



UNIVERSIDADE FEDERAL DO PARANÁ

LEONARDO ASSUMPTÃO MOREIRA

AUMENTO DE RESOLUÇÃO DE SUPERFÍCIES COM INFORMAÇÕES
ALTIMÉTRICAS COM A REDE NEURAL PROFUNDA DEM-ESRGAN

CURITIBA

2022

UNIVERSIDADE FEDERAL DO PARANÁ

LEONARDO ASSUMPÇÃO MOREIRA

AUMENTO DE RESOLUÇÃO DE SUPERFÍCIES COM INFORMAÇÕES
ALTIMÉTRICAS COM A REDE NEURAL PROFUNDA DEM-ESRGAN

Tese apresentada ao Programa de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Prof. Dr. Hideo Araki

CURITIBA

2022

FICHA CATALOGRÁFICA

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

Moreira, Leonardo Assumpção.

Aumento de resolução de superfícies com informações altimétricas com a rede neural profunda DEM-ESRGAN. / Leonardo Assumpção Moreira. – 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: Prof. Dr. Hideo Araki.

1. Cartografia. 2. Mapeamento (Cartografia). 3. Redes neurais (Computação). 4. Inteligência artificial. I. Araki, Hideo. II. Universidade Federal do Paraná. Programa de Pós-Graduação em Ciências Geodésicas. III. Título.

Bibliotecário: Nilson Carlos Vieira Junior CRB-9/1797

FOLHA DE APROVAÇÃO



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 **LEONARDO ASSUMPÇÃO MOREIRA** intitulada: **AUMENTO DE RESOLUÇÃO DE SUPERFÍCIES COM INFORMAÇÕES ALTIMÉTRICAS COM A REDE NEURAL PROFUNDA DEM-ERSGAN**, sob orientação do Prof. Dr. HIDEO ARAKI, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua **APROVAÇÃO** no rito de defesa.

A outorga do título de doutor 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, 21 de Dezembro de 2022.

Assinatura Eletrônica
21/12/2022 15:10:36.0
HIDEO ARAKI
Presidente da Banca Examinadora

Assinatura Eletrônica
21/12/2022 14:59:00.0
GABRIEL HENRIQUE DE ALMEIDA PEREIRA
Avaliador Externo (SIMEPAR)

Assinatura Eletrônica
21/12/2022 16:29:53.0
CARLOS ALBERTO PIRES DE CASTRO FILHO
Avaliador Externo (DIRETORIA DE SERVIÇO GEOGRÁFICA -
EXÉRCITO BRASILEIRO)

Assinatura Eletrônica
23/12/2022 10:03:16.0
JORGE ANTONIO SILVA CENTENO
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

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: 243589

Para autenticar este documento/assinatura, acesse <https://www.prppg.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp>
e insira o código 243589

DEDICATÓRIA

À Deus, por sua infinita misericórdia.

À minha estimada avó, Consuelo, pelo enorme carinho e dedicação, e por estar, de diferentes formas, sempre presente nos momentos mais difíceis e cruciais de minha vida.

Aos meus queridos pais, Leonel e Ester, por toda dedicação e amor.

À minha amada esposa, Viviane, por todo amor, carinho, apoio e compreensão oferecidos a mim ao longo desta trajetória.

À minha admirada irmã, Livia, por me inspirar na vida acadêmica, e por todo apoio e amor dispensados.

Ao meu estimado orientador, Prof. Dr. Hideo Araki, pela paciência, compreensão e ensinamentos.

AGRADECIMENTOS

A todos que passaram pelo meu caminho e que com certeza deixaram um pouco de si. Os momentos de alegria e sofrimento serviram para permitir um crescimento pessoal.

Em especial,

Ao meu orientador, Prof. Dr. Hideo Araki, pela oportunidade, por acreditar em mim, pela paciência e por todo conhecimento adquirido nesta etapa. Pelas sugestões que muito contribuíram para o sucesso da pesquisa.

Ao Chefe da 1ª Divisão de Levantamento, Cel QEM Cart Azeredo, por todo apoio, incentivo e conhecimentos, que foram imprescindíveis para o início desta jornada.

Ao Cel QEM Cart Marcos de Meneses Rocha, Supervisor Acadêmico, pelo auxílio e conhecimentos, viabilizando o desenvolvimento do meu estudo.

A todos os colegas do Programa de Pós-Graduação em Ciências Geodésicas, pelo companheirismo e apoio.

Ao Exército Brasileiro (EB), por propiciar a realização desse sonho.

À Diretoria do Serviço Geográfico (DSG), e em especial ao Diretor do Serviço Geográfico Gen Bda Marcis Gualberto Mendonça Júnior, pela busca incansável em manter seu Quadro de Engenheiros Militares (QEM) sempre qualificado e atualizado, realizando diversas pesquisas científicas nas melhores instituições de ensino do país, visando proporcionar ao EB cada vez mais um serviço de excelência.

À Universidade Federal do Paraná (UFPR), ao Programa de Pós-Graduação em Ciências Geodésicas (CPGCG), e a todos os seus professores e servidores, pela

oportunidade de aprimoramento pessoal e profissional. Por proporcionarem condições humanas e materiais para o desenvolvimento da aprendizagem.

À toda minha família e amigos, pelo amor, apoio, confiança e motivação incondicional, e por sempre me impulsionarem em direção às vitórias dos meus desafios.

Muito obrigado a todas as pessoas e instituições que não citei expressamente e que contribuíram de alguma forma com o desenvolvimento e a conclusão deste trabalho!

Que Deus abençoe a todos!

“Quanto mais aumenta nosso conhecimento, mais evidente fica nossa ignorância.”

(John F. Kennedy)

“A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original.”

(Albert Einstein)

“Tu só és Senhor, tu fizeste o céu, o céu dos céus, e todo o seu exército; a terra e tudo quanto nela há; os mares e tudo quanto neles há; e tu os guardas em vida a todos; e o exército dos céus te adora.”

(Neemias 9:6)

RESUMO

No processo de produção cartográfica, os modelos digitais de elevação (MDE) são responsáveis por fornecer informações altimétricas da superfície a ser mapeada. A resolução espacial de tais modelos está diretamente associada com a escala dos produtos cartográficos que podem ser utilizados. Modelos globais de baixa e média resolução espacial encontram-se disponibilizados open source por diversas agências espaciais. Entretanto, os modelos de alta resolução, utilizados em escalas 1:25.000 e maiores, são escassos e possuem custo elevado. Contudo, esse problema pode ser abordado com a utilização de algoritmos de aprendizagem profunda, associados às técnicas de super-resolução de imagens (SISR) em modelos digitais de elevação, visando obter versões de melhor qualidade espacial a partir de insumos de menor resolução utilizados inicialmente no processamento. Aqui abordamos a utilização de algoritmos de aprendizado profundo juntamente com técnicas de super-resolução de imagem única em modelos digitais de elevação para obter versões de melhor qualidade espacial a partir de entradas de resolução mais baixa. A super-resolução de imagens é um tema clássico dentro do campo da visão computacional, que pode ser amplamente aplicado em tarefas relevantes. Tal técnica tem atraído a atenção de pesquisadores de diferentes áreas por permitir recuperar detalhes de textura de alta qualidade a partir de imagens de baixa resolução. Hoje em dia, com o desenvolvimento do *deep learning*, tal técnica tem feito bastante progresso. O desenvolvimento da metodologia baseada em redes convolucionais como, por exemplo, as redes adversárias generativas (GAN), possibilita a melhora da resolução espacial inicial de imagens de baixa resolução. No contexto de dados geoespaciais, por exemplo, essas técnicas podem ser utilizadas com modelos digitais de elevação, modelos de ondulação geoidal e modelos globais de geopotencial. Similarmente ao existente com imagens digitais, foram criados *datasets* com diferentes pares de modelos digitais de elevação para a realização dos processamentos, com o objetivo de permitir a realização da pesquisa, além de permitir a comparação entre os resultados obtidos. Sendo assim, os produtos gerados foram avaliados quanto à sua utilização na produção de produtos geoespaciais, e verificados quanto à sua utilização em mapeamento cartográfico. Dentre os processamentos realizados,

verificou-se que o aumento do número de épocas é favorável ao desempenho do modelo gerado e ao aumento da qualidade da imagem gerada. Além disso, da análise visual das imagens geradas, de alta e de baixa resolução utilizadas no estudo, percebeu-se a grande semelhança entre as duas primeiras. Como ponto forte, o DEM-ESRGAN apresentou grande possibilidade de modelar superfícies altimétricas com grandes variações de altitude. Já em relação a superfícies com pouca variação de altitudes, o algoritmo em questão não apresentou tão bom desempenho quanto em relação às superfícies citadas anteriormente. Verificou-se, ainda, que o contexto atual para o estudo de super-resolução de modelos digitais de elevação é oportuno, tendo em vista os avanços tecnológicos nas áreas de inteligência artificial, sensores orbitais e recursos computacionais definidos na referida conjuntura.

Palavras-chave: modelos digitais de elevação, redes adversárias generativas, super-resolução de imagens, aprendizado de máquina, aprendizagem profunda, redes neurais, produção cartográfica.

ABSTRACT

In the cartographic production process, the digital elevation models (DEM) are responsible for providing altimetric information of the surface to be mapped. The spatial resolution of such models is directly associated with the scale of cartographic products that can be used. Global models of low and medium spatial resolution are available open source by several space agencies. However, high-resolution models, used at scales 1:25,000 and larger, are scarce and costly. However, this problem can be addressed with the use of deep learning algorithms, associated with image super-resolution techniques (SISR) in digital elevation models, aiming to obtain better spatial quality versions from lower resolution inputs used initially in processing. Here we cover the use of deep learning algorithms along with single-image super-resolution techniques on digital elevation models to obtain better spatial quality versions from lower resolution inputs. Image super-resolution is a classic theme within the field of computer vision, which can be widely applied in relevant tasks. This technique has attracted the attention of researchers from different areas because it allows recovering high quality texture details from low resolution images. Nowadays, with the development of deep learning, such technique has made a lot of progress. The development of a methodology based on convolutional networks, such as generative adversarial networks (GAN), makes it possible to improve the initial spatial resolution of low-resolution images. In the context of geospatial data, for example, these algorithms can be used with digital elevation models, geoidal undulation models and global geopotential models. Similar to what exists with digital images, datasets were created with different pairs of digital elevation models to carry out the processing, with the objective of allowing the research to be carried out, in addition to allowing the comparison between the results obtained. Therefore, the generated products were evaluated regarding their use in the production of geospatial products, and verified regarding their use in cartographic mapping. Among the processing carried out, it was verified that the increase in the number of epochs is favorable to the performance of the generated model and to the increase in the quality of the generated image. In addition, from the visual analysis of the generated images, of high and low resolution used in the study, it was noticed the great similarity between the first

two. As a strong point, DEM-ESRGAN presented a great possibility of modeling altimetric surfaces with large variations in altitude. In relation to surfaces with little variation in altitudes, the algorithm in question did not perform as well as in relation to the surfaces mentioned above. It was also verified that the current context for the study of super-resolution of digital elevation models is opportune, in view of the technological advances in the areas of artificial intelligence, orbital sensors and computational resources defined in the referred conjuncture.

Keywords: Digital Elevation Model, Generative Adversarial Network, image super resolution, machine learning, deep learning, neural networks, cartographic production.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	CONSIDERAÇÕES INICIAIS	1
1.2	PROBLEMA	6
1.3	JUSTIFICATIVA	12
1.4	OBJETIVOS	16
1.4.1	Objetivo geral	16
1.4.2	Objetivos específicos.....	16
1.5	HIPÓTESE	16
1.6	ESTADO DA ARTE	17
1.7	RECURSOS E SUPORTE	20
1.8	ESTRUTURA DA TESE	21
2	REVISÃO TEÓRICA	23
2.1	MODELOS DE SUPERFÍCIES ALTIMÉTRICAS	23
2.1.1	Modelos Digitais de Elevação.....	23
2.1.2	SRTM	24
2.1.3	Alos Palsar	29
2.1.4	MDE do Estado de Santa Catarina.....	31
2.1.5	Inclinação e aspecto do terreno.....	32
2.2	Modelos de Ondulação Geoidal e Modelos Geopotenciais Globais	33
2.3	INTELIGÊNCIA ARTIFICIAL	35
2.3.1	Definições	35
2.3.2	Deep learning	40
2.4	ACURÁCIA POSICIONAL E ANÁLISE DE OBSERVAÇÕES .	46
2.4.1	Acurácia posicional.....	46

2.5	Avaliação de super resolução de superfícies altimétricas	48
3	MATERIAIS E MÉTODOS.....	49
3.1	Aquisição dos dados	49
3.1.1	Área de estudo	49
3.1.2	Dados.....	51
3.2	Geração dos <i>datasets</i>	53
3.2.1	Pré-processamento dos dados	53
3.2.2	Criação dos <i>datasets</i>	58
3.3	Criação dos processos e recursos utilizados	62
3.3.1	Linguagem de programação e relação das bibliotecas Python utilizadas	62
3.3.2	Recursos de <i>software</i> utilizados	64
3.3.3	Recursos de <i>hardware</i> utilizados.....	65
3.4	Processamentos e Geração das superfícies altimétricas.....	66
3.4.1	Aprimoramento do SRGAN para o ESRGAN.....	66
3.4.2	Adaptação do algoritmo ESRGAN para o DEM-ESRGAN..	70
3.4.3	Realização dos Experimentos e seus respectivos processamentos.....	74
3.4.4	Geração das superfícies altimétricas	76
3.5	Avaliação dAs SUPERFÍCIES ALTIMÉTRICAS GERADAS ...	77
3.5.1	Análise dos <i>datasets</i>	77
3.5.2	Análise dos processamentos DEM-ESRGAN	78
3.5.3	Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN	79
3.5.4	Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN.....	80
3.5.5	Avaliação das métricas dos processamentos DEM-ESRGAN	

3.5.6	Visualização dos MDEs de baixa resolução (esquerda), alta resolução (direita) e gerados pelo DEM-ESRGAN (centro).....	91
3.5.7	Comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação.....	92
3.5.8	Análise de curvas de nível geradas automaticamente.....	92
3.5.9	Análise do Padrão de Exatidão Cartográfico Altimétrico.....	93
3.5.10	Análise do Padrão de Exatidão Cartográfico Planimétrico.....	93
3.5.11	Análise da diferença entre superfícies.....	94
3.5.12	Avaliação visual das cumeeiras.....	95
3.5.13	Avaliação visual das redes de drenagens.....	95
3.5.14	Avaliação dos pontos críticos.....	95
3.5.15	Avaliação da declividade dos MDEs.....	96
3.5.16	Avaliação do aspecto dos MDEs.....	96
4	APRESENTAÇÃO DOS RESULTADOS E DISCUSSÃO.....	97
4.1	RESUMO DA METODOLOGIA APLICADA AOS EXPERIMENTOS.....	97
4.1.1	<i>Datasets</i> criados.....	98
4.2	EXPERIMENTO 1 - MODELO DEM-ESRGAN APLICADO AO DATASET 1.....	99
4.2.1	Análise do <i>dataset</i> 1.....	100
4.2.2	Análise dos processamentos DEM-ESRGAN P1, P2 e P3.....	101
4.2.3	Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN.....	103
4.2.4	Análise de curvas de nível geradas automaticamente.....	107
4.2.5	Análise do Padrão de Exatidão Cartográfico Altimétrico.....	109
4.2.6	Análise do Padrão de Exatidão Cartográfico Planimétrico.....	110
4.2.7	Avaliação visual das cumeeiras.....	115

4.3 EXPERIMENTO 2 - MODELO DEM-ESRGAN APLICADO AO DATASET 2 119

4.3.1	Análise do <i>dataset</i> 2.....	120
4.3.2	Análise dos processamentos DEM-ESRGAN P4, P5 e P6	124
4.3.3	Avaliação das métricas dos processamentos DEM-ESRGAN P4, P5 e P6	126
4.3.4	Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6	129
4.3.5	Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6	131
4.3.6	Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN	135
4.3.7	Comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação	138
4.3.8	Análise de curvas de nível geradas automaticamente	139
4.3.9	Análise do Padrão de Exatidão Cartográfico Altimétrico	142
4.3.10	Análise do Padrão de Exatidão Cartográfico Planimétrico	143
4.3.11	Análise da diferença entre superfícies	145
4.3.12	Avaliação visual das cumeeiras	146
4.3.13	Avaliação visual das redes de drenagens	150
4.3.14	Avaliação dos pontos críticos	151
4.3.15	Avaliação da declividade dos MDEs	153
4.3.16	Avaliação do aspecto dos MDEs	154

4.4 EXPERIMENTO 3 - MODELO DEM-ESRGAN APLICADO AO DATASET 3 154

4.4.1	Análise do <i>dataset</i> 3.....	155
4.4.2	Análise dos processamentos DEM-ESRGAN P7, P8 e P9	155

4.4.3	Avaliação das métricas dos processamentos DEM-ESRGAN P7, P8 e P9	156
4.4.4	Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9	161
4.4.5	Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9	163
4.4.6	Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN	167
4.4.7	Análise de curvas de nível geradas automaticamente	171
4.4.8	Análise do Padrão de Exatidão Cartográfico Altimétrico	173
4.4.9	Análise do Padrão de Exatidão Cartográfico Planimétrico	174
4.4.10	Análise da diferença entre superfícies	179
4.4.11	Avaliação visual das cumeeiras	180
4.4.12	Avaliação visual das redes de drenagens	184
4.4.13	Avaliação dos pontos críticos	185
4.4.14	Avaliação da declividade dos MDEs	187
4.4.15	Avaliação do aspecto dos MDEs	188
4.5	EXPERIMENTO 4 - MODELO DEM-ESRGAN APLICADO AO DATASET 4	188
4.5.1	Análise do <i>dataset</i> 4	189
4.5.2	Análise dos processamentos DEM-ESRGAN P10, P11 e P12	194
4.5.3	Avaliação das métricas dos processamentos DEM-ESRGAN P10, P11 e P12	195
4.5.4	Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12	199
4.5.5	Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12	201

4.5.6	Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN	203
4.5.7	Comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação	206
4.5.8	Análise de curvas de nível geradas automaticamente	207
4.5.9	Análise do Padrão de Exatidão Cartográfico Altimétrico	210
4.5.10	Análise do Padrão de Exatidão Cartográfico Planimétrico	211
4.5.11	Análise da diferença entre superfícies	215
4.5.12	Avaliação visual das cumeeiras	216
4.5.13	Avaliação visual das redes de drenagens	220
4.5.14	Avaliação dos pontos críticos	221
4.5.15	Avaliação da declividade dos MDEs	223
4.5.16	Avaliação do aspecto dos MDEs	223
4.6	EXPERIMENTO 5 - MODELO DEM-ESRGAN APLICADO AO DATASET 5	224
4.6.1	Análise do <i>dataset</i> 5	225
4.6.2	Análise dos processamentos DEM-ESRGAN P13, P14 e P15	228
4.6.3	Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN	229
4.6.4	Análise de curvas de nível geradas automaticamente	232
4.6.5	Análise do Padrão de Exatidão Cartográfico Altimétrico	234
4.6.6	Avaliação visual das cumeeiras	235
4.7	EXPERIMENTO 6 - MODELO DEM-ESRGAN APLICADO AO DATASET 6	238
4.7.1	Análise do <i>dataset</i> 6	238
4.7.2	Análise dos processamentos DEM-ESRGAN P16, P17 e P18	242

4.7.3	Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN	244
4.7.4	Análise do Padrão de Exatidão Cartográfico Altimétrico	248
4.8	SÍNTESE DOS EXPERIMENTOS ANALISADOS.....	249
5	CONCLUSÕES E RECOMENDAÇÕES	251
5.1	CONCLUSÕES	251
5.2	RECOMENDAÇÕES	253
	Referências Bibliográficas	255
	ANEXO 1.....	267
	SÍNTESE DA <i>PIPELINE</i>	267

LISTA DE FIGURAS

FIGURA 1 - INCONSISTÊNCIA ENTRE OS VALORES DA MEDIDA DE DISTORÇÃO PSNR E SSIM E DA QUALIDADE PERCEPTIVA DOS MÉTODOS DE SUPER-RESOLUÇÃO SRGAN (SUPER-RESOLUTION GAN), SRRESNET (SUPER-RESOLUTION RESIDUAL NEURAL NETWORK) E NN INTERPOLATION (INTERPOLAÇÃO PELO VIZINHO MAIS PRÓXIMO), ONDE VERIFICA-SE UM DESACORDO ENTRE A ANÁLISE VISUAL DE CADA UMA DAS IMAGENS EM RELAÇÃO AOS VALORES OBTIDOS DAS MÉTRICAS UTILIZADAS EM SUAS AVALIAÇÕES (PSNR E SSIM).	5
FIGURA 2 - SITUAÇÃO ATUAL DO MAPEAMENTO SISTEMÁTICO BÁSICO NA ESCALA 1:25.000 NO ANO DE 2020. AS ÁREAS APRESENTADAS NA COR CINZA APRESENTAM O MAPEAMENTO SISTEMÁTICO BÁSICO REALIZADO NA ESCALA DE 1:25.000.....	8
FIGURA 3 - COMPARAÇÃO ENTRE 2 (DOIS) TIPOS DE MDE: O MDT E O MDS.	24
FIGURA 4 - DETALHES DO RADAR INTERFEROMÉTRICO SRTM.....	26
FIGURA 5 - IMAGEM DO PORTAL DE SIG DO ESTADO DE SANTA CATARINA.....	32
FIGURA 6 - EXEMPLO DE MAPA DE ASPECTO.	33
FIGURA 7 - DIFERENÇA ENTRE GEÓIDE, ELIPSÓIDE E SUPERFÍCIE TERRESTRE, ONDE H SIGNIFICA ALTITUDE ORTOMÉTRICA, H SIGNIFICA ALTITUDE ELIPSOIDAL, E N SIGNIFICA ONDULAÇÃO GEOIDAL.....	34
FIGURA 8 - DIVISÕES DA INTELIGÊNCIA ARTIFICIAL.....	36
FIGURA 9 - TIPOS E EXEMPLOS DE USO DO APRENDIZADO DE MÁQUINA.	39
FIGURA 10 - DIAGRAMA DE UMA CNN BÁSICA.....	41
FIGURA 11 - ESQUEMA DE UMA REDE ADVERSÁRIA GENERATIVA.	46
FIGURA 12 - LOCALIZAÇÃO DA ÁREA DE ESTUDOS.	50
FIGURA 13 - FLUXOGRAMA DE AQUISIÇÃO DOS DADOS REFERENTES AOS MDES PARA A PESQUISA.	52
FIGURA 14 - FLUXOGRAMA DE AQUISIÇÃO DOS DADOS REFERENTES AOS MGG EGM2008 E MOG MAPGEO2015 PARA A PESQUISA.....	53
FIGURA 15 - FLUXOGRAMA DE PRÉ-PROCESSAMENTO DOS DADOS DOS MODELOS PARA PESQUISA.	55
FIGURA 16 - FLUXOGRAMA DE METODOLOGIA DE GERAÇÃO DE IMAGEM BINÁRIA DOS DADOS DO MODELO.....	56

FIGURA 17 - IMAGEM BINÁRIA DO ARQUIVO DO MDE SRTM DE RESOLUÇÃO DE 30 METROS, VISUALIZADA NO QGIS, ONDE OS PIXELS EM COR AMARELA TÊM VALOR 1 E OS PIXELS EM COR PRETA TÊM VALOR 0.....	58
FIGURA 18 - FLUXOGRAMA DE CRIAÇÃO DE DATASETS PARA A PESQUISA.....	60
FIGURA 19 - FLUXOGRAMA DE CRIAÇÃO DE MOSAICOS PARA A CONSTRUÇÃO DE DATASETS PARA A PESQUISA.....	61
FIGURA 20 - GERAÇÃO DAS SUPERFÍCIES GEOIDAIS.	62
FIGURA 21 - RESULTADOS PARA A SUPER RESOLUÇÃO 4X PARA O SRGAN E O ESRGAN, MOSTRANDO A SUPERAÇÃO DO ESRGAN EM RELAÇÃO AO SRGAN EM NITIDEZ DETALHES.	67
FIGURA 22 - CONTEXTUALIZAÇÃO DE ALGORITMOS DE DEEP LEARNING ATÉ O DEM-ESRGAN.....	71
FIGURA 23 - FLUXOGRAMA DO ESRGAN.	72
FIGURA 24 - FLUXOGRAMA DO DEM-ESRGAN.	73
FIGURA 25 - DIVISÃO DOS EXPERIMENTOS EM CATEGORIAS.	75
FIGURA 26 - FLUXOGRAMA DA GERAÇÃO DAS ESTATÍSTICAS DESCRITIVAS.	78
FIGURA 27 - FLUXOGRAMA DA ANÁLISE DE ERRO E PRECISÃO DAS IMAGENS DE TREINO DOS PROCESSAMENTOS.	79
FIGURA 28 - FLUXOGRAMA DA ANÁLISE DE PIXELS DAS IMAGENS.	83
FIGURA 29 - FLUXOGRAMA DA ANÁLISE DA REDUÇÃO DOS ERROS DOS PIXELS DAS IMAGENS GERADAS.	87
FIGURA 30 - FLUXOGRAMA ANÁLISE DA VARIAÇÃO DAS MÉTRICAS DOS PROCESSAMENTOS EM FUNÇÃO DA MÉDIA.	91
FIGURA 31 - FLUXOGRAMA DO BENCHMARK DAS MÉTRICAS DAS IMAGENS INTERPOLADAS.....	92
FIGURA 32 - FLUXOGRAMA DA GERAÇÃO DA DIFERENÇA DE IMAGENS.....	94
FIGURA 33 - SOBREPOSIÇÃO DOS PARES DE AMOSTRAS DOS DATASETS.....	98
FIGURA 34 - 4 AMOSTRAS DE BAIXA RESOLUÇÃO GERADAS PARA O DATASET MDE SRTM DE 90 METROS (LR) E MDE SRTM DE 30 METROS (HR) COM TILES DE 156 X 156 PIXELS USADAS PARA PERFORMAR O TREINAMENTO MDTERSGAN.	99
FIGURA 35 - 4 AMOSTRAS DE BAIXA RESOLUÇÃO GERADAS PARA O DATASET MDE SRTM DE 90 METROS (LR) E MDE SRTM DE 30 METROS (HR) COM TILES DE 156 X 156 PIXELS USADAS PARA PERFORMAR A VALIDAÇÃO DO MDTERSGAN.	99

FIGURA 36 - IMAGEM DO ARQUIVO DE ALTA RESOLUÇÃO DO MDT ESC DE RESOLUÇÃO DE 1 METRO, VISUALIZADA NO QGIS.....	101
FIGURA 37 - VARIAÇÃO DOS VALORES DA MÉTRICA DO PSNR DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P1, P2 E P3) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000).	102
FIGURA 38 - VARIAÇÃO DOS VALORES APRESENTADOS PELAS FUNÇÕES DE PERDA L_G_PERCEP DE CADA UM DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P1, P2 E P3) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000).	103
FIGURA 39 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P1.	104
FIGURA 40 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P1.	104
FIGURA 41 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P1.	104
FIGURA 42 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P2.	105
FIGURA 43 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P2.	105
FIGURA 44 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P2.	105
FIGURA 45 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P3.	106
FIGURA 46 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P3.	106

FIGURA 47 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P3.	106
FIGURA 48 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 1 DOS PROCESSAMENTOS P1, P2 E P3.	107
FIGURA 49 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 2 DOS PROCESSAMENTOS P1, P2 E P3.	108
FIGURA 50 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 3 DOS PROCESSAMENTOS P1, P2 E P3.	108
FIGURA 51 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 1 DO PROCESSAMENTO P3 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GROUND TRUTH E AS LINHAS VERMELHAS SÃO REFERENTES À REDE.	111
FIGURA 52 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 2 DO PROCESSAMENTO P3 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GROUND TRUTH E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).	112
FIGURA 53 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 3 DO PROCESSAMENTO P3 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GROUND TRUTH E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).	114
FIGURA 54 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 1 DOS PROCESSAMENTOS DEM-ESRGAN P1, P2 E P3.	116
FIGURA 55 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 2 DOS PROCESSAMENTOS DEM-ESRGAN P1, P2 E P3.	117
FIGURA 56 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 3 DOS PROCESSAMENTOS DEM-ESRGAN P1, P2 E P3.	118
FIGURA 57 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 4 DOS PROCESSAMENTOS DEM-ESRGAN P1, P2 E P3.	119

FIGURA 58 - IMAGEM DO MDE SRTM DE ALTA RESOLUÇÃO UTILIZADO PARA A EXTRAÇÃO DOS PARES DE AMOSTRAS (NO QUE TANGE AS AMOSTRAS DE ALTA RESOLUÇÃO).....	121
FIGURA 59 - IMAGEM DO MDE SRTM DE BAIXA RESOLUÇÃO UTILIZADO PARA A EXTRAÇÃO DOS PARES DE AMOSTRAS (NO QUE TANGE AS AMOSTRAS DE BAIXA RESOLUÇÃO).....	121
FIGURA 60 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS PIXELS DO MDE (IMAGEM) DE BAIXA RESOLUÇÃO EM FUNÇÃO DE VALORES ALTIMÉTRICOS (VALOR DOS PIXELS EM METRO).....	123
FIGURA 61 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS PIXELS DO MDE (IMAGEM) DE ALTA RESOLUÇÃO MODELO EM FUNÇÃO DE VALORES ALTIMÉTRICOS (VALOR DOS PIXELS EM METRO).	124
FIGURA 62 - VARIAÇÃO DOS VALORES DA MÉTRICA DO PSNR DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P1, P2 E P3) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000).	125
FIGURA 63 - VARIAÇÃO DOS VALORES APRESENTADOS PELAS FUNÇÕES DE PERDA L_G_PERCEP DE CADA UM DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P1, P2 E P3) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000).	125
FIGURA 64 - GRÁFICO DE ANÁLISE DOS PSNR DOS PROCESSAMENTOS DEM- ESRGAN P4, P5 E P6.....	126
FIGURA 65 - VALORES DA MÉTRICA PSNR DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	127
FIGURA 66 - VALORES DA MÉTRICA SSIM DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	127
FIGURA 67 - VALORES DA MÉTRICA NIQE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	128
FIGURA 68 - VALORES DA MÉTRICA MSE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	128
FIGURA 69 - VALORES DA MÉTRICA RMSE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6 (VALOR DA MÉTRICA EM METROS).	129
FIGURA 70 – GRÁFICO DA VARIAÇÃO DO ERRO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	130

FIGURA 71 – GRÁFICO DA VARIAÇÃO DA PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	131
FIGURA 72 – GRÁFICO DE GANHOS DE ERRO E PRECISÃO DE IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	132
FIGURA 73 – GRÁFICO DE ERROS E PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P1, P2 E P3.	133
FIGURA 74 – GRÁFICO DE GANHO DAS IMAGENS GERADAS EM RELAÇÃO A IMAGEM LR EM NÚMERO DE <i>PIXELS</i> NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	134
FIGURA 75 – GRÁFICO DA ANÁLISE DO NÚMERO DE <i>PIXELS</i> COM ERROS MENORES NAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6.	134
FIGURA 76 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P4.	135
FIGURA 77 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P4.	136
FIGURA 78 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P4.	136
FIGURA 79 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P5.	136
FIGURA 80 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P5.	137
FIGURA 81 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P5.	137
FIGURA 82 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P6.	137

FIGURA 83 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P6.	138
FIGURA 84 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P6.	138
FIGURA 85 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 1 DOS PROCESSAMENTOS P4, P5 E P6.	140
FIGURA 86 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 2 DOS PROCESSAMENTOS P4, P5 E P6.	140
FIGURA 87 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 3 DOS PROCESSAMENTOS P4, P5 E P6.	141
FIGURA 88 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 4 DOS PROCESSAMENTOS P4, P5 E P6.	141
FIGURA 89 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 1 DO PROCESSAMENTO P4 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).	144
FIGURA 90 - DIFERENÇA ENTRE SUPERFÍCIES DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6 ..	146
FIGURA 91 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 1 DOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	147
FIGURA 92 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 2 DOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	148
FIGURA 93 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 3 DOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	149
FIGURA 94 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 4 DOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	150

FIGURA 95 - MDEs CONTENDO O RESULTADO DOS CANAIS DE DRENAGENS DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	151
FIGURA 96 - MDEs DE ALTA RESOLUÇÃO E MDEs GERADOS PELO CONJUNTO DE VALIDAÇÃO DO <i>DATASET 2</i> CONTENDO SUAS RESPECTIVAS ALTITUDES MÁXIMAS E MÍNIMAS DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6, ONDE OS <i>PIXELS</i> DE ALTITUDE MÍNIMA SÃO REPRESENTADOS PELA COR AZUL E OS DE ALTITUDE MÁXIMA PELA COR VERMELHA	152
FIGURA 97 - MDEs CONTENDO O RESULTADO DA DECLIVIDADE DO TERRENO DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6	153
FIGURA 98 - MDEs CONTENDO O RESULTADO DO ASPECTO DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P1, P2 E P3	154
FIGURA 99 - VARIAÇÃO DOS VALORES DA MÉTRICA DO PSNR DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P7, P8 E P9) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000)	155
FIGURA 100 - VARIAÇÃO DOS VALORES APRESENTADOS PELAS FUNÇÕES DE PERDA L_G_PERCEP DE CADA UM DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P7, P8 E P9) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000)	156
FIGURA 101 - GRÁFICO DE ANÁLISE DOS PSNR DOS PROCESSAMENTOS DEM- ESRGAN P7, P8 E P9.....	157
FIGURA 102 - VALORES DA MÉTRICA PSNR DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	158
FIGURA 103 - VALORES DA MÉTRICA SSIM DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	158
FIGURA 104 - VALORES DA MÉTRICA NIQE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	159
FIGURA 105 - VALORES DA MÉTRICA MSE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	160

FIGURA 106 - VALORES DA MÉTRICA RMSE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9 (VALOR DA MÉTRICA EM METROS).	161
FIGURA 107 - GRÁFICO DA VARIAÇÃO DO ERRO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9 (EM METROS)	162
FIGURA 108 - GRÁFICO DA VARIAÇÃO DA PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9 (ONDE K EQUIVALE A 1.000)	163
FIGURA 109 – GRÁFICO DE GANHOS DE ERRO E PRECISÃO DE IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	164
FIGURA 110 - GRÁFICO DE ERRO E PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	165
FIGURA 111 - GRÁFICO DE GANHO DAS IMAGENS GERADAS EM RELAÇÃO À IMAGEM LR EM NÚMERO DE <i>PIXELS</i> NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	166
FIGURA 112 - GRÁFICO DA ANÁLISE DO NÚMERO DE <i>PIXELS</i> COM ERROS MENORES NAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	167
FIGURA 113 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P7.	168
FIGURA 114 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P7.	168
FIGURA 115 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P7.	168
FIGURA 116 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P8.	169
FIGURA 117 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P8.	169
FIGURA 118 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P8.	169

FIGURA 119 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P9.	170
FIGURA 120 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P9.	170
FIGURA 121 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P9.	170
FIGURA 122 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 1 DOS PROCESSAMENTOS P7, P8 E P9	171
FIGURA 123 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 2 DOS PROCESSAMENTOS P7, P8 E P9	172
FIGURA 124 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 3 DOS PROCESSAMENTOS P7, P8 E P9	172
FIGURA 125 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 4 DOS PROCESSAMENTOS P7, P8 E P9	173
FIGURA 126 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 1 DO PROCESSAMENTO P9 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).....	175
FIGURA 127 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 2 DO PROCESSAMENTO P9 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).....	176
FIGURA 128 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 3 DO PROCESSAMENTO P9 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA	

IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).....	178
FIGURA 129 - DIFERENÇA ENTRE SUPERFÍCIES DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS P7, P8 E P9 (VALORES EM METROS).	180
FIGURA 130 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 1 DOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	181
FIGURA 131 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 2 DOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	182
FIGURA 132 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 3 DOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	183
FIGURA 133 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 4 DOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	184
FIGURA 134 - MDEs CONTENDO O RESULTADO DOS CANAIS DE DRENAGENS DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	185
FIGURA 135 - MDEs DE ALTA RESOLUÇÃO E MDEs GERADOS PELO CONJUNTO DE VALIDAÇÃO DO <i>DATASET 3</i> CONTENDO SUAS RESPECTIVAS ALTITUDES MÁXIMAS E MÍNIMAS DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9, ONDE OS <i>PIXELS</i> DE ALTITUDE MÍNIMA SÃO REPRESENTADOS PELA COR AZUL E OS <i>PIXELS</i> DE ALTITUDE MÁXIMA SÃO REPRESENTADOS PELA COR VERMELHA.....	186
FIGURA 136 - MDEs CONTENDO O RESULTADO DA DECLIVIDADE DO TERRENO DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	187
FIGURA 137 - MDEs CONTENDO O RESULTADO DO ASPECTO DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9	188
FIGURA 138 - IMAGEM DO MDE ALOS PALSAR DE ALTA RESOLUÇÃO UTILIZADO PARA A EXTRAÇÃO DOS PARES DE AMOSTRAS (NO QUE TANGE AS AMOSTRAS DE ALTA RESOLUÇÃO), COM RESOLUÇÃO ESPACIAL DE 12,5 METROS, VISUALIZADA NO QGIS.....	190
FIGURA 139 - IMAGEM DO MDE SRTM DE BAIXA RESOLUÇÃO UTILIZADO PARA A EXTRAÇÃO DOS PARES DE AMOSTRAS (NO QUE TANGE AS AMOSTRAS DE BAIXA	

RESOLUÇÃO), COM RESOLUÇÃO ESPACIAL DE 30 METROS, VISUALIZADA NO QGIS	191
FIGURA 140 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS <i>PIXELS</i> DO MDE (IMAGEM) DE BAIXA RESOLUÇÃO EM FUNÇÃO DE VALORES ALTIMÉTRICOS	193
FIGURA 141 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS <i>PIXELS</i> DO MDE (IMAGEM) DE ALTA RESOLUÇÃO MODELO EM FUNÇÃO DE VALORES ALTIMÉTRICOS	193
FIGURA 142 - VARIAÇÃO DOS VALORES DA MÉTRICA DO PSNR DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P10, P11 E P12) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000)	194
FIGURA 143 - VARIAÇÃO DOS VALORES APRESENTADOS PELAS FUNÇÕES DE PERDA L_G_PERCEP DE CADA UM DOS PROCESSAMENTOS DEM-ESRGAN EXECUTADOS (P10, P11 E P12) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000)	195
FIGURA 144 - GRÁFICO DE ANÁLISE DOS PSNR DOS PROCESSAMENTOS P7, P8 E P9	196
FIGURA 145 - VALORES DA MÉTRICA PSNR DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS P10, P11 E P12	197
FIGURA 146 - VALORES DA MÉTRICA SSIM DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS P10, P11 E P12	197
FIGURA 147 - VALORES DA MÉTRICA NIQE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS P10, P11 E P12	198
FIGURA 148 - VALORES DA MÉTRICA MSE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS P10, P11 E P12	198
FIGURA 149 - VALORES DA MÉTRICA RMSE DE 10 IMAGENS GERADAS NOS PROCESSAMENTOS P10, P11 E P12	199
FIGURA 150 - GRÁFICO DA VARIAÇÃO DO ERRO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12 (ONDE K EQUIVALE A 1.000)	200
FIGURA 151 - GRÁFICO DA VARIAÇÃO DA PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12 (ONDE K EQUIVALE A 1.000)	200
FIGURA 152 - GRÁFICO DE ERROS E PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	201

FIGURA 153 - GRÁFICO DE GANHO DAS IMAGENS GERADAS EM RELAÇÃO A IMAGEM LR EM NÚMERO DE <i>PIXELS</i> NOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12	202
FIGURA 154 - GRÁFICO DA ANÁLISE DO NÚMERO DE <i>PIXELS</i> COM ERROS MENORES NAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12	203
FIGURA 155 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P10.	204
FIGURA 156 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P10.	204
FIGURA 157 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P10.	204
FIGURA 158 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P11.	205
FIGURA 159 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P11.	205
FIGURA 160 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P11.	205
FIGURA 161 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P12.	205
FIGURA 162 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P12.	206
FIGURA 163 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P12.	206

FIGURA 164 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 1 DOS PROCESSAMENTOS P10, P11 E P12	208
FIGURA 165 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 2 DOS PROCESSAMENTOS P10, P11 E P12	208
FIGURA 166 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 3 DOS PROCESSAMENTOS P10, P11 E P12	209
FIGURA 167 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 4 DOS PROCESSAMENTOS P10, P11 E P12	209
FIGURA 168 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 1 DO PROCESSAMENTO P12 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).....	212
FIGURA 169 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 2 DO PROCESSAMENTO P12 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).....	213
FIGURA 170 - LEVANTAMENTO DOS 10 PONTOS HOMÓLOGOS SELECIONADOS NA IMAGEM 3 DO PROCESSAMENTO P12 UTILIZANDO AS REDES DE DRENAGENS DAS IMAGENS (ONDE AS LINHAS VERDES SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM <i>GROUND TRUTH</i> E AS LINHAS VERMELHAS SÃO REFERENTES À REDE DE DRENAGEM DA IMAGEM GERADA).....	214
FIGURA 171 - DIFERENÇA ENTRE SUPERFÍCIES DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS P10, P11 E P12.....	216
FIGURA 172 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 1 DOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	217
FIGURA 173 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 2 DOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	218

FIGURA 174 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 3 DOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	219
FIGURA 175 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 4 DOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	220
FIGURA 176 - MDEs CONTENDO O RESULTADO DOS CANAIS DE DRENAGENS DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	221
FIGURA 177 - MDEs DE ALTA RESOLUÇÃO E MDEs GERADOS PELO CONJUNTO DE VALIDAÇÃO DO <i>DATASET</i> 4 CONTENDO SUAS RESPECTIVAS ALTITUDES MÁXIMAS E MÍNIMAS DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12, ONDE OS <i>PIXELS</i> DE ALTITUDE MÍNIMA SÃO REPRESENTADOS PELA COR AZUL E OS <i>PIXELS</i> DE ALTITUDE MÁXIMA SÃO REPRESENTADOS PELA COR VERMELHA.....	222
FIGURA 178 - MDEs CONTENDO O RESULTADO DA DECLIVIDADE DO TERRENO DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12.....	223
FIGURA 179 - MDEs CONTENDO O RESULTADO DO ASPECTO DAS IMAGENS DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELOS PROCESSAMENTOS DEM-ESRGAN P10, P11 E P12	224
FIGURA 180 - IMAGEM DO ARQUIVO DE ALTA RESOLUÇÃO DO MDT ESC DE RESOLUÇÃO DE 1 METRO, VISUALIZADA NO QGIS	226
FIGURA 181 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS <i>PIXELS</i> DO MDE (IMAGEM) DE BAIXA RESOLUÇÃO EM FUNÇÃO DE VALORES ALTIMÉTRICOS	227
FIGURA 182 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS <i>PIXELS</i> DO MDE (IMAGEM) DE ALTA RESOLUÇÃO MODELO EM FUNÇÃO DE VALORES ALTIMÉTRICOS	228
FIGURA 183 - VARIAÇÃO DOS VALORES DA MÉTRICA DO PSNR DOS PROCESSAMENTOS EXECUTADOS (P13, P14 E P15) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000)	228
FIGURA 184 - VARIAÇÃO DOS VALORES APRESENTADOS PELAS FUNÇÕES DE PERDA L_G_PERCEP DE CADA UM DOS PROCESSAMENTOS EXECUTADOS (P13, P14 E P15) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000).....	229

FIGURA 185 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P13.....	230
FIGURA 186 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P13.....	230
FIGURA 187 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P13.....	230
FIGURA 188 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P14.....	231
FIGURA 189 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P14.....	231
FIGURA 190 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P14.....	231
FIGURA 191 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P15.....	231
FIGURA 192 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P15.....	232
FIGURA 193 - EXEMPLO DA IMAGEM GERADA (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P15.....	232
FIGURA 194 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 1 DOS PROCESSAMENTOS P13, P14 E P15	233
FIGURA 195 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 2 DOS PROCESSAMENTOS P13, P14 E P15	233

FIGURA 196 - CURVAS DE NÍVEL DA IMAGEM DE ALTA RESOLUÇÃO E DAS IMAGENS GERADAS PELO ALGORITMO DEM-ESRGAN DA IMAGEM 3 DOS PROCESSAMENTOS P13, P14 E P15	234
FIGURA 197 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 1 DOS PROCESSAMENTOS DEM-ESRGAN P13, P14 E P15.....	236
FIGURA 198 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 2 DOS PROCESSAMENTOS DEM-ESRGAN P13, P14 E P15.....	237
FIGURA 199 - LINHAS DE CUMEEIRAS DAS IMAGENS DA IMAGEM 3 DOS PROCESSAMENTOS DEM-ESRGAN P13, P14 E P15.....	238
FIGURA 200 - IMAGEM DO ARQUIVO ICGEM.TIF DE RESOLUÇÃO DE 30 METROS, VISUALIZADA NO QGIS.....	240
FIGURA 201 - IMAGEM DO ARQUIVO MAPGEO.TIF DO IBGE DE RESOLUÇÃO DE 90 METROS, VISUALIZADA NO QGIS	240
FIGURA 202 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS <i>PIXELS</i> DO MOG (IMAGEM) DE BAIXA RESOLUÇÃO EM FUNÇÃO DE VALORES ALTIMÉTRICOS	242
FIGURA 203 - HISTOGRAMA MOSTRANDO A DISTRIBUIÇÃO DOS <i>PIXELS</i> DO MGG (IMAGEM) DE ALTA RESOLUÇÃO MODELO EM FUNÇÃO DE VALORES ALTIMÉTRICOS	242
FIGURA 204 - VARIAÇÃO DOS VALORES DA MÉTRICA DO PSNR DOS PROCESSAMENTOS EXECUTADOS (P16, P17 E P18) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000)	243
FIGURA 205 - VARIAÇÃO DOS VALORES APRESENTADOS PELAS FUNÇÕES DE PERDA <i>L_G_PERCEP</i> DE CADA UM DOS PROCESSAMENTOS EXECUTADOS (P16, P17 E P18) EM FUNÇÃO DA PROGRESSÃO DAS ÉPOCAS DOS MESMOS (ONDE K EQUIVALE A 1.000).....	244
FIGURA 206 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P16.	245
FIGURA 207 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P16.	245
FIGURA 208 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P16.	245

FIGURA 209 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P17.	246
FIGURA 210 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P17.	246
FIGURA 211 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P17.	246
FIGURA 212 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 1 DO PROCESSAMENTO P18.	247
FIGURA 213 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 2 DO PROCESSAMENTO P18.	247
FIGURA 214 - EXEMPLO DA IMAGEM GERADA PELO ALGORITMO DEM-ESRGAN (CENTRO), DA IMAGEM DE ALTA RESOLUÇÃO (DIREITA) E DA IMAGEM DE BAIXA RESOLUÇÃO (ESQUERDA) DA IMAGEM 3 DO PROCESSAMENTO P18.	247
FIGURA 215 - FLUXOGRAMA-SÍNTESE DA PIPELINE ADOTADA NA PESQUISA.	268
FIGURA 216 - FLUXOGRAMA-SÍNTESE DA PIPELINE ADOTADA NAS ANÁLISES ESTATÍSTICAS DA PESQUISA.	269
FIGURA 217 - FLUXOGRAMA-SÍNTESE DA PIPELINE ADOTADA NAS ANÁLISES VISUAIS DA PESQUISA.	270
FIGURA 218 - FLUXOGRAMA-SÍNTESE DA PIPELINE ADOTADA NAS ANÁLISES DO PADRÃO DE EXATIDÃO CARTOGRÁFICA DA PESQUISA.	271

