation)	Esta é a fase em que o modelo aprende com a exposição às amostras de entrada que foram rotuladas. Essas técnicas aumentam a quantidade de dados, adicionando cópias ligeiramente modificadas dos dados existentes ou criando novos dados sintéticos com base nos dados existentes.
Inferência (Inference)	Faz previsões aplicando o modelo já treinado a amostras não rotuladas que você deseja prever.
Número de camadas ocultas (Number of hidden layers)	Uma rede neural pode ter quantas camadas desejar, cada uma com quantos neurônios você desejar. A ideia geral é que, quanto mais neurônios uma rede tiver, mais ela aprenderá com os dados de treinamento. No entanto, se houver muitos neurônios, isso pode levar ao overfitting, enfraquecendo sua capacidade de generalização. Portanto, é importante encontrar um equilíbrio.
Funções de ativação (Activation functions)	A função de ativação introduz não linearidade nas capacidades de modelagem da rede. As principais funções de ativação são Função Identidade, Função de Degrau, Sigmóide, Softmax, Tanh, ReLU e Leaky ReLU.
Função de perda (Loss function)	Mede o quão distante a previsão da rede está em relação ao rótulo verdadeiro. Avalia a diferença de erro entre as saídas calculadas e desejadas dos dados de treinamento. Por exemplo, o Erro

	Quadrático Médio (MSE) é comum para problemas de regressão, e a Entropia Cruzada é comum para problemas de classificação.
Optimizador (Optimizer)	Algoritmos de otimização encontram os valores de peso ótimos que minimizam o erro. Existem vários tipos de otimizadores para escolher. Entre os mais comuns Descida de Gradiente Estocástico (SGD), Descida de Gradiente em Lote (Batch Gradient Descent), Minilote de SGD (Mini-batch SGD, Momentum, Aceleração de Nesterov (Nesterov acceleration), RMSpro, AdaGrad, Adadelta, Adam, Nadam
Tamanho do lote (Batch size)	Para passar os dados de treinamento por uma rede, é necessário dividi-los em lotes menores. O tamanho do lote é o argumento que indica o tamanho do minilote (número de subamostras) fornecido à rede, após o qual o parâmetro é atualizado. Lotes maiores aprendem mais rápido, mas exigem mais espaço na memória do computador. Um bom valor padrão para o tamanho do lote pode ser 32. Tamanhos comuns incluem 32, 64, 128, 256, e outros
Número de épocas (Number of epochs)	Indica quantas vezes os dados de treinamento passaram pela rede neural no processo de treinamento. Um alto número de épocas faz com que o modelo se ajuste aos dados muito bem e pode ter problemas de generalização nos conjuntos de dados de teste e validação. Também pode causar problemas com gradientes desaparecendo e gradientes explosivos. Um número de épocas menor que o ideal pode limitar o potencial do modelo porque o modelo não recebe treinamento suficiente. Afinal, ele não viu dados suficientes, então boas previsões não são obtidas.
Taxa de aprendizado (Learning rate)	Este hiperparâmetro controla o quanto o modelo deve mudar em resposta ao erro estimado cada vez que o peso do modelo é atualizado. Escolher a taxa de aprendizado é um desafio, uma vez que um valor muito pequeno pode resultar em um processo de treinamento longo que pode ficar travado, enquanto um valor muito grande pode resultar em aprendizado de um conjunto de pesos subótimo muito rapidamente ou em um processo de treinamento instável. O valor da taxa de aprendizado depende do otimizador usado e varia entre 0 e 1. Por exemplo, para o otimizador SGD, um valor de 0,1 funciona bem, mas para o otimizador Adam, é recomendado usar entre 0,001 e 0,01.
Métricas de avaliação (Evaluation metrics)	Refere-se a como a saída produzida pela rede é avaliada em relação aos dados de referência. As métricas de avaliação explicam o desempenho de um modelo. Um aspecto importante das métricas de avaliação é sua capacidade de discriminar entre os resultados do modelo. (Acurácia, Precisão, Revocação, Matriz de Confusão, Média de Precisão Média, entre outras).
Filtros (Filters)	Usado em Redes Neurais Convolucionais (CNN). Isso se refere ao número de filtros de kernel em cada camada de convolução (a profundidade da camada oculta).
Passo (Stride)	Usado em CNNs. Isso é o número de etapas pelas quais o filtro desliza sobre a imagem. Um passo de 1 ou 2 é recomendado como um bom ponto de partida.

Tamanho do kernel (Kernel size)	Usado em CNNs, indica o tamanho do filtro de convolução ou kernel. Normalmente, 2, 3 ou 5.
Preenchimento (Padding)	Adição de colunas e linhas de valores zero ao redor da borda da imagem para preservar o tamanho da imagem na próxima camada

Fonte: Adaptado Hidalgo (2022).

ANEXO 2 - RESULTADO ALTIMÉTRICO ÁREA 01 E 02

ÁREA 01

Number	Easting	Northing	Known Z	Laser Z	Dz
B020614	663999.203	7186143.329	966.074	965.948	-0.126
B110609	664280.093	7185094.785	941.840	941.700	-0.140
B110611	665120.479	7183614.065	927.131	926.928	-0.203
BROD	664005.885	7186144.544	966.306	966.154	-0.152
PA01	663938.192	7186189.404	966.815	966.655	-0.160
PA02	664374.959	7184842.932	945.466	945.312	-0.154
PA03	664854.724	7183996.834	941.896	941.790	-0.106
PA09	665365.899	7183247.482	920.081	919.834	-0.247
PA11	664270.258	7185095.425	940.942	940.694	-0.248
PA12	664385.580	7184637.367	943.548	943.253	-0.295
PA13	664117.850	7185566.553	950.745	950.469	-0.276
PA14	663996.707	7185972.428	957.569	957.549	-0.020
PA15	663992.621	7186140.036	965.975	965.765	-0.210
PC02	664873.657	7183947.458	941.828	941.735	-0.093
PC05	665101.268	7183675.025	925.952	925.698	-0.254
PL01	663986.740	7186135.320	965.813	965.619	-0.194
PL02	664423.422	7184625.321	944.446	944.216	-0.230
Average dz	-0.183				
Minimum dz	-0.295				
Maximum dz	-0.020				
Average magnitude	0.183				
Root mean square	0.196				
Std deviation	0.073				

ÁREA 02

Number	Easting	Northing	Known Z	Laser Z	Dz
B01	289358.941	7175522.459	363.815	363.621	-0.194
PA01a	289024.818	7176868.149	411.393	411.659	+0.266
PA02	289473.910	7176651.451	422.732	422.616	-0.116
PA02a	289102.492	7176783.339	408.387	408.480	+0.093
PA03	289428.196	7176682.475	421.365	421.208	-0.157
PA03a	289448.122	7176629.707	423.074	423.161	+0.087
PA04	289403.904	7176187.773	370.291	370.190	-0.101
PA04a	289477.758	7176651.881	422.351	422.487	+0.136
PA05	289468.228	7176133.722	369.838	369.799	-0.039
PA06	289438.876	7176019.120	394.968	394.803	-0.165
PA06a	289806.261	7176481.350	422.777	422.818	+0.041
PA07	289481.698	7175972.589	395.592	395.334	-0.258
PA08	289372.109	7175525.741	362.342	362.391	+0.049
PA09	289409.420	7175485.636	354.710	354.823	+0.113
B02	289502.457	7176725.320	422.740	outside	*
B2a	289502.015	7176725.165	422.740	outside	*
PA01	289501.490	7176713.368	422.058	outside	*
PA05a	289835.564	7176555.406	421.070	outside	*
PA07a	289501.292	7176721.306	422.309	outside	*
Average dz	-0.017				
Minimum dz	-0.258				
Maximum dz	+0.266				
Average magnitude	0.130				
Root mean square	0.147				
Std deviation	0.152				

ANEXO 3 – CAMADAS DA REDE POINTNET++

ID	Nome	Tipo	Ativação
1	'InputPoints'	Point Cloud Input	Point clouds of size 8000×3
2	'SA1-SampleAndGroup'	Function	Generate 1024 clusters with cluster radius 0.1 and cluster size 32
3	'SA1-Conv1'	2-D Convolution	32 1×1×3 convolutions with stride [1 1] and padding [0 0 0 0]
4	'SA1-Norm1'	Batch Normalization	Batch normalization with 32 channels
5	'SA1-Relu1'	ReLU	ReLU
6	'SA1-Conv2'	2-D Convolution	32 1×1×32 convolutions with stride [1 1] and padding [0 0 0 0]
7	'SA1-Norm2'	Batch Normalization	Batch normalization with 32 channels
8	'SA1-Relu2'	ReLU	ReLU
9	'SA1-Conv3'	2-D Convolution	64 1×1×32 convolutions with stride [1 1] and padding [0 0 0 0]
10	'SA1-Norm3'	Batch Normalization	Batch normalization with 64 channels
11	'SA1-Relu3'	ReLU	ReLU
12	'SA1-Maxpool'	2-D Max Pooling	1×32 max pooling with stride [1 1] and padding [0 0 0 0]
13	'FP4-Interpolation'	Function	Interpolation
14	'FP4-Conv1'	2-D Convolution	128 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
15	'FP4-Norm1'	Batch Normalization	Batch normalization with 128 channels
16	'FP4-Relu1'	ReLU	ReLU
17	'FP4-Conv2'	2-D Convolution	128 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
18	'FP4-Norm2'	Batch Normalization	Batch normalization with 128 channels
19	'FP4-Relu2'	ReLU	ReLU
20	'FP4-Conv3'	2-D Convolution	128 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
21	'FP4-Norm3'	Batch Normalization	Batch normalization with 128 channels
22	'FP4-Relu3'	ReLU	ReLU
23	'FinalConvLayer'	2-D Convolution	5 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
24	'Softmax'	Softmax	softmax
25	'SegmentationLayer'	Pixel Classification Layer	Class weighted cross-entropy loss with 'Terreno', 'Superficie', and 3 other classes
26	'SA2-SampleAndGroup'	Function	Generate 256 clusters with cluster radius 0.2 and cluster size 32
27	'SA2-Conv1'	2-D Convolution	64 1×1×67 convolutions with stride [1 1] and padding [0 0 0 0]
28	'SA2-Norm1'	Batch Normalization	Batch normalization with 64 channels
29	'SA2-Relu1'	ReLU	ReLU
30	'SA2-Conv2'	2-D Convolution	64 1×1×64 convolutions with stride [1 1] and padding [0 0 0 0]
31	'SA2-Norm2'	Batch Normalization	Batch normalization with 64 channels
32	'SA2-Relu2'	ReLU	ReLU
33	'SA2-Conv3'	2-D Convolution	128 1×1×64 convolutions with stride [1 1] and padding [0 0 0 0]