LISTA DE TABELAS

TABELA 1 - QUADRO COM O PEC ALTIMÉTRICO E O EP (ERRO PADRÃO) DAS CARTAS EM FUNÇÃO DAS EQUIDISTÂNCIAS.....	47
TABELA 2 - QUADRO COM O PEC PLANIMÉTRICO E O EP (ERRO PADRÃO) DAS CARTAS EM FUNÇÃO DAS EQUIDISTÂNCIAS.....	47
TABELA 3 - QUADRO COM OS VALORES DO PEC-PCD PARA MODELOS DIGITAIS DE SUPERFÍCIE E DO TERRENO PARA A PRODUÇÃO DE PRODUTOS CARTOGRÁFICOS DIGITAIS.....	48
TABELA 4 - ESPECIFICAÇÕES TÉCNICAS DO HARDWARE DE PROCESSAMENTO.....	66
TABELA 5 - TABELA CONTENDO OS DADOS E OS PARÂMETROS UTILIZADOS NOS EXPERIMENTOS DA TESE.....	76
TABELA 6 - CARACTERÍSTICAS DO DATASET 1	100
TABELA 7 - TABELA DOS VALORES CALCULADOS DO ERRO MÉDIO E DO ERRO PADRÃO DAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS.....	109
TABELA 8 - TABELA DO PEC ALTIMÉTRICO ATINGIDO PELAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS PARA AS ESCALAS DO MAPEAMENTO SISTEMÁTICO.....	110
TABELA 9 - TABELA COM AS DIFERENÇAS DOS PONTOS HOMÓLOGOS	111
TABELA 10 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 1 DO PROCESSAMENTO P3 PARA AS ESCALAS DE 1:250.000 A 1:1.000.....	112
TABELA 11 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 2 DO PROCESSAMENTO P3.	113
TABELA 12 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 2 DO PROCESSAMENTO P3 PARA AS ESCALAS DE 1:250000 A 1:1000.....	113
TABELA 13 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 3 DO PROCESSAMENTO P3.	114
TABELA 14 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 3 DO PROCESSAMENTO P3 PARA AS ESCALAS DE 1:250000 A 1:1000.....	114
TABELA 15 - TABELA DAS CARACTERÍSTICAS DOS MDEs DE ALTA E DE BAIXA RESOLUÇÃO UTILIZADOS NO DATASET 2.	120

TABELA 16 – APRESENTAÇÃO DAS ESTATÍSTICAS DOS MDEs DE ALTA E BAIXA RESOLUÇÃO UTILIZADOS PARA A EXTRAÇÃO DOS PARES DE AMOSTRAS DAS IMAGENS DE TREINAMENTO E VALIDAÇÃO DO <i>DATASET 2</i>	122
TABELA 17 - TABELA DE CÁLCULO DA MÉDIA DO ERRO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6 (ONDE K EQUIVALE A 1.000).	129
TABELA 18 - TABELA DE CÁLCULO DA MÉDIA DA PRECISÃO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P4, P5 E P6 (ONDE K EQUIVALE A 1.000).	130
TABELA 19 - TABELA DAS ANÁLISES DAS IMAGENS DOS PROCESSAMENTOS DEM- ESRGAN P4, P5 E P6 QUANTO AOS GANHOS DE ERRO E PRECISÃO PERCENTUAIS.....	132
TABELA 20 - TABELA DE COMPARAÇÃO DAS MÉTRICAS PSNR, SSIM, MSE E RMSE DOS RESULTADOS DE DIFERENTES INTERPOLADORES	139
TABELA 21 - TABELA DOS VALORES CALCULADOS DO ERRO MÉDIO E DO ERRO PADRÃO DAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS.....	142
TABELA 22 - TABELA DO PEC ALTIMÉTRICO ATINGIDO PELAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS PARA AS ESCALAS DO MAPEAMENTO SISTEMÁTICO.....	142
TABELA 23 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 1 DO PROCESSAMENTO P4	144
TABELA 24 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 1 DO PROCESSAMENTO P4 PARA AS ESCALAS DE 1:250.000 A 1:1.000	144
TABELA 25 - TABELA DE CÁLCULO DA MÉDIA DO ERRO DAS IMAGENS GERADAS NOS PROCESSAMENTOS DEM-ESRGAN P7, P8 E P9 (EM METROS)	161
TABELA 26 - TABELA DOS VALORES CALCULADOS DO ERRO MÉDIO E DO ERRO PADRÃO DAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS.....	174
TABELA 27 - TABELA DO PEC ALTIMÉTRICO ATINGIDO PELAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS PARA AS ESCALAS DO MAPEAMENTO SISTEMÁTICO.....	174
TABELA 28 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 1 DO PROCESSAMENTO P9	176

TABELA 29 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 1 DO PROCESSAMENTO P9 PARA AS ESCALAS DE 1:250000 A 1:1000	176
TABELA 30 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 2 DO PROCESSAMENTO P9	177
TABELA 31 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 2 DO PROCESSAMENTO P9 PARA AS ESCALAS DE 1:250000 A 1:1000.....	177
TABELA 32 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 3 DO PROCESSAMENTO P9	178
TABELA 33 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 3 DO PROCESSAMENTO P9 PARA AS ESCALAS DE 1:250000 A 1:1000	179
TABELA 34 – TABELA DAS CARACTERÍSTICAS DOS MDEs DE ALTA E BAIXA RESOLUÇÃO UTILIZADOS NO <i>DATASET 4</i>	189
TABELA 35 - ANÁLISE ESTATÍSTICA DAS IMAGENS UTILIZADAS.....	192
TABELA 36 - TABELA DE COMPARAÇÃO DAS MÉTRICAS PSNR, SSIM, MSE E RMSE DOS RESULTADOS DE DIFERENTES INTERPOLADORES	207
TABELA 37 - TABELA DOS VALORES CALCULADOS DO ERRO MÉDIO E DO ERRO PADRÃO DAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS.....	210
TABELA 38 - TABELA DO PEC ALTIMÉTRICO ATINGIDO PELAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS PARA AS ESCALAS DO MAPEAMENTO SISTEMÁTICO.....	211
TABELA 39 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 1 DO PROCESSAMENTO P12.....	212
TABELA 40 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 1 DO PROCESSAMENTO P12 PARA AS ESCALAS DE 1:250000 A 1:1000	212
TABELA 41 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 2 DO PROCESSAMENTO P12.....	213
TABELA 42 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 2 DO PROCESSAMENTO P12 PARA AS ESCALAS DE 1:250000 A 1:1000	214

TABELA 43 - TABELA DOS VALORES CALCULADOS DAS DIFERENÇAS EM E E N, DAS DISTÂNCIAS EUCLIDIANAS E DAS EXISTÊNCIAS DE TENDÊNCIA EM E E N DA IMAGEM GERADA 3 DO PROCESSAMENTO P12.....	214
TABELA 44 - TABELA DO PEC PLANIMÉTRICO ATINGIDO PELA IMAGEM GERADA 3 DO PROCESSAMENTO P12 PARA AS ESCALAS DE 1:250.000 A 1:1.000	215
TABELA 45 - CARACTERÍSTICAS DO DATASET 5.....	225
TABELA 46 - ANÁLISE ESTATÍSTICA DAS IMAGENS UTILIZADAS.....	226
TABELA 47 - TABELA DOS VALORES CALCULADOS DO ERRO MÉDIO E DO ERRO PADRÃO DAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS.....	234
TABELA 48 - TABELA DO PEC ALTIMÉTRICO ATINGIDO PELAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS PARA AS ESCALAS DO MAPEAMENTO SISTEMÁTICO.....	235
TABELA 49 - TABELA DAS CARACTERÍSTICAS DO MGG DE ALTA RESOLUÇÃO E DO MOG DE BAIXA RESOLUÇÃO UTILIZADOS NO DATASET 6.....	239
TABELA 50 – APRESENTAÇÃO DAS ESTATÍSTICAS DO MGG DE ALTA RESOLUÇÃO E DO MOG BAIXA RESOLUÇÃO UTILIZADOS PARA A EXTRAÇÃO DOS PARES DE AMOSTRAS DAS IMAGENS DE TREINAMENTO E VALIDAÇÃO DO DATASET 6	241
TABELA 51 - TABELA DOS VALORES CALCULADOS DO ERRO MÉDIO E DO ERRO PADRÃO DAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS.....	248
TABELA 52 - TABELA DO PEC ALTIMÉTRICO ATINGIDO PELAS IMAGENS GERADAS NOS RESPECTIVOS PROCESSAMENTOS PARA AS ESCALAS DO MAPEAMENTO SISTEMÁTICO.....	248

LISTA DE ABREVIATURAS E SIGLAS

AAF	- <i>American Air Force</i>
ADALINE	- <i>Adaptative Linear Neuron / Adaptative Linear Element</i>
ALOS	- <i>Advanced Land Observing Satellite</i>
ASF	- <i>Alaska Satellite Facility</i>
ASI	- Agência Espacial Italiana
ASTER	- <i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
AVNIR-2	- <i>Advanced Visible and Near Infrared Radiometer-type 2</i>
BE Const	- Batalhões de Engenharia de Construção
BEIDOU/COMPASS	- Sistema Experimental de Navegação por Satélite BeiDou
BI	- <i>Business Intelligence</i>
BN	- <i>Batch Normalization</i>
CGED	- Coordenação de Geodésia
CNN	- <i>Convolutional Neural Network</i>
Cosmo-SkyMed	- <i>Constellation of Small Satellites for Mediterranean basin Observation - SkyMed</i>
CRO	- Comissão Regional de Obras
DGPS	- <i>Differential GPS</i>
DHN	- Diretoria de Hidrografia e Navegação
DLR	- Agência Espacial Alemã
DoD	- <i>U.S. Department of Defense</i>
DSG	- Diretoria do Serviço Geográfico
DVB	- Datum Vertical Brasileiro
DW	- <i>Data Warehouse</i>
EGM2008	- <i>Earth Gravitational Model 2008</i>
EGM96	- <i>Earth Gravitational Model 96</i>
EM	- Erro Máximo
EP	- Erro Padrão
EPSG	- <i>European Petroleum Survey Group Geodetic Parameter Dataset</i>

EPUSP	- Escola Politécnica da Universidade de São Paulo
ERDGPS	- Estações de Referência DGPS
ESRGAN	- <i>Enhanced Super-Resolution Generative Adversarial Networks</i>
ESC	- Estado de Santa Catarina
ET-ADGV	- Especificações Técnicas para Aquisição de Dados Geoespaciais Vetoriais
FKP	- <i>Flachen Corretour Parameter</i>
GALILEO	- <i>European Satellite Navigation System</i>
GAN	- <i>Generative Adversarial Network</i>
GDAL	- <i>Geospatial Data Abstraction Library</i>
GDEM	- <i>Global Digital Elevation Model</i>
gf	- inteligência fluida
GGOS	- <i>Global Geodetic Observing System</i>
GLONASS	- <i>GLOBAL NAVIGATION Satellite System</i>
GNSS	- <i>Global Navigation Satellite System</i>
GNU	- <i>GNU's Not Unix</i>
Goce	- <i>Gravity field and steady-state Ocean Circulation Explorer</i>
GPRS	- <i>General Packet Radio Services</i>
GPS	- <i>Global Positioning System</i>
GPU	- <i>Graphics processing unit</i>
Grace	- <i>Gravity Recovery and Climate Experiment</i>
GSM	- <i>Global System for Mobile Communications</i>
GT	- <i>Ground Truth</i>
HR	- <i>High Resolution</i>
IA	- Inteligência Artificial
IBGE	- Instituto Brasileiro de Geografia e Estatística
IBM	- <i>International Business Machines Corporation</i>
IBP	- <i>Iterative Back-Projection</i>
ICGEM	- <i>International Centre for Global Earth Models</i>
IN	- Inteligência Natural
InSAR	- <i>Interferometric synthetic aperture radar</i>
ISO	- <i>International Organization for Standardization</i>

JAXA	- <i>Japan Aerospace Exploration Agency</i>
LF	- <i>Low Frequency</i>
Lageos	- <i>Laser Geometric Environmental Observation Survey</i>
LLE	- <i>Locally-Linear Embedding</i>
LR	- <i>Low Resolution</i>
MAC	- <i>Master Auxiliary Concept</i>
MCC	- <i>Microelectronics and Computer Technology Corporation</i>
MDE	- <i>Modelo Digital de Elevação</i>
MDS	- <i>Modelo Digital de Superfície</i>
MDT	- <i>Modelo Digital do Terreno</i>
METI	- <i>Ministério de Economia, Industria e Comércio do Japão</i>
MF	- <i>Medium Frequency</i>
MGG	- <i>Modelos Globais de Geopotencial</i>
MLP	- <i>Multi Layer Perceptron</i>
MOG	- <i>Modelo de Ondulação Geoidal</i>
MSE	- <i>Mean Squared Error</i>
NaN	- <i>Not a Number</i>
NASA	- <i>National Aeronautics and Space Administration</i>
NAVSTAR-GPS	- <i>Navigation System with Time and Ranging Global Positioning System</i>
NBS	- <i>National Bureau of Standards</i>
NGA	- <i>National Geospatial-Intelligence Agency</i>
NH	- <i>New Hampshire</i>
NIMA	- <i>National Imagery and Mapping Agency</i>
NIQe	- <i>Naturalness Image Quality Evaluator</i>
NIST	- <i>National Institute of Standards and Technology</i>
NMAS	- <i>National Map Accuracy Standard</i>
NTRIP	- <i>Networked Transport of RTCM via Internet Protocol</i>
OG	- <i>Ondulação Geoidal</i>
OLTP	- <i>OnLine Transaction Processing</i>
OSGeo	- <i>Open-Source Geospatial Foundation</i>
PALSAR	- <i>Phased Array type L-band Synthetic Aperture Radar</i>
PC	- <i>Personal Computer</i>
PDGPS	- <i>Precise DGPS</i>

PEC	- Padrão de Exatidão Cartográfica
PEC-PCD	- Padrão de Exatidão Cartográfica destinado a atender os Produtos Cartográficos Digitais
PNG	- <i>Portable Network Graphic</i>
PP	- Posicionamento por ponto
PPP	- Posicionamento por ponto preciso
PRISM	- <i>Panchromatic Remote-Sensing Instrument for Stereo Mapping</i>
PSNR	- <i>Peak signal-to-noise ratio</i>
QGIS	- <i>Quantum Geographic Information System</i>
QI	- Quociente de Inteligência
RAM	- <i>Random Access Memory</i>
RBMC	- Rede Brasileira de Monitoramento Contínuo
RBMC-IP	- Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS em tempo real
RGB	- <i>Red Green Blue</i>
RMSE	- <i>Root Mean Squared Error</i>
RN	- Referências de nível
RRDB	- <i>Residual-in-Residual Dense Block</i>
RTCM	- <i>Radio Technical Commission for Maritime Services</i>
RTK	- <i>Real Time Kinematic</i>
SAR	- <i>Synthetic-aperture radar</i>
SDS/ESC	- Secretaria de Estado do Desenvolvimento Econômico Sustentável do Estado de Santa Catarina
SEAC	- <i>Standards Electronic Automatic Computer</i>
SGBD	- Sistema de Gerenciamento de Banco de Dados
SIRGAS	- Sistema de Referência Geocêntrico para as Américas
SISR	- <i>Single Image Super-Resolution</i>
Spyder	- <i>Scientific PYthon Development EviRonment</i>
SR	- <i>Super-Resolution</i>
SRCNN	- <i>Single image Super-Resolution deep Convolutional Neural Network</i>
SRTM	- <i>Shuttle Radar Topography Mission</i>
SRGAN	- <i>Super-resolution GAN</i>

SSIM	- <i>Structural Similarity Index Measure</i>
Strong AI	- <i>Inteligência Artificial Forte</i>
TanDEM-X	- <i>TerraSAR-X add-on for Digital Elevation Measurement</i>
TIFF	- <i>Tagged Image File Format</i>
TPU	- <i>Tensor processing unit</i>
USA	- <i>United States of America</i>
VRS	- <i>Virtual Reference Station</i>
VTBuilder	- <i>Virtual Terrain Builder</i>
WADGPS	- <i>Wide Area DGPS</i>
Weak AI	- <i>Inteligência Artificial Fraca</i>
WGS84	- <i>World Geodetic System 1984</i>

1 INTRODUÇÃO

Este capítulo é organizado da seguinte maneira: na seção 1.1 são apresentadas as considerações iniciais, a contextualização e a motivação da presente tese, destacando seus principais desafios. Nas seções 1.2 e 1.3 são apresentados o problema a ser investigado e as justificativas para a sua realização, além das razões práticas e teóricas que tornam a sua realização importante. Na seção 1.4 são apresentados o objetivo geral e os específicos desta tese. Já na seção 1.5, é destacada a hipótese, ou seja, a afirmação provisória realizada no início da pesquisa. Nas seções 1.6 e 1.7, respectivamente, são apresentados o estado da arte e os recursos e suporte obtidos durante a realização da tese. Na seção 1.8, por fim, é descrita a estrutura da tese.

1.1 CONSIDERAÇÕES INICIAIS

Atualmente, a utilização de imagens digitais é cada vez mais frequente em diversas áreas do conhecimento como medicina, engenharia, agricultura, geologia, defesa, antes dominadas por outras tecnologias. São exemplos de tais aplicações realização de diagnósticos médicos, a vigilância e monitoramento por câmeras de segurança e satélites, manejo florestal, cadastro urbano e cartas topográficas. Para algumas dessas aplicações, as imagens de melhor resolução espacial, por possuírem maior quantidade de informações e riqueza de detalhes, possibilitam melhor interpretação, utilização, análise e representação computacional em relação aos fins desejados.

Muitas pesquisas têm sido realizadas no sentido de melhorar a resolução espacial das imagens digitais existentes. Uma solução regularmente buscada é a da adoção de técnicas de *upscaling*, onde operações matemáticas de interpolação, normalmente bilineares ou bicúbicas, são aplicadas para criar uma versão com maior resolução espacial da imagem original. Tais técnicas costumam apresentar resultados satisfatórios para alguns casos em que o aumento de resolução desejado é de até duas vezes o valor da imagem original. Em aumentos superiores ao valor da escala, os resultados obtidos são piores, e

muitas vezes não aceitáveis para os fins propostos, fazendo-se necessária a utilização de técnicas mais robustas.

A resolução espacial dos sensores responsáveis pela geração de imagens digitais varia em função da densidade de fotodetectores existentes nos mesmos. O IFOV (*Istantaneous Field of View* - Campo de Visada Instantâneo) define-se como o ângulo que determina o campo de visada que projeta sobre a superfície a dimensão mínima detectada em cada posição da faixa imageada. Dessa forma, tem-se que o tamanho da área vista no terreno é determinado pelo IFOV e pela distância do sensor à essa superfície. No terreno, essa área vista pelo IFOV é denominada Elemento de Resolução do Terreno (NOVO, 2010).

Uma maior resolução espacial da imagem representa uma mesma região do terreno com um maior número de *pixels*. Ela refere-se ao tamanho que a área compreendida em um *pixel* corresponde na realidade. Em sensoriamento remoto, os *pixels* de uma mesma imagem representam sempre uma mesma área (mesmas dimensões na superfície da Terra).

Levando-se em consideração diversos fatores associados ao custo e às limitações dos dispositivos de aquisição, uma alternativa viável seria aumentar a resolução e melhorar a qualidade psicovisual das imagens por meio da aplicação de técnicas conhecidas como super-resolução (SR) (RÉZIO et al., 2011).

De acordo com Junior (2008), as técnicas de SR combinam uma ou mais imagens de baixa resolução espacial (LR – *Low Resolution*) de uma mesma cena, a fim de produzir uma ou diversas imagens de alta resolução espacial (HR – *High Resolution*). As imagens LR e HR representam a mesma área, mas possuem diferenças entre elas, que podem ser caracterizadas por: diferentes datas de aquisição; diferentes projeções; pequenas variações na resolução espacial; e, deslocamentos de *pixels* ou *subpixels* (JUNIOR, 2008).

A SR de imagens é uma classe de técnicas que aprimoram a resolução de uma imagem, realizando o aumento da resolução espacial da mesma, aumentando o seu número de *pixels*, procurando diminuir a ocorrência de efeitos por conta da própria aquisição, como perda de detalhes, perda de qualidade, falta de nitidez, ocorrência de borrões, dentre outros. Ela baseia-se na ideia de que imagens de baixa resolução de uma determinada cena pode ser gerada uma imagem de alta resolução. Dessa forma, ela tenta reconstruir a imagem da cena

original com alta resolução, dado um conjunto de imagens observadas em resolução mais baixa (GAIDHANI, 2011).

Diferentes aplicações possuem uma grande demanda em imagens com alta resolução espacial, tais como medicina, biologia, automação industrial, vigilância, sensoriamento remoto (CHAUDHURI, 2001). No contexto da ciência da Terra, e desse trabalho, pode-se citar como exemplo da empregabilidade da SR o aumento da resolução de imagens de satélites.

As primeiras pesquisas em SR foram feitas por Tsai e Huang (1984). Inicialmente, aplicadas em imagens de vídeo, essas técnicas foram posteriormente utilizadas em pesquisas de imagens estáticas (JUNIOR, 2008).

As técnicas de SR têm recebido um aumento de interesse nos últimos anos, onde o objetivo principal é aumentar a resolução espacial das imagens, favorecendo a precisão na análise e a interpretação das imagens, e melhorando a qualidade da visualização (LUCIEN, 1999; DANTAS, 2013).

São apresentadas três dentre as principais abordagens aplicadas para a obtenção de imagens super-resolvidas: SR baseada em interpolação, SR baseada em reconstrução e SR baseada em aprendizado. Em geral, métodos mais recentes têm se baseado na última abordagem (RÉZIO et al., 2011).

Os métodos baseados em interpolação da imagem buscam a estimação dos valores dos *pixels* na imagem de alta resolução, que é realizada pela interpolação da intensidade ou cor dos *pixels* já existentes na imagem de entrada. Existem diferentes métodos de interpolação documentados, sendo que os mais comumente utilizados são a interpolação por vizinho mais próximo, a interpolação bilinear e a interpolação bicúbica (RÉZIO et al., 2011).

Sobre a segunda abordagem, utiliza-se um procedimento iterativo para a minimização do erro entre os dados originais e a saída do modelo. A técnica de SR *Iterative Back-Projection* (IBP) foi criada a partir de variações da técnica de *back-projection*, originalmente proposta para a reconstrução de vistas tomográficas de imagens médicas. Tal método é similar aos métodos iterativos para solução de mínimos quadrados. Apresenta como uma de suas vantagens a velocidade de convergência, que está relacionada ao operador *back-projection* (RÉZIO et al., 2011).

Finalmente, sobre a terceira abordagem, propõe-se um método de SR dividido em dois passos: a preparação de um conjunto de treinamento e a

construção da banda de alta frequência que falta na imagem de entrada. Yu et al. (2009) desenvolveu uma pesquisa que utilizava a compensação residual associado a um método de aprendizado conhecido como *Locally-Linear Embedding* (LLE) para efetuar a correspondência entre imagens residuais de baixa e alta resolução (CHANG et al., 2004).

Algumas pesquisas ainda procuram realizar a SR de imagens utilizando-se de métodos estocásticos, como as técnicas bayesianas. Tais métodos apresentam uma forma flexível e eficiente de modelar um conhecimento a priori da solução (JUNIOR, 2008).

Schulter, Leistner e Bischof (2015) citam como um dos objetivos da SISR (*Single Image Super Resolution*) reconstruir uma imagem de alta resolução a partir de uma única entrada de baixa resolução. No mesmo artigo, os autores se propuseram a realizar o mapeamento direto dos fragmentos de baixa para alta resolução, usando a técnica do *Random Forest* (RF), produzindo resultados altamente precisos, e modelos de treinamento e avaliação rápidos.

Para avaliar o desempenho das imagens geradas pelos algoritmos de SR em relação à percepção visual humana, Jiang et al. (2016) realizaram estudos com seres humanos usando um grande conjunto de imagens de SR e propuseram uma métrica definida a partir de pontuações visuais perceptivas. Os resultados advindos dos experimentos alcançaram uma métrica eficaz e eficiente para a avaliação da qualidade das imagens de SR com base na percepção humana.

Recentemente, o grande salto em desempenho apresentado pelas técnicas de SR de imagens digitais pode ser verificado tanto pelos resultados apresentados da acurácia das reconstruções, como pelas avaliações obtidas de observações humanas da qualidade visual. Entretanto, notou-se em diversos estudos que os novos modelos tendiam a adaptar-se preferencialmente a um ou a outro conjunto de tais métodos de avaliação, apresentando resultados cada vez mais em desacordo entre si (Figura 1) (CHEON et al., 2018).



Figura 1 - Inconsistência entre os valores da medida de distorção PSNR e SSIM e da qualidade perceptiva dos métodos de super-resolução SRGAN (Super-resolution GAN), SRResNet (Super-resolution Residual neural network) e NN interpolation (interpolação pelo vizinho mais próximo), onde verifica-se um desacordo entre a análise visual de cada uma das imagens em relação aos valores obtidos das métricas utilizadas em suas avaliações (PSNR e SSIM).

FONTE: CHEON et al. (2018).

Blau e Michaeli (2018) em seu artigo procuraram provar matematicamente a existência do desacordo existente entre a distorção e a qualidade perceptiva por ocasião da avaliação das imagens digitais aumentadas em resolução. Verificam, dessa forma, que à medida que a distorção média da imagem gerada diminui, a probabilidade de discriminar corretamente as saídas do algoritmo utilizado aumenta (indicando pior qualidade perceptiva). Constataram ainda em seu estudo que as redes adversárias generativas são baseadas em fundamentos que lhes permite se aproximar do limite existente entre a percepção e a distorção (BLAU E MICHAELI, 2018).

Kim e Lee (2018) desenvolveram uma metodologia de avaliação para SR de imagens que procura quantificar conjuntamente a acurácia e a qualidade perceptiva, permitindo, assim, que os resultados dos métodos orientados à percepção possam ser comparados com os dos algoritmos que visam à maximização do PSNR (*Peak signal-to-noise ratio*).

Cheon et al. (2018) utilizaram uma rede adversária generativa para aumentar a resolução de imagens digitais buscando desenvolver um modelo onde o equilíbrio entre percepção e distorção fossem considerados. Para tanto, baseou-se na *Residual Network with Enhanced Upscaling Module for Super-resolution* de Kim e Lee (2018), e obtiveram como resultado no treinamento de seu modelo proposto um bom desempenho tanto para percepção quanto para distorção, sendo ainda eficaz em aplicações de SR perceptiva.

A super-resolução de imagem única (*Single Image Super Resolution - SISR*) é uma área de pesquisa bastante importante no campo da visão

computacional e encontra muitas aplicações práticas. Modernamente, os métodos que integram o estado da arte em SR de imagens têm utilizado para a solução do problema diversos conceitos de inteligência artificial (IA) e de *Deep Learning* (DL) e têm obtido bons resultados.

O campo da computação nos últimos anos vem evoluindo devido à melhoria do poder computacional e com o surgimento de novos algoritmos de processamento de dados. Tais algoritmos, conhecidos por *machine learning* (ML) são ferramentas que nos últimos anos tiveram um grande desenvolvimento, e sua pesquisa aplicada cresceu exponencialmente tanto nos ambientes empresariais como no meio acadêmico. Apesar de seu significativo sucesso nas práticas de mineração e visualização de dados, e na apresentação de previsões aos problemas que são submetidos, seus métodos ainda necessitam ser utilizados com cautela devido ao grau de complexidade que possuem.

1.2 PROBLEMA

A Diretoria do Serviço Geográfico (DSG) e o Instituto Brasileiro de Geografia e Estatística (IBGE) são responsáveis pelo mapeamento sistemático do Brasil. Ambas as instituições vêm constantemente buscando formas de automatizar e reduzir o custo de sua produção cartográfica. Tal mapeamento é realizado com o objetivo de representação, de forma sistemática, todo território brasileiro, através de uma série de cartas articuladas, contínuas e homogêneas, em escalas padronizadas de 1:1.000.000, 1:500.000, 1:250.000, 1:100.000, 1:50.000 e 1:25.000.

O Brasil, justamente por ser o quinto maior país em extensão territorial da atualidade, apresenta-se de forma bastante heterogênea e complexa. Devido a essas e outras características, enfrenta grandes desafios para realizar e manter atualizado todo o seu mapeamento sistemático básico.

A necessidade da sociedade de representar o espaço geográfico que ocupa ocorre pelas diferentes utilidades que podem advir da obtenção de tais informações. Dessa forma, os usuários desses conhecimentos passam a se beneficiar das características físicas obtidas das diferentes regiões da superfície terrestre mapeadas.

Com o decorrer dos anos, aumenta cada vez mais a busca pela sociedade pelo acesso aos dados geoespaciais para a realização de diferentes atividades, quer sejam profissionais, quer sejam de lazer ou lúdicas. O surgimento e o desenvolvimento de novas tecnologias e metodologias tornam possível aos profissionais da área das geociências o atendimento dessa demanda gerada (LUNARDI et al., 2012).

O mapeamento sistemático básico terrestre na escala 1:25.000 (mapa índice 1:25.000) possui um expressivo vazio cartográfico (grandes áreas do território que não foram mapeadas oficialmente), onde a progressão do mapeamento de novas áreas ainda não mapeadas e a atualização temporal das cartas segue de maneira lenta ou até mesmo nula. Desde 2008, por exemplo, tal escala não apresenta progressão significativa em sua situação. Na Figura 2, verifica-se um mapa do Brasil onde somente as áreas apresentadas na cor cinza apresentam o mapeamento sistemático básico realizado na escala de 1:25.000. Existem diferentes fatores que influenciam esta questão, indo desde problemas políticos e institucionais, até questões de falta de recursos humanos, financeiros e técnicos. As relações entre os diferentes níveis de governo da federação brasileira (federal, estadual, municipal e distrital), apesar da existência de hierarquia entre as entidades, apresentam muitas atividades que se sobrepõem. Alguns dos setores que sentem com maior intensidade as consequências da ausência das cartas topográficas na referida escala são os governamentais, os de empreendedorismo e os de construção civil.



Figura 2 - Situação atual do mapeamento sistemático básico na escala 1:25.000 no ano de 2020. As áreas apresentadas na cor cinza apresentam o mapeamento sistemático básico realizado na escala de 1:25.000.

Fonte: Adaptado do mapa índice IBGE (2020).

Da construção e disponibilização das diversas escalas do mapeamento sistemático pelos órgãos governamentais, os demais setores da sociedade podem então construir suas bases cartográficas em função de suas atividades específicas e áreas de interesse. Segundo a Diretoria do Serviço Geográfico (2011), base cartográfica é uma área delimitada e extraída de um dos produtos cartográficos de referência, conhecidos por “Produtos de Conjunto de Dados Geoespaciais Vetoriais”, que compõem o espaço geográfico brasileiro. Diferentes bases cartográficas podem ser definidas para a realização de diferentes atividades como, por exemplo, realização de obras, planejamentos estatais, desenvolvimento e acompanhamento de projetos.

Os vazios cartográficos também podem se apresentar como áreas encontradas dentro dos próprios mapas, cartas topográficas ou outro produto cartográfico diverso. Nesses casos, tais áreas apresentam pouca ou nenhuma informação, sendo muitas vezes mostrado, por exemplo, apenas os seus limites preenchidos com vastos espaços internos vazios, dando a percepção de que o

espaço geográfico em questão não possua nenhum tipo de antropização ou construção (NUWER, 2014).

Existem, na literatura científica, vários trabalhos acadêmicos que abordam múltiplos aspectos das técnicas utilizadas na consecução de modelos digitais de superfície (MDS) e modelos digitais do terreno (MDT), no que se refere à obtenção de altitudes sobre a superfície terrestre para a construção de cartas topográficas e temáticas. Tais aplicações são vastamente utilizadas em diferentes esferas das ciências, tais como: a geodésia, a fotogrametria, o sensoriamento remoto, a cartografia, a hidrologia, a topografia, dentre outros.

Dentre estes campos de ação, pode-se citar como exemplo as seguintes atividades: o monitoramento de deformações de estruturas; a integração de imagens de satélites e dados auxiliares para delimitação de unidades fisionômicas e geológicas; o processamento digital de imagens de satélites; a modelagem numérica do terreno; predição de anomalia gravitacional; a transformação entre sistemas geodésicos de referência; entre outros.

As ciências aplicadas buscam, através da aquisição de dados de medições e simulações, e da análise e da modelagem deles, chegar a novos conhecimentos científicos. As técnicas de aprendizado de máquina em conjunto com tais ciências permitem mensurar, otimizar e automatizar os processos a que são submetidos. Nesse contexto, o aprendizado de máquina pode ser caracterizado como um conjunto de alternativas mais práticas e simples voltadas para a resolução de problemas para os quais são destinados. Cita-se, por exemplo, as ciências geodésicas, no que lhe concerne apresentam os seus métodos muito bem estabelecidos, entretanto com grande dificuldade de implementação ou de resolução, podendo ser nesse caso a utilização de IA uma alternativa a ser estabelecida para a realização de uma modelagem capaz de implementá-los.

Dentre as potencialidades da IA, encontra-se a possibilidade de, por exemplo, através de métodos de mineração de dados, identificar quais elementos e atributos de um determinado conjunto de dados possuem maior poder de predição dentre os demais, a despeito do tamanho da base de dados utilizada e dos diferentes tipos de dados apresentados pelas mesmas. Os algoritmos de IA também podem inferir regras sobre os dados, atribuindo pesos aos atributos com melhor poder de predição, ponderando a relevância entre eles

e obtendo um resultado conclusivo. O algoritmo de IA tem a potencialidade de se desenvolver e se reprogramar à medida que realiza as iterações previstas em sua rotina, podendo apresentar mudanças em suas decisões ao avaliar novas informações e resultados mais recentes advindos de seus processamentos (STERNE, 2017).

Atualmente, mesmo com todo o desenvolvimento da área, a implementação de algoritmos de ML ainda enfrentam os desafios provenientes das restrições oferecidas pelos problemas apresentados por dados coletados de experimentos reais no desenvolvimento dos modelos como, por exemplo: conjuntos de dados apresentando certa quantidade de erros e ruídos, conjuntos de dados distribuídos temporal e espacialmente, existência de atributos irrelevantes e redundantes, aprendizagem com mudanças de conceito, aprendizagem incremental, presença de dados viciados, aprendizagem com custos, aprendizagem de padrões isolados, dentre outros.

Atualmente, o *deep learning* (DL) tem logrado sucesso em uma vasta área de aplicações, despontando-se, como o campo do ML, com maior e mais rápida difusão dentre utilizações em áreas tradicionais ou até mesmo em áreas mais modernas (ALOM *et al.*, 2018).

Um sistema de referência altimétrico moderno deve ser capaz de determinar a existência de variações milimétricas em suas variáveis. É importante também para um moderno sistema de referência altimétrico procurar estar de acordo com as preconizações e padronizações estabelecidas pelo *Global Geodetic Observing System* (GGOS). O GGOS é um sistema que integra diferentes técnicas geodésicas, modelos e aproximações no intuito de assegurar um monitoramento preciso e duradouro de observáveis geodésicas.

No Brasil, trabalhava-se com a altitude normal-ortométrica como altitude oficial. A nova representação altimétrica nacional do IBGE, desde a realização do último reajustamento da Rede Altimétrica, são as altitudes normais. As referências de nível (RRNN) nos fornecem a altitude normal de pontos medidos em campo diferentemente da altitude elipsoidal que é fornecida pelo *Global Navigation Satellite System* (GNSS). Tanto a altitude normal, como a altitude normal-ortométrica, são altitudes científicas que utilizam como parâmetros dados gravimétricos e desníveis medidos em campo. Outrossim, a altitude elipsoidal, fornecida pelos sistemas GNSS, é uma altitude estritamente geométrica

amarrada ao elipsóide de referência. Porém, muitas vezes em levantamentos de campo onde se necessita da altitude ortométrica, principalmente em áreas mais isoladas existe a dificuldade de acesso às RRNN. Assim, é comum a utilização de modelos geoidais associados à altitude elipsoidal (obtida através de observações GNSS) para se chegar às altitudes normal-ortométrica e normal.

Ao longo dos anos o IBGE vem disponibilizando alguns modelos de ondulação geoidal (OG) com erros que variam entre 50 cm (cinquenta centímetros) no caso do MAPGEO2004, 32 cm (trinta e dois centímetros) MAPGEO2010 e 17 cm (MAPGEO2015). Comparando os erros obtidos pelos modelos de ondulação geoidal (MOG) disponibilizados pelo IBGE com modelos geoidais de países como Argentina (GEOIDEAR16) e Uruguai (URUGEOIDE2007), com acurácia entre 2 e 10 cm, os erros dos MOGs fornecidos pelo IBGE podem ser considerados altos. Outra limitação dos MOGs disponibilizados pelo IBGE se refere à região amazônica, em função da dificuldade de acesso e, também da dificuldade de realização de circuitos de nivelamento geométrico.

A Amazônia Brasileira é uma região de grande extensão territorial (com cerca de 5 milhões de quilômetros quadrados, correspondendo a aproximadamente 59% do território brasileiro), que em função de imensa quantidade de fauna, flora e riquezas, demanda grande quantidade de conhecimento e vigilância, além de integração ao restante do território nacional (MARGULIS, 2003). Tal área é deficiente no que tange ao alinhamento ao Sistema Vertical de Referência Global (ou Sistema Internacional de Referência Altimétrico) e à Rede Vertical Brasileira, já que os mesmos apresentam necessidade quanto ao preenchimento de informações altimétricas. A solução clássica apresentada para a realização de tal densificação conjugando nivelamento e gravimetria encontra, atualmente, entraves no que diz respeito à situação econômica do país, à dificuldade logística de se realizar tais levantamentos na região, a longa duração da realização da atividade, à questão do desmatamento, dentre outros, fortalecendo a procura por novas soluções e tecnologias para a solução de tal deficiência.

A modelagem altimétrica está prevista como parte dos estudos que envolvem a geodésia. No que se refere ao contexto das Américas, existe o Sistema de Referência Geocêntrico para a América do Sul (SIRGAS), com o seu

Grupo de Trabalho III (SIRGAS-GTIII), que é responsável pela altimetria nas regiões das Américas do Sul e Central. O SIRGAS-GTIII (*Datum* vertical) foi estabelecido durante a Assembleia Geral da Associação Internacional de Geodésia (*International Association of Geodesy* - IAG), realizada no Rio de Janeiro em 1997. Seus principais objetivos são definir um sistema de referência vertical unificado para o SIRGAS, estabelecer um sistema correspondente e transformar os sistemas de altitudes clássicos existentes em um sistema moderno. Uma das atividades fundamentais do SIRGAS-GTIII é a elaboração do diagnóstico dos *data* verticais existentes (SIRGAS, 2021).

No que tange às técnicas de IA selecionadas, é possível a realização tanto da super resolução dos dados como da conformação ou adaptação das superfícies. O primeiro visa alcançar a super resolução da superfície aumentando sua resolução espacial e o segundo intenciona a conformação e adaptação de uma superfície à outra.

Dessa forma, esta pesquisa pode ajudar na questão do vazio cartográfico, na questão da modelagem altimétrica e na disponibilização de *datasets* para DL. Cabe ressaltar que alguns dos tópicos acima citados são objetos de estudo da geodésia, que é a parte da cartografia que se preocupa com o estudo da forma e da dimensão da superfície terrestre e seu campo gravitacional externo, juntamente com suas variações temporais.

1.3 JUSTIFICATIVA

Os modelos digitais de elevação (MDEs) são importantes na produção cartográfica por serem responsáveis pelo fornecimento de informações altimétricas do terreno como, por exemplo, informações altimétricas em um ponto e curvas de nível. Existe atualmente uma carência de MDEs disponíveis para a realização de produtos cartográficos e afins para as escalas maiores de 1:50.000, incluindo as escalas cadastrais. Tais escalas são as que apresentam o maior vazio cartográfico no Brasil, e são de extrema utilidade para as prefeituras e as empresas na realização de suas atividades inerentes. Atualmente, as formas existentes de solucionar de tal problema são: a contratação de voos fotogramétricos, a aquisição de imagens de satélites com visada inclinada (como as *WorldView* e *Pleiades*), e a aquisição de imagens

radar (como as TanDEM-X, RADARSAT e Cosmo-SkyMed). Todas possuem um custo bastante elevado, já que são produtos de engenharia de alto investimento, o que impossibilita muitas vezes sua aquisição.

Alguns MDEs disponíveis atualmente são referentes ao SRTM, assim como o ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*), ALOS (*Advanced Land Observing Satellite*) e o ASF (*Alaska Satellite Facility*), o que não permite a utilização deles em diversas aplicações cartográficas, em função da exatidão necessária.

Uma alternativa viável para a obtenção de MOG com acurácia superior aos modelos disponibilizados pelo IBGE é a utilização de dados obtidos pelo ICGEM (*International Centre for Global Earth Models – Centro Internacional de Modelos Globais Terrestres*) denominados Modelos Globais do Geopotencial (MGG). Os dados obtidos através do *site* do ICGEM (<http://icgem.gfz-potsdam.de/home>) são oriundos das missões espaciais Grace (*Gravity Recovery and Climate Experiment*), Goce (*Gravity field and steady-state Ocean Circulation Explorer*) e Lageos (*Laser Geometric Environmental Observation Survey*).

Assim, pode-se obter dados referentes a diversos MGG disponibilizados bem como dados referentes a reduções gravimétricas. Esses modelos são uma alternativa viável para regiões de difícil acesso como, por exemplo, a região amazônica. Nos produtos cartográficos gerados pelo Exército Brasileiro (EB), os dados altimétricos como pontos cotados e curvas de nível, são referenciados ao *Datum Vertical Brasileiro* (DVB), ou seja, são altitudes normais. Como a maior escala de trabalho utilizada pela força terrestre, no caso escala 1:25.000, utiliza curvas de nível com equidistância de 10 (dez) metros e os erros existentes nos MOGs disponibilizados pelo IBGE podem ser considerados desprezíveis. Porém, em alguns projetos específicos como, por exemplo, a Copa do Mundo de 2014 ou o Convênio do Amapá, a DSG trabalhou com escalas de trabalho maiores que as existentes no mapeamento sistemático. Assim, em escalas de trabalho entre 1:5.000 e 1:1.000, os erros existentes nos MOGs disponibilizados pelo IBGE podem ser considerados significativos, e é nesse contexto que os MGGs podem ser considerados uma alternativa viável a tais MOGs.

Não é função da DSG a elaboração de MOG para o território brasileiro e, também não é função desse estudo tecer críticas aos modelos gerados pelo IBGE; mas, uma das funções desse estudo é a determinação de uma alternativa

viável para a geração de MOG para regiões de difícil acesso como a região amazônica, bem como a geração de modelos com uma acurácia superior ao MAPGEO2015, modelo mais atual disponibilizado pelo IBGE, que é 17 cm (dezessete centímetros).

A geração desses modelos pode ter amplo emprego pela Força Terrestre em trabalhos executados pelos Batalhões de Engenharia de Construção (BE Cnst) na construção de estradas, aeroportos e estacionamentos. As Comissões Regionais de Obras (CRO) também podem se beneficiar de tais estudos em levantamentos topográficos bem como os Grupamentos de Engenharia.

Os modelos geoidais atualmente existentes para uso na Amazônia são imprecisos e deficientes, pois não possibilitam as acurácias adequadas para levantamentos altimétricos por GNSS em projetos de mapeamento e de engenharia, nos quais a informação altimétrica tem importância fundamental. Nesse contexto, é de suma importância que se tenha um modelo geoidal com melhor qualidade de dados altimétricos na região.

A utilização da metodologia ora proposta pode vir a ser utilizada para a construção e densificação de modelos geoidais na região amazônica, por exemplo, com erros cada vez menores, a partir do uso de diferentes fontes de dados, como os MGGs, os MDSs, e os MDTs (como exemplo cita-se os confeccionados no âmbito do Projeto Mapeamento da Amazônia, também conhecido por Radiografia da Amazônia).

Com o acelerado desenvolvimento das ciências e da tecnologia ocorrido nas últimas décadas, as técnicas anteriormente utilizadas pela geodésia para a realização das observações no intuito de determinar a forma e a dimensão da Terra e, também ainda o campo da gravidade em seu exterior, sofreram evoluções. Atualmente, até mesmo métodos computacionais vêm sendo utilizados para o seu processamento. Além disso, os problemas da geodésia, antes considerados clássicos, agora abrangem também a detecção dos efeitos de mudanças globais e da geodinâmica.

Tal cenário torna necessária a compreensão da Terra como um planeta que se comporta como um sistema, e que para entendê-lo, é preciso entender os entes físicos associados diretamente a ele, chegando até mesmo a realizar o monitoramento contínuo destas variáveis. Tal monitoramento permitirá, desta maneira, a detecção das modificações que ocorrem na superfície terrestre ao

longo do tempo. Para tanto, é necessário, entre outros, a existência de um sistema de referência geodésico com estabilidade e homogeneidade, juntamente com sua materialização suficientemente precisa para a determinação da magnitude das perquirições desejadas.

As formas tradicionalmente utilizadas para a geração dos modelos geoidais são deveras custosas e demoradas. Uma dificuldade existente que pode ser apontada é no que se refere à realização do nivelamento geométrico, já que tal procedimento deve ser realizado em somente poucas horas do dia, no intuito de minimizar os efeitos da reverberação (estima-se baseado na literatura existente que os intervalos apropriados estariam contidos entre às 07:00 e às 08:30 da manhã e entre às 16:30 e às 18:00 da tarde).

Vários estudos demonstraram que usando MDTs de alta resolução como entradas é possível construir mapas de inundação (mapas que possibilitam delimitar as áreas atingidas por inundações, delimitadas em campo e/ou previstas por um modelo hidráulico, associadas às vazões e cotas dos rios) mais precisos em comparação com MDTs de baixa resolução. Apesar da importância do MDT de alta resolução, muitas áreas nos Estados Unidos e no mundo não têm acesso a MDTs de alta resolução devido às limitações tecnológicas ou ao custo do processo de coleta de dados (DEMIRAY, SIT e DEMIR, 2020).

Deseja-se desenvolver alternativas de geração de MDE com melhor resolução espacial por meio da utilização de técnica de SISR através de *Generative Adversarial Network* (GAN). O modelo que se pretende utilizar para a produção de um MDE com SR tem sido utilizado para obtenção de SR de fotografias coloridas e preto e branco, porém não foi encontrada nenhuma pesquisa no que se refere à aplicação do mesmo a dados espaciais altimétricos.

A conjuntura atual para o estudo de SR de modelos digitais de elevação é oportuna, tendo em vista os avanços tecnológicos nas áreas de IA, sensores orbitais e recursos computacionais definidos no referido contexto.

Em síntese, a presente tese visa contribuir para o meio acadêmico através de novas abordagens para a geração de informações oriundas de dados provenientes de informações altimétricas orbitais, assunto este intimamente ligado às atividades, não só referentes à geodésia, como a diversas outras áreas afins como a cartografia, o sensoriamento remoto, a fotogrametria, dentre outros.

1.4 OBJETIVOS

1.4.1 Objetivo geral

O objetivo geral da presente tese é: considerando o contexto da técnica de super-resolução de imagens únicas com base nas *Generative Adversarial Network*, propor um modelo denominado DEM-ESRGAN, adaptado para o refinamento da resolução espacial de superfícies digitais com informações altimétricas (MDEs, MOGs e MGGs).

1.4.2 Objetivos específicos

Os objetivos específicos da presente tese são:

1 – Avaliar o desempenho do modelo proposto DEM-ESRGAN em função da capacidade de aumento da resolução espacial;

2 – Avaliar o desempenho do modelo proposto DEM-ESRGAN em relação aos métodos tradicionais de melhoria de resolução espacial;

3 – Avaliar o desempenho do modelo proposto DEM-ESRGAN com diferentes números de épocas e diferentes número de amostras;

4 – Analisar as diferentes métricas quando aplicadas a diferentes superfícies geradas pelo modelo proposto DEM-ESRGAN, e verificar que métricas são adequadas quando se utiliza DEM como dados a serem processados;

5 – Avaliar o desempenho do modelo proposto DEM-ESRGAN em sua capacidade de conformação de 2 (duas) superfícies altimétricas.