34	'SA2-Norm3'	Batch Normalization	Batch normalization with 128 channels
35	'SA2-Relu3'	ReLU	ReLU
36	'SA2-Maxpool'	2-D Max Pooling	1×32 max pooling with stride [1 1] and padding [0 0 0 0]
37	'FP3-Interpolation'	Function	Interpolation
38	'FP3-Conv1'	2-D Convolution	128 1×1×320 convolutions with stride [1 1] and padding [0 0 0 0]
39	'FP3-Norm1'	Batch Normalization	Batch normalization with 128 channels
40	'FP3-Relu1'	ReLU	ReLU
41	'FP3-Conv2'	2-D Convolution	128 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
42	'FP3-Norm2'	Batch Normalization	Batch normalization with 128 channels
43	'FP3-Relu2'	ReLU	ReLU
44	'SA3-SampleAndGroup'	Function	Generate 64 clusters with cluster radius 0.4 and cluster size 32
45	'SA3-Conv1'	2-D Convolution	128 1×1×131 convolutions with stride [1 1] and padding [0 0 0 0]
46	'SA3-Norm1'	Batch Normalization	Batch normalization with 128 channels
47	'SA3-Relu1'	ReLU	ReLU
48	'SA3-Conv2'	2-D Convolution	128 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
49	'SA3-Norm2'	Batch Normalization	Batch normalization with 128 channels
50	'SA3-Relu2'	ReLU	ReLU
51	'SA3-Conv3'	2-D Convolution	256 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]
52	'SA3-Norm3'	Batch Normalization	Batch normalization with 256 channels
53	'SA3-Relu3'	ReLU	ReLU
54	'SA3-Maxpool'	2-D Max Pooling	1×32 max pooling with stride [1 1] and padding [0 0 0 0]
55	'FP2-Interpolation'	Function	Interpolation
56	'FP2-Conv1'	2-D Convolution	256 1×1×384 convolutions with stride [1 1] and padding [0 0 0 0]
57	'FP2-Norm1'	Batch Normalization	Batch normalization with 256 channels
58	'FP2-Relu1'	ReLU	ReLU
59	'FP2-Conv2'	2-D Convolution	256 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]
60	'FP2-Norm2'	Batch Normalization	Batch normalization with 256 channels
61	'FP2-Relu2'	ReLU	ReLU
62	'SA4-SampleAndGroup'	Function	Generate 16 clusters with cluster radius 0.8 and cluster size 32
63	'SA4-Conv1'	2-D Convolution	256 1×1×259 convolutions with stride [1 1] and padding [0 0 0 0]
64	'SA4-Norm1'	Batch Normalization	Batch normalization with 256 channels
65	'SA4-Relu1'	ReLU	ReLU
66	'SA4-Conv2'	2-D Convolution	256 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]
67	'SA4-Norm2'	Batch Normalization	Batch normalization with 256 channels
68	'SA4-Relu2'	ReLU	ReLU
69	'SA4-Conv3'	2-D Convolution	512 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]
70	'SA4-Norm3'	Batch Normalization	Batch normalization with 512 channels

71	'SA4-Relu3'	ReLU	ReLU
72	'SA4-Maxpool'	2-D Max Pooling	1×32 max pooling with stride [1 1] and padding [0 0 0]
73	'FP1-Interpolation'	Function	Interpolation
74	'FP1-Conv1'	2-D Convolution	256 1×1×768 convolutions with stride [1 1] and padding [0 0 0 0]
75	'FP1-Norm1'	Batch Normalization	Batch normalization with 256 channels
76	'FP1-Relu1'	ReLU	ReLU
77	'FP1-Conv2'	2-D Convolution	256 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]
78	'FP1-Norm2'	Batch Normalization	Batch normalization with 256 channels
79	'FP1-Relu2'	ReLU	ReLU