1.5 HIPÓTESE

A hipótese básica considerada nesta tese é: dado que existem métodos para a realização de aumento de resolução de imagens digitais, então é possível adaptar esses métodos para o aumento de resolução de superfícies com informações altimétricas?

1.6 ESTADO DA ARTE

Nesta seção serão apresentados trabalhos publicados durante o desenvolvimento da pesquisa. Os modelos recentes encontrados foram o CEDGAN, B-SRGAN, SRGAN, ESRGAN, D-SRGAN, U-net e EfficientNetV2. As arquiteturas da CNN e da GAN serão explicadas no Capítulo 2 da tese.

Zhang e Yu (2022) apresentam uma pesquisa comparando os métodos de interpolação tradicional de MDEs (interpolação pelo vizinho mais próximo, interpolação bilinear e interpolação bicúbica) e três outros métodos de SR baseados em redes neurais (SRGAN, ESRGAN e CEDGAN). Resultados experimentais sugerem que SRGAN (*Super-Resolution with Generative Adversarial Network*) apresenta o melhor desempenho na avaliação de acurácia em uma série de experimentos DEM SR. Outros resultados mostram que o SRGAN supera os outros três métodos em termos da maioria dos índices de avaliação, e o CEDGAN apresenta-se como o pior. Considerando esses dois métodos, existem duas diferenças principais. A primeira é que a SRGAN projeta uma rede geradora muito mais profunda que a CEDGAN, e a segunda é que a SRGAN usa funções de perda específicas e a CEDGAN usa apenas a perda adversária. O ESRGAN é proposto com base na adaptação do SRGAN, e sugere-se que o ESRGAN seja capaz de gerar imagens naturais com melhor desempenho de percepção visual. Finalmente, em comparação com métodos baseados em redes neurais, a interpolação bicúbica pode produzir resultados relativamente equilibrados considerando diferentes índices de avaliação.

Demiray, Sit e Demir (2021) visaram desenvolver um modelo de aprendizado de máquina que aumentasse a resolução espacial do MDE em questão sem a utilização de informações adicionais. Para tal, desenvolveram um modelo baseado em GAN (D-SRGAN), inspirado em métodos de super-resolução de imagem única, avaliado para aumentar a resolução de MDEs. Os resultados do experimento mostraram que o D-SRGAN produziu resultados

promissores ao construir MDEs de alta resolução de 3 pés (0,9144 metro) a partir de MDEs de baixa resolução de 50 pés (15,24 metros), superando métodos comuns de interpolação estatística e algoritmos de redes neurais. O estudo mostrou, dessa forma, que é possível usar o poder das redes neurais artificiais para aumentar a resolução dos MDEs. O estudo também demonstra que abordagens de super-resolução de imagem única podem ser aplicadas para super-resolução MDEs.

Adicionalmente, Demiray, Sit e Demir (2021), em função dos conjuntos de dados dos MDEs de versões de baixa resolução estarem amplamente disponíveis e as versões de alta resolução serem escassas, desenvolveram e avaliaram um modelo baseado em EfficientNetV2, com o intuito de aumentar a resolução espacial de MDEs em até 16 vezes sem informações adicionais. A rede proposta mostrou-se promissora ao superar os métodos comparados por uma margem significativa. Considerando que os tempos de treinamento da rede baseada em EfficientNetV2 são gerenciáveis, os autores acreditam que ela fornece uma alternativa comparável aos métodos clássicos e baseados em aprendizado de máquina com conjuntos de dados MDEs maiores. Para criar uma rede neural que compreenda melhor a correlação entre MDEs de baixa e alta resolução, outro aspecto futuro é criar uma função de custo personalizada em vez de usar MSE.

Yan, Tang e Zhang (2021) utilizaram o algoritmo CEDGAN para a interpolação espacial como uma tarefa generativa. Apesar de consistir apenas em um gerador simples e um discriminador simples, esta rede supera facilmente o método IDW (*Inverse Distance Weighted*) tradicional, com maior precisão e maior velocidade. No entanto, o gerador possui apenas seis camadas convolucionais, o que limita seus campos receptivos. Portanto, a rede só é válida para imagens pequenas, como imagens de 32×32 , e a interpolação de imagens grandes, como imagens de 256×256 , pode falhar. Os autores utilizaram os MDTs do USGS 3D Elevation Program (3DEP) com resolução de 1 m neste experimento. Cada imagem DEM tem 10.000×10.000 células, com uma precisão original de 3,04 m com um nível de confiança de 95%. Para o treinamento e validação, três MDTs foram selecionados como dados brutos, cujas elevações variaram de 1.793 m a 2.690 m, 222 m a 2.102 m, e 1.618 m a 2.840 m, respectivamente. Sem repetição, os MDTs foram cortados em 12.000

tiles MDTs (256×256) no total, como verdadeiras, com 10.000 *tiles* para o treinamento e 2.000 para a validação. Os GANs utilizados na pesquisa provaram ser mais eficientes do que os métodos tradicionais, pois podem complementar mais detalhes locais e evitar suavização excessiva do espaço previsto. Com base no desempenho dos diferentes métodos, os autores concluíram que o método baseado em CNN apresenta uma vantagem na precisão quantitativa, mas o método baseado em GAN pode obter uma melhor qualidade visual principalmente em terrenos complexos.

No estudo apresentado por Sebastianelli et al (2021), o gerador é uma estrutura codificador-decodificador chamada U-net, frequentemente usada para tarefas de segmentação de imagens. Tal proposição consiste em dois submodelos: o gerador e o discriminador, pertencendo a uma família de redes neurais GANs. Os autores afirmam que o projeto ainda está em evolução, e que a ideia mais recente é adicionar a dimensão do tempo aos dados. Com a introdução da série temporal, a rede deverá ser capaz de “reconstruir” a imagem semelhante à ótica, restrita a características temporais. Citam, por exemplo, que a rede poderá aprender a evolução sazonal da cena e, então, produzir uma imagem com características temporais específicas.

O projeto de rede do estudo de Demiray, Sit e Demir (2020) consiste em dois componentes opostos (ou seja, um gerador e um discriminador). A arquitetura dos componentes é baseada no modelo SRGAN. O gerador da rede utiliza o MDT de baixa resolução como entrada e a passa para uma camada de convolução com 128 mapas de recursos seguidos por ParametricRelu como uma função de ativação, passando para os blocos residuais. O gerador possui oito blocos residuais com projeto duplicado. O conjunto de dados usado no experimento foi coletado do Programa de Mapeamento de Várzea da Carolina do Norte. O conjunto de dados cobre uma área total de 732 km^2 dos condados de Wake e Guilford. O objetivo da rede foi aumentar a resolução de determinado MDT com fator de aumento de escala de 4 vezes. Os resultados do experimento mostram que o D-SRGAN produz resultados promissores ao construir DEMs de alta resolução de 3 pés (0,9144 metros) a partir de MDTs de baixa resolução de 50 pés (15,24 metros). Apesar do sucesso geral do D-SRGAN, o D-SRGAN não conseguia ter um desempenho uniforme nos terrenos, por produzir resultados mais realistas em terrenos mais planos do que terrenos acidentados. Os autores

acreditam que esse problema pode ser superado com o uso de diferentes métricas na fase de treinamento do gerador.

O experimento encontrado mais similar com a presente pesquisa foi o de Zhang e Yu (2022). O referido experimento apresentou, como forma de avaliação do método pretendido, um benchmark com diversos tipos de interpoladores tradicionalmente utilizados.

Dessa forma, esta pesquisa se insere na utilização dos métodos mais promissores sendo estudados recentemente na pesquisa mundial.

1.7 RECURSOS E SUPORTE

O presente item tem por objetivo apresentar e descrever as fontes de recursos físicos, materiais e financeiros que foram fundamentais à realização da pesquisa. Ressalta-se, oportunamente, que as cooperações ora apresentadas, foram essenciais para o sucesso das atividades atinentes à confecção desse estudo.

Primeiramente, destaca-se como principal órgão de cooperação o EB, através de seu Departamento de Ciência e Tecnologia (DCT) e da DSG, por conceder ao autor desta pesquisa liberação total de suas atividades laborais diárias para fins de execução da pesquisa em regime de dedicação integral.

Em segundo lugar, a Universidade Federal do Paraná (UFPR), mais precisamente o Programa de Pós-Graduação em Ciências Geodésicas (PPGCG), que também figurou como peça-chave para a elaboração da pesquisa. Seus recursos materiais e pessoais integrados foram essenciais, desde o provimento de embasamento teórico ímpar ao autor, durante o período de realização de disciplinas e obtenção de créditos, até a disponibilização de instalações e equipamentos adequados às demandas da pesquisa.

Em relação às agências espaciais NGA (Agência Nacional de Informação Geoespacial - *National Geospatial-Intelligence Agency*) e JAXA (*Japan Aerospace eXploration Agency*), cabe ressaltar o agradecimento aos serviços prestados no que se refere ao armazenamento, à padronização e à disponibilização de informações dos MDEs globais SRTM e Alos Palsar, utilizados neste estudo.

Com não menos importância, é de grande valia mencionar e agradecer a iniciativa do Governo do Estado de Santa Catarina, através de sua Secretaria de Estado do Desenvolvimento Econômico Sustentável (SDS/GSC), pela realização do Levantamento Aerofotogramétrico do Estado na escala de mapeamento de 1:50.000, com disponibilização de produtos, dados e insumos através do site SIGSC (<http://sigsc.sc.gov.br/>).

No que se refere aos serviços prestados pelo IBGE, deve-se ressaltar ainda suas atividades de projeto, desenvolvimento e disponibilização do modelo geoidal nacional MAPGEO2015, utilizado nesta pesquisa. Certamente, sua utilização foi de grande valor e enriqueceu as análises realizadas, bem como sua documentação conveniente facilitou o entendimento de seu funcionamento.

Na sequência, deve-se enaltecer ainda o serviço prestado pelo ICGEM, no tocante ao armazenamento, à padronização e à disponibilização de informações dos Modelos Globais do Geopotencial e de seu serviço de cálculo.

Finalmente, é pertinente mencionar o substancial serviço prestado pela comunidade OSGeo na elaboração, manutenção e constante melhoria do software QGIS, disponibilizado como ferramenta SIG de código aberto e utilizado amplamente para manipulação inicial dos dados e para elaboração de diferentes análises constantes no presente texto.

1.8 ESTRUTURA DA TESE

A presente tese encontra-se dividida em 6 capítulos, e se apresenta da seguinte forma:

O capítulo 1 apresenta as considerações iniciais, o contexto, a motivação, a justificativa, o objetivo e a hipótese da tese, apresenta trabalhos relacionados ao tema, realiza comparações entre as soluções disponíveis, e introduz as questões que são abordadas no transcurso da mesma.

O capítulo 2 apresenta o referencial teórico que norteou a pesquisa e faz uma revisão das técnicas utilizadas.

O capítulo 3 discorre sobre a área de estudo, as bases de dados utilizadas, os *datasets* desenvolvidos, os procedimentos metodológicos, as medidas de avaliação e os recursos computacionais e de *software* empregados no desenvolvimento da pesquisa.

O capítulo 4 descreve os resultados e as discussões obtidos com os experimentos realizados e apresenta a validação das abordagens propostas.

O capítulo 5 apresenta as conclusões levantadas a partir dos experimentos realizados na presente tese.

Por fim, as referências bibliográficas são apresentadas contendo a literatura associada ao tema sob investigação consultada, assim como os anexos ao texto.

2 REVISÃO TEÓRICA

Este capítulo apresenta uma revisão teórica no que é concernente à tese em questão. Tal capítulo está dividido em 2 (duas) partes, onde a primeira aborda os principais conceitos relacionados aos modelos de superfícies altimétricas, como MDEs, MOGs e MGGs. Já a segunda parte se refere às noções inteligência artificial, aprendizado de máquina, deep learning, acurácia posicional e avaliação de super resolução de superfícies altimétricas.

2.1 MODELOS DE SUPERFÍCIES ALTIMÉTRICAS

2.1.1 Modelos Digitais de Elevação

De acordo com IBGE (2022), o modelo digital de elevação é uma referência que representa as altitudes da superfície topográfica agregada aos elementos geográficos existentes sobre ela, como cobertura vegetal e edificações. Um MDE consiste em uma representação numérica da superfície com células que representam valores de elevação (CHAPLOT, 2006).

Um MDS (Modelo Digital de Superfície) é um modelo que representa a superfície do terreno acrescida de quaisquer objetos como árvores e construções, onde a parte superior desses objetos é representada como a superfície do terreno (CRUZ et al.,2011).

Já um MDT (Modelo Digital do Terreno) refere-se a um tipo específico de MDE, que representa a superfície física do terreno, não incluindo objetos acima do mesmo, tais como vegetação e feições antrópicas (PAPARODITIS e POLIDORI, 2002) (Figura 3).




Figura 3 - Comparação entre 2 (dois) tipos de MDE: o MDT e o MDS.
 Fonte: <https://docs.maply.io/analizando-dados/modelos-digitais>

A modelagem de superfície ou modelagem geométrica é a construção de representações para superfícies físicas ou artificialmente criadas, através de processos matemáticos, ou seja, através da modelagem procura-se determinar a superfície que melhor representa um conjunto de dados pontuais, em geral por ajuste de funções ou por interpolações (SIMÕES, 1993).

As fontes de dados para a geração de um MDE podem ser curvas de nível digitalizadas, levantamentos realizados em campo, métodos fotogramétricos aplicados sobre imagens aéreas ou em imagens de satélite e, também, são utilizados dados provenientes de radar e varredura a laser.

2.1.2 SRTM

Atualmente, existem alguns MDE de abrangência global ou regional que proporcionam uma série de aplicações. Dentre eles, encontra-se o SRTM (*Shuttle Radar Topography Mission*), missão realizada em conjunto pela Agência Espacial Norte-americana (NASA), o Departamento de Defesa dos Estados Unidos da América (USDOD), representado pela *National Geospatial-Intelligence Agency* (NGA), a Agência Espacial Alemã (*Deutsches Zentrum für*

Luft- und Raumfahrt eV - DLR) e a Agência Espacial Italiana (*Agenzia Spaziale Italiana* - ASI). O objetivo da missão foi adquirir um MDE entre as latitudes 60°N a 56°S, cobrindo assim, 80% da superfície continental do globo terrestre. Para tal, foram utilizados 2 (dois) radares de abertura sintética (*Synthetic-aperture radar* - SAR) e por interferometria (*Interferometric Synthetic Aperture Radar* - InSAR). Um dos sistemas possuía um sensor com a banda X, com resolução espacial de aproximadamente 30 metros no equador. O outro sistema possuía um sensor com a banda C, com resolução de aproximadamente 90 metros no equador. Ambos os sistemas são referenciados ao sistema geodésico WGS84 e ao MGG EGM96, para a representação da altitude ortométrica.

De forma geral, o SRTM apresenta uma acurácia vertical absoluta de cerca de 16 metros para a banda C e de 6 metros para a banda X, a acurácia planimétrica absoluta é da ordem de 20 metros na banda C e 15 metros para a banda X, utilizando um nível de confiança de 90%, de acordo com a *National Map Accuracy Standard* (NMAP) (FARR et al., 2007) (Figura 4). Tem havido muitos estudos mostrando que a precisão vertical real do SRTM é significativamente maior do que a precisão projetada em áreas livres de vegetação em todo o mundo (Berthier et al. 2006; Bourguine e Baghdadi 2005; Weydahl et al. 2007; Zhang, Yang e Wang 2016).




Figura 4 - Detalhes do radar interferométrico SRTM.
 Fonte: <http://mar.te.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.19.16.24/doc/4473.pdf>

Em áreas com vegetação, a precisão vertical do SRTM torna-se muito menor devido aos efeitos de absorção e reflexão de folhas, galhos e troncos ao sinal de radar do SRTM (Farr et al. 2007). As relações geométricas entre as características da superfície e os sinais de radar causam o viés sistemático do SRTM sobre áreas com cobertura vegetal. A localização do centro de altura de fase do SRTM é, na verdade, entre o solo nu e o topo do dossel da floresta. Características da vegetação, como altura das árvores, cobertura do dossel, densidade das árvores, ângulo de ramificação e umidade da madeira, têm influência no erro SRTM (Brown, Sarabandi e Pierce 2010).

De acordo com Duarte e Assad (2007), o SRTM de 90 metros de resolução pode ter produtos finais com uma resolução espacial de até 10 metros. Já de acordo com Lemos, Rocha e Souza (2004), pode-se afirmar que o modelo topográfico derivado do SRTM apresenta uma exatidão altimétrica muito próximas às informações altimétricas existentes nas cartas topográficas na escala 1:250.000.

Ainda de acordo com Brubacher et al (2012), em relação à extração automática de sub-bacias e de drenagens, comparação de valores altimétricos, de áreas de bacias e de extensão dos rios para a base SRTM utilizadas, assim

como a avaliação do deslocamento das drenagens extraídas em relação à hidrografia das cartas da DSG, na escala 1:50.000, verificou-se que as maiores discrepâncias na extensão dos rios ocorreram nas sub-bacias mais planas com rios sinuosos, onde foram subtraídos alguns meandros existentes na hidrografia das cartas da DSG; que há tendência de aumento no deslocamento das drenagens extraídas à medida que diminui a declividade e aumenta a sinuosidade dos rios; que entre os segmentos de drenagem foram obtidos deslocamentos inferiores a 90 m nos trechos de rio com declividade superior a 0,4%; e que a drenagem extraída do SRTM NASA apresentou a maior precisão, com deslocamento médio de 246 m.

Conforme Oliveira, Guasseli e Saldanha (2009), verificou-se que a qualidade da rede de drenagem extraída do MDE SRTM 90m esteve intrinsecamente associada ao tipo de vale avaliado e à declividade do rio, decrescendo à medida que os vales ficam mais abertos e o rio atinge as áreas de planícies; que os deslocamentos, em alguns trechos dos rios Caí e Taquari, foram superiores a 3km, de acordo com as características da várzea fluvial; e que a rede de drenagem extraída atingiu compatibilidade com escalas entre 1:250.000 e 1:500.000, de acordo com o PEC.

Schiatti et al (2007) afirma que a congruência entre os dados de elevação medidos em campo e os gerados pelo SRTM 90m na região amazônica indica que os modelos digitais de elevação deste podem potencialmente ser empregados em estudos ecológicos na região. Os resultados apresentados apontaram regiões declivosas e úmidas como áreas importantes para levantamentos de fisionomia e estrutura da vegetação, informações que contribuirão para futuras correções nos MDEs gerados pelo SRTM na região amazônica (recomendações para pesquisas futuras à época da publicação do artigo).

Iwashita e Souza Filho (2009) apresentou uma análise da qualidade dos dados SRTM 90m interpolados para 30m, em relação aos dados 30m disponíveis para o território americano. Como resultado, verificou que é possível aplicar um modelo variográfico bem ajustado em uma área amostral para regiões mais extensas dentro da cena, pois os diferentes modelos variográficos (modelos estatísticos utilizados para modelar fenômenos não estacionários e a

covariância, pelo não conhecimento da média) não apresentam diferenças significativas para uma mesma área.

De acordo com Viel, Rosa e Mendes (2020), o Padrão de Exatidão Cartográfica dos Produtos Cartográficos Digitais dos MDEs SRTM v.3 atenderam o PEC-PCD altimétrico classe A na escala 1:100.000. Todos os demais modelos, na escala 1:50.000, enquadraram-se na classe D, enquanto na escala 1:25.000 não houve enquadramento. O MDE SRTM v.3 foi o que apresentou melhores resultados morfométricos e o maior coeficiente de correlação de Pearson ($r=0,995$).

Celestino e Philips (2016) afirmam que como o MDE do SRTM possui uma exatidão altimétrica declarada (*a priori*) de 16 m, valor que pode ser considerado como meia equidistância de curva de nível, para o cálculo da expectativa de exatidão e EP foi levada em consideração sua escala compatível, ou seja, 1:80.000.

De acordo com Moura, Bia e Brites (2014), as avaliações realizadas indicaram que os MDEs globais SRTM possuem aplicações possíveis em escalas de 1:25.000 e menores. Em uma bacia de relevo pouco movimentado, os resultados mostraram compatibilidade com escala de até 1:50.000. Já em uma bacia com maiores declividades e maior densidade de drenagem, os resultados indicaram escala de 1:100.000 e menores. A avaliação do PEC-PCD apresentou limitações, especialmente pela quantidade limitada de vértices geodésicos disponíveis e sua distribuição não-homogênea nas bacias analisadas. No entanto, considera-se que os resultados são um bom indicativo da acurácia dos MDEs, especialmente quando combinados com a comparação com um MDE de melhor resolução por meio de álgebra de mapas (subtração entre rasters).

De acordo com Pereira e Ten Caten (2019), existem na literatura uma ampla variação entre os resultados do RMSE obtidos para os modelos SRTM e TOPODATA (projeto que oferece o MDE e suas derivações locais básicas em cobertura nacional, ora elaborados a partir dos dados SRTM disponibilizados pelo USGS na rede mundial de computadores). São encontrados valores da análise de precisão para o SRTM desde 2,9m (BHANG & SCHWARTZ 2008); 4,95 m (MORAIS 2017); 5,57 m (SOUZA 2015) 5,95 m (MOURA-BUENO et al. 2016); 7 m (PINHEIRO 2006); 9,4 m (MICELI et al. 2011); 9,6 m

(RODRIGUES et al. 2011) até 11 m (SANTOS et al. 2006). Para o TOPODATA os valores da análise de precisão variam entre 4,45 m (SOUZA 2015); 8,9 m (MORAIS 2017); 9,78 m (MOURA-BUENO et al. 2016) e 10,9 m (MICELI et al. 2011).

2.1.3 Alos Palsar

O satélite Alos foi lançado em 24 de janeiro de 2006 pela *Japan Aerospace Exploration Agency* (JAXA), e entrou na fase operacional e fornecimento de dados ao público em 24 de outubro de 2006, tendo sua operação sido concluída em 12 de maio de 2011. Possuía três tipos de sensores: o radiômetro PRISM (*Panchromatic Remote-Sensing Instrument for Stereo Mapping*) capaz de adquirir imagens tridimensionais detalhadas da superfície terrestre; o radiômetro multiespectral AVNIR-2 (*Advanced Visible and Near Infrared Radiometer-type 2*) voltado aos mapeamentos de uso e cobertura das terras e o sensor de microondas PALSAR (*Phased Array type L-band Synthetic Aperture Radar*) com a capacidade de obter imagens diurnas e noturnas sem a interferência de nebulosidade (EMBRAPA, 2021).

Em 24 de maio de 2014 foi lançado o ALOS-2 como continuidade da missão ALOS, apresentando recursos aprimorados para uma observação mais ampla e alta resolução. Outras duas missões estão em desenvolvimento: ALOS-3 do ALOS-4 (EMBRAPA, 2021).

Junior et al (2022) afirma que o MDE ALOS PALSAR apresentou menores valores de RMSE e desvio padrão, indicando que apresenta maior acurácia em relação ao ASTER. As áreas urbanas apresentaram variações de discrepância média entre 0,1 e 3m para os dados ALOS PALSAR enquanto o ASTER foram entre 6 e 8 m, porém em áreas de vegetação densa, ambos os dados apresentaram discrepâncias acima de 10 m.

Sampaio et al (2021) afirmou em sua pesquisa que o MDE ALOS PALSAR é o mais indicado dentre os demais MDEs analisados (SRTM GL1 v3, ALOS PALSAR, ALOS PRISM, ASTER GDEM v3 e MDT LAGEO UFPR) para projetos a serem desenvolvidos no Paraná que empreguem diferentes classes de uso. Já em áreas de vegetação, os modelos ALOS PALSAR e o MDT LAGEO UFPR (modelo desenvolvido pelo LAGEO-UFPR para todo o estado do Paraná, a partir

de um processo de interpolação de um conjunto de dados de altitudes ortométricas-normais, obtidas a partir de vetorização de curvas de nível de cartas topográficas do mapeamento sistemático brasileiro (MSB) nas escalas 1:25.000 e 1:50.000) devem ser priorizados. Para projetos a serem desenvolvidos em áreas abertas e não vegetadas, indica-se o uso do MDE ALOS PALSAR e, em áreas urbanas, recomenda-se o uso do MDS ALOS AW3D30 (modelo obtido com o sensor PRISM por estereoscopia e paralaxe óptica). A pesquisa ainda mostrou que a escolha de um modelo em detrimento de outro pode implicar em divergências de acurácia da ordem de até 10m e, que as diferentes classes de uso podem apresentar padrões de qualidade significativamente distintos.

Simões e Caldeira (2019) avaliaram os MDEs Shuttle Radar Topography Mission (SRTM) GL1, SRTM/X-SAR DEM, SRTM GL1 Alaska Satellite Facility (ASF) Up Sampled, TOPODATA, ALOS Global Digital Surface Model AW3D30 e Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) Global Digital Elevation Model (GDEM) 2, estes gerados por Interferometria SAR (InSAR) e Estereoscopia. Obteve o melhor RMSE para o MDE estereoscópico AW3D30, na ordem de 4.01 m, enquanto os demais MDEs testados, alcançaram RMSE entre 4.53 e 14.72 m, observando-se o ASTER GDEM 2 com pior desempenho. Em adição, ao aplicar o PEC-PCD, constatou aderência a normalidade para os MDEs GL1 e GL1 ASF Up Sampled e presença de viés exceto no MDEs AW3D30, as escalas compatíveis foram entre 1:25.000 a 1:50.000, variando entre as categorias B, C e D. Ao considerar as tolerâncias da classe A, os MDEs SRTM/X-SAR DEM e TOPODATA obtiveram a escalas de 1:50.000, enquanto os demais MDEs obtiveram 1:100.000 e 1:250.000. A pesquisa mostrou que é relevante a produção de MDEs mais acurados e a frequente atualização cartográfica da região, no suporte dos estudos na região de Belém e Zona Costeira Amazônica (ZCA).

De acordo com Angar et al (2019), os resultados da verificação altimétrica dos MDEs mostraram que o SRTM e o ASTER GDEM apresentaram EMQ de 11,30 e 11,68 metros, respectivamente. O ALOS-PALSAR, com uma resolução espacial melhor que a dos demais, atingiu um EMQ de 16,41 metros. A partir dos resultados, concluiu-se que os sensores geram erros de altimetria muito elevados no talvegue encaixado estudado, porém a maioria dos dados de erros concentram-se nas diferenças altimétricas mais baixas.

Pereira (2019) verificou que o MDE ALOS PALSAR resolução 12 m apresentou melhor precisão para a sub-bacia do Ribeirão dos Mangues com EMQ de $\pm 8,22$ m, enquanto para a sub-bacia do Rio Soninho, o MDE que apresentou melhor precisão foi o SRTM1 resolução 30m com EMQ de $\pm 9,32$ m.

2.1.4 MDE do Estado de Santa Catarina

Em 2010, o Governo do Estado de Santa Catarina, através da Secretaria de Estado do Desenvolvimento Econômico Sustentável (SDS), realizou o Levantamento Aerofotogramétrico do Estado (área de 97.037 km²) na escala de mapeamento de 1:50.000. Tal projeto teve como objetivo a obtenção de dados geográficos de alta precisão que ajudarão no desenvolvimento sustentável do Estado. O Levantamento Aerofotogramétrico contou com mais de 70 mil aerofotos, ortofotomosaicos coloridos e infravermelhos, modelos digitais altimétricos, restituição da hidrografia, bacias hidrográficas e infraestrutura hídrica, com potencial de utilização em diversas atividades ligadas à gestão territorial e ambiental (SIGSC, 2021) (Figura 5). Os dados podem ser encontrados no site SIGSC (<http://sigsc.sc.gov.br/>). A técnica utilizada foi a geometria epipolar em aerofotos, resultando em um MDE de 1 m de resolução espacial.

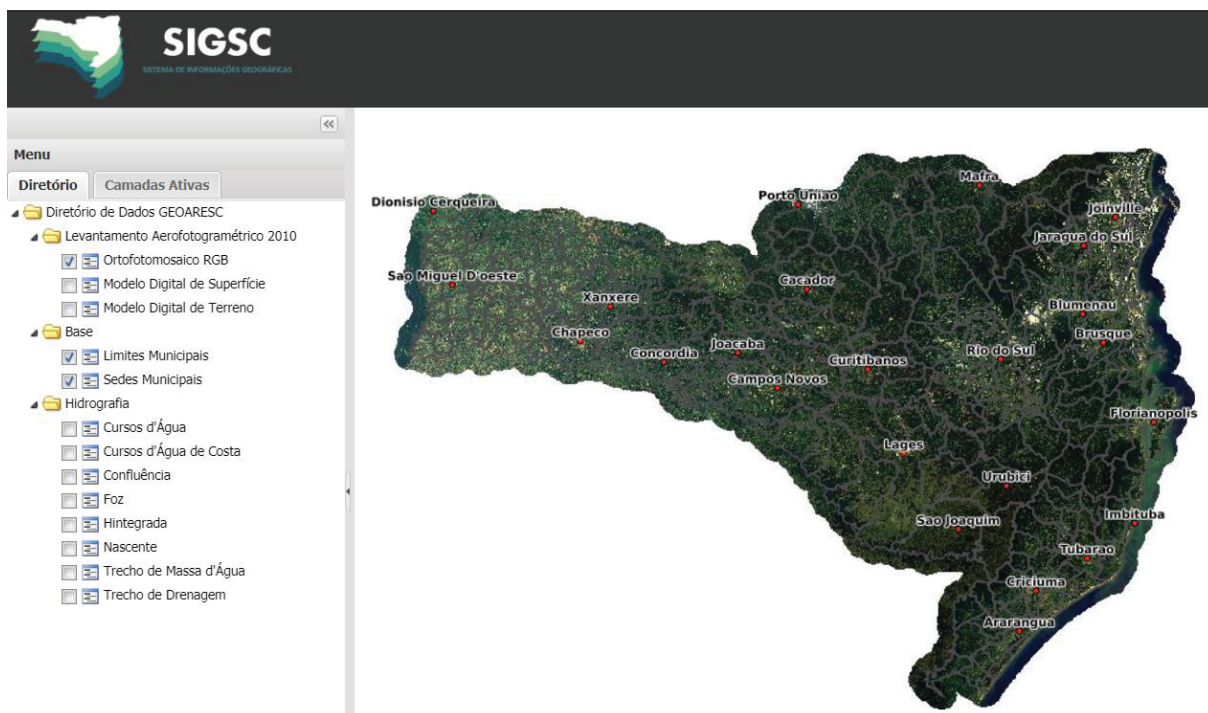


Figura 5 - Imagem do portal de SIG do Estado de Santa Catarina.
Fonte: <http://sigsc.sc.gov.br/mapa-publico.html>

2.1.5 Inclinação e aspecto do terreno

O MDE é amplamente utilizado em diferentes práticas de aplicação de SIG, por fornecer a descrição da superfície tridimensional do terreno, mas também por permitir uma base para derivar outros parâmetros morfológicos da superfície, como inclinação, aspecto, curvatura, perfil de inclinação e áreas de captação. Tais parâmetros são amplamente utilizados em modelagem hidrológica, estudos de erosão do solo, simulação de ambientes ecológicos, dentre outros (Zhou e Liu, 2004).

Um terreno plano não possui inclinação, e, portanto, também não possui aspecto. Em elevações, como montanhas, existem encostas em várias direções (norte, sul, leste e oeste), e é essa direção da inclinação que caracteriza o aspecto. O aspecto apresenta algumas aplicações práticas, como por exemplo, seleção de encostas na agricultura em função do recebimento de radiação solar, estudo da relação de microclimas e biodiversidade, predição de desastres naturais como avalanches, dentre outros.

A inclinação e o aspecto de um MDE são calculados para cada célula deste usando as elevações dos *pixels* e de seus vizinhos.

De acordo com Li, Z., Zhu, Q., Gold, C. (2005), a inclinação é a primeira derivada de uma superfície e tem magnitude e direção. Dessa forma, inclinação é um vetor que consiste em gradiente e aspecto. A inclinação para um determinado local é calculada como a taxa máxima de mudança de elevação entre esse local e seus arredores. A inclinação pode ser expressa em graus ou em porcentagem.

Ainda de acordo com Li, Z., Zhu, Q., Gold, C. (2005), o termo aspecto é definido como a direção do maior vetor de inclinação no plano tangente projetado no plano horizontal. O aspecto é o rumo (ou azimute) da direção da inclinação, e o seu ângulo varia de 0 a 360°, medido no sentido horário em graus de 0 a 360, onde 0 é voltado para o norte, 90 é voltado para o leste, 180 é voltado para o sul e 270 é voltado para o oeste (Figura 6).




Figura 6 - Exemplo de mapa de aspecto.
FONTE: GISGEOGRAPHY, 2022.

2.2 MODELOS DE ONDULAÇÃO GEOIDAL E MODELOS GEOPOTENCIAIS GLOBAIS

O MOG (Modelo de Ondulação Geoidal) é um modelo digital obtido por levantamentos geodésicos, que descreve a variação entre a superfície elipsoidal e a superfície do geóide (IBGE, 2021).

O geóide é uma superfície suavemente ondulada e de difícil modelagem matemática, na literatura é representado por desenvolvimento em séries de harmônicos esféricos. (FREITAS, 1999). Ele é um modelo físico desenvolvido para representar a forma física e equipotencial da Terra, fica definido por uma superfície de mesmo geopotencial, que mais se aproxima do Nível Médio dos Mares (NMM) não perturbado, prolongado através dos continentes (LIMA, 2017).

Carl Fredrich Gauss (1777-1855), matemático, físico e astrônomo alemão, introduziu em 1828 um modelo aperfeiçoado da figura da Terra, entretanto o termo geóide foi criado em 1873 por J.F. Listing (MÉTRICA, 2021).

O objetivo de se conhecer a diferença entre as superfícies geoidal e elipsoidal é para que a altitude acima do nível médio do mar possa ser obtida com sentido físico (MÉTRICA, 2021) (Figura 7).




Figura 7 - Diferença entre geóide, elipsóide e superfície terrestre, onde H significa Altitude Ortométrica, h significa Altitude Elipsoidal, e N significa Ondulação Geoidal.
 Fonte: <https://www.ibge.gov.br/geociencias/modelos-digitais-de-superficie/modelos-digitais-de-superficie/10855-modelo-de-ondulacao-geoidal.html?=&t=o-que-e>

Segundo o IBGE (2021), sobre o MAPGEO2015, tem-se que:

“A nova versão do Modelo de Ondulação Geoidal do Brasil foi calculada com aproximadamente 950.000 estações gravimétricas terrestres na América do Sul, sendo 450.000 dentro do Brasil. Entre estas, 18.485 correspondem a novas estações medidas no território brasileiro desde a divulgação da versão anterior MAPGEO2010.

A informação altimétrica utilizada na redução dos valores de gravidade foi obtida do modelo digital de terreno (MDT) SAM3s_v2, o mesmo adotado na versão anterior do MAPGEO, que se baseia no SRTM - Shuttle Radar Topography Mission. O modelo geopotencial global utilizado para o tratamento dos longos comprimentos de onda do campo da gravidade foi o European Improved Gravity model of the Earth by New techniques - EIGEN-6C4, até o grau e ordem 200, elaborado pelo GFZ/Potsdam e GRGS/Toulouse. Este é um modelo completo derivado da combinação dos dados das missões gravimétricas/modelos LAGEOS, GRACE, GOCE, EGM2008 e DTU.”

2.3 INTELIGÊNCIA ARTIFICIAL

2.3.1 Definições

O termo inteligência tem origem no latim sendo dividido em *inter* (entre) e *legere* (escolher), enquanto o termo artificial vem de *ars* (arte) e *fax* (fazer). A inteligência natural (IN) é o que permite o ser humano poder escolher entre uma coisa e outra, sendo uma habilidade de resolver problemas. Já a IA é uma inteligência desenvolvida pelo homem, por meio de máquinas, que simulam a inteligência e a habilidade natural do próprio homem (FERNANDES, 2003).

A IA consiste na construção e modelagem de um algoritmo que pode descobrir as coisas por si mesmo, que pode reprogramar a si próprio (STERNE, 2017).

Para Kurzweil (1990), a IA é a arte de criar máquinas que executam funções que exigem inteligência quando executadas por pessoas, enquanto para Charniak e McDermott (1985) a IA é o estudo das faculdades mentais pelo seu uso de modelos computacionais. Poole et al. (1998) ainda acrescenta que a inteligência computacional é o estudo do projeto de agentes inteligentes.

A IA simula o comportamento dos seres humanos. Trata-se de um termo bastante abrangente, utilizado para uma grande variedade de tecnologias. Muitas vezes se divide em *Weak AI* (em português, IA Fraca) e *Strong AI* (em português, IA Forte). A primeira tem como características realizar tarefas específicas de forma bastante acurada, enquanto a segunda tem como características pensar como os humanos e imitar o senso comum. (STERNE, 2017).

A IA faz parte da ciência da computação, sendo voltada para o desenvolvimento de sistemas de computadores inteligentes. Tais sistemas exibem características que se relacionam com a inteligência dos humanos, como compreensão de linguagem, resolução de problemas, raciocínio lógico, dentre outros (BARR e FEIGENBAUM, 1981).

O ML (*Machine Learning*), um subcampo da IA, é um sistema desenvolvido com o objetivo de determinar ou descobrir o funcionamento de uma determinada tarefa. Os sistemas de aprendizado de máquina procuram padrões

e tentam compreendê-los. A inovação que envolve o aprendizado de máquina é o fato dele ter sido desenvolvido para aprender, ao invés de seguir regras rígidas e estritas (STERNE, 2017) (Figura 8).

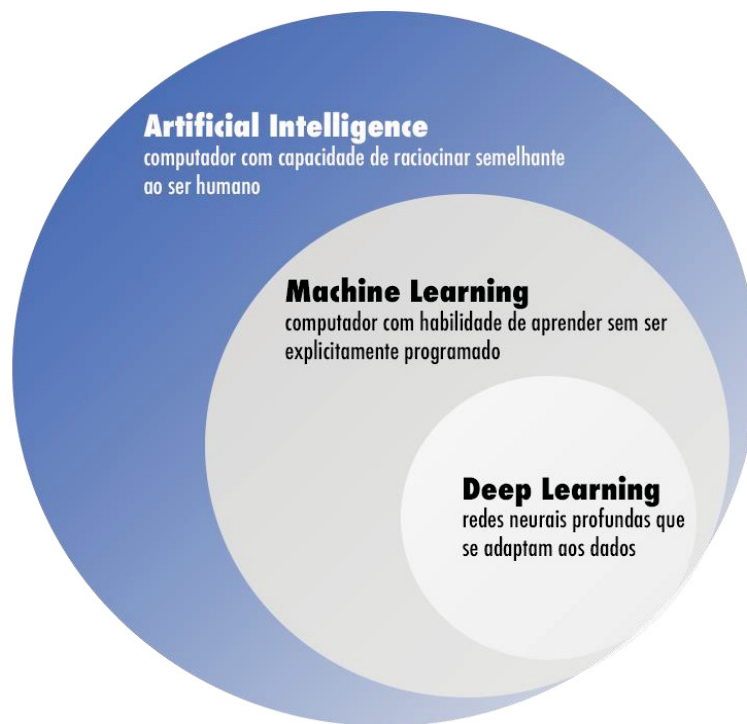


Figura 8 - Divisões da inteligência artificial.

Fonte: <https://medium.com/huia/intelig%C3%A2ncia-artificial-uma-corrida-desleal-80bfa53075ed>

O termo *machine learning* foi cunhado por Arthur Samuel em seu artigo *Some Studies in Machine Learning* (em português, *Alguns Estudos em Aprendizado de Máquina*), em 1959. Segundo ele, o aprendizado de máquina dá aos computadores a capacidade de aprender sem serem programados de forma categórica (PATHAK, 2017).

O aprendizado de máquina está ligado diretamente com a inteligência artificial, dado que se um sistema é capacitado a aprender e exercer determinada tarefa pode ser chamado de inteligente. O aprendizado de máquina é um conceito funcional da IA, pois é responsável pela alimentação da máquina e gera a IA. Tem a possibilidade de aprender com os dados e ainda fazer previsões baseadas em seu aprendizado (PATHAK, 2017).

Segundo Santos (2005), tem-se que:

“Um processo de aprendizagem inclui a aquisição de novas formas de conhecimento: o desenvolvimento motor e a habilidade cognitiva (através de instruções ou prática), a organização do novo conhecimento (representações efetivas) e as descobertas de novos fatos e teorias através da observação e experimentação. Desde o início da era dos computadores, têm sido realizadas pesquisas para implantar algumas destas capacidades em computadores. Resolver este problema tem sido o maior desafio para os pesquisadores de inteligência artificial (IA). O estudo e a modelagem de processos de aprendizagem em computadores e suas múltiplas manifestações constituem o objetivo principal do estudo de aprendizado de máquinas.”

O aprendizado de máquina é um aprendizado por experiência, e, de acordo com a execução da tarefa, o sistema implementa melhores formas de resolver o problema, estruturando o conhecimento existente, chegando a um entendimento do aprendizado (SANTOS, 2005).

Os algoritmos de ML se mostraram ao longo dos anos como uma solução apropriada para problemas com modelagens não-lineares, onde os programas e algoritmos tradicionais que utilizam instruções estáticas não se mostram viáveis. São exemplos de problemas com modelagens não-lineares: tradução de idiomas, previsão do tempo, filtragem de *spam* de correios eletrônicos, previsão do resultado de eleições, problemas de classificação (PATHAK, 2017). São uma alternativa frente a outras técnicas já existentes, sendo que muitas vezes os resultados alcançados podem ser similares, e em outras até mesmo melhores.

São vários os métodos de aprendizado de máquina existentes. O aprendizado por hábito tem por características aprender por experiência, conforme as informações obtidas previamente. O aprendizado por conceito procura analisar todas as hipóteses existentes e provar qual é a correta .

Após a escolha do escopo a ser atingido, a seleção dos dados a serem utilizados, a construção dos *datasets* (em português, conjuntos de dados), e o desenvolvimento do algoritmo, o sistema de aprendizado de máquina necessita de um treinamento inicial apropriado. Tal treinamento é feito utilizando-se o *training dataset* (em português, conjunto de dados de treinamento).

Uma forma de aprendizado de máquina são as RNA (Redes Neurais Artificiais). Tais redes possuem semelhança com o cérebro humano, por serem

uma grande rede de neurônios. Apesar de sua complexidade, é bastante útil devido à sua boa precisão .

O treinamento de uma rede neural artificial (RNA) consiste no ajuste dos pesos sinápticos e bias de modo que o vetor de saída se aproxime da saída esperada. (RUSSELL; NORVIG, 1995).

Na etapa em questão são de suma importância a quantidade e a qualidade dos dados, e a forma como o modelo de aprendizagem foi projetado. O tratamento dos dados antes da construção dos *datasets* se mostra uma medida muito eficaz, já que é desejável que os mesmos sejam precisos, confiáveis, dentre outras características.

Dada a importância dos dados para eficiência do aprendizado de máquina, é necessário que haja grande atenção aos métodos utilizados para a coleta dos mesmos (STERNE, 2017).

Numa etapa subsequente o algoritmo utilizará o *input dataset* na máquina (modelo de aprendizagem) já treinado com o intuito de obter as respostas para o escopo determinado inicialmente, podendo inclusive realizar previsões.

Para a obtenção de uma solução com um maior grau de confiança, fases como aquisição e seleção de dados, configuração de *datasets*, seleção e ajuste (adaptação) do algoritmo do modelo de aprendizagem, interpretação dos resultados, dentre outras devem ser realizadas com devido critério e cautela, face à grande flexibilidade apresentada por tais métodos. Dentre alguns processos que envolvem o desenvolvimento de sistemas de aprendizado de máquina, destacam-se: preparação e exploração de dados, engenharia de recursos, modelagem e avaliação de modelos.

De acordo com Luger (2004), o aprendizado é qualquer mudança num sistema que melhore o seu desempenho na segunda vez que ele repetir a mesma tarefa, ou uma outra tarefa sobre a mesma população. Já para Dean et al. (1995), tal aprendizado ocorre quando o sistema adquire novo conhecimento a partir de seu ambiente ou quando ele organiza seu conhecimento para fazer melhor uso deste.

Os MLs podem ser classificados quanto ao tipo de aprendizagem de três maneiras diferentes: supervisionado, não supervisionado e por reforço (STERNE, 2017) (Figura 9).



Figura 9 - Tipos e exemplos de uso do Aprendizado de Máquina.
 Fonte: <https://dev.to/beatrizmaiads/tipos-de-aprendizado-de-maquina-3-5d66>

A aprendizagem supervisionada ocorre quando o sistema computacional que se deseja que realize uma determinada tarefa, o faz aprendendo a partir de dados que contêm variáveis (variáveis independentes) e resultados (variáveis dependentes), de forma que ao final do processo tenha conseguido melhorar sua performance. São classificados em problemas de regressão e classificação.

A aprendizagem não supervisionada trata de problemas onde se tem pouco ou nenhum conhecimento acerca dos resultados que devem ser apresentados. Para tanto, deriva-se a estrutura dos dados, onde não necessariamente se saberia o efeito das variáveis, agrupando-os com base nas relações existentes entre eles. O aprendizado não supervisionado pode ser usado para reduzir o número de dimensões em um conjunto de dados para concentrar somente os atributos mais úteis, e para detectar tendências.

A aprendizagem por reforço é aquela em que a máquina tenta aprender qual é a melhor ação a ser tomada, em função das circunstâncias na qual essa ação é inserida. Esse tipo de aprendizagem utiliza-se do conceito de “aprendizagem por reforço” da psicologia, onde uma recompensa ou punição é dada a um agente, de acordo com a decisão escolhida. Com o tempo e a repetição dos experimentos, a máquina vai associando as ações que geram maior recompensa para cada situação que o ambiente apresenta, e passa a furta-se das ações que geram punição.

2.3.2 Deep learning

O *deep learning* (DL) (em português, aprendizado profundo) é uma técnica específica dentre as demais existentes no aprendizado de máquina. É uma técnica inovadora, que tem como característica tornar o aprendizado de máquina mais rápido e mais preciso (PATHAK, 2017).

Em comparação com a tradicional técnica de aprendizagem de máquina denominada *Artificial Neural Networks (ANN)* (em português, redes neurais artificiais - RNA), a técnica DL costuma ser mais vantajosa, já que a primeira apresenta um uso bastante intensivo em CPU e produz resultados piores que o esperado (PATHAK, 2017).

Os algoritmos de DL possuem várias camadas de redes neurais, e necessitam de grandes quantidades de dados de treinamento para atingir seus objetivos (PATHAK, 2017).

O DL utiliza arquiteturas profundas de aprendizado, possuindo várias camadas ocultas de processamento (*hidden layers*) entre a camada de entrada dos dados e a camada de saída dos resultados do algoritmo. Diversos artigos científicos têm descrito o DL como uma abordagem do aprendizado de máquina com capacidade de resolver aproximadamente todos os tipos de problemas em diferentes áreas do conhecimento (ALOM *et al.*, 2019).

De acordo com ALOM *et al.* (2019), o emprego do DL se dá em situações em que a solução do problema em questão muda em função do tempo (como previsões do tempo, levantamento de estoques, previsão de preços, rastreamento de coordenadas, dentre outros), em situações onde as soluções devem ser adaptadas e específicas (como no caso de personalizações e biometrias), em situações onde seja necessário a utilização de grande quantidade de processamento para a resolução do problema, em situações onde há a ausência da expertise humana, e em situações onde a descrição dos conhecimentos necessários para a resolução do problema é demasiadamente complexa (como no caso do reconhecimento de fala, visão e a compreensão de linguagem).

2.3.2.1 Convolutional Neural Network

Entende-se como Rede Neural Convolucional (*Convolutional Neural Network* – CNN) a variação das redes de Perceptrons de Múltiplas Camadas, que é inspirada no processo biológico de processamentos de dados visuais, e utiliza conceitos de DL. A CNN possui a característica de aplicar filtros em dados visuais, mantendo a relação de vizinhança entre os *pixels* da imagem ao longo do processamento da rede (OUYANG e WANG., 2013) (Figura 10). Foi desenvolvida, inicialmente, por Yann LeCun, em 1998. Teve inspiração biológica nos experimentos realizados em 1962 de Hubel e Wisel, que tinham o objetivo de demonstrar que a ativação conjunta de determinados neurônios produzia o reconhecimento visual de algumas linhas ou curvas.

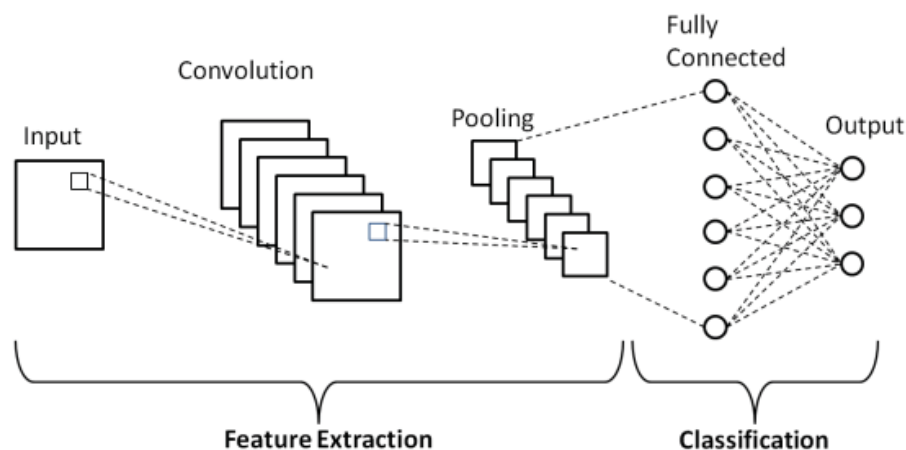


Figura 10 - Diagrama de uma CNN básica.

Fonte: https://www.researchgate.net/figure/Schematic-diagram-of-a-basic-convolutional-neural-network-CNN-architecture-26_fig1_336805909

Uma CNN é constituída de múltiplas partes com funções diferentes (*input layer, convolutional layers, pooling layers, fully connected neural network, output layer*). Uma camada de convolução (*convolutional layer*) compõe-se de diversos neurônios, cada um destes com a função de aplicar um filtro em uma determinada área da imagem. Cada neurônio pode ser entendido como estando conectado a um conjunto de *pixels* da camada anterior e que a cada uma dessas conexões se atribui um peso. A combinação das entradas de um neurônio, utilizando os pesos de suas conexões, produz uma saída que é repassada para a camada seguinte. Os pesos das conexões de um neurônio podem ser

entendidos como uma matriz que representa o filtro de uma convolução de imagens no domínio espacial (kernel ou máscara) (OUYANG e WANG, 2013).

Na formulação de perceptrons clássica, um neurônio é conectado a todos os neurônios da camada anterior, ao passo que nas CNN é possível que apenas um subconjunto de entradas seja conectado a cada neurônio. O tamanho do filtro define o tamanho da vizinhança que cada neurônio da camada irá processar. Nas camadas de convolução das CNN é preciso definir somente a arquitetura dos filtros, como quantidade e tamanhos (*stride*), dos filtros por camada. O processo de aprendizado da rede altera os pesos ao longo do treinamento, até encontrar os melhores valores dos filtros para o conjunto de dados utilizados. Uma das formas de se avaliar o aprendizado é verificar as ativações dos filtros obtidos no final do treinamento (ZEILER e FERGUS, 2014).

Comumente, aplica-se uma função de ativação logo após a convolução. Esta função é responsável por aplicar uma transformação nos dados recebidos. Outra camada comumente utilizada após as camadas de convolução e ativação é a camada de agrupamento (*pooling*). A função desta camada é reduzir a dimensionalidade dos dados na rede. Quando se deseja realizar uma tarefa de classificação é acrescentada após o conjunto das camadas de convolução e *pooling* ao menos uma camada totalmente conectada. Esta camada é responsável por traçar um caminho de decisão a partir das respostas dos filtros vindos das camadas anteriores, para cada classe de resposta. Depois da camada completamente conectada, o último passo é a função de classificação. Essa camada é muito importante no treinamento, pois influencia no aprendizado dos filtros e conseqüentemente no resultado da rede (VARGAS et al., 2016).

Ao final da rede convolucional, fica situada uma rede neural que é responsável pela função de classificação do algoritmo. Tal camada pode ser ou não completamente conectada. Sua entrada é a saída da camada convolucional anterior, e a sua saída é formada por N neurônios, sendo N a quantidade de classes do seu modelo necessárias para realizar a classificação.

Atualmente, as principais aplicações dessa classe de rede neural são: reconhecimento de imagens e processamento de vídeo, processamento de voz, linguagem natural e detecção de patologias na medicina.

2.3.2.2 *Generative Adversarial Network*

Uma *Generative Adversarial Network* (GAN) é uma classe de sistemas de aprendizado de máquina inventada por Ian Goodfellow em 2014 (GOODFELLOW et al., 2013). Duas redes neurais competem entre si em um jogo (no sentido da teoria dos jogos, na forma de um jogo de soma zero). Essa técnica gera novos dados com as mesmas estatísticas que o conjunto de treinamento.

Nos últimos anos, as GANs têm apresentado resultados muito promissores no que tange à geração de novos conteúdos ou à geração de conteúdos falsos. As RNs aprendem a relação que os dados possuem, compreendendo dessa forma o que caracteriza cada um desses dados. As GANs, como RNAs, se utilizam dessa possibilidade para a geração de dados novos.

Por exemplo, uma GAN treinado em fotografias pode gerar novas fotografias que parecem pelo menos superficialmente autênticas para os observadores humanos, com muitas características realistas. Embora originalmente proposto como uma forma de modelo generativo para aprendizado não supervisionado, as GAN também se mostraram úteis para aprendizado semi-supervisionado, aprendizado totalmente supervisionado e aprendizado por reforço (PHILLIP et al., 2017).

As GANs também apresentam como recurso a possibilidade de reconstruir parte de dados perdidos, como por exemplo parte de imagens cortadas, imagens com ruídos, imagens históricas, imagens com borrões, dentre outros.

A GAN pode ser utilizada tanto em imagens estáticas como em vídeos. Os algoritmos GAN têm sido empregados na consecução de filmes de animação, com o objetivo de aumentar a resolução dos frames da produção. As técnicas de visão computacional anteriormente utilizadas não alcançavam a mesma qualidade no que tange ao aumento de resolução de imagens (aumento de dimensão das imagens). Tal desempenho é obtido pela GAN, dentre outras características, pela capacidade de criação de *pixels* a partir do conhecimento de outras imagens.

No que tange aos vídeos, verifica-se que a renderização dos mesmos é uma etapa custosa, já que as produções apresentam muitos frames por segundo, demandando alto custo computacional. Com a possibilidade do emprego das GANs, pode-se vislumbrar uma renderização em baixa resolução e, numa etapa posterior, se utilizar o referido algoritmo para um aumento de resolução da produção, sendo uma solução economicamente mais viável.

O algoritmo possui duas redes neurais associadas: uma denominada modelo discriminador e outra denominada modelo gerador. O modelo discriminador é treinado com imagens reais e imagens falsas com o intuito de aprender a diferenciar entre as duas, de forma que ele consiga fazer a discriminação entre ambas. Já o modelo gerador tem a função de transformar uma entrada, que pode ser, por exemplo, um ruído, em uma imagem que tenta se assemelhar ao máximo de uma imagem real. Dessa forma, o gerador produz imagens falsas, envia para o discriminador, que as classifica com real ou falsa. O resultado de tal classificação serve como entrada para a calibração dos pesos do algoritmo do gerador, aprimorando o modelo.

O modelo gerador recebe um ruído como entrada. Sua camada inicial alimenta uma camada totalmente conectada de neurônios. Tal camada inicial, ao invés de ser um vetor, ela é conectada como uma matriz, criando uma camada convolucional, com o objetivo de criar uma imagem ao final do modelo. Uma camada convolucional é criada contendo 3 dimensões, onde 2 (duas) são referentes ao tamanho da imagem e uma referente ao número de *feature maps* existentes.

A rede convolucional criada realiza o *upsampling* da imagem a cada nova camada de convolução. Assim sendo, o ruído inicial que foi transformado em uma imagem alimenta as demais camadas convolucionais, com a aplicação de diversos *feature maps*, até alcançar a imagem resultante com as dimensões e características desejadas. Quanto mais camadas de convolução, mais pesos serão utilizados para a calibração dos parâmetros desejados, aumentando-se também o tamanho da imagem. Na última camada convolucional, ao invés de se utilizar vários filtros empilhado, adota-se um único filtro de saída, com o objetivo de gerar a imagem final.

O modelo discriminador recebe 2 tipos de dados de entrada: as imagens reais (*Ground Truth*) e as imagens falsas (*Low Resolution Images*). O

treinamento realizado com esses 2 diferentes insumos faz com que ela aprenda a diferenciar um do outro. Atribui-se, para fins de treinamento, um valor de classe 1 para as imagens reais e um valor de classe 0 para as imagens falsas. Após o treinamento, a RN em questão estará apta a classificar uma nova imagem como 1 ou 0 (real ou falsa). As imagens reais se constituem do *dataset* utilizado. Já as imagens falsas são as próprias imagens criadas pela RN geradora.

Quando da utilização das RNs conectadas, pode-se verificar o erro obtido, de forma que o mesmo possa ser aplicado aos algoritmos através do *backpropagation*. Ao passar uma imagem falsa pela RN discriminadora, o algoritmo faz uma previsão do valor de saída da mesma, utilizando uma função de ativação sigmoideal, gerando valores no intervalo entre 0 e 1, onde os valores mais próximos de 0 apresentam maior probabilidade de serem falsos e os valores mais próximos de 1 apresentam maior probabilidade de serem reais. Calcula-se o complementar em relação a 1 do resultado obtido, denominando-se tal valor de erro. Tal informação é dessa forma transmitida para o gerador por meio do *backpropagation*, fazendo com que o referido algoritmo busque a diminuição de tal parâmetro em processamentos futuros, através da atualização de seus pesos.

O SRGAN (*Super Resolution GAN*) utiliza uma GAN para produzir imagens de alta resolução (Figura 11). Durante o treinamento, uma imagem de alta resolução (HR) é degradada para uma imagem de baixa resolução (LR). Um gerador GAN modela as imagens de baixa resolução para imagens de SR. Utiliza-se um discriminador para distinguir as imagens de HR e retropropagar a perda de GAN para treinar o discriminador e o gerador. O discriminador é composto principalmente por camadas de convolução, normalização de lote e ReLU (*Rectified Linear Unit*) parametrizado (PReLU - *Parametric Rectified Linear Unit*) (LEDIG et al., 2017).

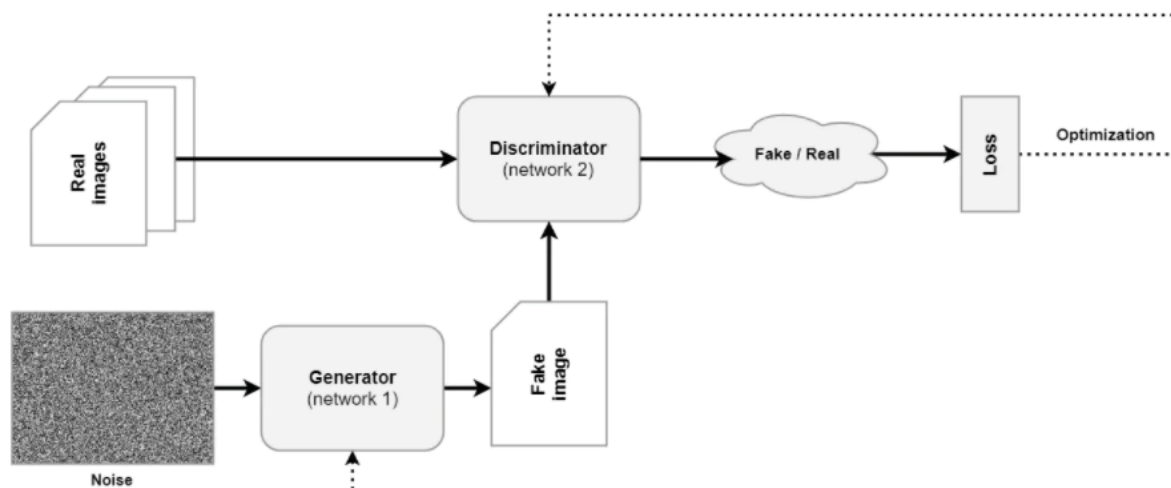


Figura 11 - Esquema de uma Rede Adversária Generativa.

Fonte: <https://www.machinecurve.com/index.php/2021/03/23/generative-adversarial-networks-a-gentle-introduction/>

O ESRGAN (*Enhanced Super-Resolution Generative Adversarial Networks*), derivado do SRGAN, alcança qualidade visual consistentemente melhor com texturas mais realistas e naturais do que a SRGAN. O ESRGAN é capaz de gerar estruturas mais detalhadas na construção, enquanto outros métodos falham ao produzir detalhes suficientes (SRGAN) ou adicionam texturas indesejadas (EnhanceNet). Além disso, métodos anteriores baseados em GAN às vezes introduzem distorções na imagem. O método ESRGAN produz texturas mais naturais (WANG et al., 2018).

2.4 ACURÁCIA POSICIONAL E ANÁLISE DE OBSERVAÇÕES

2.4.1 Acurácia posicional

Obtém-se a acurácia posicional a partir do cálculo das diferenças entre as coordenadas de feições em uma fonte de maior qualidade e seus pontos homólogos no produto a ser avaliado, comparando o desvio padrão obtido com o valor correspondente à escala do produto e verificando se o mesmo possui acurácia posicional mínima exigida (MARANHÃO, 2013).

Da necessidade da normatização de produtos geoespaciais, a *International Organization for Standardization* (ISO) lançou a série ISO 19000, com o objetivo de padronizar os dados geoespaciais. Tal série de normas

procurou, principalmente, definir formas para classificar a qualidade da informação geoespacial de duas maneiras: posicional e semântica (ISO 19157, 2013).

Dada a importância do controle de qualidade posicional dos produtos cartográficos, diversos países estabelecem normas com o objetivo de realizar tal controle em seus territórios.

De acordo com o Decreto n.º 89.817 de 20 de junho de 1984 foram estabelecidas as Instruções Reguladoras das Normas Técnicas da Cartografia Brasileira, em que foram utilizados como referência os parâmetros que as constituem e dividem o Padrão de Exatidão Cartográfica (PEC) em diferentes classes, considerando 90% de probabilidade, que define a exatidão de trabalhos cartográficos (BRASIL, 1984). Tal Decreto não previa um número mínimo de pontos de verificação necessários à comprovação da acurácia dos documentos, refletindo os métodos e tecnologias disponíveis à época (DSG, 2016) (Tabela 1 e Tabela 2).

Tabela 1 - Quadro com o PEC altimétrico e o EP (Erro Padrão) das cartas em função das equidistâncias.

Carta	PEC altimétrico	Erro padrão
Classe A	½ da equidistância	1/3 da equidistância
Classe B	3/5 da equidistância	2/5 da equidistância
Classe C	3/4 da equidistância	½ da equidistância

Fonte: Adaptado de BRASIL, 1984.

Tabela 2 - Quadro com o PEC planimétrico e o EP (Erro Padrão) das cartas em função das equidistâncias.

Carta	PEC planimétrico	Erro padrão
Classe A	0,5 mm x escala	0,3 mm x escala
Classe B	0,8 mm x escala	0,5 mm x escala
Classe C	1,0 mm x escala	0,6 mm x escala

Fonte: Adaptado de BRASIL, 1984.

A ET-ADGV estabeleceu um novo Padrão de Exatidão Cartográfica destinado a atender os Produtos Cartográficos Digitais (PEC-PCD) (DSG, 2011). O enquadramento das classes no PEC-PCD baseia-se nas estatísticas de 90% dos pontos coletados no produto cartográfico em relação às coordenadas dos pontos homólogos coletados na fonte de maior precisão. Para que sejam enquadrados nas classes do PEC-PCD, as discrepâncias entre as coordenadas dos pontos homólogos devem resultar em valores iguais ou inferiores de erro

máximo (EM) e de erro padrão (EP) previstos para cada produto (DSG, 2016) (Tabela 3).

Tabela 3 - Quadro com os valores do PEC-PCD para modelos digitais de superfície e do terreno para a produção de produtos cartográficos digitais.

PEC -PCD	1:1.000		1:2.000		1:5.000		1:10.000		1:25.000		1:50.000		1:100.000		1:250.000	
	PEC	EP	PEC	EP	PEC	EP	PEC	EP	PEC	EP	PEC	EP	PEC	EP	PEC	EP
	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)	(m)
A	0,27	0,17	0,27	0,17	0,54	0,34	1,35	0,84	2,70	1,67	5,50	3,33	13,70	8,33	27,00	16,67
B	0,50	0,33	0,50	0,33	1,00	0,66	2,50	1,67	5,00	3,33	10,00	6,66	25,00	16,66	50,00	33,33
C	0,60	0,40	0,60	0,40	1,20	0,80	3,00	2,00	6,00	4,00	12,00	8,00	30,00	20,00	60,00	40,00
D	0,75	0,50	0,75	0,50	1,50	1,00	3,75	2,50	7,50	5,00	15,00	10,00	37,50	25,00	75,00	50,00

Fonte: Adaptado de DSG, 2011.

2.5 AVALIAÇÃO DE SUPER RESOLUÇÃO DE SUPERFÍCIES ALTIMÉTRICAS

Os métodos de avaliação de super resolução de superfícies altimétricas serão apresentados e discutidos no Capítulo 3, na seção 3.5. Foram apresentadas diferentes formas de avaliação de super resolução na seção 1.6 Estado da Arte do Capítulo 1. Algumas das métricas apresentadas serão próprias de imagens, porém outras são amplamente utilizadas em avaliação em comparação de MDEs.

3 MATERIAIS E MÉTODOS

Neste capítulo serão apresentadas a forma de aquisição dos dados, a área de estudo, a geração dos *datasets*, os recursos utilizados na pesquisa, as etapas metodológicas dos processamentos, geração e avaliação dos produtos, permitindo a realização das análises. Esse arcabouço metodológico servirá como uma apresentação dos resultados obtidos no Capítulo 4.

3.1 AQUISIÇÃO DOS DADOS

Os dados selecionados para a realização desta pesquisa foram os MDEs, os MOGs, e os MGGs. Tais dados são representações de elevação para a representação de superfícies altimétricas (terreno e ondulação geoidal) e são de extrema importância para a determinação de mapas de relevo, sendo amplamente utilizados em sistemas de informações geográficas (SIG). São úteis para a modelagem de paisagem, modelagem de cidades, aplicações de visualização, modelagem de inundação ou drenagem, estudos de uso da terra, aplicações geológicas, fornecer os fatores para conversão das altitudes dadas pelos receptores GNSS, cálculo dos valores numéricos de grandezas relacionadas ao potencial da gravidade, dentre outras.

Tais superfícies altimétricas podem ser representadas como um *raster*, como uma rede irregular triangular baseada em vetor (TIN), como uma lista de pontos com coordenadas e informações altimétricas associadas, dentre outros.

3.1.1 Área de estudo

O Estado da Área de Estudo desta pesquisa - região do Estado de Santa Catarina (ESC) - recentemente realizou o mapeamento sistemático de seu território na escala de 1:50.000 e, dentre os insumos adquiridos para a produção cartográfica objetivada estão os modelos digitais de superfície e os modelos digitais do terreno. Tais insumos possuem alta resolução espacial, com *pixels* de 1 metro, e encontram-se disponibilizados em site mantido pelo próprio governo estadual, que visa tornar acessíveis tais dados geográficos para toda a população. Esses dados podem ser livremente utilizados para fins de pesquisa.

Tal área de estudos encontra-se localizada na região sul do Brasil, compreendida entre as longitudes $-54^{\circ} \leq \lambda \leq -48^{\circ}$ e latitudes $-30^{\circ} \leq \varphi \leq -25^{\circ}$, que abrange totalmente o anteriormente referido Estado (Figura 12).

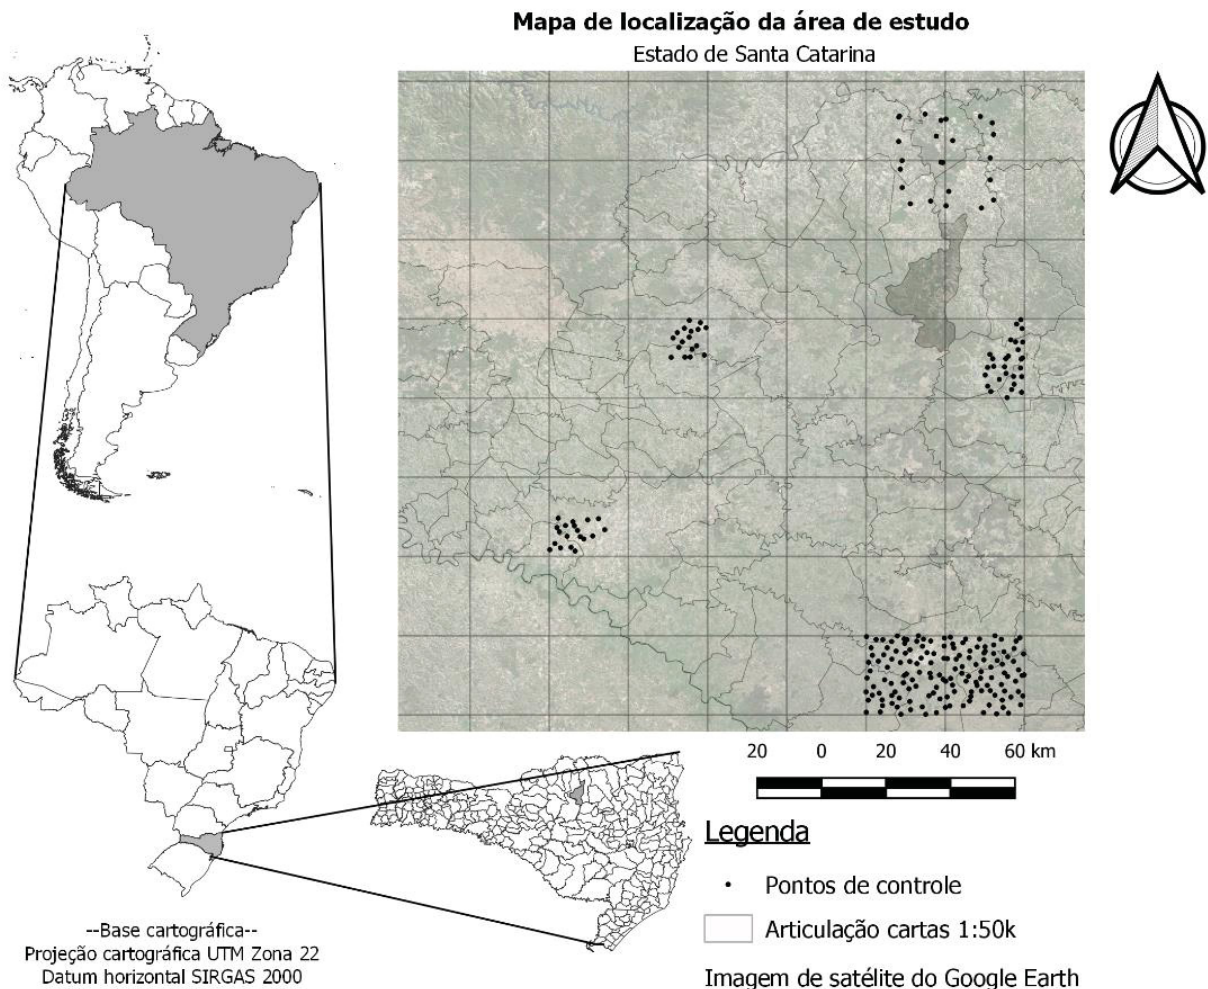


Figura 12 - Localização da área de estudos.
Fonte: O autor (2020).

Os MDEs globais selecionados podem ser utilizados livremente para fins de mapeamento, porém o fato de suas resoluções variarem entre 90 e 12,5 metros reduz as possibilidades dos seus empregos em mapeamento de escalas maiores, como 1:25.000.

Percebe-se ainda, que na área de estudos o Modelo de Ondulação Geoidal brasileiro MAPGEO2015 apresenta grandes discrepâncias relativamente a GNSS/RN, na ordem de -1 metro a +0,6 metros em cerca de 500 km (IBGE, 2015).

A Serra do Mar está incluída na Área de Estudo. Tal formação geológica, característica da região leste de Santa Catarina, apresenta variação de altitudes com cimos elevados acima de 1800 metros. A referida serra teve sua formação a partir de movimentos epirogênicos, tectônicos e das alterações do clima, sendo um sistema montanhoso constituído por montanhas, escarpas e restos de planaltos. É um relevo com características acentuadas devido à processos erosivos intensos.

3.1.2 Dados

Para a realização da presente pesquisa, foram selecionados os seguintes dados: MDE SRTM de 90 metros (<https://earthdata.nasa.gov>), MDE SRTM de 30 metros (<https://earthdata.nasa.gov>), MDE Alos Palsar de 12,5 metros (<https://earthdata.nasa.gov>), e MDE do Estado de Santa Catarina (MDE ESC) de 1 metro (<http://sigsc.sc.gov.br>).

Todos os modelos digitais selecionados encontram-se disponíveis para a aquisição e uso na internet.

Foram ainda utilizados o MOG MAPGEO2015 (<https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/10855-modelo-de-ondulacao-geoidal.html?=&t=acesso-ao-produto>) e o MGG EGM2008 (<http://icgem.gfz-potsdam.de/home>), ambos referentes à área indicada na seção 1.1.1. O MAPGEO2015 apresenta cobertura nacional, enquanto o EGM2008 apresenta cobertura global.

Após a inscrição nos referidos portais, foram identificadas as áreas de interesse para a pesquisa, feito o download das imagens e *grids* de interesse e o arquivamento das mesmas no banco de dados criado (Figura 13 e Figura 14).

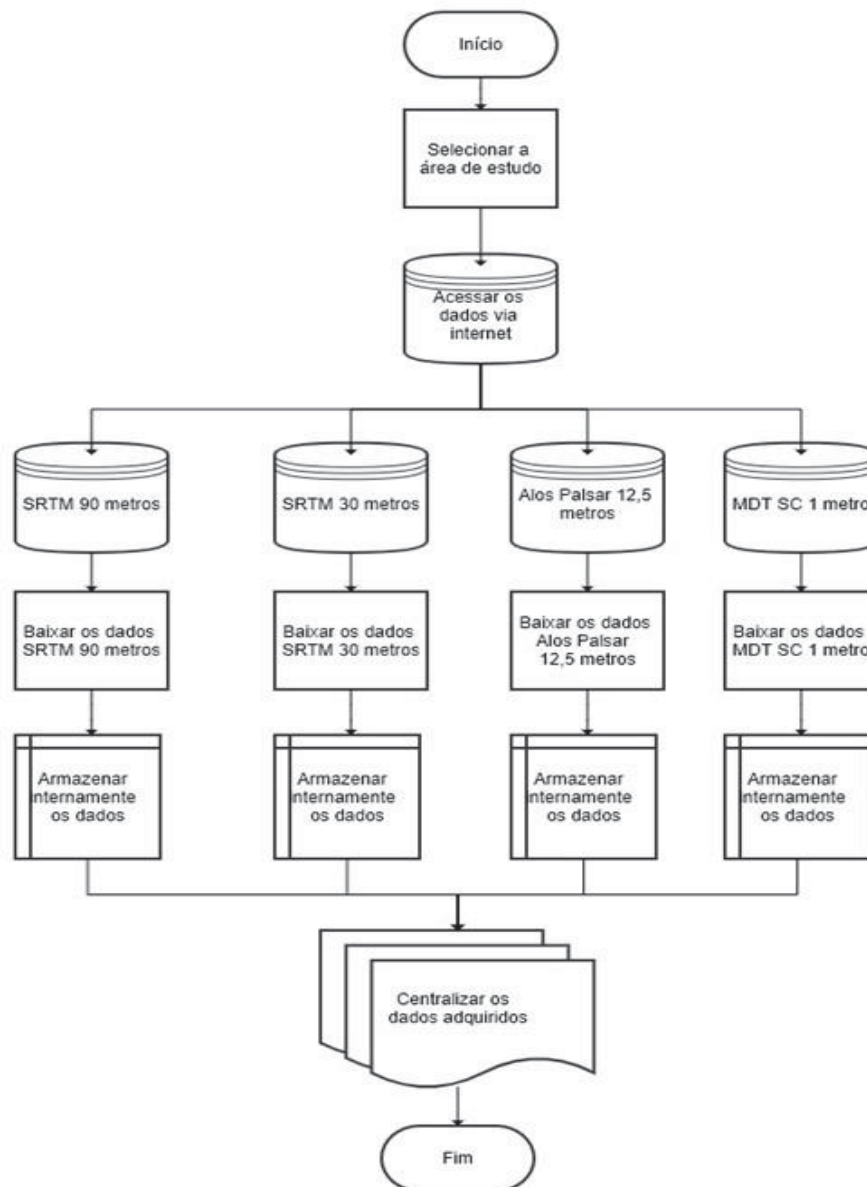


Figura 13 - Fluxograma de aquisição dos dados referentes aos MDEs para a pesquisa.
Fonte: O autor (2022).

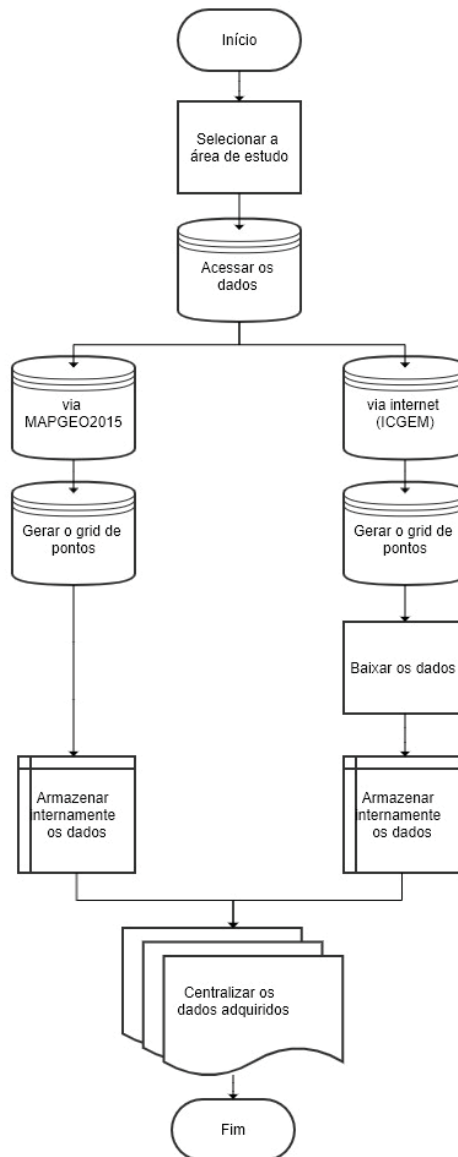


Figura 14 - Fluxograma de aquisição dos dados referentes aos MGG EGM2008 e MOG MAPGEO2015 para a pesquisa.
Fonte: O autor (2022).

3.2 GERAÇÃO DOS DATASETS

A conformação de bons *datasets* é um trabalho importante, tanto do ponto de vista técnico como também do ponto de vista conceitual.

3.2.1 Pré-processamento dos dados

A qualidade dos dados é uma das principais preocupações quando da utilização de modelos de aprendizagem de máquina e *deep learning*. Se a

existência de problemas nos dados for identificada e tratada antes de sua utilização em algum algoritmo, espera-se obter informações mais preditivas e representativas.

A fase de análise preliminar dos dados se inicia após a coleta e organização dos mesmos. Tal fase possibilita: aprender mais sobre os dados, alterar sua estrutura, identificar e tratar dados corrompidos, valores desconhecidos, dentre outros.

Para a realização do pré-processamento dos dados, inicialmente se acessa o arquivo das imagens, faz-se a verificação da consistência dos dados, realiza-se a conversão dos EPSG (utilizando o Python e a biblioteca GDAL) e, por fim, salva-se os novos arquivos no novo banco de dados (Figura 15).

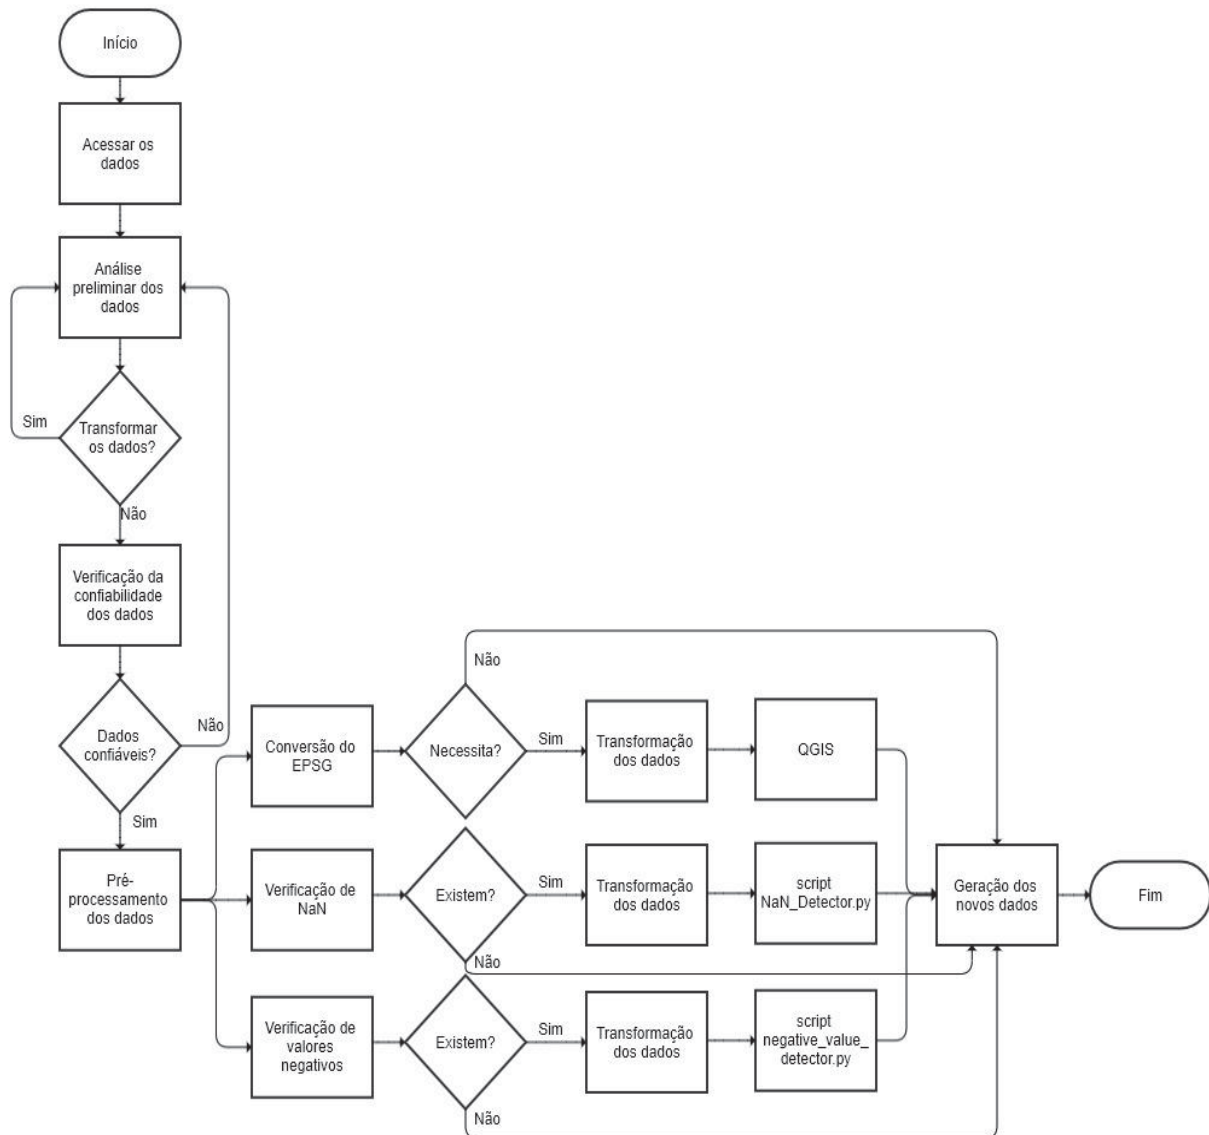


Figura 15 - Fluxograma de pré-processamento dos dados dos modelos para pesquisa.
Fonte: O autor (2022).

Posteriormente, ainda foram realizados dois procedimentos, sendo um para a verificação de valores *Not a Number* (NaN) nas amostras, e outro para a verificação de valores negativos. O procedimento para a detecção de valores *Not a Number* nas amostras se inicia com a abertura dos arquivos, é feita uma avaliação e verificação dos dados, e caso necessário ainda é feita a transformação dos dados, e o salvamento do novo arquivo.

Já o procedimento para a verificação dos valores negativos nas amostras se inicia com a abertura do arquivo, seguido por uma avaliação e verificação dos dados do modelo quanto aos seus valores. Caso necessário, o algoritmo desenvolvido faz a transformação dos dados e o salvamento do novo arquivo.

A transformação dos dados neste procedimento para a verificação dos valores negativos nas amostras se inicia com a abertura dos arquivos, seguida pela criação do Pandas *DataFrame* com os dados. Em seguida, o algoritmo desenvolvido modifica os valores negativos dos dados e por fim, realiza o salvamento do novo arquivo em .TIF.

A biblioteca Pandas é muito utilizada em ciências de dados, oferecendo estruturas de dados intuitivas e ajustáveis. Permite manipular diferentes tipos de dados, como dados estruturados e séries temporais. Admite lidar com valores ausentes em listas ou matrizes.

Para a realização da análise da disposição e localização dos valores negativos e nulos detectados em algum modelo, foi desenvolvido um algoritmo em Python com o objetivo de gerar uma imagem binária do MDE em questão. Assim sendo, inicia-se o processo com a abertura do arquivo, seguido pela criação do Pandas *DataFrame* com os dados. Em seguida, atribui-se o valor 0 para os *pixels* de valores negativos e nulos da imagem, e o valor 1 para os *pixels* de valores positivos da imagem. Por fim, realizou-se o salvamento do novo arquivo em .TIF (Figura 16).

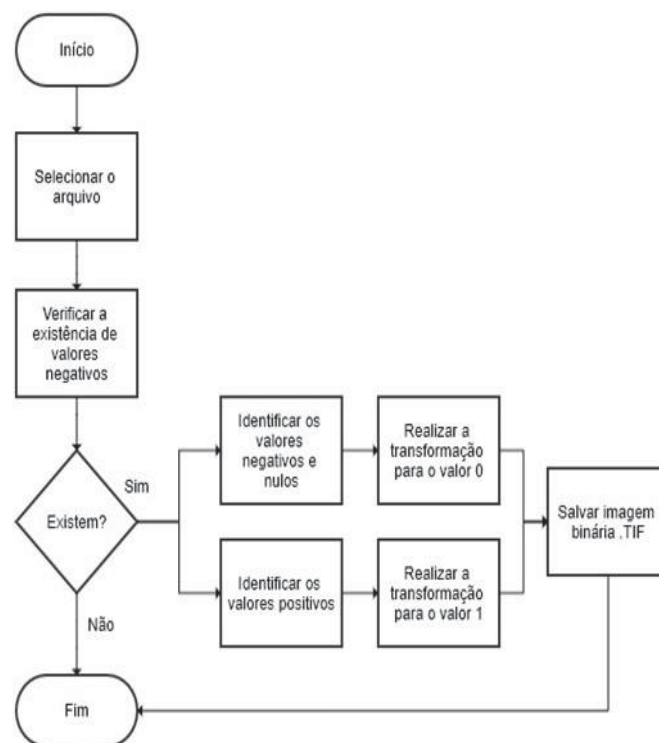


Figura 16 - Fluxograma de metodologia de geração de imagem binária dos dados do modelo.
Fonte: O autor (2022).

Conforme a disposição dos *pixels* negativos na imagem, pode-se optar pela utilização do algoritmo de filtro de matriz 3x3 (ARAKI, 2021), que atenua os valores a serem substituídos dos *pixels* em função dos seus oito *pixels* vizinhos (média dos *pixels*), gerando maior suavização no terreno. Tal filtro é utilizado em toda a imagem.

Foi feita uma verificação nos arquivos dos MDEs (de alta e de baixa resolução) utilizados nos *datasets* 1, 2, 3, 4, 5 e 6 apresentados quanto à existência de dados com o valor *Not a Number* (NaN), e foi obtido como resultado que nenhuma das imagens continha tais tipos de valores, não sendo necessário a realização de nenhum tipo de tratamento de imagens nas mesmas nesse sentido.

Quanto aos *datasets* 2, 3 e 4, ainda foram feitas verificações nos arquivos MDEs quanto à existência de dados negativos, e foi obtido como resultado que a imagem do modelo SRTM 30 possuía tais tipos de valores (28917 *pixels* com valores negativos), sendo necessário a realização de uma análise para verificar a necessidade ou não de algum tipo de tratamento de imagens. Primeiramente foi realizada a geração da imagem binária do modelo, com o objetivo de identificar a distribuição e localização de tais *pixels*, possibilitando posterior decisão quanto à solução a ser aplicada (Figura 17). Foram encontrados *pixels* com valores negativos em locais em que se encontravam regiões com água. Tais valores foram processados utilizando algoritmo desenvolvido para identificar tais *pixels*, assim como suas vizinhanças. Nos *datasets* 5 e 6 não houve necessidade de nenhuma correção nesse sentido.



Figura 17 - Imagem binária do arquivo do MDE SRTM de resolução de 30 metros, visualizada no QGIS, onde os pixels em cor amarela têm valor 1 e os pixels em cor preta têm valor 0.
Fonte: O autor (2022).

3.2.2 Criação dos *datasets*

A criação dos *datasets* se deu a partir do recorte de cada uma das imagens utilizadas dos MDEs de alta e baixa resolução espacial em *tiles* (em tradução livre, recortes) de 156 por 156 *pixels* para as imagens do *ground truth* (verdade de campo). Tais recortes foram organizados em pares (ground truth e imagem de baixa resolução), sendo então, constituídos como os *datasets* de treino e de validação, onde foram procedidos os treinamentos dos modelos DEM-ESRGAN utilizados para a geração da imagem de super-resolução, assim como a realização das avaliações.

Para a criação dos *datasets* envolvendo o MOG e o MGG houve a necessidade de uma fase adicional, onde *grids* foram convertidos em *rasters* por meio de interpolação, para só então serem recortados em *tiles*.

A criação dos *datasets* se iniciou a partir da seleção dos arquivos .TIF (arquivos de alta resolução ou *ground truth*, que são a verdade do terreno, e os arquivos de baixa resolução, que são processados pelo algoritmo GAN) da área determinada para a realização do processamento do modelo. Posteriormente,

determinou-se o número de pares de amostras de acordo com cada processamento. Em seguida, fez-se o corte dos pares de amostra selecionando-se o número de linhas e colunas que comporão a imagem de alta resolução (*tiles* de 156 x 156 *pixels*). As amostras de baixa resolução espacial foram cortadas obedecendo-se a área determinada anteriormente pelas amostras de alta resolução espacial. Os pares de amostras foram salvos com o mesmo nome.

Foi desenvolvido um algoritmo em Python denominado *Dataset Maker* com o objetivo de otimizar as etapas exigidas para a criação dos *datasets* (Figura 18).

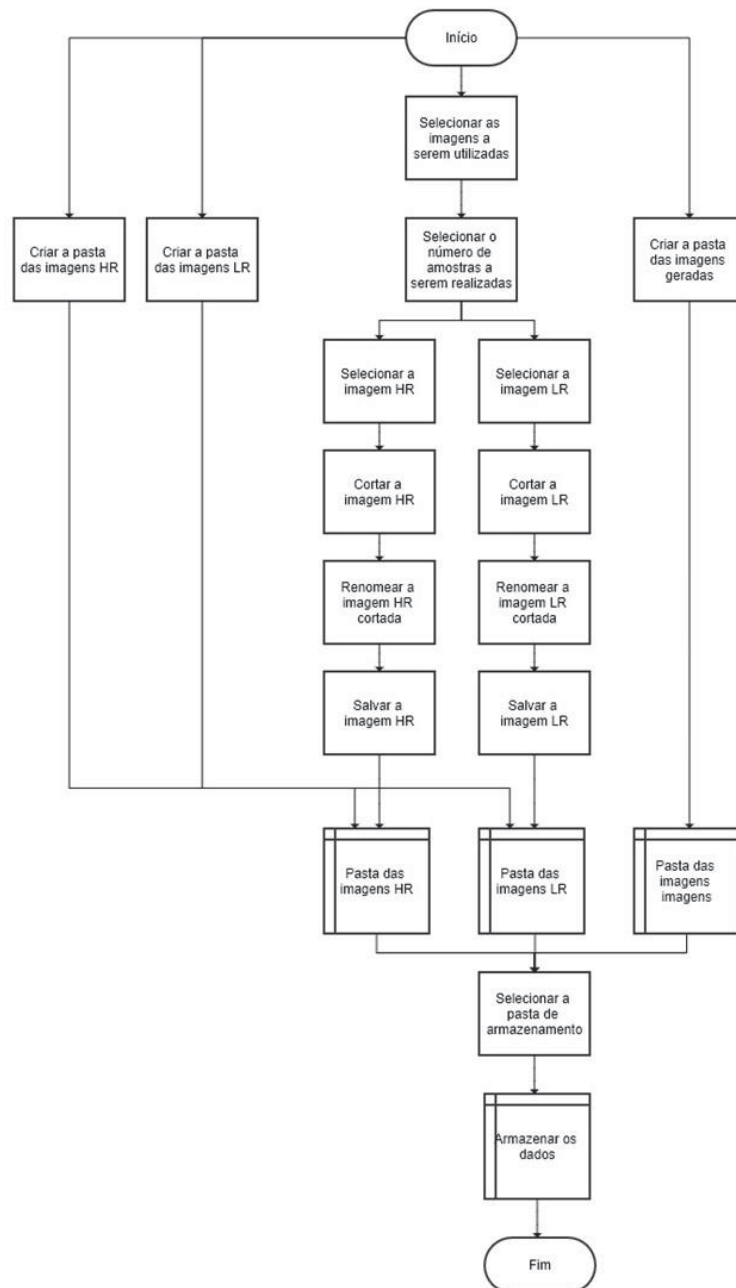


Figura 18 - Fluxograma de criação de datasets para a pesquisa.
Fonte: O autor (2022).

Para possibilitar a construção dos *datasets*, foi necessário, no MDE ESC, que possui resolução espacial de 1 metro e imagens recortadas com pouca extensão territorial, realizar a seleção de diversos arquivos com áreas contíguas para a criação de um novo arquivo através da realização da operação de mosaicagem com área suficiente para a extração dos pares de amostras necessárias aos *datasets* (Figura 19).

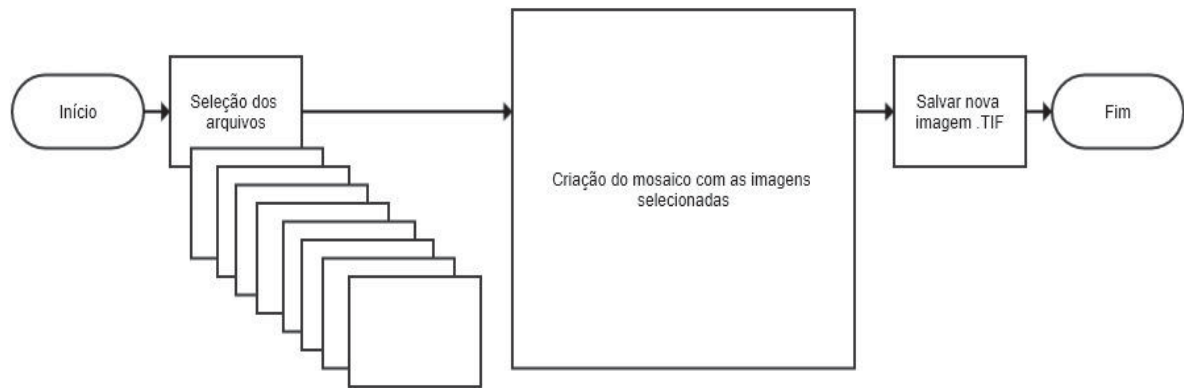


Figura 19 - Fluxograma de criação de mosaicos para a construção de datasets para a pesquisa.

Fonte: O autor (2022).

Para a criação de um *dataset* de modelos geoidais de superfície e modelos geopotencias globais, foi necessário a geração de tais superfícies. Dessa forma, utilizou-se o aplicativo MAPGEO2015 do IBGE e o site ICGEM (EGM2008) para a obtenção de uma grade de pontos dentro da área selecionada para a realização da pesquisa. De posse dos pontos, gerou-se 2 arquivos distintos, que foram interpolados dando origem às superfícies, e sendo salvos em imagem .TIF, que posteriormente foram utilizadas na criação do *dataset* desejado (Figura 20).

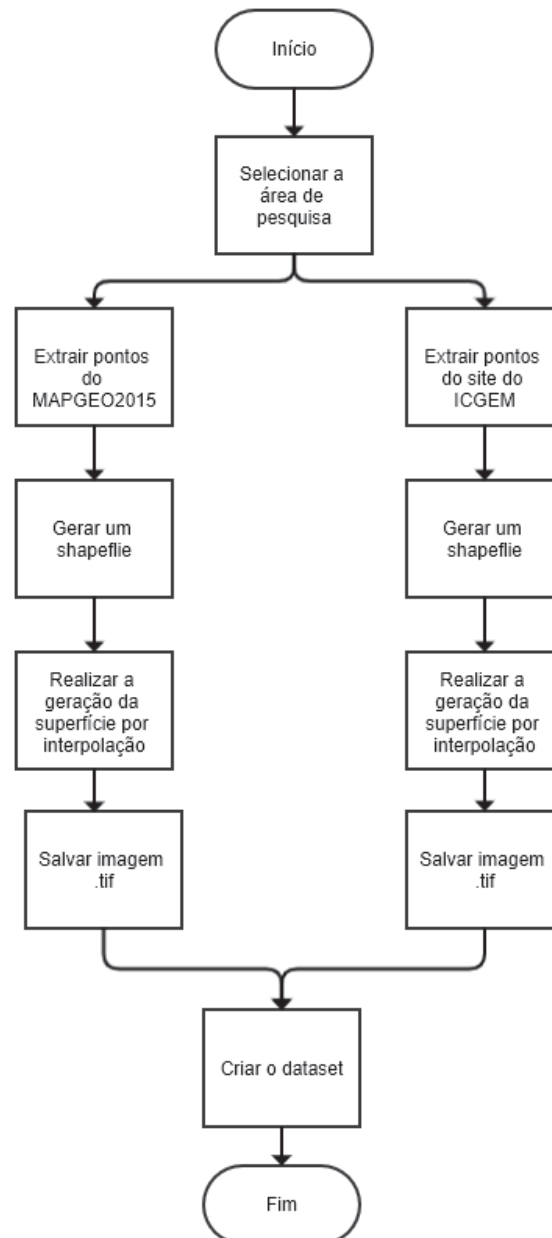


Figura 20 - Geração das superfícies geoidais.
Fonte: O autor (2022).

3.3 CRIAÇÃO DOS PROCESSOS E RECURSOS UTILIZADOS

3.3.1 Linguagem de programação e relação das bibliotecas Python utilizadas

A linguagem de programação utilizada nos desenvolvimentos realizados na presente pesquisa foi o interpretador Python 3.

Foi ainda utilizada a implementação CPython, que é uma implementação de referência na linguagem Python e é escrita em C. O CPython possui um grande nível de compatibilidade com pacotes Python e módulos de extensão C. Tem-se ainda importantes bibliotecas científicas escritas em C, como o Numpy.

A distribuição de Python utilizada foi a Anaconda da Continuum Analytics, por ser bastante indicada para a realização de pesquisas científicas e possuir vasta gama de bibliotecas como o Numpy e o Matplotlib.

Como ambiente de desenvolvimento integrado, foi selecionado o Spyder, que é um IDE preparado especialmente para trabalhar com bibliotecas Python científicas, e vem distribuído juntamente com o Anaconda.

As bibliotecas e os pacotes para o Python são conjuntos de módulos e funções que facilitam a programação dos desenvolvedores. Por ter uma comunidade vasta de programadores e usuários, a linguagem de programação Python disponibiliza milhares de bibliotecas para diversas áreas da tecnologia.

Para a consecução da presente pesquisa, estas foram algumas das bibliotecas utilizadas: Argparse, Datetime, Logging, Math, Random, Time, Torch, Os, Cv2, Glob, Numpy, Matplotlib, Sklearn, Psutil, Humanize, GPUUtil, Google.colab, Basicsr, Sys, Skimage, Statistics, Scipy, Tkinter, Pandas, Csv, PIL, Rasterio, Osopen/GDAL.

O Scikit Learn (sklearn) é uma biblioteca Python de aprendizado de máquina gratuita. É bastante flexível, permitindo funcionar de forma eficiente com outras bibliotecas, como o Numpy ou o Scipy. Possui ainda métodos para a representação dos dados.

O Matplotlib é uma biblioteca Python desenvolvida para construir gráficos e plotagens bidimensionais. Permite integrar-se a diferentes bibliotecas, como a Seaborn, a Ggplot e o Basemap.

A biblioteca Numpy realiza o processamento de matrizes e vetores como objetos do tipo *array*. Possui um conjunto de frameworks que lhe permite manipular tais tipos de dados de forma rápida e eficiente.

O Scipy é uma biblioteca Python gratuita muito utilizada para o aprendizado de máquina. Realiza, dentre outras tarefas, a manipulação de imagens. Possui módulos voltados para otimização, integração, álgebra linear e estatística.

A biblioteca Pytorch possui recursos que aproveitam a aceleração da GPU para cálculo de tensores. Serve ainda para desenvolver grafos dinâmicos e projetos de aplicativos ligados a redes neurais. Foi desenvolvida inicialmente pelos pesquisadores do A.I do Facebook. Nessa pesquisa foi utilizado para o desenvolvimento do algoritmo GAN.

3.3.2 Recursos de *software* utilizados

Para a realização de todas as etapas da presente pesquisa foram utilizados diferentes recursos de *softwares* com finalidades diversas. Tal situação ressalta a importância do planejamento quanto à seleção e uso dos recursos de programas a serem empregados, assim como a utilização rigorosa e apropriada dos mesmos, possibilitando a realização correta dos processamentos e análises pretendidos, entre outros que terão diretamente impacto sobre a realização das referidas atividades. Desta forma, os *softwares* de importância primordial e imprescindível que serão apresentados garantiram a consecução dos objetivos da referida tese.

O Google Colaboratory Pro é um aplicativo *web* que permite escrever *scripts* em Python a partir de um navegador de internet e executá-los. É de grande importância em desenvolvimentos de *machine learning* por permitir realizar processamentos nos GPUs e TPUs da Google.

O Wandb é um aplicativo *web* composto de ferramentas de desenvolvimento para *machine learning*, que permitem a construção de modelos de forma otimizada, a partir da experiência obtida com o monitoramento, visualização e gerenciamento do mesmo, além do acompanhamento dos *datasets*. Possibilita a obtenção de métricas instantâneas, registros de terminal e estatísticas do sistema apresentadas em um dashboard centralizado, permitindo o acompanhamento do fluxo dos processamentos. É um aplicativo *open source* para aplicações acadêmicas.

O QGIS é um *software* livre e de código aberto de sistema de informação geográfica, capaz de realizar visualização, gestão, edição, análise de dados georreferenciados, e mapas para impressão. É licenciado pela Licença Pública Geral GNU, e é um projeto oficial da *Open Source Geospatial Foundation* (OSGeo).

O aplicativo permite que os dados possam ser armazenados como pontos, linhas, ou polígonos, suporta diferentes tipos de imagens *raster*, e ainda tem a capacidade de georreferenciar imagens. Permite a extensão de suas capacidades com a utilização de *plugins* escritos em Python.

O MAPGEO2015 é um modelo digital obtido através de levantamentos geodésicos, que possibilita a descrição entre a superfície elipsoidal e a superfície do geóide. O aplicativo MAPGEO2015, assim como seus modelos anteriores (MAPGEO2010, MAPGEO2004, MAPGEO92), foi concebido e produzido conjuntamente pelo Instituto Brasileiro de Geografia e Estatística (IBGE), através da Coordenação de Geodésia (CGED), e pela Escola Politécnica da Universidade de São Paulo – EPUSP (IBGE, 2021).

O modelo MAPGEO2015 foi calculado com uma resolução de 5' de arco, e o Sistema de Interpolação de Ondulações Geoidais foi atualizado em relação aos modelos anteriores. O aplicativo permite obter a ondulação geoidal em um ponto ou conjunto de pontos, cujas coordenadas refiram-se ao SIRGAS2000 e compreendidas entre as latitudes de 6°N e 35°S e entre as longitudes de 75°W e 30°W, dentro do território brasileiro (IBGE, 2021).

3.3.3 Recursos de *hardware* utilizados

Para todos os processamentos direcionados à engenharia em que se almeja a análise da precisão e da acurácia dos mesmos, é de fundamental importância o planejamento referente aos recursos materiais e humanos a serem empregados, assim como a realização da correta aquisição e armazenamento dos dados, análise das condições dos mesmos, entre outros que terão diretamente impacto sobre a realização das referidas atividades. Desta forma, os materiais de importância primordial e imprescindível que serão apresentados garantiram a perfeita execução dos processamentos, e a posterior análise dos dados obtidos.

Para a realização dos processamentos GAN, foi utilizado o seguinte equipamento de hardware (Tabela 4):

Tabela 4 - Especificações técnicas do hardware de processamento.

Componentes	Especificações
Marca	DELL
Memória Física (RAM)	16.0 GB
Instalada	
Placa de vídeo	Geforce RTX 2060
Nome do Sistema Operacional	Microsoft Windows 10 Home Single Language
Modelo do sistema	G5 5590
Tipo do sistema	PC baseado em X64
Processador	Intel Core i7 9750H 2.60GHz

Fonte: Dell (2021).

3.4 PROCESSAMENTOS E GERAÇÃO DAS SUPERFÍCIES ALTIMÉTRICAS

3.4.1 Aprimoramento do SRGAN para o ESRGAN

O algoritmo *Super-Resolution Generative Adversarial Network* (SRGAN) foi um trabalho que estimulou novas criações e que trouxe novas ideias capazes de gerar texturas realistas durante a super-resolução de uma única imagem. No intuito de aperfeiçoar ainda mais a qualidade visual, foram aprimorados três componentes principais do SRGAN, sendo eles a arquitetura de rede (*network architecture*), a perda adversária (*adversarial loss*) e a perda perceptiva (*perceptual loss*), e aprimorou-se cada um deles para derivar um SRGAN aprimorado (*Enhanced SRGAN*). Em particular, apresentou-se o Bloco Denso Remanescente-em-Remanescente (*Residual-in-Residual Dense Block - RRDB*) sem normalização de lote (*batch normalization*) como a unidade básica de construção da rede. Utilizou-se ainda a ideia do GAN relativístico (*relativistic GAN*) para deixar o discriminador predizer a realidade relativa (*relative realness*) em vez do valor absoluto. Também se melhorou a perda de percepção (*perceptual loss*) usando os recursos antes da ativação, o que forneceram supervisão mais forte para consistência de brilho e recuperação de textura. Beneficiando-se dessas melhorias, a proposta ESRGAN atingiu qualidade visual consistentemente melhor com texturas mais realistas e naturais do que SRGAN (WANG et al., 2018).

A Super-resolução de Imagem Única (*Single Image Super-Resolution - SISR*), como um problema fundamental de visão de baixo nível, tem atraído cada vez mais atenção na comunidade de pesquisa de IA. A SISR visa recuperar uma imagem de *High Resolution* (HR) de uma única imagem de *Low Resolution* (LR).

Desde o trabalho pioneiro de SRCNN (*Single image Super-Resolution deep Convolutional Neural Network*), abordagens de rede neural de convolução profunda (CNN) trouxeram um desenvolvimento próspero. Vários projetos de arquitetura de rede e estratégias de treinamento têm melhorado continuamente o desempenho do SR (*Super-Resolution*), especialmente o valor da relação sinal-ruído de pico (*Peak Signal-to-Noise Ratio* - PSNR). No entanto, essas abordagens orientadas por PSNR tendem a produzir resultados super suavizados, sem detalhes de alta frequência suficientes, uma vez que a métrica PSNR discorda fundamentalmente da avaliação subjetiva de observadores humanos (WANG et al., 2018) (Figura 21).




Figura 21 - Resultados para a super resolução 4x para o SRGAN e o ESRGAN, mostrando a superação do ESRGAN em relação ao SRGAN em nitidez detalhes.

Fonte: Wang et al., 2018

Vários métodos orientados pela percepção já foram propostos para melhorar a qualidade visual dos resultados de SR. A Rede Adversária Gerativa (GAN) é introduzida na SR (Super-Resolution) para encorajar a rede a favorecer soluções que se parecem mais com imagens naturais. O modelo básico é construído com blocos residuais e otimizado usando perda perceptual (*perceptual loss*) em um *framework* GAN. Com tais técnicas, o SRGAN melhora significativamente a qualidade visual geral da reconstrução em relação aos métodos orientados por PSNR (WANG et al., 2018).

Os algoritmos SR são tipicamente avaliados por várias medidas de distorção amplamente utilizadas, por exemplo, PSNR e SSIM (*Structural Similarity Index Measure*). No entanto, essas métricas discordam fundamentalmente da avaliação subjetiva de observadores humanos. Medidas não de referência são usadas para avaliação da qualidade perceptiva, como o NIQE (*Naturalness Image Quality Evaluator*) (WANG et al., 2018).

A remoção de camadas BN (*Batch Normalization*) aumentou o desempenho e reduziu a complexidade computacional em diferentes tarefas orientadas a PSNR, incluindo SR (*Super-Resolution*) e *deblurring*. As camadas BN normalizaram os recursos usando média e variação em um lote durante o treinamento e usaram a média e a variação estimadas de todo o conjunto de dados de treinamento durante o teste. Quando as estatísticas de conjuntos de dados de treinamento e teste diferem muito, as camadas BN tendem a apresentar artefatos indesejados e limitar a capacidade de generalização. Observa-se empiricamente que as camadas BN são mais propensas a trazer artefatos quando a rede é mais profunda e treinada em uma estrutura GAN. Esses artefatos aparecem ocasionalmente entre iterações e configurações diferentes, violando as necessidades de um desempenho estável durante o treinamento. Portanto, removeu-se as camadas BN para um treinamento estável e desempenho mais consistente. Além disso, a remoção de camadas BN ajudou a melhorar a capacidade de generalização e a reduzir a complexidade computacional e o uso de memória (WANG et al., 2018).

WANG et al. (2018) manteve o projeto de arquitetura de alto nível de SRGAN, e usou um novo bloco básico chamado RRDB. Com base na observação de que mais camadas e conexões sempre poderiam aumentar o desempenho, o RRDB utilizado empregou uma estrutura mais profunda e complexa do que o bloco residual original no SRGAN. Especificamente, o RRDB proposto tem uma estrutura *residual-in-residual*, onde o aprendizado residual é usado em diferentes níveis.

Além da arquitetura aprimorada, WANG et al. (2018) também explorou várias técnicas para facilitar o treinamento de uma rede muito profunda; escalonamento residual, ou seja, escalonamento dos resíduos multiplicando uma constante entre 0 e 1 antes de adicioná-los ao principal caminho para prevenir a instabilidade; e, inicialização menor, pois empiricamente acredita-se

que a arquitetura residual é mais fácil de treinar quando a variância do parâmetro inicial se torna menor.

Além da estrutura aprimorada do gerador, WANG et al. (2018) também aprimorou o discriminador baseado no GAN Relativístico. Diferente do discriminador padrão no SRGAN, que estima a probabilidade de que uma imagem de entrada seja real e natural, o discriminador relativístico tenta prever a probabilidade de que uma imagem real seja relativamente mais realista do que uma falsa.

Para remover ruídos desagradáveis em métodos baseados em GAN e ao mesmo tempo manter uma boa qualidade perceptual, WANG et al. (2018) utilizou uma estratégia flexível e eficaz de interpolação de rede. Especificamente, primeiro treinou-se uma rede G_{PSNR} orientada para PSNR e, em seguida, obteve-se uma rede GAN baseada em G_{GAN} por meio do ajuste fino. Interpola-se todos os parâmetros correspondentes dessas duas redes para derivar um modelo interpolado G_{INTERP} .

WANG et al. (2018) também explorou métodos alternativos para equilibrar os efeitos dos métodos orientados para PSNR e baseados em GAN. Interpola-se diretamente suas imagens de saída (*pixel por pixel*) ao invés dos parâmetros de rede. No entanto, tal abordagem falhou em alcançar uma boa compensação entre ruído e desfoque, ou seja, a imagem interpolada tinha aparência muito borrada ou barulhenta com artefatos. Outro método utilizado foi ajustar os pesos de perda de conteúdo e perda adversária. Tal abordagem necessitou do ajuste dos pesos de perda e do ajuste fino da rede, sendo, portanto, muito caro obter o controle contínuo do estilo da imagem.

O Batch Normalization é uma técnica que consiste em normalizar os pesos de um layer antes de transmitir essas informações para a próxima camada. Pode ser utilizada em qualquer estrutura de RN. Foi proposto por Sergey Ioffe e Christian Szegedy em 2015.

Os updates da RN são realizados em lotes de amostras de treinamento. Dessa forma, o BN tenta evitar que durante a atualização dos pesos, os mesmos fiquem muito desproporcionais entre si. Tende a ocorrer em lotes pequenos de amostras. A normalização, dessa forma, limita os valores dos neurônios a um máximo e a um mínimo, ajudando a RN a ficar com o treinamento mais estável.

Tal técnica se adapta melhor a determinados tipos de modelos, como em situações de aprendizado caótico, demora na aprendizagem, algoritmos que ficam presos em mínimos locais, algoritmos que não alcançam a convergência, dentre outros.

Pode ser combinado ainda com outras técnicas, como a diminuição da taxa de aprendizagem (*learning rate*), mudança do algoritmo descendente, dentre outros.

Observa-se que o BN se adapta muito bem com as RN adversárias. A técnica do BN ainda permite a utilização do cálculo do momentum, onde se utiliza não só os valores dos pesos do lote de amostras atual, mas também os valores dos lotes anteriores de forma percentual. Tal técnica se assemelha ao uso de uma média móvel exponencial, gerando atualizações mais suaves, devido a preservação de *batches* antigos. Pode-se dar, dessa forma, grandes pesos aos updates anteriores.

Para maiores detalhes, verificar em WANG, Xintao et al. Esrgan: Enhanced super-resolution generative adversarial networks. In: Proceedings of the European conference on computer vision (ECCV) workshops. 2018. p. 0-0.

3.4.2 Adaptação do modelo ESRGAN para o DEM-ESRGAN

Para a solução do problema apresentado na presente tese, pretendeu-se utilizar as Redes Adversárias Generativas (GAN), que têm tido um grande destaque na área de inteligência artificial desde que foram introduzidas pelo artigo chamado *Generative Adversarial Nets*, publicado em 2014 por Ian J. Goodfellow e outros autores, pois a introdução do conceito de treinamento antagônico representou um progresso conceitual para as pesquisas realizadas com o uso do *machine learning* e do *deep learning* (GOODFELLOW et al., 2013).

As *Generative Adversarial Networks* pertencem ao conjunto de modelos generativos, ou seja, são algoritmos capazes de gerar conteúdo inédito a partir de treinamentos realizados a partir dos dados recebidos. Dentre as suas possibilidades de utilização encontram-se o aumento de resolução de imagens e o aumento da quantidade de dados existentes em aplicações com carência dos mesmos. Possui como aspecto negativo a não moldabilidade a todos os tipos de base de dados (GOODFELLOW et al., 2013).

Uma das variações dos modelos GAN que pode ser utilizada para a obtenção de super-resolução de imagens é o *Enhanced Super-Resolution Generative Adversarial Networks* (ESRGAN), que através de modificações realizadas no algoritmo originalmente proposto, alcançou consistentemente melhor qualidade visual com texturas mais realistas e naturais do que o GAN e o *Super-Resolution Generative Adversarial Network* (SRGAN).

Para desenvolver este trabalho foi construída uma primeira versão do modelo MDTESRGAN, que depois foi redenominado para DEM-ESRGAN. Foram necessárias alterações nas entradas e nas saídas dos modelos. O ESRGAN tem como entrada e saída imagens .PNG, coloridas com 3 bandas (RGB). Para executar arquivos com informações altimétricas, foi necessário alterar as entradas e a saída para imagens .TIF, com apenas 1 banda (Figura 22, Figura 23 e Figura 24).

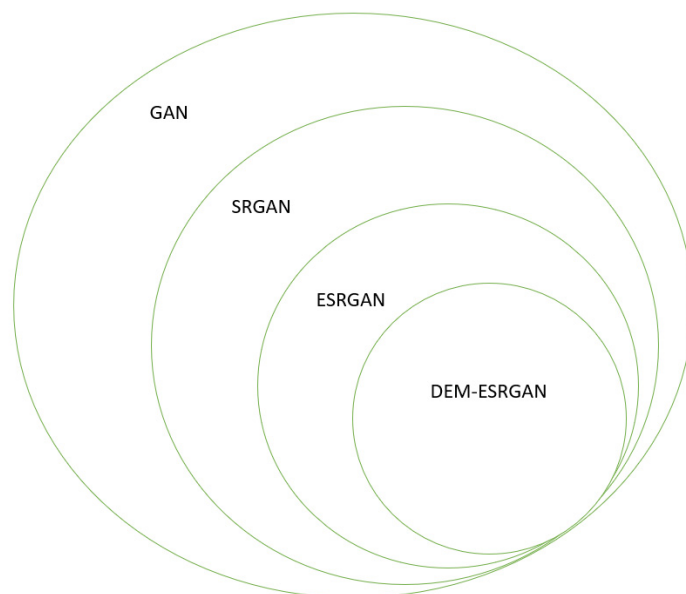


Figura 22 - Contextualização de algoritmos de deep learning até o DEM-ESRGAN.
Fonte: O autor (2022).

Outra modificação necessária foi quanto ao dimensionamento das imagens, para que o algoritmo permitisse receber diferentes combinações de modelos digitais.

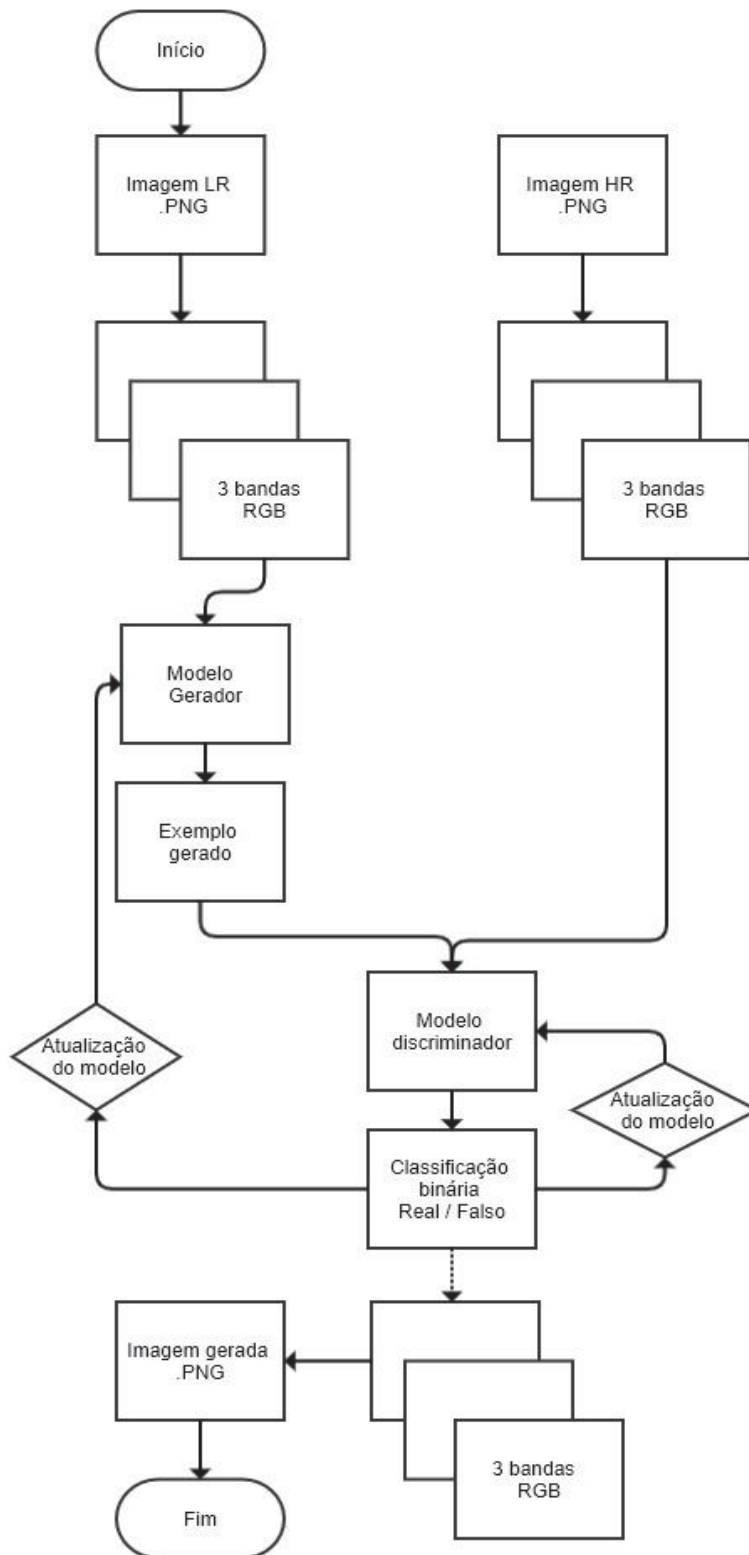


Figura 23 - Fluxograma do ESRGAN.
Fonte: O autor (2022).

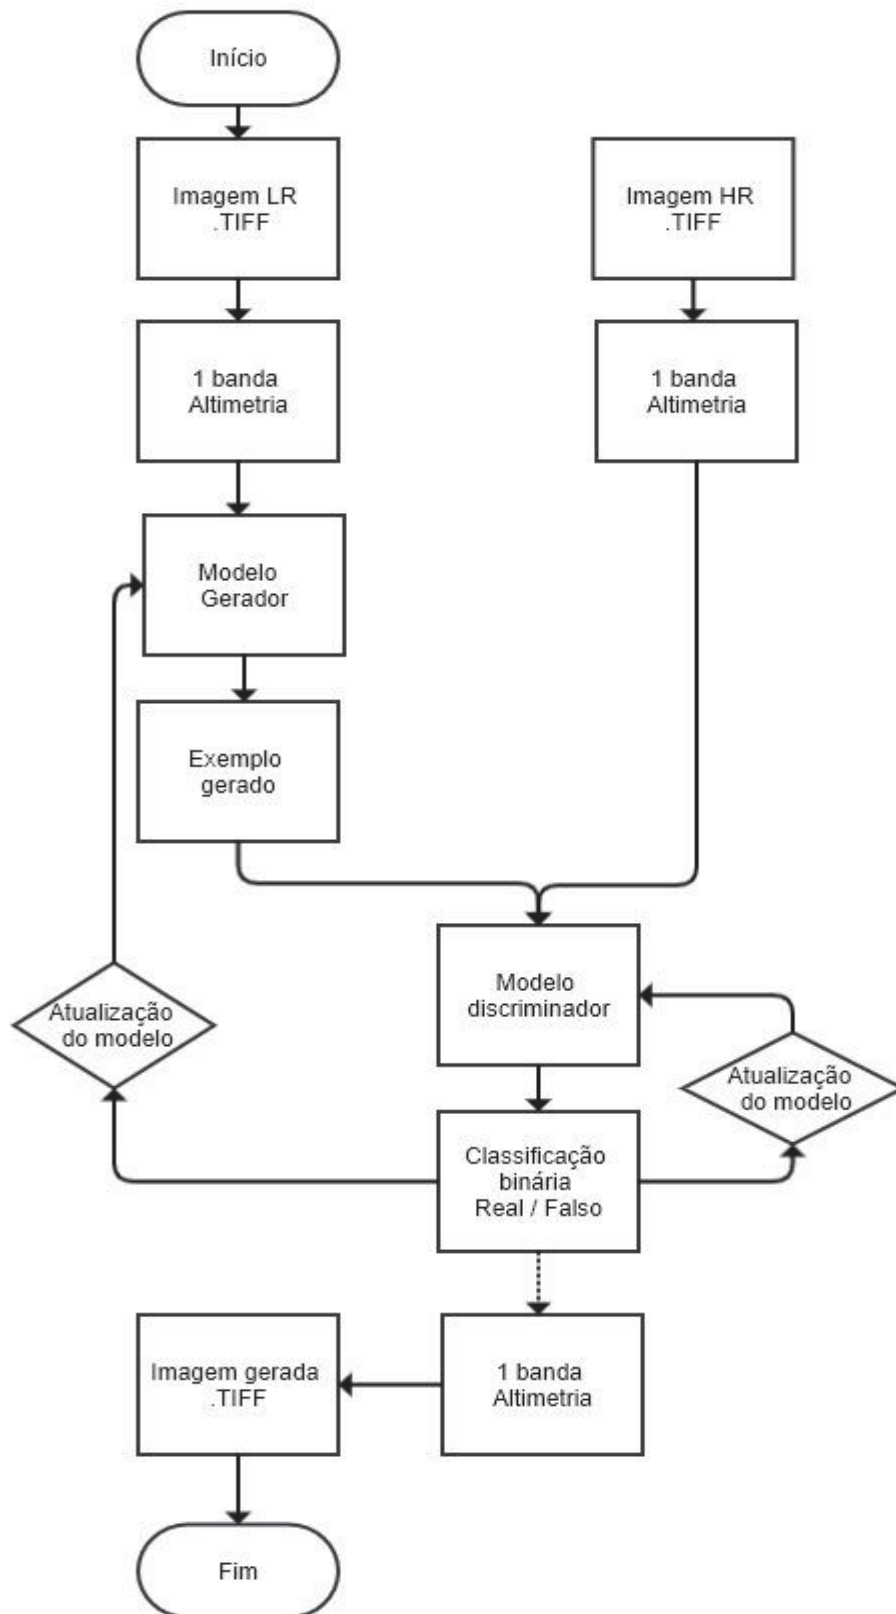


Figura 24 - Fluxograma do DEM-ESRGAN.
Fonte: O autor (2022).

3.4.3 Realização dos Experimentos e seus respectivos processamentos

O objetivo dos experimentos realizados foi de verificar a possibilidade do aumento da resolução de superfícies digitais com informações altimétricas através do emprego de técnicas de super-resolução de imagens únicas, utilizando *Generative Adversarial Network* (Objetivo Geral da pesquisa), em função de diferentes dados com diferentes resoluções espaciais.

A variação do número de amostras tem por objetivo analisar a conformação do modelo gerado em relação a diferentes quantidades de amostras empregadas pelo treinamento.

A variação no número de iteração intenciona encontrar o processamento mais adequado do algoritmo no que tange a manutenção das características geoespaciais dos produtos gerados.

Define-se época como uma passagem completa de todas as amostras do *dataset* pelo modelo durante a realização do treinamento. Já iteração pode ser definido como um processo realizado várias vezes. Optou-se por adotar os valores referentes às iterações dos processamentos, considerando que esse foi o padrão adotado pelo algoritmo utilizado.

No que tange aos resultados dos experimentos, os mesmos podem ser divididos em duas categorias, objetivando a super resolução dos dados e a conformação ou adaptação das superfícies (Figura 25). A primeira categoria visa alcançar a super resolução da superfície (Experimento 1), e a segunda categoria intenciona tanto a super resolução como a conformação e adaptação de uma superfície (Experimentos 2, 3, 4, 5 e 6).

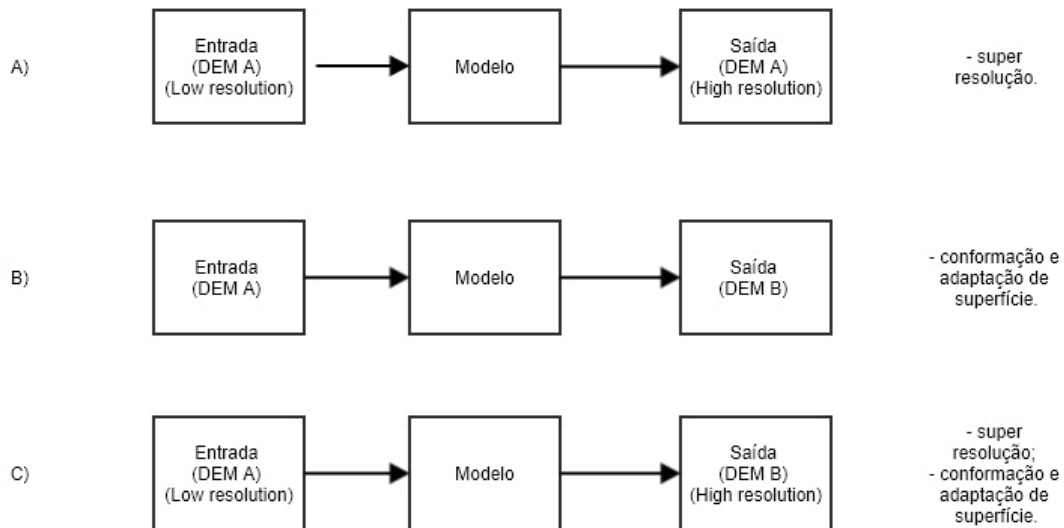


Figura 25 - Divisão dos experimentos em categorias.
Fonte: O autor (2022).

As vantagens da conformação e adaptação de superfícies é a possibilidade de geração de novos dados em áreas anteriormente não mapeadas. Já a super resolução só pode ser utilizada em áreas previamente mapeadas.

Para a realização dos experimentos referentes à presente pesquisa, foi realizada a seguinte separação entre os dados e os parâmetros utilizados (Tabela 5):

Tabela 5 - Tabela contendo os dados e os parâmetros utilizados nos experimentos da tese.

Experimento	<i>Dataset</i> HR	<i>Dataset</i> LR	Número de amostras por <i>dataset</i>	Número de iterações
1	ESC 1 m	ESC 4 m	50 de treinamento; 20 de validação	10.000; 50.000; 100.000
2	SRTM 30 m	SRTM 90 m	10 de treinamento; 4 de validação	10.000; 50.000; 100.000
3	SRTM 30 m	SRTM 90 m	50 de treinamento; 20 de validação	10.000; 50.000; 100.000
4	Alos Palsar 12,5 m	SRTM 30 m	50 de treinamento; 20 de validação	10.000; 50.000; 100.000
5	ESC 1 m	Alos Palsar 12,5 m	50 de treinamento; 20 de validação	10.000; 50.000; 100.000
6	EGM2008 30 m	MAPGEO2015 90 m	50 de treinamento; 20 de validação	10.000; 50.000; 100.000

Fonte: O autor (2022).

3.4.4 Geração das superfícies altimétricas

Para a geração das superfícies altimétricas nos referidos experimentos, foram selecionadas 3 amostras de cada um dos *datasets*, no que se refere às imagens de baixa resolução.

Foi ainda desenvolvido, com linguagem Python e ambiente Colab, um algoritmo responsável por, através dos modelos criados pelos processamentos, produzir as imagens geradas pelo DEM-ESRGAN, utilizando as imagens de baixa resolução.

De posse das imagens geradas, deu-se início à fase de avaliação dos produtos e análise dos resultados.

Ressalta-se que a aproximação do produto GAN gerado é em relação ao *ground truth*, e não em relação ao terreno.

3.5 AVALIAÇÃO DAS SUPERFÍCIES ALTIMÉTRICAS GERADAS

Diferentemente do uso de algoritmos GAN para a geração de fotografias de alta resolução, em se tratando de produtos geoespaciais, há uma necessidade de se preocupar com diversos fatores, como orientações de normas internacionais, de especificações técnicas nacionais e literatura sobre o tema. Dessa forma, com a referida seção, pretende-se orientar as inspeções de qualidade de produtos geocientíficos gerados, retratar a qualidade dos dados geoespaciais e verificar os níveis de conformidade demandados, tanto pelo produtor, quanto por seus usuários.

3.5.1 Análise dos *datasets*

Em se tratando da análise dos *datasets*, pretende-se verificar a conformação e a compatibilidade de suas partes integrantes, de forma a permitir acompanhar as mudanças ocorridas em relação aos produtos gerados pelos processamentos GAN e seus produtos.

Para tal análise, a estatística descritiva foi bastante apropriada, já que a mesma é uma das etapas da análise dos dados que é utilizada para resumir e compreender a amostra. É bastante utilizada em situações em que há a necessidade de lidar com uma quantidade grande de informações, tornando-as mais condensadas, para que se consiga trabalhar com elas.

Foi desenvolvido um algoritmo em Python denominado *Statistics_Maker* (ARAKI e MOREIRA, 2021) com o objetivo de obter as características dos dados gerados, além de criar os histogramas, os box plots e as diferenças das imagens.

Para o cálculo das estatísticas descritivas, primeiramente converte-se a imagem em uma matriz, faz-se a conversão da matriz obtida em um único vetor (*flatten*), para em seguida gerar os valores desejados e armazená-los em *.CSV* (Figura 26).



Figura 26 - Fluxograma da geração das estatísticas descritivas.
Fonte: O autor (2022).

3.5.2 Análise dos processamentos DEM-ESRGAN

A análise dos processamentos DEM-ESRGAN é realizada concomitantemente com a realização dos processamentos em si, e obtida a posteriori através de um relatório.

Atrelando-se a biblioteca Wandb ao processamento dos dados do algoritmo, foi possível obter diferentes informações e métricas do andamento dos mesmos, como a progressão das funções de perda, utilização da CPU, utilização de energia em Watts e porcentagem de uso da GPU, porcentagem de alocação da memória e temperatura da GPU, utilização da memória do sistema, dentre outros.

Ao término dos processamentos, são calculados os valores de suas referidas métricas PSNR (valor inicial, valor médio e valor final). A relação sinal-ruído de pico levantada por tal métrica define a relação entre a energia total de um sinal e o ruído que afeta sua representação verídica. É comumente utilizada como medida quantitativa da qualidade de reconstrução no campo de compressão de imagem.

Também se realiza a comparação dos resultados apresentados pelas funções de perda dos geradores de cada um dos processamentos `l_g_percep`, verificando-se a sua tendência ou não de aproximação do zero.

3.5.3 Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN

Foi empregada na pesquisa a análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN quanto à variação do erro de tais imagens em função da média aritmética calculada dos erros, e quanto à variação da precisão das imagens em função da média aritmética calculada das precisões. Tal procedimento teve como intuito verificar o comportamento dos *pixels* das imagens geradas após os respectivos processamentos em relação à imagem de alta resolução (Figura 27).

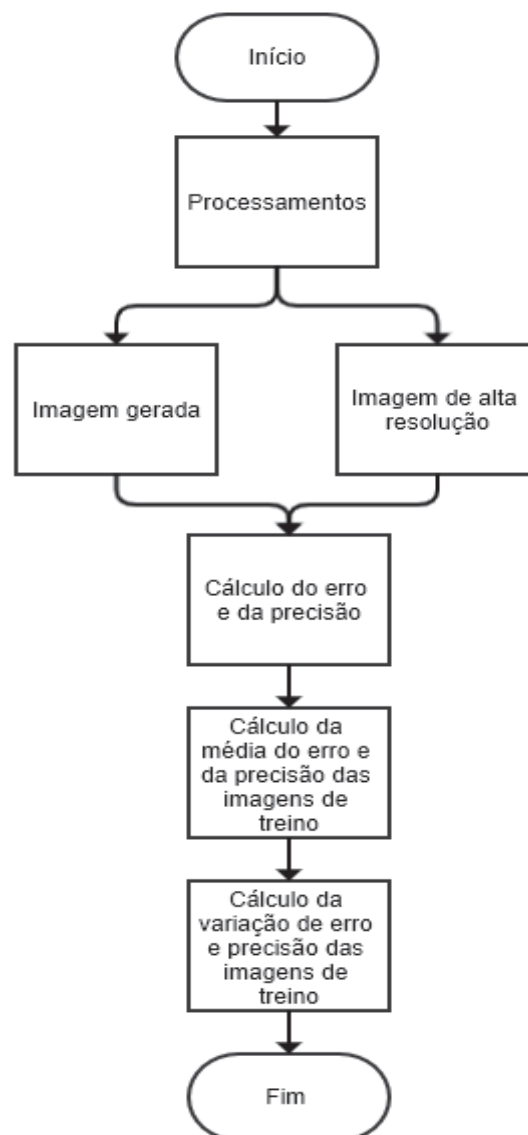


Figura 27 - Fluxograma da análise de erro e precisão das imagens de treino dos processamentos.

Fonte: O autor (2022).

3.5.4 Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN

3.5.4.1 Análise de ganho de acurácia e precisão

Os ganhos em acurácia e precisão foram calculados através da subtração do valor do erro e da precisão da imagem de alta resolução pelo valor da imagem gerada obtida na presente pesquisa. Tal procedimento teve como intuito avaliar a eficácia da utilização dos métodos e critérios selecionados. Quando positivos, esses valores implicam que as metodologias aplicadas aos dados causaram melhora aos resultados. Tal comparação foi apresentada em valores absolutos e em percentuais.

A fórmula utilizada para calcular o ganho em acurácia total é a seguinte (Fórmula 1), onde $GANHO_{Acurácia\ total}$ é o ganho da acurácia total calculada; $\underline{X}_{Img\ HR}$ é a média dos valores dos *pixels* da diferença da imagem de alta resolução e $\underline{X}_{Img\ LR}$ é a média dos valores dos *pixels* da diferença da imagem de baixa resolução; e $\underline{X}_{Img\ Gerada}$ é a média dos valores dos *pixels* da diferença da imagem de alta resolução e da imagem gerada pelo modelo.

$$GANHO_{Acurácia\ total} = \underline{X}_{Dif\ HR-LR} - \underline{X}_{Dif\ HR-Gerada} \quad (1a)$$

$$GANHO_{Acuráciatotal||} = |\underline{X}_{DifHR-LR}| - |\underline{X}_{DifHR-Gerada}| \quad (1b)$$

$$GANHO_{Acuráciatotalquadrático} = \sqrt{(\underline{X}_{DifHR-LR})^2 - (\underline{X}_{DifHR-Gerada})^2} \quad (1c)$$

Já a fórmula utilizada para calcular o ganho em precisão total é a seguinte (Fórmula 2), onde $GANHO_{Prec\ total}$ é o ganho da precisão total calculado; $\underline{\sigma}_{Dif\ HR-LR}$ é a precisão dos valores dos *pixels* da diferença da imagem de alta resolução e a imagem de baixa resolução; e $\underline{\sigma}_{Dif\ HR-Gerada}$ é a precisão dos valores dos *pixels* da diferença da imagem da imagem de alta resolução e a imagem gerada pelo modelo.

$$GANHO_{Prec\ total} = \underline{\sigma}_{Dif\ HR-LR} - \underline{\sigma}_{Dif\ HR-Gerada} \quad (2)$$

A fórmula utilizada para calcular o ganho em Acurácia percentual é a seguinte (Fórmula 3), onde $GANHO_{acurácia\ \%}$ é o ganho da acurácia percentual calculada; $\underline{X}_{Dif\ HR-LR}$ é a média dos valores dos *pixels* da diferença entre a imagem de alta resolução e a imagem de baixa resolução; e $\underline{X}_{Dif\ HR-Gerada}$ é a média dos valores dos *pixels* da diferença entre a imagem de alta resolução e a imagem gerada pelo modelo.

$$GANHO_{acurácia\ \%} = \frac{\underline{X}_{Dif\ HR-LR} - \underline{X}_{Dif\ HR-Gerada}}{\underline{X}_{Dif\ HR-LR}} \quad (3)$$

A fórmula utilizada para calcular o ganho em precisão percentual é a seguinte (Fórmula 4), onde $GANHO_{Prec\ \%}$ é o ganho da precisão percentual calculada; $\underline{\sigma}_{Dif\ HR-LR}$ é o valor do desvio padrão da amostra dos *pixels* da diferença entre a imagem de alta resolução e a imagem de baixa resolução; e $\underline{\sigma}_{Dif\ HR-Gerada}$ é o valor do desvio padrão da amostra dos *pixels* da diferença entre a imagem de alta resolução e a imagem gerada pelo modelo.

$$GANHO_{Prec\ \%} = \frac{\underline{\sigma}_{Dif\ HR-LR} - \underline{\sigma}_{Dif\ HR-Gerada}}{\underline{\sigma}_{Dif\ HR-LR}} \quad (4)$$

3.5.4.2 Análise de discrepância entre superfícies

Foi empregada na pesquisa a análise e comparação dos *pixels* das imagens de alta resolução, baixa resolução e imagens geradas pelo algoritmo. Foram comparados *pixel a pixel* em cada par de imagem buscando *pixels* coincidentes de três formas: analisando o valor dos *pixels* propriamente dito, analisando o valor dos *pixels* dentro de um intervalo de desvio padrão de 1 metro, e analisando o valor dos *pixels* dentro do intervalo de desvio padrão de 2 metros. Tal procedimento teve como intuito avaliar a eficácia da utilização dos métodos e critérios selecionados.

Para a apresentação dos resultados, foram utilizadas as seguintes formas de apresentação dos dados: número de linhas e colunas das imagens, número total de *pixels*, número de *pixels* iguais existentes no par de imagens, número de *pixels* iguais existentes com o intervalo de desvio padrão igual a 1 metro, número de *pixels* iguais existentes com o intervalo de desvio padrão igual a 2 metros, porcentagem do número de *pixels* iguais existentes no par de imagens, porcentagem do número de *pixels* iguais existentes com o intervalo de desvio padrão igual a 1 metro, porcentagem do número de *pixels* iguais existentes com o intervalo de desvio padrão igual a 2 metros, ganho em número de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução, ganho em número de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução com o intervalo de desvio padrão igual a 1 metro, ganho em número de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução com o intervalo de desvio padrão igual a 2 metros, ganho em porcentagem de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução, ganho em porcentagem de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução com o intervalo de desvio padrão igual a 1 metro, e ganho em porcentagem de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução com o intervalo de desvio padrão igual a 2 metros (Figura 28).

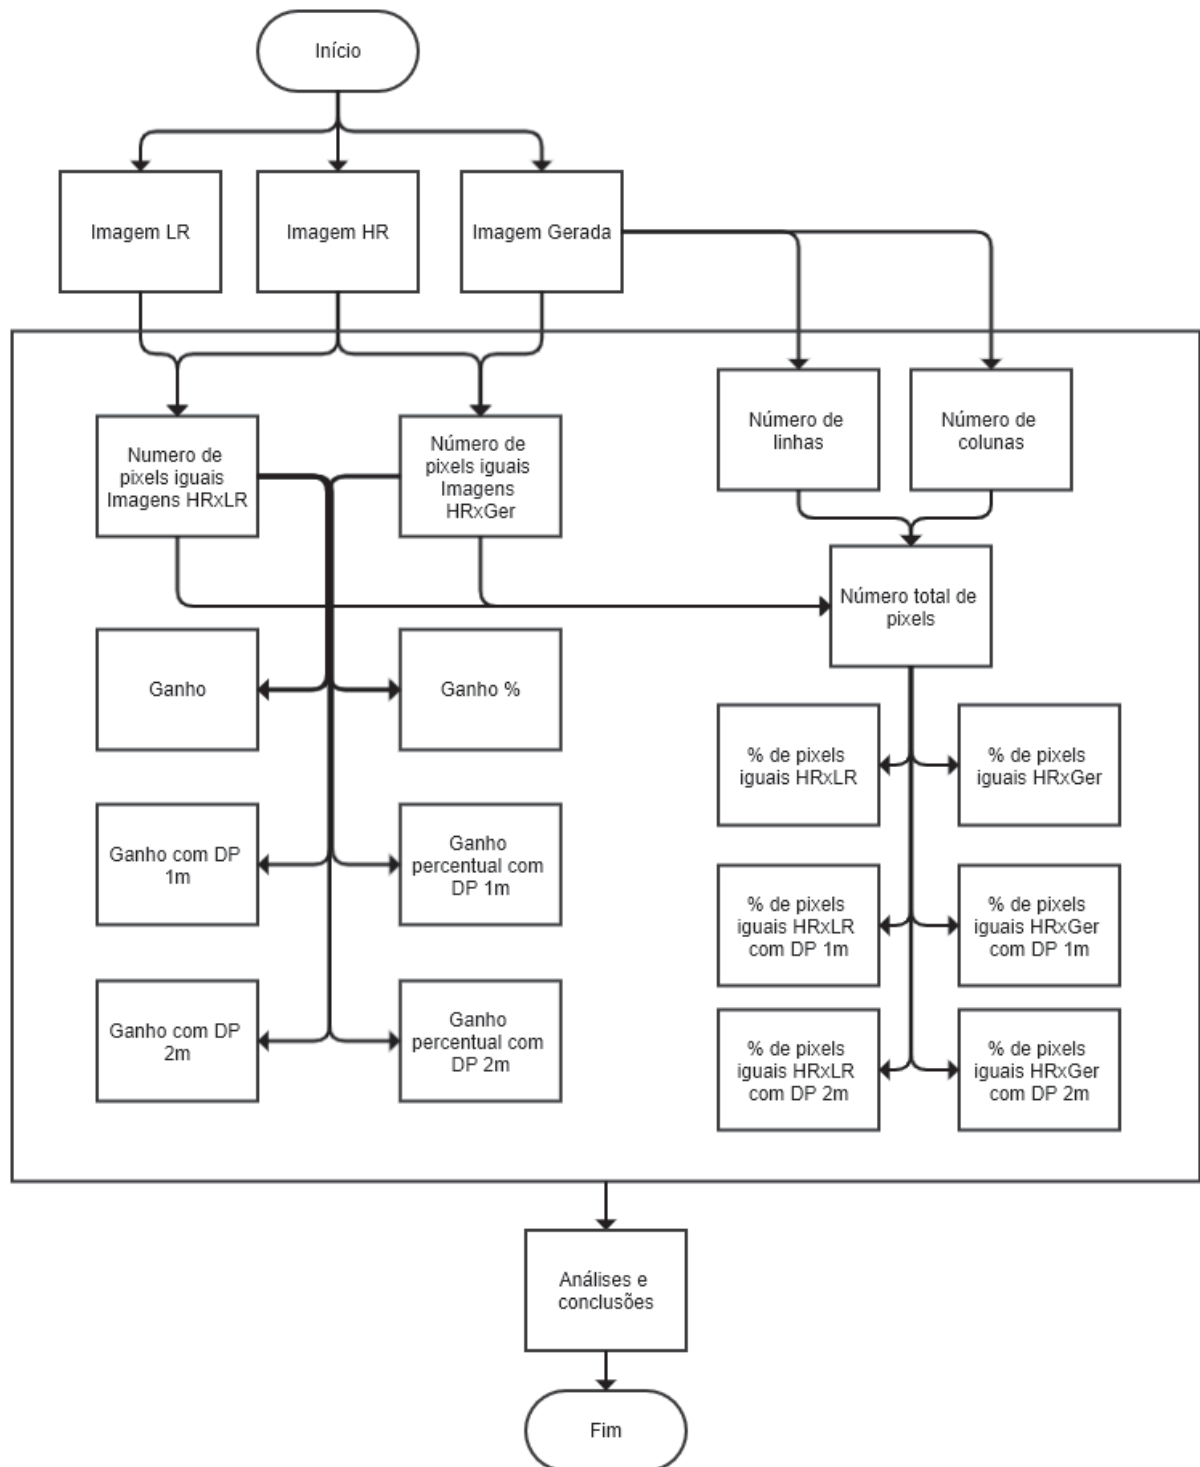


Figura 28 - Fluxograma da análise de pixels das imagens.
Fonte: O autor (2022).

A geração do ganho em número de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução segue a seguinte fórmula (Fórmula 5), onde $Ganho_{pix}$ é o ganho em número de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução; $Pixels\ iguais\ HRxGer$ é o número de

pixels iguais existentes entre a imagem de alta resolução e a imagem gerada pelo algoritmo; e *Pixels iguais HRxLR* é o número de *pixels* iguais existentes entre a imagem de alta resolução e a imagem de baixa resolução.

$$Ganho_{pix} = Pixels\ iguais\ HRxGer - Pixels\ iguais\ HRxLR \quad (5)$$

Da mesma forma, realizou-se os cálculos da geração do ganho em número de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução com o intervalo de desvio padrão igual a 1 metro e com o intervalo de desvio padrão igual a 2 metros (Fórmula 6 e Fórmula 7).

$$Ganho_{pix\ DP\ 1} = Pixels\ iguais\ HRxGer\ DP\ 1m - Pixels\ iguais\ HRxLR\ DP\ 1m \quad (6)$$

$$Ganho_{pix\ DP\ 2} = Pix\ iguais\ HRxGer\ DP\ 2m - Pix\ iguais\ HRxLR\ DP\ 2m \quad (7)$$

A geração do ganho em porcentagem de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução segue a seguinte fórmula (Fórmula 8), onde $Ganho\ \%_{pix}$ é o ganho em porcentagem de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução; *Pixels iguais HRxGer* é o número de *pixels* iguais existentes entre a imagem de alta resolução e a imagem gerada pelo algoritmo; e *Pixels iguais HRxLR* é o número de *pixels* iguais existentes entre a imagem de alta resolução e a imagem de baixa resolução.

$$Ganho\ \%_{pix} = (1 - Pixels\ iguais\ HRxLR \div Pixels\ iguais\ HRxGer) * 100 \quad (8)$$

De forma similar, realizou-se os cálculos da geração do ganho em porcentagem de *pixels* iguais da imagem gerada em relação à imagem de baixa resolução com o intervalo de desvio padrão igual a 1 metro e com o intervalo de desvio padrão igual a 2 metros (Fórmula 9 e Fórmula 10).

$$Ganho\ \%_{pix\ DP\ 1} = (1 - Pix\ ig\ HRxLR\ DP\ 1m \div Pix\ ig\ HRxGer\ DP\ 1m) * 100 \quad (9)$$

$$\text{Ganho } \%_{\text{pix DP } 2} = (1 - \text{Pix ig HRxLR DP } 2m \div \text{Pix ig HRxGer DP } 2m) * 100 \quad (10)$$

O cálculo da porcentagem do número de *pixels* iguais existentes em um par de imagens (imagem de alta resolução em relação à imagem de baixa resolução) segue a seguinte fórmula (Fórmula 11), onde *Pix ig %_{HRxLR}* é a porcentagem do número de *pixels* iguais da imagem de alta resolução em relação à imagem de baixa resolução; *Pixels iguais HRxLR* é o número de *pixels* iguais existentes entre a imagem de alta resolução e a imagem de baixa resolução; e *Total pixels* é o número total de *pixels* existentes nas imagens. Realizou-se ainda o cálculo da porcentagem do número de *pixels* iguais existentes em um par de imagens de alta resolução em relação à imagem gerada pelo algoritmo.

$$\text{Pix ig } \%_{\text{HRxLR}} = \text{Pixels iguais HRxLR} \div \text{Total pixels} * 100 \quad (11)$$

$$\text{Pix ig } \%_{\text{HRxGer}} = \text{Pixels iguais HRxGer} \div \text{Total pixels} * 100 \quad (12)$$

De maneira similar, foi feito o cálculo da porcentagem do número de *pixels* iguais existentes em um par de imagens (imagem de alta resolução em relação à imagem de baixa resolução e imagens de alta resolução em relação à imagem gerada pelo algoritmo) com um intervalo de desvio padrão de 1 metro e 2 metros (Fórmula 13, Fórmula 14, Fórmula 15 e Fórmula 16).

$$\text{Pix ig } \%_{\text{HRxLR DP } 1} = \text{Pixels iguais HRxLR DP } 1m \div \text{Total pixels} * 100 \quad (13)$$

$$\text{Pix ig } \%_{\text{HRxGer DP } 1} = \text{Pixels iguais HRxGer DP } 1m \div \text{Total pixels} * 100 \quad (14)$$

$$\text{Pix ig } \%_{\text{HRxLR DP } 2} = \text{Pixels iguais HRxLR DP } 2m \div \text{Total pixels} * 100 \quad (15)$$

$$\text{Pix ig } \%_{\text{HRxGer DP } 2} = \text{Pixels iguais HRxGer DP } 2m \div \text{Total pixels} * 100 \quad (16)$$

3.5.4.3 Análise da redução dos erros dos *pixels* das imagens geradas

Foi empregada na pesquisa a análise da redução dos erros altimétricos dos *pixels* das imagens geradas pelo algoritmo em relação aos erros anteriormente existentes nas imagens de baixa resolução. Foram comparados os erros referentes a cada *pixel* das imagens buscando os casos em que os erros das imagens geradas fossem menores. As análises foram feitas de três formas: analisando o valor dos *pixels* propriamente dito, analisando o valor dos *pixels* dentro de um intervalo de desvio padrão de 1 metro, e analisando o valor dos *pixels* dentro do intervalo de desvio padrão de 2 metros. Tal procedimento teve como intuito avaliar a eficácia da utilização dos métodos e critérios selecionados. Procurou-se apresentar, ainda, os resultados em sua forma percentual (Figura 29).

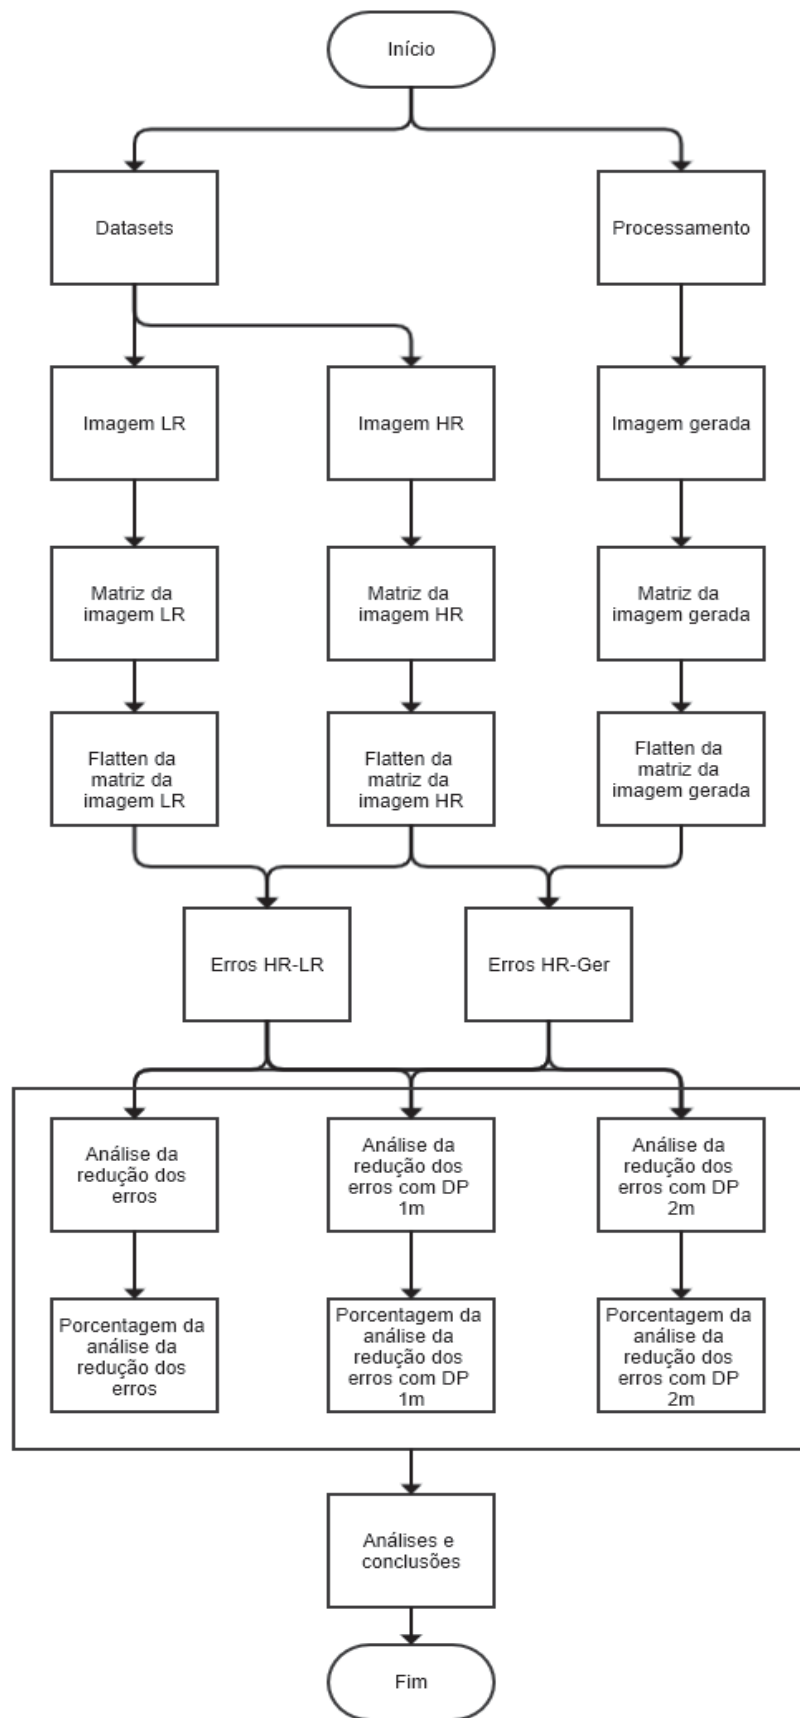


Figura 29 - Fluxograma da análise da redução dos erros dos pixels das imagens geradas.
Fonte: O autor (2022).

O cálculo da porcentagem dos erros dos *pixels* existentes menores na imagem gerada em relação à imagem de baixa resolução segue a seguinte fórmula (Fórmula 17), onde $Erros \%_{HLxGer}$ é a porcentagem dos erros dos *pixels* existentes menores na imagem gerada em relação à imagem de baixa resolução; $Erros HLxGer$ é o número de erros dos *pixels* existentes menores na imagem gerada em relação à imagem de baixa resolução; e $Total\ pixels$ é o número total de *pixels* existentes nas imagens.

$$Erros \%_{HLxGer} = Erros\ HLxGer \div Total\ pixels * 100 \quad (17)$$

Analogamente, foi realizado cálculo da porcentagem dos erros dos *pixels* existentes menores na imagem gerada em relação à imagem de baixa resolução com um intervalo de desvio padrão de 1 metro e 2 metros (Fórmula 18 e Fórmula 19),

$$Erros \%_{HLxGer\ DP\ 1} = Erros\ HLxGer\ DP\ 1m \div Total\ pixels * 100 \quad (18)$$

$$Erros \%_{HLxGer\ DP\ 2} = Erros\ HLxGer\ DP\ 2m \div Total\ pixels * 100 \quad (19)$$

3.5.5 Avaliação das métricas dos processamentos DEM-ESRGAN

3.5.5.1 Métricas

Para a realização do controle de qualidade dos resultados provenientes dos experimentos serão utilizadas medidas quantitativas da qualidade como o *Peak Signal-to-Noise Ratio* (PSNR), o *Structural Similarity Index Measure* (SSIM), o *Mean Squared Error* (MSE), o *Naturalness Image Quality Evaluator* (NIQe), e o *Root Mean Squared Error* (RMSE). Tais métricas são utilizadas na comparação dos modelos digitais do terreno gerados e dos modelos utilizados como *ground truth*.

O erro quadrático médio (MSE) é uma medida da qualidade de um determinado estimador. Os valores dos MSE de dois modelos estatísticos podem ser usados para medir o quanto os mesmos explicam um determinado conjunto de observações. O RMSE é a raiz quadrada do MSE, e permite a análise dos

resultados da métrica na mesma dimensão dos dados. De acordo com a fórmula a seguir tem-se que n é um vetor de previsões gerado a partir de uma amostra de n pontos de dados, Y é o vetor dos valores observados das variáveis preditas e \hat{Y} são os valores preditos (Fórmula 20).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (20)$$

O *Peak Signal-to-Noise Ratio* (PSNR) é uma das medidas a ser utilizada na avaliação dos produtos gerados. Tal medida define a relação entre a máxima energia de um sinal e o ruído que afeta sua representação fidedigna. De acordo com a fórmula a seguir tem-se que, MAX_i é o valor máximo possível do *pixel* da imagem, enquanto MSE é o erro médio quadrado da imagem (Fórmula 21).

$$PSNR = 20 \log_{10}(MAX_i) - 10 \log_{10}(MSE) \quad (21)$$

O índice de similaridade estrutural (SSIM) é uma métrica utilizada para medir a semelhança entre duas imagens. O índice SSIM resultante é um valor decimal entre -1 e 1, sendo que o valor 1 ocorre apenas quando os dois conjuntos de dados são idênticos e, portanto, indica perfeita semelhança estrutural. De acordo com a fórmula a seguir temos que, μ_x é a média de x , μ_y é a média de y , σ_x^2 é a variância de x , σ_y^2 é a variância de y , σ_{xy} é a covariância de x e y , e c_1 e c_2 são as variáveis de estabilização da divisão com o denominador (Wang et al, 2003) (Fórmula 22).

$$SSIM(x, y) = \frac{(2\mu_x \mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (22)$$

O avaliador de qualidade da imagem na naturalidade (NIQE) é uma pontuação de qualidade de imagem sem referência. Compara uma determinada imagem a um modelo padrão calculado a partir de imagens de cenas naturais, onde uma menor pontuação obtida indica melhor qualidade perceptiva.

3.5.5.2 Perda perceptual

Foi desenvolvido pelo algoritmo ESRGAN um L_{percep} de perda de percepção mais eficaz restringindo os recursos antes da ativação, em vez de após a ativação, conforme praticado no SRGAN. Com base na ideia de estar mais próximo da similaridade perceptiva, foi proposto a perda perceptiva estendida ao SRGAN. A perda perceptiva foi previamente definida nas camadas de ativação de uma rede profunda pré-treinada, onde a distância entre dois recursos ativados é minimizada. Ao contrário da convenção, utilizou-se os recursos antes das camadas de ativação, o que superou duas desvantagens do design original (WANG et al., 2018).

Em contraste com a perda de percepção comumente usada que adota uma rede VGG treinada para classificação de imagens, desenvolveu-se uma perda de percepção mais adequada para perda de SR. Tal rede foi baseada em uma rede VGG ajustada para reconhecimento de materiais, que se concentrava em texturas ao invés de objetos (WANG et al., 2018).

3.5.5.3 Análise da variação das métricas dos processamentos em função da média

Empregou-se na pesquisa a análise da variação das métricas das imagens de treino dos processamentos em função da média calculada de cada uma das métricas avaliadas nos processamentos. Tal procedimento teve como intuito verificar o comportamento e a variação da métrica das imagens geradas após os respectivos processamentos em relação à centralidade das medidas (Figura 30).

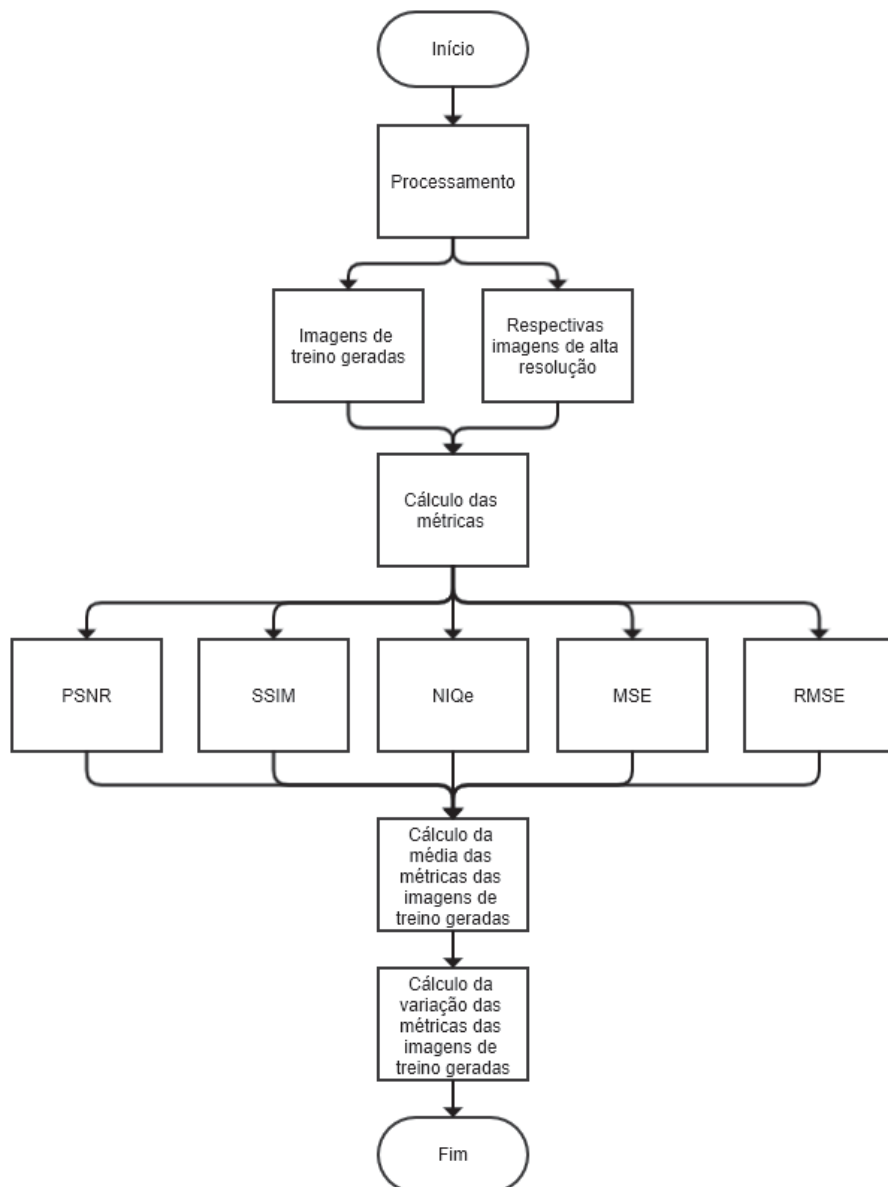


Figura 30 - Fluxograma análise da variação das métricas dos processamentos em função da média.

Fonte: O autor (2022).

3.5.6 Visualização dos MDEs de baixa resolução (esquerda), alta resolução (direita) e gerados pelo DEM-ESRGAN (centro)

Foi realizada a visualização lado a lado dos MDEs: o de baixa e o alta resolução, assim como o MDE gerado. Tal procedimento foi efetuado com 3 (três) amostras de cada um dos 3 (três) processamentos realizados em cada experimento.

O objetivo de tal avaliação é permitir a visualização e a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução, verificando suas semelhanças e diferenças.

3.5.7 Comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação

Para possibilitar a comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação típicos, verificando como os mesmos pontuam neste problema, foi realizada uma avaliação com tais métodos (interpolação bicúbica, interpolação bilinear e interpolação lanczos), viabilizando obter resultados de diferentes métricas (PSNR, SSIM, MSE e RMSE) (Figura 31).

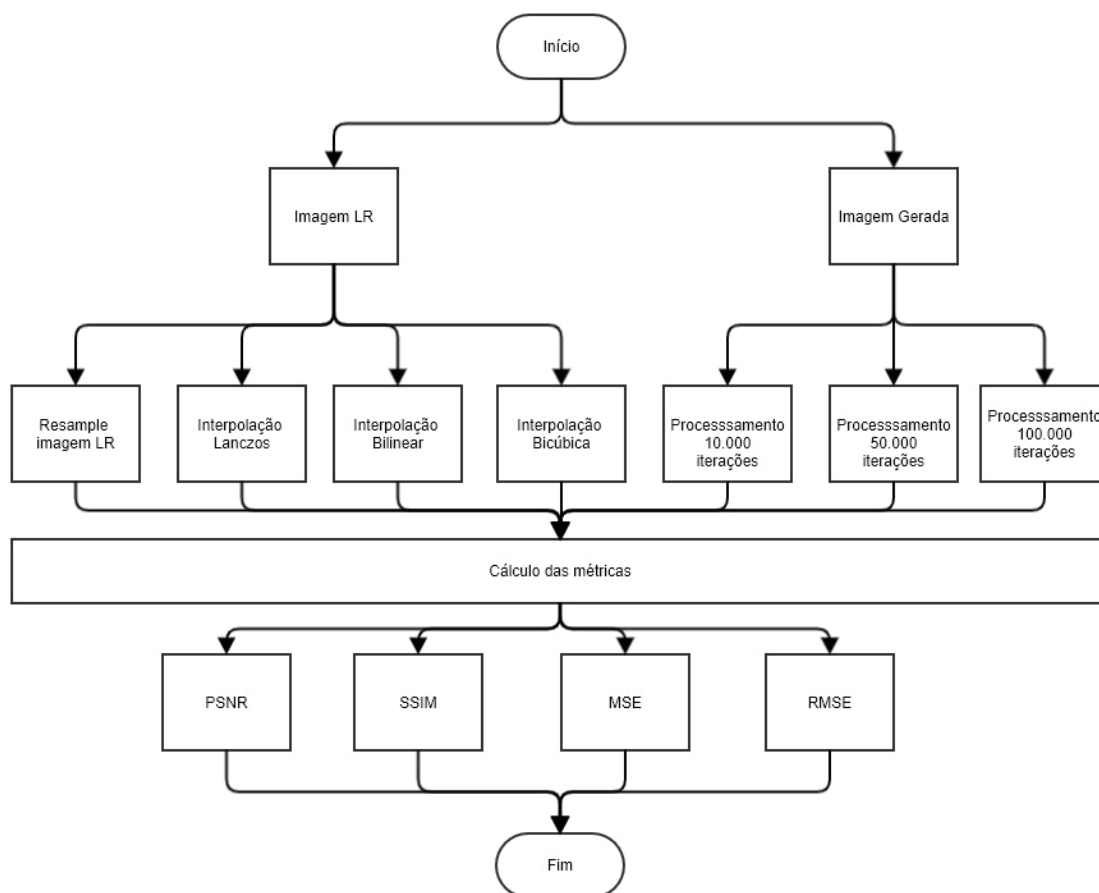


Figura 31 - Fluxograma do benchmark das métricas das imagens interpoladas.
Fonte: O autor (2022).

3.5.8 Análise de curvas de nível geradas automaticamente

Para a realização da presente análise, foi construído um algoritmo em Python para gerar automaticamente curvas de nível nas imagens de alta e baixa resolução, assim como nas imagens geradas. Tal análise permite a comparação visual das curvas em diferentes altitudes, possibilitando verificar quais processamentos atingiram melhor conformação em comparação com a imagem de alta resolução.

3.5.9 Análise do Padrão de Exatidão Cartográfico Altimétrico

A presente análise tem por objetivo verificar o padrão de exatidão cartográfico dos produtos gerados. A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto.

Para a realização da análise do Padrão de Exatidão Cartográfico Altimétrico, foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerado). Calculou-se, em seguida, o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado.

3.5.10 Análise do Padrão de Exatidão Cartográfico Planimétrico

Para a realização da avaliação do Padrão de Exatidão Cartográfico Planimétrico foram selecionados 10 pontos homólogos em cada par de imagem utilizadas (*ground truth* e gerado). Os pontos foram distribuídos privilegiando as regiões de maior índice de concentração de informações cartografadas, utilizando método não tendencioso de escolha dos mesmos, como o método de sorteio manual simples sem reposição.

Após o término da etapa de levantamento dos pontos de controle, realizou-se o processamento, o cálculo das coordenadas e identificação dos valores cartográficos para os pontos. Através da comparação dos dois grupos de coordenadas, realizou-se o cálculo dos resíduos.

Para examinar se os resultados estão dentro da expectativa, em relação à precisão, utilizou-se o teste *t-student*, verificando se a variância das diferenças das coordenadas levantadas, quando comparadas com as de referência

possuem diferenças significativas ou não, com a variância da expectativa definida antecipadamente.

3.5.11 Análise da diferença entre superfícies

Outra forma de análise e comparação a ser empregada na pesquisa é a geração de *rasters* com a diferença das discrepâncias entre os MDE gerados pelo algoritmo de IA e os MDE utilizados como referência. A subtração entre duas superfícies altimétricas permite avaliar as diferenças existentes entre ambas.

Para a geração das diferenças, primeiramente transformou-se as imagens em matrizes, para em seguida realizar a diferença entre as matrizes, e por fim salvar a matriz obtida (Figura 32).

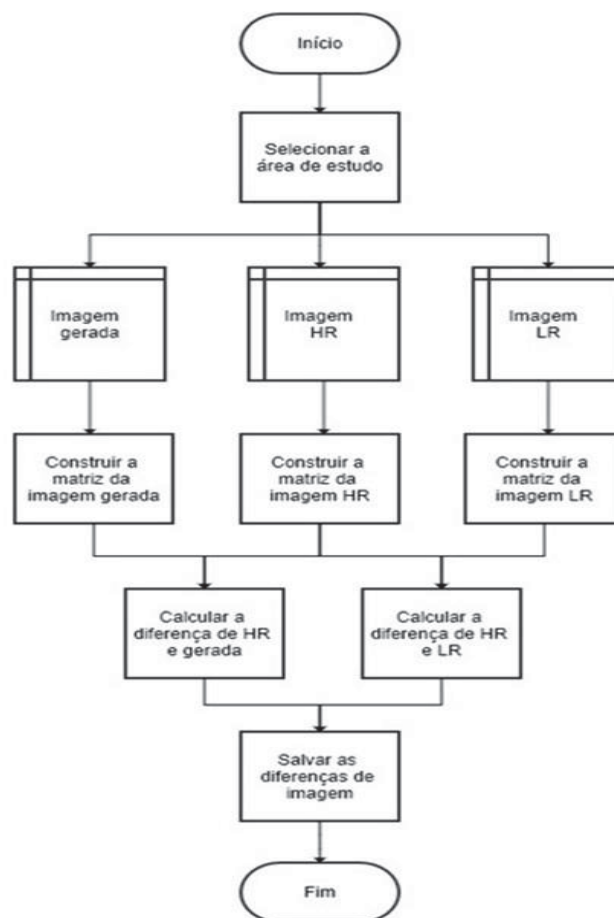


Figura 32 - Fluxograma da geração da diferença de imagens.
Fonte: O autor (2022).

3.5.11.1 Geração de diferença de superfícies

A geração de diferença de imagens segue a seguinte fórmula (Fórmula 23), onde $Dif_{img}HR - LR$ é a imagem gerada; $Matriz_{img}HR$ é a matriz da imagem de alta resolução; e $Matriz_{img}LR$ é a matriz da imagem de baixa resolução.

$$Dif_{img}HR - LR = Matriz_{img}HR - Matriz_{img}LR \quad (23)$$

3.5.12 Avaliação visual das cumeeiras

O objetivo de tal avaliação é apresentar os resultados das linhas estruturais (cumeeiras) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Para tal, realizou-se a construção das matrizes simétricas dos valores altimétricos dos MDEs, realizando-se posteriormente processamentos no intuito de obter as cumeeiras propriamente ditas para as referidas análises.

3.5.13 Avaliação visual das redes de drenagens

Esta avaliação visa levantar resultado as características das linhas estruturais (canais de drenagem) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Assim sendo, pode-se comparar tais resultados entre si e verificar os processamentos que mais se assemelham com o *ground truth* no quesito em questão.

3.5.14 Avaliação dos pontos críticos

Na presente seção, foi realizada uma investigação quanto à eficácia dos métodos utilizados na recuperação dos pontos críticos. Dessa forma, pode-se comparar os pontos máximos e mínimos das imagens geradas com os das imagens de alta resolução.

Para consecução de tal objetivo, foi desenvolvido um algoritmo em Python responsável por destacar tais pontos nas imagens de entrada.

3.5.15 Avaliação da declividade dos MDEs

A presente avaliação busca apresentar os resultados da declividade do terreno dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN nos diferentes processamentos. Tal avaliação permite a comparação da declividade do terreno de forma intuitiva.

3.5.16 Avaliação do aspecto dos MDEs

A avaliação do aspecto dos MDEs gerados e de alta resolução é possível através da utilização de processamento das imagens, no intuito de determinar a direção do maior vetor de inclinação no plano tangente projetado no plano horizontal. O aspecto é o rumo (ou azimute) da direção da inclinação, e o seu ângulo varia de 0 a 360°.

4 APRESENTAÇÃO DOS RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos com o processamento dos dados coletados utilizando o modelo DEM-ESRGAN de acordo com a descrição dos experimentos contida nas seções do capítulo 3 (materiais e métodos). As análises efetuadas acerca dos resultados alcançados e suas respectivas discussões são também abordadas neste capítulo.

4.1 RESUMO DA METODOLOGIA APLICADA AOS EXPERIMENTOS

Os três processamentos com o modelo DEM-ESRGAN de cada um dos conjuntos de dados coletados nos *datasets* foram denominados processamentos P1, P2 e P3 para o *dataset* 1, P4, P5 e P6 para o *dataset* 2, P7, P8 e P9 para o *dataset* 3, P10, P11 e P12 para o *dataset* 4, P13, P14 e P15 para o *dataset* 5 e P16, P17 e P18 para o *dataset* 6. O número total de pares de amostras (156 por 156 *pixels*) para o treinamento foi de 10, enquanto para a validação foi de 4 pares de imagens para o *dataset* 1, enquanto que para os demais *datasets* respeitou a proporção de 50 para 20. Por se tratar de modelos digitais de elevação, MOG e MGG, os dados possuem apenas uma banda. A escala de aumento de resolução das imagens configurada para todos os processamentos em questão foi de até quatro vezes (4x) o valor da imagem de resolução mais baixa.

Com tais características, foram feitos os três processamentos para cada experimento, com a variação do número de iterações entre eles, sendo que o primeiro processamento foi realizado com 10.000 iterações, o segundo com 50.000 iterações, e o terceiro com 100.000 iterações.

Ressalta-se ainda que os critérios de escolha de regiões para compor os *datasets* foram referentes às áreas de maior movimentação do relevo, resultando de maiores variações de altitudes, geralmente encontradas em regiões de serras.

Nos *datasets* criados com a mesma fonte de dados (MDE ESC 1m / 4m), tem-se os *tiles* de alta e baixa resolução coincidentes. Já o mesmo não ocorre quando da utilização de sensores ou processamentos diferentes, devido a não coincidência dos *grids* das imagens (Figura 33). Ao se fazer os recortes dos *tiles*,

a diferença dos grids faz com que as áreas selecionadas não sejam completamente coincidentes (por exemplo, no *dataset* SRTM 30 m / 90 m).




Figura 33 - Sobreposição dos pares de amostras dos datasets.
Fonte: O autor (2022).

4.1.1 *Datasets* criados

Para a consecução da presente pesquisa, foram criados os seguintes *datasets*: MDE ESC de 4 metros (LR – low resolution) e MDE ESC de 1 metro (HR – High resolution ou ground truth) (Experimento 1); MDE SRTM de 90 metros (LR) e MDE SRTM de 30 metros (HR) (Experimentos 2 e 3); MDE SRTM de 30 metros (LR) e MDE Alos Palsar de 12,5 metros (HR) (Experimento 4); e MDE Alos Palsar de 12,5 metros (LR) e MDE ESC de 1 metro (HR) (Experimento 5); MGG MAPGEO2015 de 90 metros (LR) e MGG EMG2008 de 30 metros (HR) (Experimento 6) (Figura 34 e Figura 35).




Figura 34 - 4 amostras de baixa resolução geradas para o dataset MDE SRTM de 90 metros (LR) e MDE SRTM de 30 metros (HR) com tiles de 156 x 156 pixels usadas para realizar o treinamento MDTERSGAN.

Fonte: O autor (2022).




Figura 35 - 4 amostras de baixa resolução geradas para o dataset MDE SRTM de 90 metros (LR) e MDE SRTM de 30 metros (HR) com tiles de 156 x 156 pixels usadas para realizar a validação do MDTERSGAN.

Fonte: O autor (2022).

Quanto à quantidade de amostras, foram construídos 2 (dois) tipos de *datasets* diferentes. Para o Experimento 2, foram utilizadas 10 pares de amostras para o treino e 4 pares de amostras para a validação. Para os demais experimentos, foram utilizadas 50 pares de amostras para o treino e 20 pares de amostras para a validação. Tal proporção (divisão entre 70% e 30% das amostras entre treino e validação) foi selecionada baseando-se na Técnica de Holdout.

4.2 EXPERIMENTO 1 - MODELO DEM-ESRGAN APLICADO AO DATASET 1

O processamento P1, assim como o processamento P2 e o processamento P3 utilizaram amostras de imagens degradadas do MDE ESC

com 4 metros de resolução espacial para os arquivos de baixa resolução e amostras de imagens do MDE ESC de 1 metro para os arquivos de alta resolução (como exemplificado na seção a seguir).

4.2.1 Análise do *dataset* 1

O *dataset* 1, montado para a realização do experimento em questão, foi feito a partir de 2 MDEs (ESC 4 metros e ESC 1 metro), o de alta resolução com 1 metro de resolução espacial e o de baixa resolução com 4 metros. Suas características podem ser verificadas de acordo com o apresentado na **Erro! Fonte de referência não encontrada**. No que se refere às imagens de baixa resolução, foi feita a degradação de 4 (quatro) vezes das imagens de alta resolução (resolução espacial de 1 metro) com interpolação bicúbica para a definição dos novos valores de altimetria dos *pixels*.

Tabela 6 - Características do Dataset 1

Características	HR	LR
Resolução espacial	1 metro	4 metros
Nome do arquivo	img_DEM_ESC_dataset.tif	img_DEM_ESC_dataset_4.tif
Projeção cartográfica	EPSG 31982	EPSG 32722
<i>Datum</i>	WGS84	WGS84
Largura	6379 <i>pixels</i>	1595 <i>pixels</i>
Altura	3601 <i>pixels</i>	901 <i>pixels</i>
Tipo de dado	Float32	Float32
Número de bandas	1	1
Tipo de metadados do driver GDAL	GeoTIFF	GeoTIFF

Fonte: O autor (2022).

A Figura 36 apresenta a área de uma imagem do MDE ESC de alta resolução utilizada para a extração dos pares de amostras (no que tange as amostras de alta resolução) de treinamento e validação do modelo com resolução espacial de 1 metro visualizada no QGIS.




Figura 36 - Imagem do arquivo de alta resolução do MDT ESC de resolução de 1 metro.
Fonte: O autor (2022).

4.2.2 Análise dos processamentos DEM-ESRGAN P1, P2 e P3

Ao término dos processamentos DEM-ESRGAN, foram calculados os valores de suas referidas métricas PSNR. Em relação a este quesito, o primeiro processamento (P1) apresentou o PSNR de 48,779, o segundo processamento (P2) apresentou o PSNR de 49,172, enquanto o terceiro (P3) apresentou um PSNR de 51,511.

Durante os processamentos, verificou-se que ocorre uma variação oscilatória na progressão dos valores do PSNR, não ocorrendo dessa maneira um crescimento contínuo com o decorrer do tempo (Figura 37).

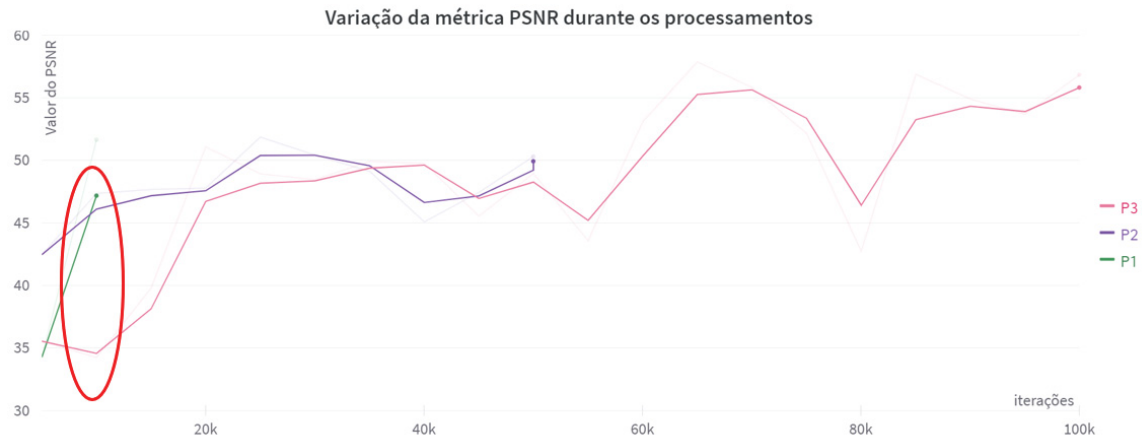


Figura 37 - Variação dos valores da métrica do PSNR dos processamentos DEM-ESRGAN executados (P1, P2 e P3) em função da progressão das épocas dos mesmos (onde k equivale a 1.000).

Fonte: O autor (2022).

Verifica-se, nas iterações próximas ao valor 10.000, que o PSNR do processamento P1 é maior em valor que os processamentos P2 e P3. Tal fato pode ser comprovado pelo fato do algoritmo DEM-ESRGAN utilizar valores aleatórios para a inicialização dos processamentos.

Ao se realizar a comparação dos resultados apresentados pelas funções de perda dos geradores de cada um dos processamentos `l_g_percep`, percebeu-se que todos partem de um pico inicial comum, e a partir daí passam a demonstrar uma tendência de aproximação do zero. Percebe-se que os processamentos com mais épocas se aproximaram mais do 0 do que os com menos épocas (Figura 38).



Figura 38 - Variação dos valores apresentados pelas funções de perda l_g percep de cada um dos processamentos DEM-ESRGAN executados (P1, P2 e P3) em função da progressão das épocas dos mesmos (onde k equivale a 1.000).
Fonte: O autor (2022).

Conclui-se, parcialmente, que o 3º processamento do referido experimento apresentou melhor métrica final dentre as apresentadas durante o processamento em si, dado que teve mais épocas para treinamento. Já em relação à variação da função de perda L_{percep} , o 3º processamento também apresentou menor erro final.

4.2.3 Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN

A presente análise foi efetuada com os resultados dos três processamentos realizados, resultando na visualização das imagens geradas pelo algoritmo DEM-ESRGAN, das imagens de baixa resolução e das imagens de alta resolução. Nessa visualização, colocou-se lado a lado, para comparação, as três imagens equivalentes, estando a de menor resolução à esquerda, a gerada ao centro e a de maior resolução à direita.

Dessa forma, a visualização permite a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução. Pôde-se observar que todas as imagens geradas analisadas apresentaram

grande semelhança com as respectivas imagens de alta resolução (Figura 39 a Figura 47). Nas imagens de P1 foram verificados efeitos de borda horizontal e vertical.




Figura 39 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P1.

Fonte: O autor (2022).




Figura 40 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P1.

Fonte: O autor (2022).




Figura 41 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P1.

Fonte: O autor (2022).




Figura 42 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P2.

Fonte: O autor (2022).




Figura 43 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P2.

Fonte: O autor (2022).




Figura 44 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P2.

Fonte: O autor (2022).




Figura 45 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P3.
Fonte: O autor (2022).




Figura 46 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P3.
Fonte: O autor (2022).




Figura 47 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P3.
Fonte: O autor (2022).

Como conclusão parcial dessa visualização, verificou-se que as 3 (três) imagens analisadas alcançaram melhor compatibilidade com o *ground truth* no 3º processamento.

4.2.4 Análise de curvas de nível geradas automaticamente

As seguintes figuras (Figura 48 a Figura 50) mostram a conformação das curvas de nível geradas automaticamente sem suavização, tanto para as imagens de alta resolução quanto para as imagens geradas pelos processamentos DEM-ESRGAN.




Figura 48 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 1 dos processamentos P1, P2 e P3.
Fonte: O autor (2022).




Figura 49 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 2 dos processamentos P1, P2 e P3.
Fonte: O autor (2022).

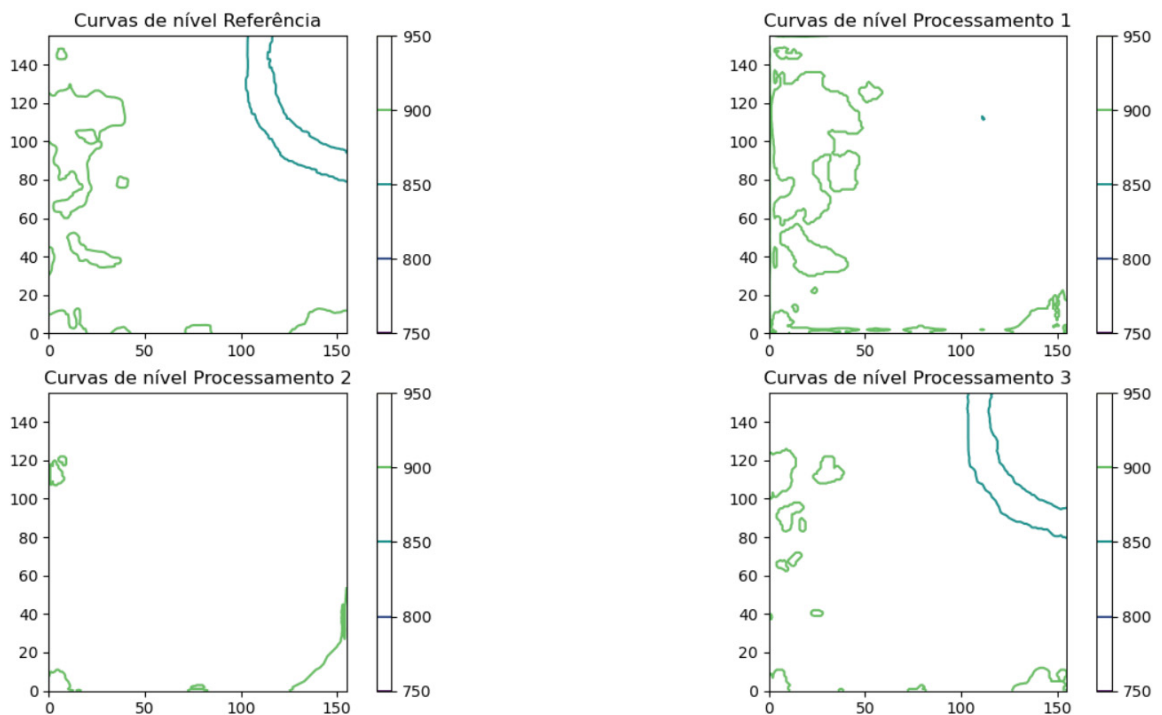


Figura 50 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 3 dos processamentos P1, P2 e P3.
Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que, em se tratando das 3 (três) imagens analisadas, o 3º processamento apresentou melhor coincidência de suas curvas de nível com as curvas de nível do *ground truth*. Nas curvas de nível do Processamento 1 foram verificados os efeitos de borda, e em menor nível também no Processamento 2.

4.2.5 Análise do Padrão de Exatidão Cartográfica Altimétrico

A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto. Para a realização da análise do Padrão de Exatidão Cartográfica Altimétrico foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerado). Calculou-se em seguida o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado (Tabela 7 e Tabela 8).

Tabela 7 - Tabela dos valores calculados do Erro Médio e do Erro Padrão das imagens geradas nos respectivos processamentos.

Processamento	Imagem	Resolução Inicial	Resolução final	EM	EP
P1	1	4 metros	1 metro	-4,257	2,291
	2			-2,523	2,680
	3			3,985	2,466
	4			5,179	2,166
P2	1	4 metros	1 metro	-2,361	2,333
	2			-1,591	2,243
	3			-1,142	7,752
	4			2,145	5,988
P3	1	4 metros	1 metro	-0,601	0,449
	2			-1,051	0,454
	3			-1,320	1,033
	4			-0,742	1,213

Fonte: O autor (2022).

Tabela 8 - Tabela do PEC altimétrico atingido pelas imagens geradas nos respectivos processamentos para as escalas do mapeamento sistemático.

Processamento	Imagem	1:250000	1:100000	1:50000	1:25000
P1	1	Classe A	Classe A	Classe A	Classe A
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A
P2	1	Classe A	Classe A	Classe A	Classe A
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe B
	4	Classe A	Classe A	Classe A	Classe A
P3	1	Classe A	Classe A	Classe A	Classe A
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A

Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que o processamento P3 alcançou os menores erros médio e erros padrão dentre as imagens avaliadas. Comparando-se ainda o P1 e P2, verificou-se melhores valores calculados no segundo, apontando para a melhora dos produtos gerados em função do aumento das iterações dos processamentos.

4.2.6 Análise do Padrão de Exatidão Cartográfico Planimétrico

Para a realização da avaliação do Padrão de Exatidão Cartográfico Planimétrico foram selecionados 10 pontos homólogos em cada par de imagem utilizadas (*ground truth* e gerado). Os pontos foram distribuídos privilegiando as regiões de maior índice de concentração de informações cartografadas, utilizando método não tendencioso de escolha dos mesmos, como o método de sorteio manual simples sem reposição.

Os sistemas naturais ou artificiais capazes de drenar água superficial, em geral proveniente das chuvas, compostos de canais conectados entre si é denominado rede de drenagem. Para a obtenção dos pontos homólogos às imagens (pontos notáveis no terreno) para a realização dos PECs Planimétricos foram utilizadas tais redes.

Após o término da etapa de levantamento dos pontos de controle, realizou-se o processamento, o cálculo das coordenadas e identificação dos

valores cartográficos para os pontos. Através da comparação dos dois grupos de coordenadas, realizou-se o cálculo dos resíduos.

Para examinar se os resultados estão dentro da expectativa, em relação à precisão, utilizou-se o teste *t-student*, verificando se a variância das diferenças das coordenadas levantadas, quando comparadas com as de referência possuem diferenças significativas ou não, com a variância da expectativa definida antecipadamente.

As três imagens dos processamentos avaliados apresentaram resultados para todas as classes do PEC de 1:250.000 até 1:2.000, sendo que apenas a terceira imagem apresentou resultado para a escala 1:1.000 (Figura 51 a Figura 53, Tabela 9 a Tabela 14).



Figura 51 - Levantamento dos 10 pontos homólogos selecionados na imagem 1 do processamento P3 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem ground truth e as linhas vermelhas são referentes à rede).

Fonte: O autor (2022).

Tabela 9 - Tabela com as diferenças dos pontos homólogos

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	532725,14	6878001,41	532725,07	6878001,50	0,08	-0,09	0,12	NÃO	NÃO
2	532734,83	6877999,38	532734,88	6877999,43	-0,05	-0,05	0,07	NÃO	NÃO
3	532731,39	6878030,54	532731,37	6878030,50	0,02	0,04	0,04	NÃO	NÃO
4	532738,47	6878023,46	532738,47	6878023,48	0,00	-0,03	0,03	NÃO	NÃO
5	532748,19	6878014,36	532748,22	6878014,39	-0,03	-0,03	0,04	NÃO	NÃO
6	532812,66	6878057,85	532812,73	6878057,82	-0,07	0,03	0,07	NÃO	NÃO
7	532813,12	6878043,25	532811,38	6878042,31	1,74	0,94	1,98	NÃO	NÃO
8	532744,68	6877993,38	532745,59	6877994,36	-0,91	-0,98	1,34	NÃO	NÃO
9	532757,15	6878008,40	532757,17	6878008,45	-0,02	-0,05	0,06	NÃO	NÃO
10	532810,47	6878050,38	532809,65	6878050,37	0,83	0,01	0,83	NÃO	NÃO

Fonte: O autor (2022).

Tabela 10 - Tabela do PEC planimétrico atingido pela imagem gerada 1 do processamento P3 para as escalas de 1:250.000 a 1:1.000.

PEC-PCD Planimétrico	
Escala	Classe
1:250000	Classe A
1:100000	Classe A
1:50000	Classe A
1:25000	Classe A
1:10000	Classe A
1:5000	Classe A
1:2000	Classe C
1:1000	Rejeitado

Fonte: O autor (2022).




Figura 52 - Levantamento dos 10 pontos homólogos selecionados na imagem 2 do processamento P3 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem ground truth e as linhas vermelhas são referentes à rede de drenagem da imagem gerada).

Fonte: O autor (2022).

Tabela 11 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 2 do processamento P3.

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	533357,12	6877986,61	533357,12	6877986,61	0,001	0,000	0,00	NÃO	NÃO
2	533420,60	6877987,96	533420,59	6877987,96	0,001	0,000	0,00	NÃO	NÃO
3	533423,76	6878019,56	533422,02	6878019,58	1,742	-0,018	1,74	NÃO	NÃO
4	533444,29	6878037,56	533444,28	6878037,56	0,011	0,000	0,01	NÃO	NÃO
5	533447,87	6878040,55	533447,88	6878041,51	-0,014	-0,958	0,96	NÃO	NÃO
6	533454,94	6878045,53	533454,07	6878045,56	0,871	-0,028	0,87	NÃO	NÃO
7	533449,21	6878059,13	533449,20	6878059,12	0,006	0,006	0,01	NÃO	NÃO
8	533435,99	6878089,23	533435,98	6878089,23	0,006	0,000	0,01	NÃO	NÃO
9	533370,23	6878080,87	533370,23	6878080,87	-0,001	-0,002	0,00	NÃO	NÃO
10	533349,45	6878112,02	533349,45	6878112,01	0,000	0,016	0,02	NÃO	NÃO

Fonte: O autor (2022).

Tabela 12 - Tabela do PEC planimétrico atingido pela imagem gerada 2 do processamento P3 para as escalas de 1:250000 a 1:1000.

PEC-PCD Planimétrico	
Escala	Classe
1:250000	Classe A
1:100000	Classe A
1:50000	Classe A
1:25000	Classe A
1:10000	Classe A
1:5000	Classe A
1:2000	Classe C
1:1000	Rejeitado

Fonte: O autor (2022).




Figura 53 - Levantamento dos 10 pontos homólogos selecionados na imagem 3 do processamento P3 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem ground truth e as linhas vermelhas são referentes à rede de drenagem da imagem gerada).

Fonte: O autor (2022).

Tabela 13 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 3 do processamento P3.

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	533477,29	6878052,49	533477,30	6878052,49	-0,003	0,000	0,003	NÃO	NÃO
2	533484,40	6878053,48	533484,41	6878053,48	-0,001	-0,002	0,002	NÃO	NÃO
3	533511,49	6878046,34	533511,49	6878046,34	0,000	0,000	0,000	NÃO	NÃO
4	533573,47	6878026,67	533573,47	6878026,66	0,000	0,003	0,003	NÃO	NÃO
5	533589,39	6878100,82	533589,40	6878100,77	-0,011	0,051	0,052	NÃO	NÃO
6	533594,13	6878066,70	533593,27	6878066,69	0,860	0,010	0,860	NÃO	NÃO
7	533599,80	6878021,07	533599,82	6878022,04	-0,020	-0,970	0,971	NÃO	NÃO
8	533593,57	6878019,58	533593,57	6878019,58	0,000	0,003	0,003	NÃO	NÃO
9	533496,11	6878111,62	533495,24	6878111,61	0,871	0,010	0,871	NÃO	NÃO
10	533504,14	6878120,61	533504,13	6878120,62	0,006	-0,006	0,009	NÃO	NÃO

Fonte: O autor (2022).

Tabela 14 - Tabela do PEC planimétrico atingido pela imagem gerada 3 do processamento P3 para as escalas de 1:250000 a 1:1000.

PEC-PCD Planimétrico	
Escala	Classe
1:250000	Classe A
1:100000	Classe A

1:50000	Classe A
1:25000	Classe A
1:10000	Classe A
1:5000	Classe A
1:2000	Classe B
1:1000	Classe C

Fonte: O autor (2022).

Como conclusão parcial da avaliação, notou-se que nenhuma das imagens geradas verificadas apresentou tendência no sentido E em relação aos pontos homólogos coletados, nem no sentido N, e que todas obtiveram PEC classe A para a escala 1:5.000.

4.2.7 Avaliação visual das cumeeiras

As seguintes figuras apresentam os resultados das linhas estruturais (cumeeiras) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Para tal, realizou-se a construção das matrizes simétricas dos valores altimétricos dos MDEs antes da realização dos processamentos de obtenção das linhas estruturais em questão (Figura 54 a Figura 57).

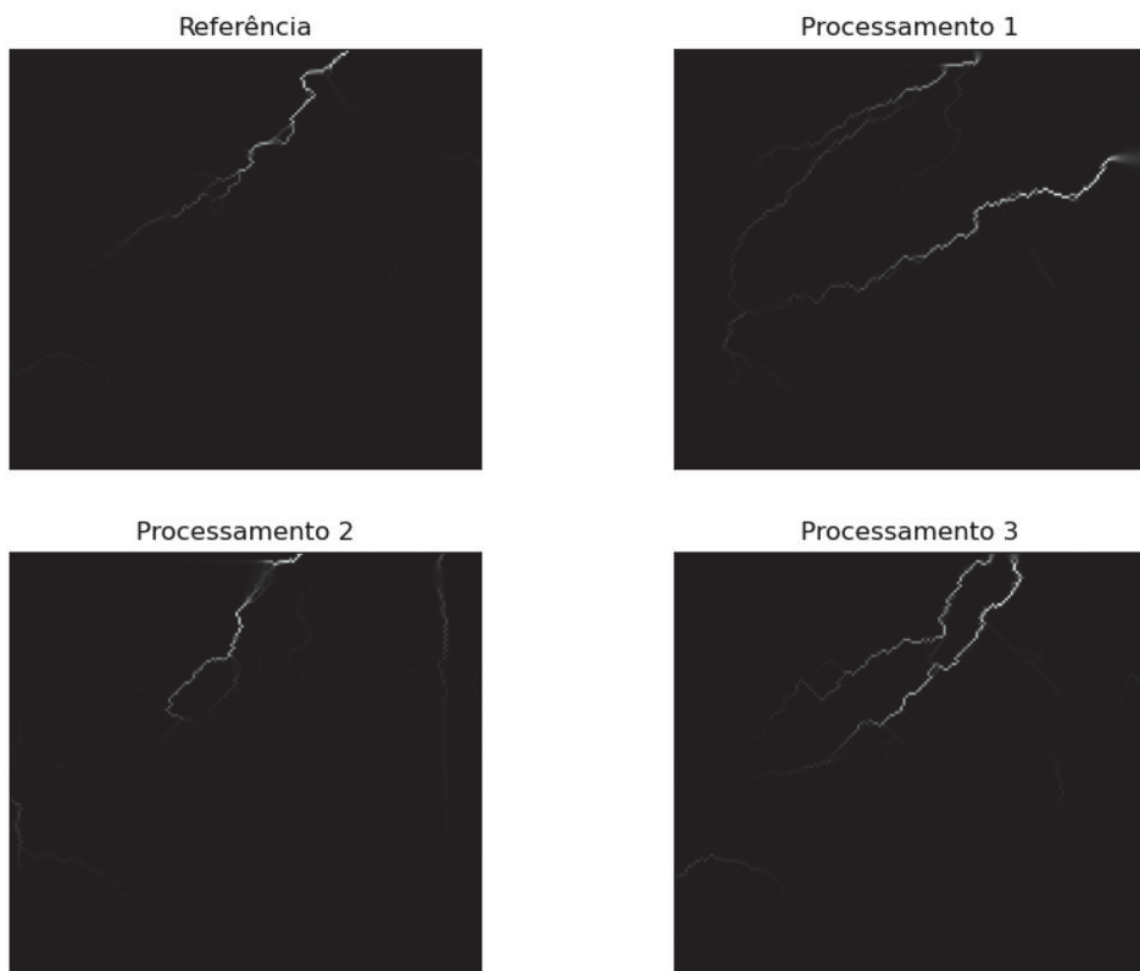


Figura 54 - Linhas de cumeeiras das imagens da imagem 1 dos processamentos DEM-ESRGAN P1, P2 e P3.
Fonte: O autor (2022).

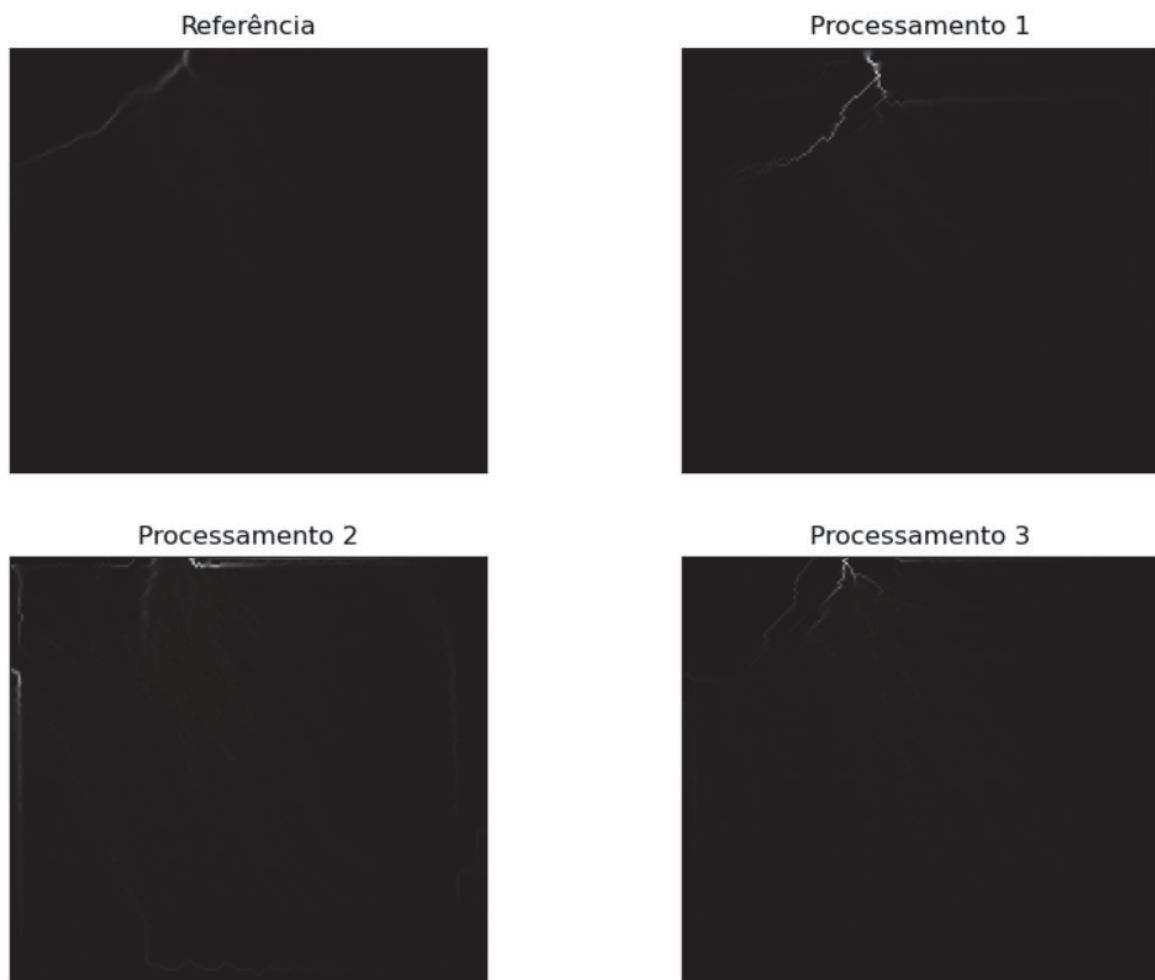


Figura 55 - Linhas de cumeeiras das imagens da imagem 2 dos processamentos DEM-ESRGAN P1, P2 e P3.
Fonte: O autor (2022).

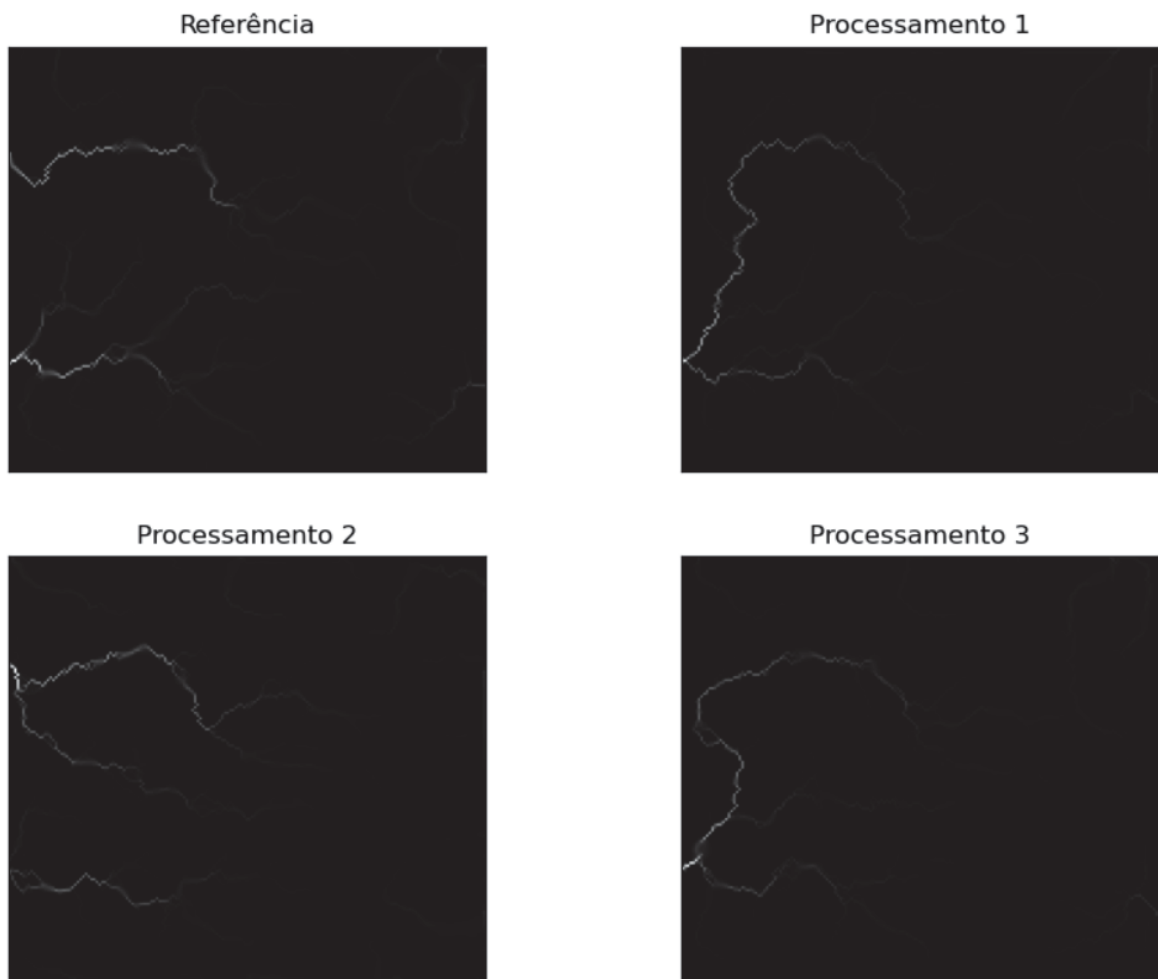


Figura 56 - Linhas de cumeeiras das imagens da imagem 3 dos processamentos DEM-ESRGAN P1, P2 e P3.
Fonte: O autor (2022).

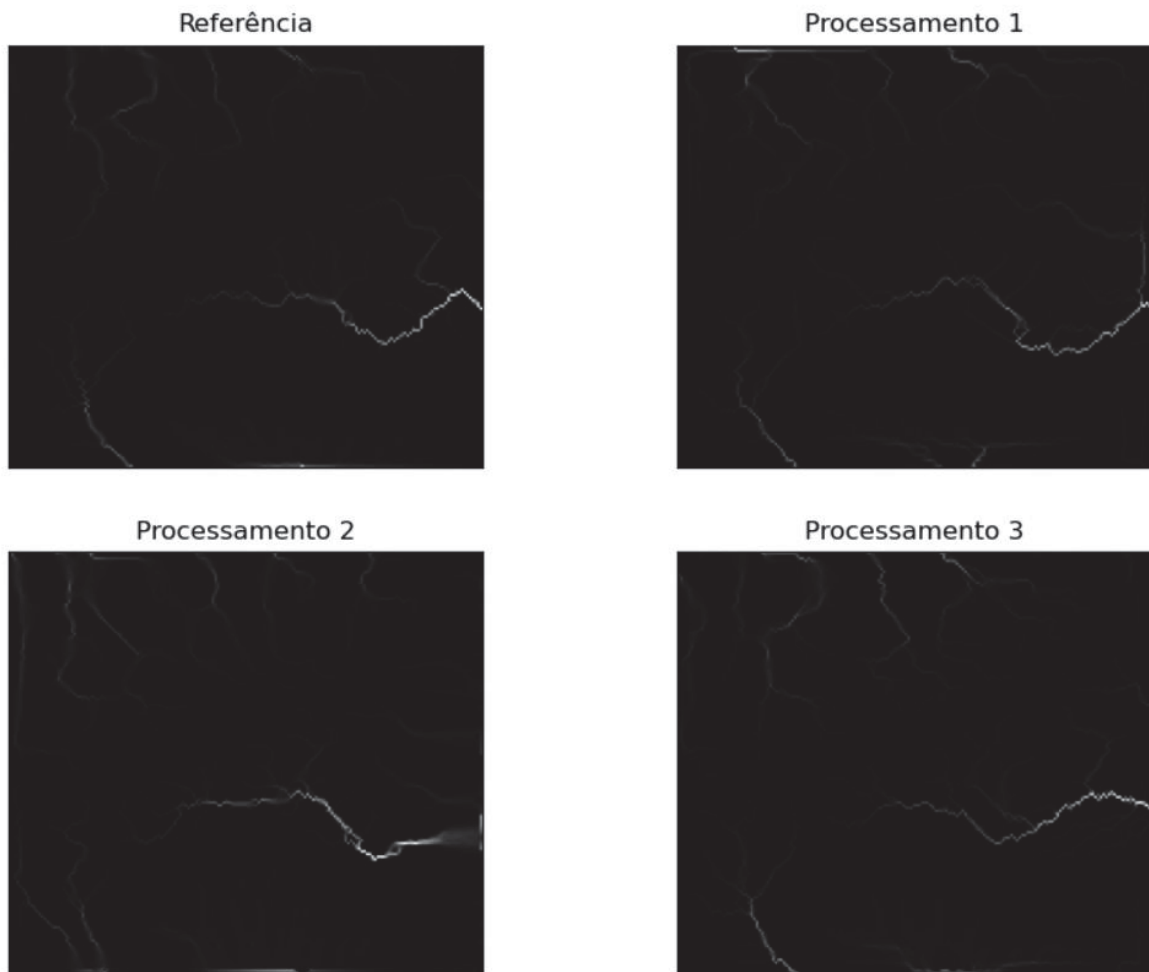


Figura 57 - Linhas de cumeeiras das imagens da imagem 4 dos processamentos DEM-ESRGAN P1, P2 e P3.
Fonte: O autor (2022).

Pode-se observar nos resultados apresentados que o P3 pôde obter a melhor taxa de correspondência das características das cumeeiras (exceto na imagem 2, que apresentou resultado inconclusivo). Então, o P3 supera P1 e P2 na preservação das características das cumeeiras.

4.3 EXPERIMENTO 2 - MODELO DEM-ESRGAN APLICADO AO *DATASET 2*

O processamento P4, assim como o processamento P5 e o processamento P6 utilizaram amostras de imagens do MDE SRTM de 90 metros para os arquivos de baixa resolução e amostras de imagens do MDE SRTM de 30 metros para os arquivos de alta resolução.

4.3.1 Análise do *dataset 2*

O *dataset 2*, montado para a realização do experimento em questão, foi feito a partir de 2 MDEs SRTM, o de alta resolução com 30 metros e o de baixa resolução com 90 metros. Suas características podem ser verificadas de acordo com o apresentado na Tabela 15.

Tabela 15 - Tabela das características dos MDEs de alta e de baixa resolução utilizados no *dataset 2*.

Características	HR	LR
Resolução espacial	30 metros	90 metros
Nome do arquivo	S30W051.hgt	SH-22-X-C.tif
Projeção cartográfica	EPSG 4326	EPSG 4326
<i>Datum</i>	WGS84	WGS84
Largura	3601 <i>pixels</i>	1200 <i>pixels</i>
Altura	3601 <i>pixels</i>	1200 <i>pixels</i>
Tipo de dado	Int16	UInt16
Número de bandas	1	1
Tipo de metadados do driver GDAL	SRTMHGT File Format	GeoTIFF

Fonte: O autor (2022).

As duas figuras seguintes (Figura 58 e Figura 59) apresentam respectivamente uma imagem do MDE SRTM de alta resolução e uma imagem do MDE SRTM de baixa resolução.




Figura 58 - Imagem do MDE SRTM de alta resolução utilizado para a extração dos pares de amostras (no que tange as amostras de alta resolução)
Fonte: O autor (2022).




Figura 59 - Imagem do MDE SRTM de baixa resolução utilizado para a extração dos pares de amostras (no que tange as amostras de baixa resolução).
Fonte: O autor (2022).

Foi necessário realizar um recorte nos MDEs (de alta e de baixa resolução) para fazer a comparação estatística das duas imagens, de modo a representarem a mesma porção do terreno.

A análise estatística das imagens utilizadas para a coleta das amostras do *dataset 2* aponta que a média aritmética da imagem de alta resolução é de 489,1774 metros, enquanto a média aritmética da imagem de baixa resolução é de 489,7005 metros. Já quanto ao desvio padrão, a imagem de alta resolução apresentou um valor de 507,1952 metros, e a imagem de baixa resolução apresentou um valor de 383,9342 metros (Tabela 16). Os dados apresentados na referida tabela são referentes aos dados brutos dos MDEs, antes da realização dos pré-processamentos. Os valores negativo não foram utilizados para fins da pesquisa, sendo convertidos durante a fase de pré-processamento dos dados.

Tabela 16 – Apresentação das estatísticas dos MDEs de alta e baixa resolução utilizados para a extração dos pares de amostras das imagens de treinamento e validação do *dataset 2*

Estatísticas	MDE LR	MDE HR
Número de <i>pixels</i>	1.440.000,0000	12.967.201,0000
Número de linhas	1.200,0000	3.601,0000
Número de colunas	1.200,0000	3.601,0000
Mínimo (metros)	0,0000	-19,0000
Máximo (metros)	1.166,0000	1.169,0000
Mediana (metros)	506,0000	505,0000
Média aritmética (metros)	489,7005	489,1774
Moda (metros)	0,0000	0,0000
Desvio padrão da população (metros)	383,9342	507,1952
Desvio padrão da amostra (metros)	383,9340	507,1952
Coefficiente de variação	0,7840	0,7852
Amplitude (metros)	820,0000	821,0000

Fonte: O autor (2022).

Os histogramas dos MDEs pré-processados utilizados apresentados permitem ilustrar suas respectivas distribuições de *pixels* por intervalos de altitudes (Figura 60 e Figura 61), se caracterizando por grande similaridade, exceto em relação ao intervalo de 0 a 40 metros. As regiões escolhidas para a seleção das amostras foram prioritariamente de regiões mais altas (regiões de serra, com terrenos acidentados, fortes desníveis e muitos picos), com altitudes variando entre 800 e 1100 metros. Os picos primários dos histogramas (valores mais comuns), em ambos os MDEs, encontram-se próximo ao valor de altitude

0 metros. Já os picos secundários encontram-se entre os valores de altitude de 800 metros e 1000 metros. Não se verificou a ocorrência de outliers. Não houve um bom ajuste em relação à curva de Gauss.




Figura 60 - Histograma mostrando a distribuição dos pixels do MDE (imagem) de baixa resolução em função de valores altimétricos (valor dos pixels em metro).
Fonte: O autor (2022).




Figura 61 - Histograma mostrando a distribuição dos pixels do MDE (imagem) de alta resolução modelo em função de valores altimétricos (valor dos pixels em metro).
Fonte: O autor (2022).

4.3.2 Análise dos processamentos DEM-ESRGAN P4, P5 e P6

Ao término dos processamentos, foram calculados os valores de suas referidas métricas PSNR. Em relação a este quesito, o primeiro processamento apresentou o PSNR de 33,754, o segundo processamento apresentou o PSNR de 32,646, enquanto o terceiro apresentou um PSNR de 32,374. A relação sinal-ruído de pico define a relação entre a energia total de um sinal e o ruído que afeta sua representação verídica. É comumente utilizada como medida quantitativa da qualidade de reconstrução no campo de compressão de imagem.

Durante os processamentos, verificou-se que ocorre uma variação oscilatória na progressão dos valores do PSNR, não ocorrendo dessa maneira um crescimento contínuo com o decorrer do tempo (Figura 62).




Figura 62 - Variação dos valores da métrica do PSNR dos processamentos DEM-ESRGAN executados (P1, P2 e P3) em função da progressão das épocas dos mesmos (onde k equivale a 1.000).
Fonte: O autor (2022).

Assim como no experimento 1, verificou-se, nas iterações próximas ao valor 10.000, que o PSNR do processamento P1 é maior em valor que os processamentos P2 e P3. Tal fato reafirma o comportamento do algoritmo DEM-ESRGAN ao utilizar valores randômicos para a inicialização dos processamentos.

Ao se realizar a comparação dos resultados apresentados pelas funções de perda dos geradores de cada um dos processamentos l_g_percep , percebe-se que todos partem de um pico inicial e a partir daí passam a demonstrar uma tendência de aproximação do zero. Percebe-se que os processamentos com mais épocas se aproximaram mais do 0 do que os com menos épocas (Figura 63).




Figura 63 - Variação dos valores apresentados pelas funções de perda l_g_percep de cada um dos processamentos DEM-ESRGAN executados (P1, P2 e P3) em função da progressão das épocas dos mesmos (onde k equivale a 1.000).
Fonte: O autor (2022).

Conclui-se, parcialmente, que o 3º processamento do referido experimento apresentou melhor métrica final dentre as apresentadas durante o processamento em si. Já em relação à variação da função de perda L_{percep} , o 3º processamento também apresentou menor erro final.

4.3.3 Avaliação das métricas dos processamentos DEM-ESRGAN P4, P5 e P6

Quanto à análise dos PSNR dos referidos processamentos, verificou-se que o P4 apresentou o maior valor de PSNR final (valor desejado) dentre os processamentos realizados (Figura 64).




Figura 64 - Gráfico de análise dos PSNR dos processamentos DEM-ESRGAN P4, P5 e P6. Fonte: O autor (2022).

Os gráficos a seguir apresentam as métricas de 10 imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6, que são o PSNR, o SSIM, o NIQE, o MSE e o RMSE (Figura 65, Figura 66, Figura 67, Figura 68 e Figura 69). No que se refere às métricas PSNR e SSIM, as imagens que obtiveram maiores valores em suas métricas obtiveram melhores desempenhos. Já em relação às

métricas NIQE, MSE e RMSE, os melhores desempenhos são atingidos pelos menores valores.

Das imagens analisadas, as geradas pelo processamento DEM-ESRGAN P6 se mostraram superiores em todas as métricas utilizadas para a avaliação.




Figura 65 - Valores da métrica PSNR de 10 imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6.
Fonte: O autor (2022).




Figura 66 - Valores da métrica SSIM de 10 imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6.
Fonte: O autor (2022).




Figura 67 - Valores da métrica NIQE de 10 imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).




Figura 68 - Valores da métrica MSE de 10 imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6.
Fonte: O autor (2022).




Figura 69 - Valores da métrica RMSE de 10 imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6 (valor da métrica em metros).
Fonte: O autor (2022).

Conclui-se parcialmente que, em relação às métricas avaliadas (PSNR, SSIM, NIQE, MSE e RMSE), o processamento P6 apresentou melhor desempenho que P4 e P5. Destaca-se que nas métricas PSNR e SSIM esperam-se valores maiores, enquanto que nas métricas NIQE, MSE e RMSE esperam-se valores menores.

4.3.4 Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6

A análise da variação de erro e precisão das imagens geradas tem por objetivo mostrar a constância do comportamento dos *pixels* de cada uma das imagens geradas analisadas em relação às imagens de alta resolução de referência (Tabela 17, Tabela 18, Figura 70 e Figura 71).

Tabela 17 - Tabela de cálculo da média do erro das imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6 (onde k equivale a 1.000).

Imagem	10k (m)	50k (m)	100k (m)
1	-3,2280	-5,5796	1,7880
2	-7,2302	-12,8259	0,5246
3	-2,1464	-1,7076	0,1471
Média do erro (m)	-4,2015	-6,7044	0,8199

Fonte: O autor (2022).




Figura 70 – Gráfico da variação do erro das imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6.

Fonte: O autor (2022).

Tabela 18 - Tabela de cálculo da média da precisão das imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6 (onde k equivale a 1.000).

Imagem	10k (m)	50k (m)	100k (m)
1	23,3841	18,8558	4,8267
2	34,4545	18,8390	5,6155
3	33,1161	15,6424	4,5639
Média da precisão (m)	30,3182	17,7791	5,0020

Fonte: O autor (2022).




Figura 71 – Gráfico da variação da precisão das imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6.
Fonte: O autor (2022).

Em relação à média do erro obtida em função da análise de 3 imagens, o processamento P6 apresentou menor valor que os processamentos P4 e P5. Da mesma forma, o processamento P6 exprimiu menor valor em relação à média da precisão em função da análise de 3 imagens.

4.3.5 Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6

Quanto à análise de imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6 em relação ao ganho de erro total e ao ganho de precisão total, verifica-se que o desempenho das imagens do processamento P6 foram superiores ao desempenho dos demais processamentos em todos os aspectos avaliados, exceto o ganho do erro total da imagem 1 (Figura 72).




Figura 72 – Gráfico de ganhos de erro e precisão de imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

Já em relação ao ganho de erro percentual e precisão percentual, verifica-se que o desempenho da imagem 2 do processamento de 50.000 teve a maior perda em relação às demais imagens (Tabela 19).

Tabela 19 - Tabela das análises das imagens dos processamentos DEM-ESRGAN P4, P5 e P6 quanto aos ganhos de erro e precisão percentuais.

Estadísticas	P4	P5	P6
Ganho erro percentual – img 1	4,9320	-579,6436	-117,7937
Ganho erro percentual – img 2	-29,8086	-130,2742	90,5819
Ganho erro percentual – img 3	-87,4543	-49,1280	87,1564
Ganho precisão percentual – img 1	0,0094	20,1221	79,5529
Ganho precisão percentual – img 2	-1,1214	44,7087	83,5189
Ganho precisão percentual – img 3	1,7858	53,6084	86,4645

Fonte: O autor (2022).

Na análise do erro e da precisão da diferença das imagens geradas em relação à imagem HR dos 3 processamentos em questão, verifica-se que o desempenho das imagens do processamento de 100.000 épocas foi superior ao desempenho dos demais processamentos em todos os aspectos avaliados (Figura 73).




Figura 73 – Gráfico de erros e precisão das imagens geradas nos processamentos DEM-ESRGAN P1, P2 e P3.
Fonte: O autor (2022).

Quanto à análise do ganho de imagens geradas em relação à imagem LR em número de *pixels* dos 3 processamentos em questão, verifica-se que os desempenhos das imagens do processamento DEM-ESRGAN de 100.000 épocas foram superiores ao desempenho dos demais processamentos (Figura 74).




Figura 74 – Gráfico de ganho das imagens geradas em relação a imagem LR em número de *pixels* nos processamentos DEM-ESRGAN P4, P5 e P6.
Fonte: O autor (2022).

Na análise dos *pixels* com erros menores nas imagens geradas em relação à imagem LR dos 3 processamentos em questão, verifica-se que o desempenho das imagens do processamento P3 foram superiores ao desempenho dos demais processamentos (Figura 75).




Figura 75 – Gráfico da análise do número de *pixels* com erros menores nas imagens geradas nos processamentos DEM-ESRGAN P4, P5 e P6.
Fonte: O autor (2022).

Como conclusão parcial da referida avaliação, verificou-se que a avaliação estatística realizada dos produtos gerados aponta para o melhor desempenho do processamento P6.

4.3.6 Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN

Outro tipo de análise que foi efetuada com os resultados dos 3 (três) processamentos realizados foi a visualização das imagens geradas pelo algoritmo DEM-ESRGAN, das imagens de baixa resolução e das imagens de alta resolução. Nessa visualização, colocou-se lado a lado, para comparação, as três imagens equivalentes, estando a de menor resolução à esquerda, a gerada ao centro e a de maior resolução à direita.

Dessa forma, a visualização permite a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução. Pôde-se observar, por meio de tal visualização, que todas as imagens geradas analisadas apresentaram grande semelhança com as respectivas imagens de alta resolução (Figura 76, Figura 77, Figura 78, Figura 79, Figura 80, Figura 81, Figura 82, Figura 83 e Figura 84).




Figura 76 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P4.

Fonte: O autor (2022).




Figura 77 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P4.
Fonte: O autor (2022).




Figura 78 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P4.
Fonte: O autor (2022).




Figura 79 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P5.
Fonte: O autor (2022).




Figura 80 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P5.
Fonte: O autor (2022).




Figura 81 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P5.
Fonte: O autor (2022).




Figura 82 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P6.
Fonte: O autor (2022).




Figura 83 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P6.

Fonte: O autor (2022).




Figura 84 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P6.

Fonte: O autor (2022).

Como conclusão parcial, verificou-se que as imagens do processamento P6 apresentou maior proximidade com as imagens de alta resolução do que as imagens do demais processamentos do experimento.

4.3.7 Comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação

Para possibilitar a comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação típicos, verificando como os mesmos pontuam neste problema, foi realizada uma avaliação com tais métodos, viabilizando obter resultados de diferentes métricas (PSNR, SSIM, MSE e RMSE) (Tabela 20). O algoritmo DEM-ESRGAN com 100.000 épocas (P6) mostrou melhor resultado entre todos os outros métodos de interpolação típicos usados neste *benchmark*.

Tabela 20 - Tabela de comparação das métricas PSNR, SSIM, MSE e RMSE dos resultados de diferentes interpoladores

Interpoladores	PSNR	SSIM	MSE	RMSE (m)
low-resolution	20,6918	0,5561	554,4939	23,5477
bilinear	22,4056	0,6824	373,6995	19,3313
bicubic	22,2540	0,6687	386,9754	19,6717
lanczos	22,2501	0,6680	387,3231	19,6805
DEM-ESRGAN 10.000 (P4)	20,5421	0,5710	573,9508	23,9573
DEM-ESRGAN 50.000 (P5)	22,9123	0,6249	332,5414	18,2357
DEM-ESRGAN 100.000 (P6)	36,5822	0,9711	14,2841	3,7794

Fonte: O autor (2022).

Verificou-se, dessa forma, que o processamento P6 apresentou o melhor desempenho tanto em comparação aos interpoladores testados, como em relação aos demais processamentos do experimento.

4.3.8 Análise de curvas de nível geradas automaticamente

As seguintes figuras (Figura 85 a Figura 88) mostram a conformação das curvas de nível geradas automaticamente sem suavização, tanto para as imagens de alta resolução quanto para as imagens geradas pelos processamentos DEM-ESRGAN.

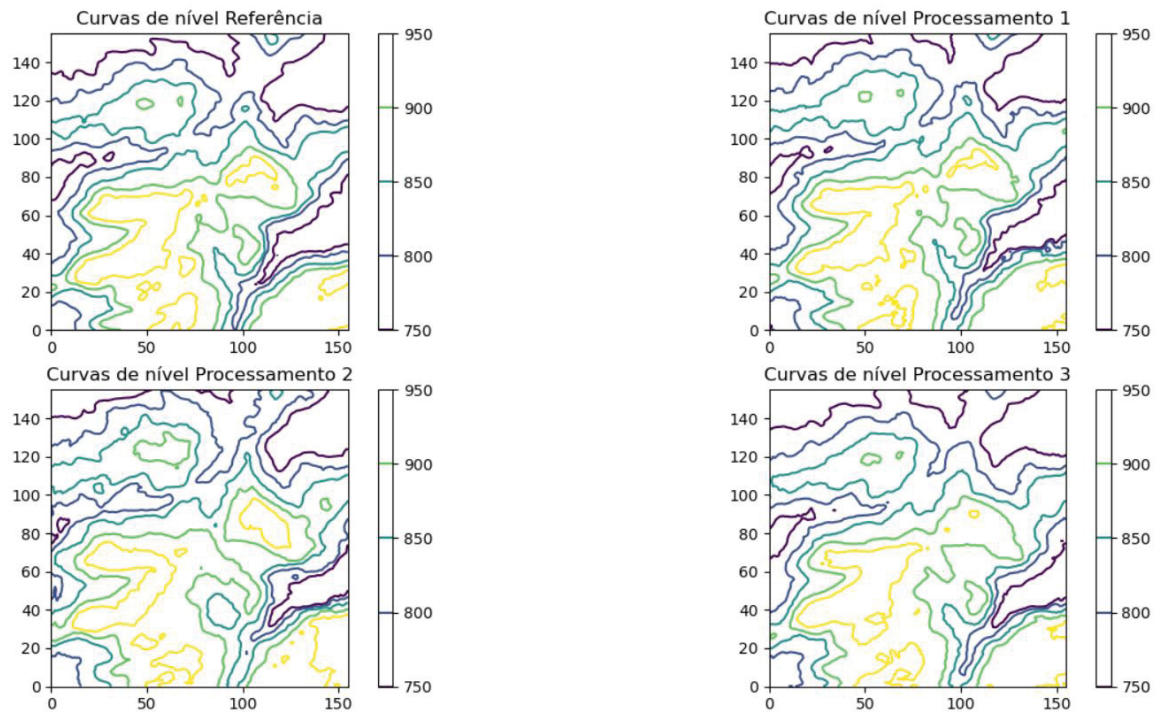


Figura 85 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 1 dos processamentos P4, P5 e P6.
Fonte: O autor (2022).

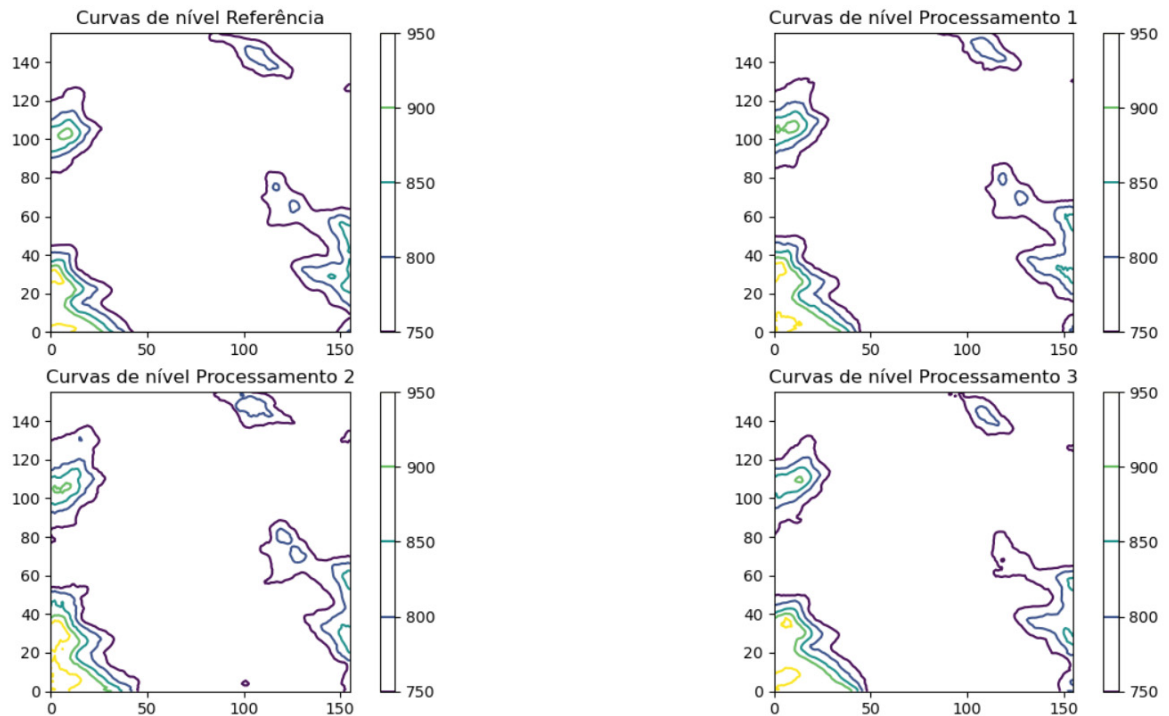


Figura 86 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 2 dos processamentos P4, P5 e P6.
Fonte: O autor (2022).

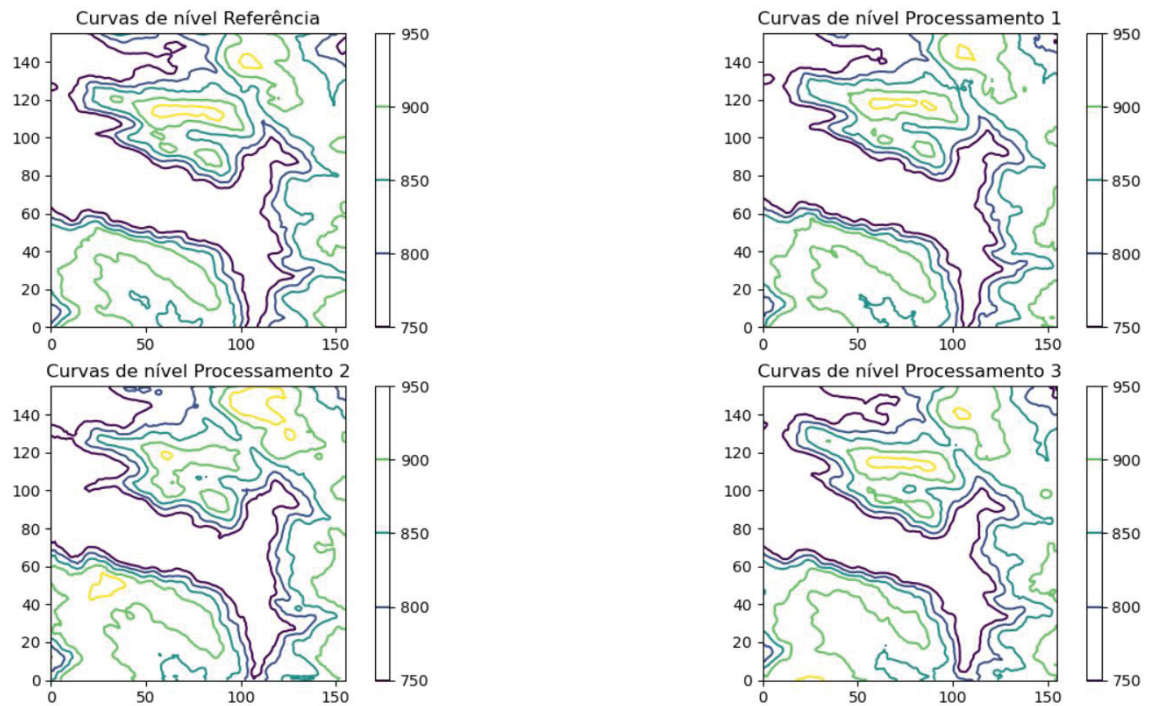


Figura 87 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 3 dos processamentos P4, P5 e P6.
Fonte: O autor (2022).

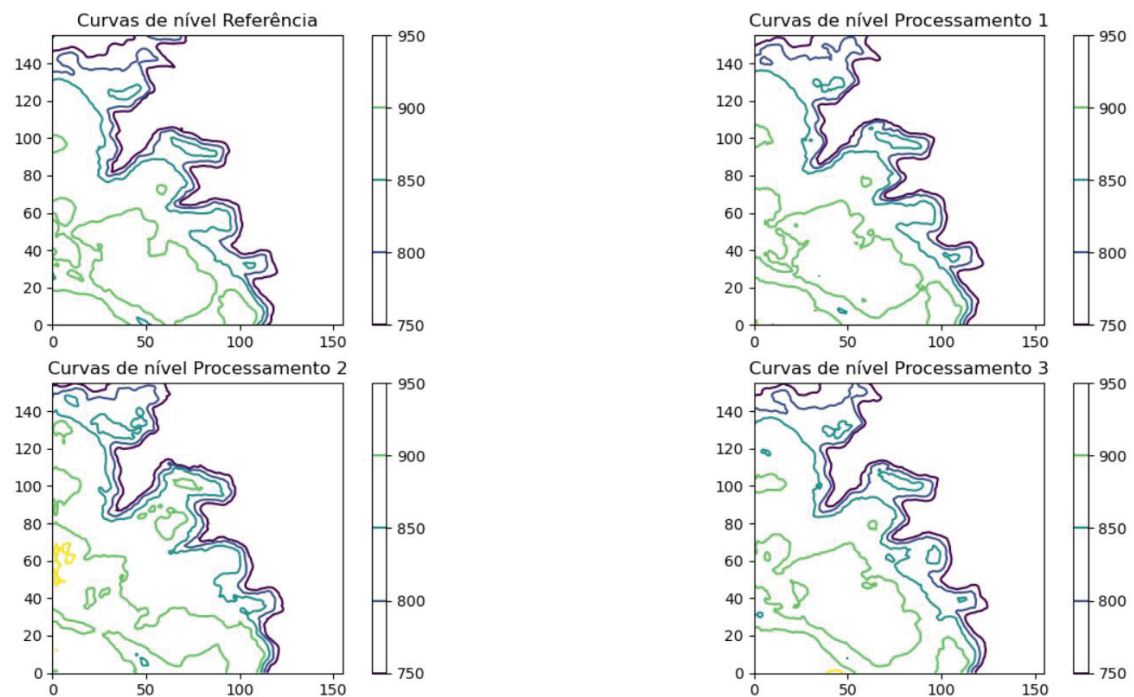


Figura 88 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 4 dos processamentos P4, P5 e P6.
Fonte: O autor (2022).

A partir desta análise, verificou-se que o processamento P4 apresentou melhor desempenho na comparação com as imagens de alta resolução, seguido pelo processamento P6. Para alcançar tal conclusão, buscou-se comparar visualmente as curvas de nível de cada um dos processamentos com as curvas de nível geradas a partir da imagem de alta resolução, que é considerada a verdade de campo para o experimento em questão.

4.3.9 Análise do Padrão de Exatidão Cartográfica Altimétrico

A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto. Para a realização da análise do Padrão de Exatidão Cartográfica Altimétrico foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerado). Calculou-se em seguida o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado (Tabela 21 e Tabela 22).

Tabela 21 - Tabela dos valores calculados do Erro Médio e do Erro Padrão das imagens geradas nos respectivos processamentos

Processamento	Imagem	Resolução Inicial	Resolução final	EM	EP
P4	1	90 metros	30 metros	8,117	28,136
	2			15,507	39,848
	3			7,822	49,470
	4			2,272	39,266
P5	1	90 metros	30 metros	17,268	31,895
	2			20,440	54,474
	3			11,818	59,602
	4			14,175	49,129
P6	1	90 metros	30 metros	4,573	29,568
	2			26,363	62,501
	3			10,296	59,877
	4			6,706	46,579

Fonte: O autor (2022).

Tabela 22 - Tabela do PEC altimétrico atingido pelas imagens geradas nos respectivos processamentos para as escalas do mapeamento sistemático

Processamento	Imagem	1:250000	1:100000	1:50000	1:25000
P4	1	Classe A	Classe D	Classe D	Classe D
	2	Classe A	Classe D	Classe D	Classe D

	3	Classe A	Classe D	Classe D	Classe D
	4	Classe A	Classe D	Classe D	Classe D
P5	1	Classe A	Classe D	Classe D	Classe D
	2	Classe A	Classe D	Classe D	Classe D
	3	Classe A	Classe D	Classe D	Classe D
	4	Classe A	Classe D	Classe D	Classe D
P6	1	Classe A	Classe D	Classe D	Classe D
	2	Classe A	Classe D	Classe D	Classe D
	3	Classe A	Classe D	Classe D	Classe D
	4	Classe A	Classe D	Classe D	Classe D

Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que o processamento P4 alcançou os menores erros médio e erros padrão dentre as imagens avaliadas. Comparando-se ainda o P5 e P6, verificou-se melhores valores calculados no segundo.

4.3.10 Análise do Padrão de Exatidão Cartográfico Planimétrico

Para a realização da avaliação do Padrão de Exatidão Cartográfico Planimétrico foram selecionados 10 pontos homólogos em cada par de imagem utilizadas (*ground truth* e gerado). Os pontos foram distribuídos privilegiando as regiões de maior índice de concentração de informações cartografadas, utilizando método não tendencioso de escolha dos mesmos, como o método de sorteio manual simples sem reposição.

Após o término da etapa de levantamento dos pontos de controle, realizou-se o processamento, o cálculo das coordenadas e identificação dos valores cartográficos para os pontos. Através da comparação dos dois grupos de coordenadas, realizou-se o cálculo dos resíduos.

Para examinar se os resultados estão dentro da expectativa, em relação à precisão, utilizou-se o teste *t-student*, verificando se a variância das diferenças das coordenadas levantadas, quando comparadas com as de referência possuem diferenças significativas ou não, com a variância da expectativa definida antecipadamente (Tabela 23, Tabela 24 e Figura 89).



Figura 89 - Levantamento dos 10 pontos homólogos selecionados na imagem 1 do processamento P4 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada).

Fonte: O autor (2022).

Tabela 23 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 1 do processamento P4 .

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	553929,19	6733301,72	553927,77	6733178,12	1,42	123,60	123,61	NÃO	SIM
2	552513,14	6736824,30	552597,06	6736696,04	-83,92	128,26	153,28	NÃO	SIM
3	550166,89	6734825,98	550137,90	6734733,76	28,99	92,22	96,67	NÃO	SIM
4	550502,22	6734779,73	550476,33	6734687,49	25,89	92,24	95,80	NÃO	SIM
5	553913,80	6735820,64	553887,41	6735759,68	26,39	60,97	66,44	NÃO	SIM
6	549962,52	6737293,02	549801,55	6737292,31	160,97	0,71	160,97	NÃO	SIM
7	551144,50	6737132,15	551171,43	6737040,39	-26,93	91,76	95,63	NÃO	SIM
8	552792,09	6735810,32	552878,56	6735696,25	-86,46	114,07	143,14	NÃO	SIM
9	552025,54	6736140,67	552032,39	6736007,08	-6,84	133,59	133,76	NÃO	SIM
10	552232,53	6733067,95	552311,60	6732970,96	-79,07	96,98	125,13	NÃO	SIM

Fonte: O autor (2022).

Tabela 24 - Tabela do PEC planimétrico atingido pela imagem gerada 1 do processamento P4 para as escalas de 1:250.000 a 1:1.000

Escala	Classe
1:250.000	Classe C
1:100.000	Rejeitado
1:50.000	Rejeitado

1:25.000	Rejeitado
1:10.000	Rejeitado
1:5.000	Rejeitado
1:2.000	Rejeitado
1:1.000	Rejeitado

Fonte: O autor (2022).

A imagem 1 do processamento P4 apresentou como resultado PEC Classe C na escala 1:250.000 e PEC rejeitado nas demais classes.

4.3.11 Análise da diferença entre superfícies

A subtração entre duas superfícies altimétricas permite avaliar as diferenças existentes entre ambas. Para que sejam enquadrados nas classes do PEC-PCD B da escala de 1:50.000, as discrepâncias entre as coordenadas dos pontos homólogos devem resultar em valores iguais ou inferiores de erro máximo (EM) de 10,00 metros e de erro padrão (EP) de 6,66 metros (Figura 90).




Figura 90 - Diferença entre superfícies das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

Como conclusão parcial da avaliação, verificou-se que as imagens do processamento P6 apresentaram as menores diferenças entre superfícies, em comparação com as imagens dos processamentos P4 e P5.

4.3.12 Avaliação visual das cumeeiras

As seguintes figuras (Figura 91 a Figura 94) apresentam os resultados das linhas estruturais (cumeeiras) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Para tal, realizou-se a construção das matrizes simétricas dos valores altimétricos dos MDEs antes da realização dos processamentos.

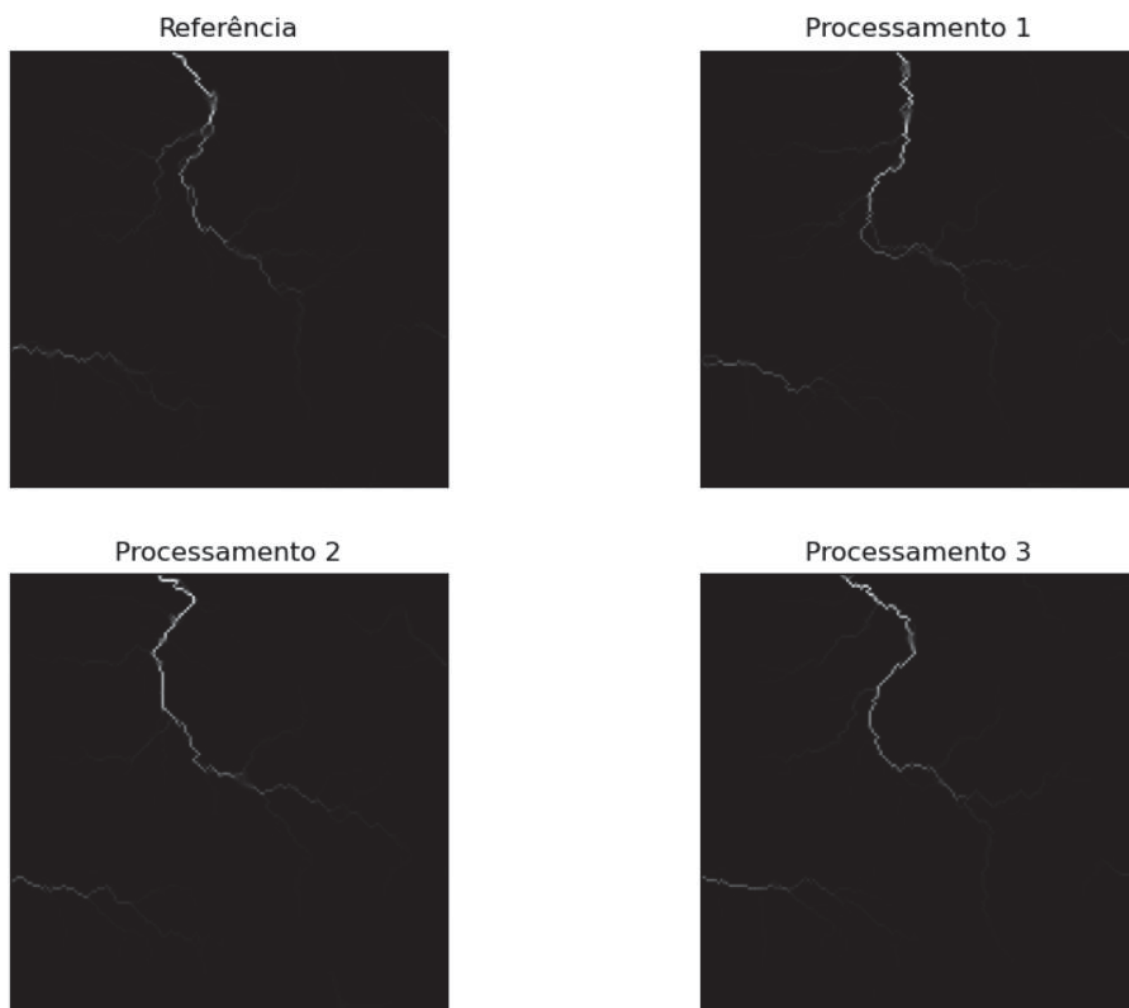


Figura 91 - Linhas de cumeeiras das imagens da imagem 1 dos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

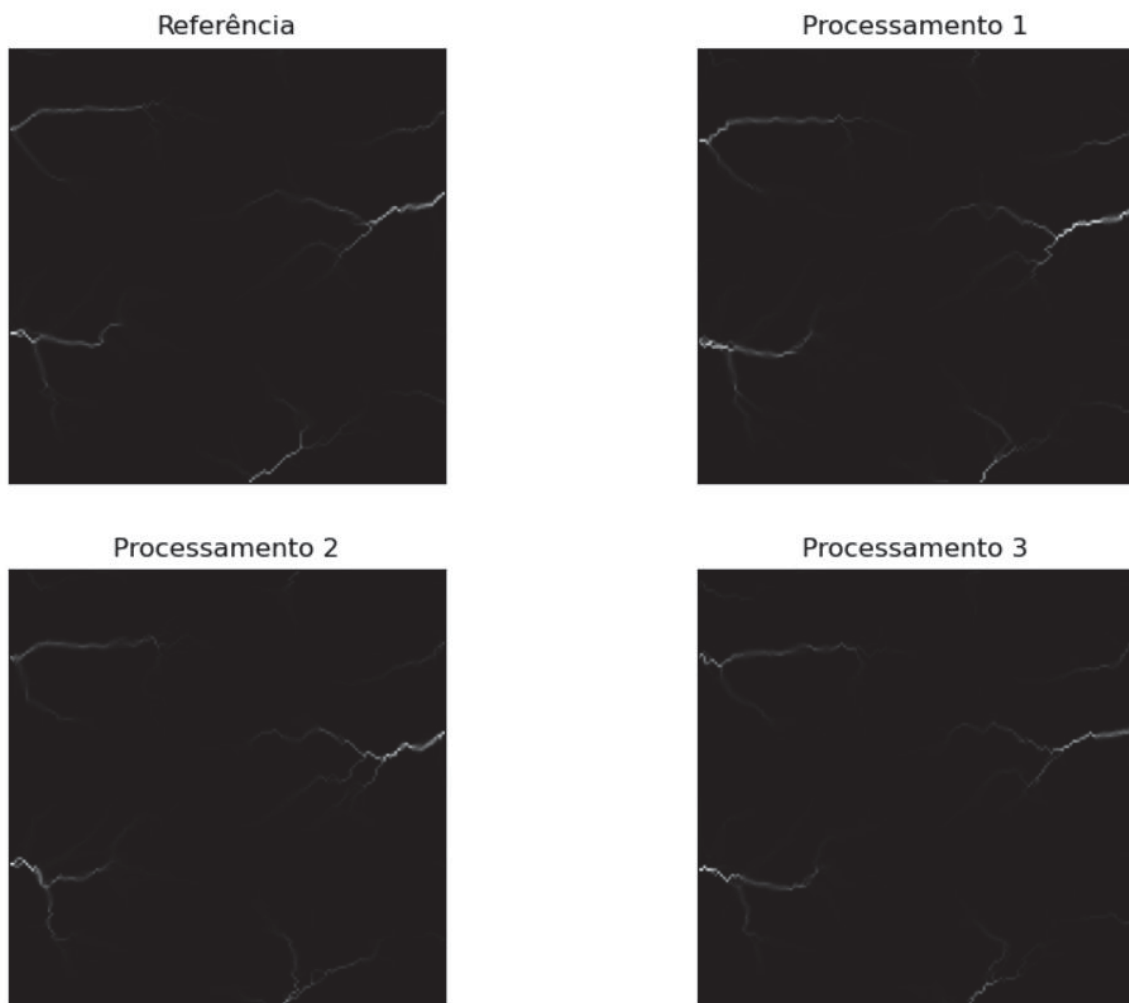


Figura 92 - Linhas de cumeeiras das imagens da imagem 2 dos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

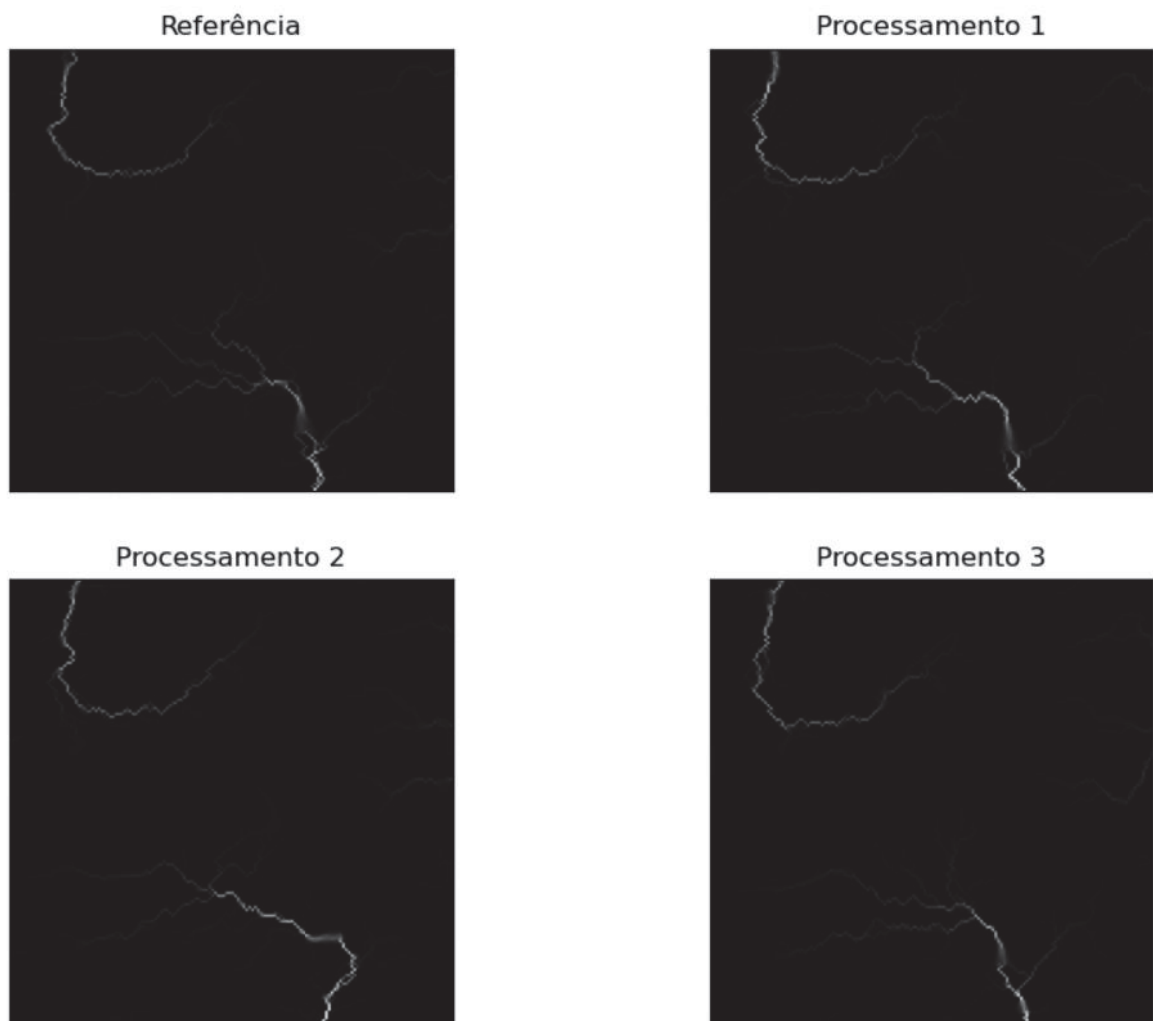


Figura 93 - Linhas de cumeeiras das imagens da imagem 3 dos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

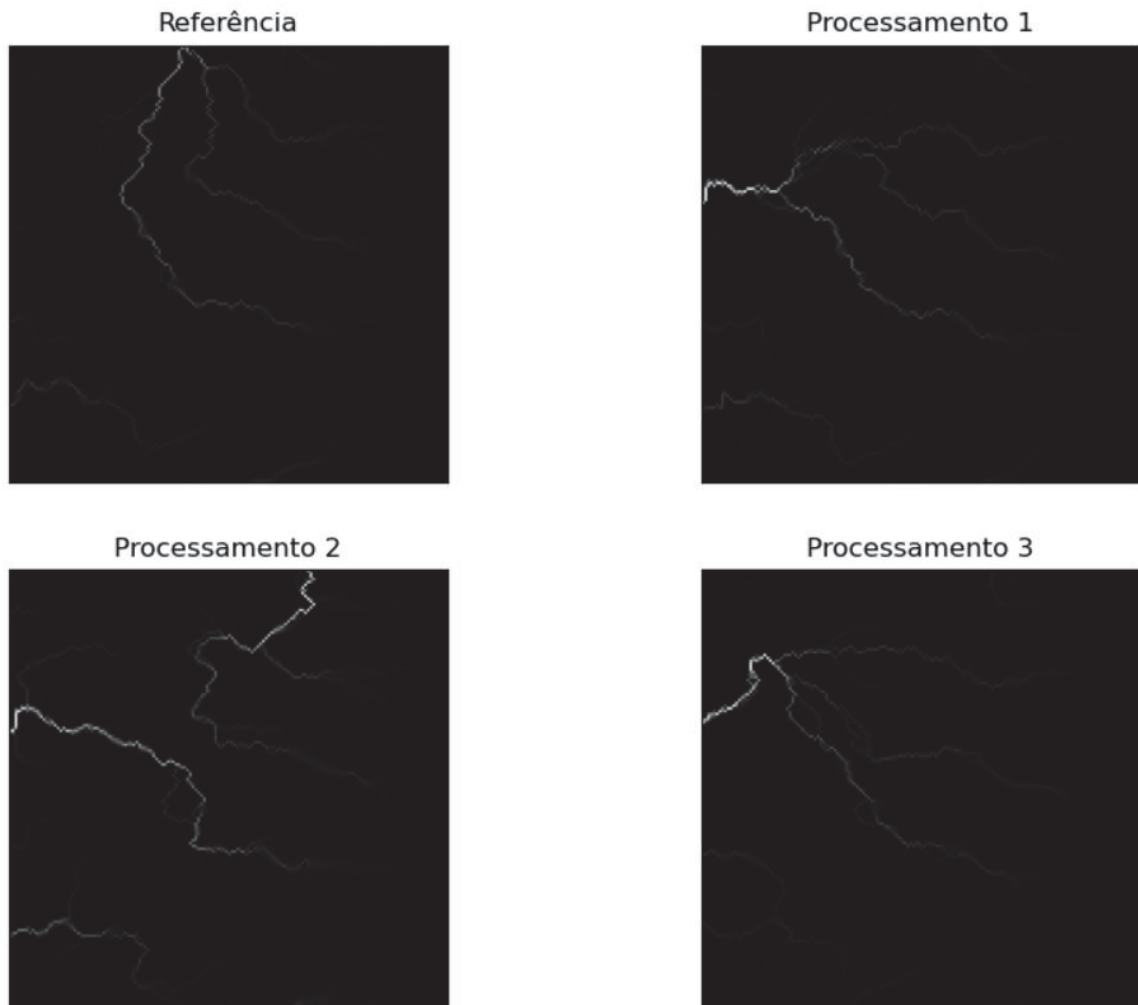


Figura 94 - Linhas de cumeeiras das imagens da imagem 4 dos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

Pode-se observar nos resultados apresentados que o P6 pode obter a melhor taxa de correspondência das características das cumeeiras. Então, o P6 supera P4 e P5 na preservação das características das cumeeiras.

4.3.13 Avaliação visual das redes de drenagens

A Figura 95 apresenta os resultados das linhas estruturais (canais de drenagem) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Em primeiro lugar, pode-se observar que o P3 pode obter a melhor taxa de correspondência das características dos canais de drenagem. Então, o P3 supera P1 e P2 na preservação das características dos canais de drenagem.




Figura 95 - MDEs contendo o resultado dos canais de drenagens das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

Pode-se observar que o P6 pode obter a melhor taxa de correspondência das características dos canais de drenagem. Então, o P6 supera P4 e P5 na preservação das características dos canais de drenagem.

4.3.14 Avaliação dos pontos críticos

Na presente seção, foi realizada uma investigação quanto à eficácia dos métodos utilizados na recuperação dos pontos críticos. Pelas avaliações anteriores, pode-se observar que o algoritmo DEM-ESRGAN gera melhores resultados em relação à geração de SR que os outros métodos. Dessa maneira, nesta avaliação, apenas os resultados do *ground truth* e as interpolações dos processamentos P4, P5 e P6 são focados.

A Figura 96 apresenta um conjunto de imagens contendo a análise visual dos *pixels* contendo altitudes máximas e mínimas das imagens de alta resolução e das imagens geradas pelos processamentos P4, P5 e P6, onde os *pixels* de altitude máxima são representados pela cor vermelha e os *pixels* de altitude mínima são representados pela cor azul. Tais *pixels* representam pontos críticos para os MDEs gerados pelo método utilizado na presente pesquisa.

Quanto à preservação de pontos críticos (Figura 96), nenhuma regra óbvia foi encontrada nos três resultados de exemplo. Nesse sentido, os resultados estatísticos podem ser a melhor solução para avaliar a preservação dos pontos críticos, e as principais conclusões podem ser obtidas a partir de uma análise das métricas obtidas das respectivas imagens. Portanto, para resumir, neste quesito, o processamento P3 supera os demais processamentos na preservação da maioria das características do terreno na SR do MDE.




Figura 96 - MDEs de alta resolução e MDEs gerados pelo conjunto de validação do *dataset 2* contendo suas respectivas altitudes máximas e mínimas das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6, onde os *pixels* de altitude mínima são representados pela cor azul e os de altitude máxima pela cor vermelha

Fonte: O autor (2022).

Conclui-se parcialmente que, as imagens dos processamentos P4 e P6 são as que mais se assemelham com as imagens de alta resolução, seguidas pelas imagens do processamento P5.

4.3.15 Avaliação da declividade dos MDEs

A Figura 97 apresenta os resultados da declividade do terreno dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN P1, P2 e P3.

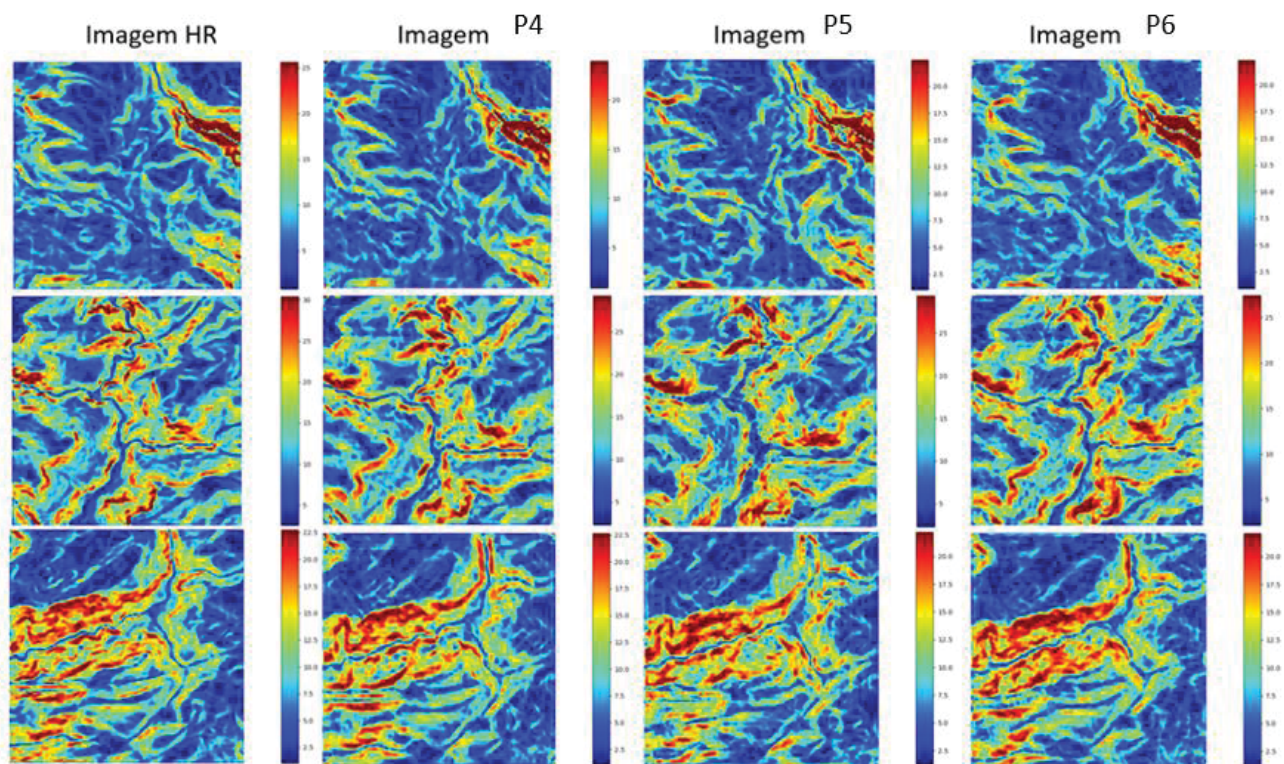


Figura 97 - MDEs contendo o resultado da declividade do terreno das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P4, P5 e P6
Fonte: O autor (2022).

Considerando a avaliação da declividade do terreno, a percepção intuitiva é de que os resultados de P6 são muito mais suaves que os de P4 e P5, e algumas texturas são mais reforçadas nos resultados da interpolação de P5, mas ficam retidas em P4 e P6.

4.3.16 Avaliação do aspecto dos MDEs

A Figura 98 apresentam os resultados do aspecto dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN P4, P5 e P6.

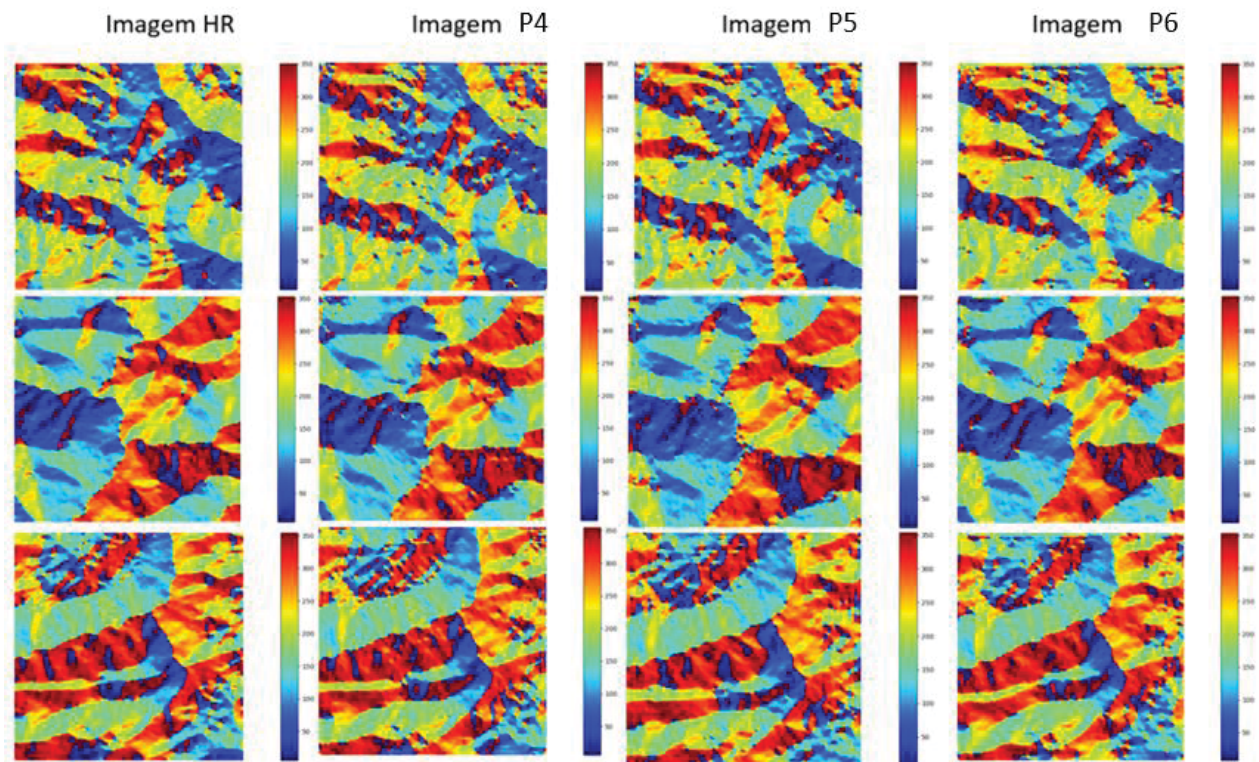


Figura 98 - MDEs contendo o resultado do aspecto das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P1, P2 e P3
Fonte: O autor (2022).

Quanto ao aspecto, intuitivamente, verifica-se que as distorções nos resultados do P5 ocorreram em comparação aos resultados do P4 e do P6. No entanto, os resultados de declividade do terreno do P6 apresentam um melhor equilíbrio entre precisão global e características locais, o que pode ser a razão pela qual o P6 supera os outros métodos. Então, considerando-se a avaliação de aspecto, os três processamentos geram resultados comparáveis, e tal conclusão é consistente com as avaliações estatísticas.

4.4 EXPERIMENTO 3 - MODELO DEM-ESRGAN APLICADO AO DATASET 3

O processamento P7, assim como o processamento P8 e o processamento P9, utilizaram amostras de imagens do MDE SRTM de 90 metros para os arquivos de baixa resolução e amostras de imagens do MDE SRTM de 30 metros para os arquivos de alta resolução.

4.4.1 Análise do *dataset* 3

A análise referente ao *dataset* 3 é a mesma feita para o *dataset* 2.

4.4.2 Análise dos processamentos DEM-ESRGAN P7, P8 e P9

Ao término dos processamentos DEM-ESRGAN, foram calculados os valores de suas referidas métricas PSNR. Em relação a este quesito, o primeiro processamento (P7) apresentou o PSNR de 39,103, o segundo processamento (P8) apresentou o PSNR de 41,317, enquanto o terceiro (P9) apresentou um PSNR de 42,049. Dessa forma, o processamento P6 apresentou maior medida quantitativa da qualidade de reconstrução no campo de compressão de imagem em relação aos demais processamentos analisados.

Durante os processamentos, verificou-se que ocorre uma variação oscilatória na progressão dos valores do PSNR, não ocorrendo dessa maneira um crescimento contínuo com o decorrer do tempo (Figura 99).




Figura 99 - Variação dos valores da métrica do PSNR dos processamentos DEM-ESRGAN executados (P7, P8 e P9) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)

Fonte: O autor (2022).

Ao se realizar a comparação do *loss l_g_perceptron* dos processamentos em questão, percebe-se que todos partem de um pico inicial e a partir daí passam a demonstrar uma tendência de aproximação do zero. Percebe-se que os processamentos com mais épocas se aproximaram mais do 0 do que os com menos épocas (Figura 100).



Figura 100 - Variação dos valores apresentados pelas funções de perda *l_g_percep* de cada um dos processamentos DEM-ESRGAN executados (P7, P8 e P9) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)

Fonte: O autor (2022).

Conclui-se, parcialmente, que o 3º processamento do referido experimento apresentou melhor métrica final dentre as apresentadas durante o processamento em si. Já em relação à variação da função de perda *Lpercep*, o 3º processamento também apresentou menor erro final.

4.4.3 Avaliação das métricas dos processamentos DEM-ESRGAN P7, P8 e P9

Quanto à análise dos PSNR dos processamentos, verificou-se que o processamento P9 apresentou o maior valor de PSNR final (valor desejado) dentre os processamentos realizados (Figura 101).




Figura 101 - Gráfico de análise dos PSNR dos processamentos DEM-ESRGAN P7, P8 e P9.
Fonte: O autor (2022).

As imagens geradas pelo processamento DEM-ESRGAN P6 se mostraram superiores em praticamente todas as imagens empregadas para o cálculo das métricas da referida avaliação (Figura 102, Figura 103, Figura 104, Figura 105 e Figura 106).




Figura 102 - Valores da métrica PSNR de 10 imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).




Figura 103 - Valores da métrica SSIM de 10 imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9

Fonte: O autor (2022).




Figura 104 - Valores da métrica NIQE de 10 imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).




Figura 105 - Valores da métrica MSE de 10 imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).




Figura 106 - Valores da métrica RMSE de 10 imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9 (valor da métrica em metros).
Fonte: O autor (2022).

Conclui-se parcialmente que, em relação às métricas avaliadas (PSNR, SSIM, NIQE, MSE e RMSE), o processamento P9 apresentou melhor desempenho que P7 e P8.

4.4.4 Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9

A análise da variação de erro e precisão das imagens geradas tem por objetivo mostrar a constância do comportamento dos *pixels* de cada uma das imagens geradas analisadas em relação às imagens de alta resolução de referência (Tabela 25, Tabela 24, Figura 107 e Figura 108).

Tabela 25 - Tabela de cálculo da média do erro das imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9 (em metros)

Imagem	P4 (m)	P5 (m)	P6 (m)
imagem 1	-6,0551	-2,9848	-0,4135

imagem 2	-9,8107	-3,9592	-2,5879
imagem 3	-8,3231	-2,0759	0,9737
Média do erro (m)	-8,0630	-3,0066	-0,6759

Fonte: O autor (2022).

Tabela 24- Tabela de variação dos erros das imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9 (em metros)

Imagem	P7	P8	P9
imagem 1	-6,0551	-2,9848	-0,4135
imagem 2	-9,8107	-3,9592	-2,5879
imagem 3	-8,3231	-2,0759	0,9737
Média do erro	-8,0630	-3,0066	-0,6759

Fonte: O autor (2022).




Figura 107 - Gráfico da variação do erro das imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9 (em metros)

Fonte: O autor (2022).

Tabela 25- Tabela de variação das precisões das imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9 (em metros)

Imagem	10k	50k	100k
imagem 1	16,8790	15,9675	16,0210
imagem 2	14,3726	13,6654	14,0931
imagem 3	10,6047	10,1710	10,6444
Média da precisão	13,9521	13,2680	13,5862

Fonte: O autor (2022).




Figura 108 - Gráfico da variação da precisão das imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9 (onde k equivale a 1.000)
Fonte: O autor (2021).

Em relação à média do erro obtida em função da análise de 3 imagens, o processamento P9 apresentou menor valor que os processamentos P7 e P8. Já em relação à média da precisão, os 3 processamentos apresentaram valores próximos (Tabela 25, Tabela 24, Tabela 25, Figura 107 e Figura 108).

4.4.5 Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9

Quanto à análise de imagens geradas pelo processamento P7, pelo processamento P8 e pelo processamento P9 em relação ao ganho de erro total, verifica-se que o desempenho das imagens do processamento P7 foram superiores ao desempenho dos demais processamentos, exceto em relação à imagem 2 de P7 (Figura 109). Em relação ao ganho de precisão total, as imagens de P8 obtiveram melhor desempenho.




Figura 109 – Gráfico de ganhos de erro e precisão de imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

Já em relação ao ganho de erro percentual e precisão percentual, verifica-se que o desempenho da imagem 2 do processamento de 10.000 teve a maior perda em relação às demais imagens no que tange ao erro (Tabela 27).

Tabela 27- Tabela de ganho de erro percentual e precisão percentual

Estatísticas	Proc 10k	Proc 50k	Proc 100K
Ganho erro percentual – img 1	-213,2278	-54,4011	78,6098
Ganho erro percentual – img 2	-3449,7174	-1332,5007	-836,3664
Ganho erro percentual – img 3	-428,4234	-31,7967	38,1806
Ganho precisão percentual – img 1	-17,4553	-11,1126	-11,4849
Ganho precisão percentual – img 2	-14,5217	-8,8861	-12,2946
Ganho precisão percentual – img 3	-13,808	-9,1536	-14,2342

Fonte: O autor (2022).

Na análise do erro e da precisão da diferença das imagens geradas em relação à imagem HR dos 3 processamentos em questão, verifica-se que o desempenho das imagens do processamento de 100.000 épocas foi superior ao desempenho dos demais processamentos no quesito erro (Figura 110). Em relação à precisão, P8 apresentou melhores resultados.




Figura 110 - Gráfico de erro e precisão das imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

Quanto à análise do ganho da imagem gerada em relação a imagem LR em número de *pixels* dos 3 processamentos em questão, verifica-se que o desempenho das imagens do processamento P9 foram superiores ao desempenho dos demais processamentos nas imagens 1 e 2 (Figura 111).

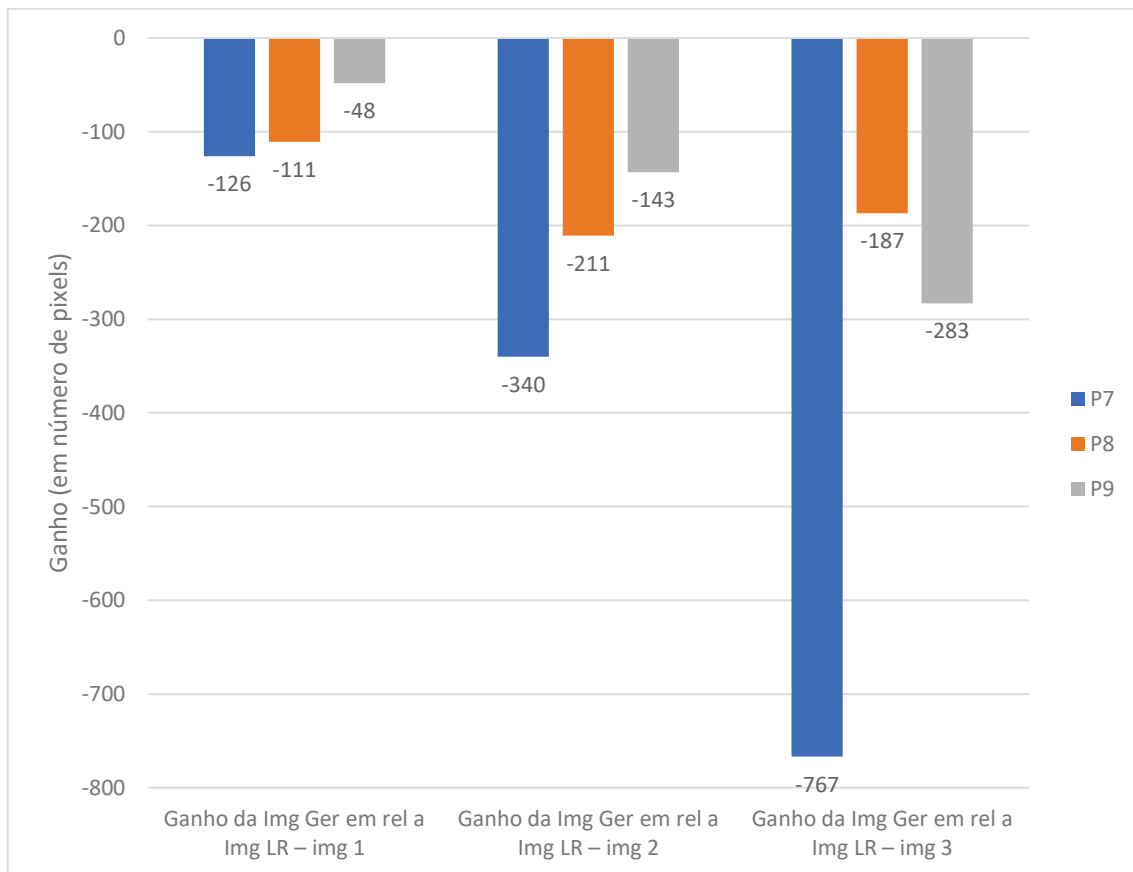


Figura 111 - Gráfico de ganho das imagens geradas em relação à imagem LR em número de *pixels* nos processamentos DEM-ESRGAN P7, P8 e P9
 Fonte: O autor (2021).

Na análise dos *pixels* com erros menores nas imagens geradas em relação à imagem LR dos 3 processamentos em questão, verifica-se que o desempenho da imagem 1 do processamento P9 foi superior ao desempenho dos demais processamentos, enquanto as imagens 2 e 3 apresentaram desempenho similar nos processamentos P8 e P9 (Figura 112).




Figura 112 - Gráfico da análise do número de *pixels* com erros menores nas imagens geradas nos processamentos DEM-ESRGAN P7, P8 e P9

Fonte: O autor (2022).

Como conclusão parcial da referida avaliação, verificou-se que a avaliação estatística realizada dos produtos gerados aponta para o melhor desempenho do processamento P9.

4.4.6 Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN

A presente análise foi efetuada com os resultados dos 3 (três) processamentos realizados, resultando na visualização das imagens geradas pelo algoritmo DEM-ESRGAN, das imagens de baixa resolução e das imagens de alta resolução. Nessa visualização, colocou-se lado a lado, para comparação, as três imagens equivalentes, estando a de menor resolução à esquerda, a gerada ao centro e a de maior resolução à direita.

Dessa forma, a visualização permite a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução. Pôde-se observar que todas as imagens geradas analisadas apresentaram grande semelhança com as respectivas imagens de alta resolução (Figura 113,

Figura 114, Figura 115, Figura 116, Figura 117, Figura 118, Figura 119, Figura 120 e Figura 121).




Figura 113 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P7.
Fonte: O autor (2022).




Figura 114 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P7.
Fonte: O autor (2022).




Figura 115 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P7.
Fonte: O autor (2022).




Figura 116 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P8.
Fonte: O autor (2022).




Figura 117 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P8.
Fonte: O autor (2022).




Figura 118 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P8.
Fonte: O autor (2022).




Figura 119 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P9.
Fonte: O autor (2022).




Figura 120 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P9.
Fonte: O autor (2022).




Figura 121 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P9.
Fonte: O autor (2022).

Como conclusão parcial, verificou-se que as imagens do processamento P9 apresentou maior proximidade com as imagens de alta resolução do que as imagens do demais processamentos do experimento.

4.4.7 Análise de curvas de nível geradas automaticamente

As seguintes figuras (Figura 122 a Figura 125) mostram a conformação das curvas de nível geradas automaticamente sem suavização, tanto para as imagens de alta resolução quanto para as imagens geradas pelos processamentos DEM-ESRGAN.

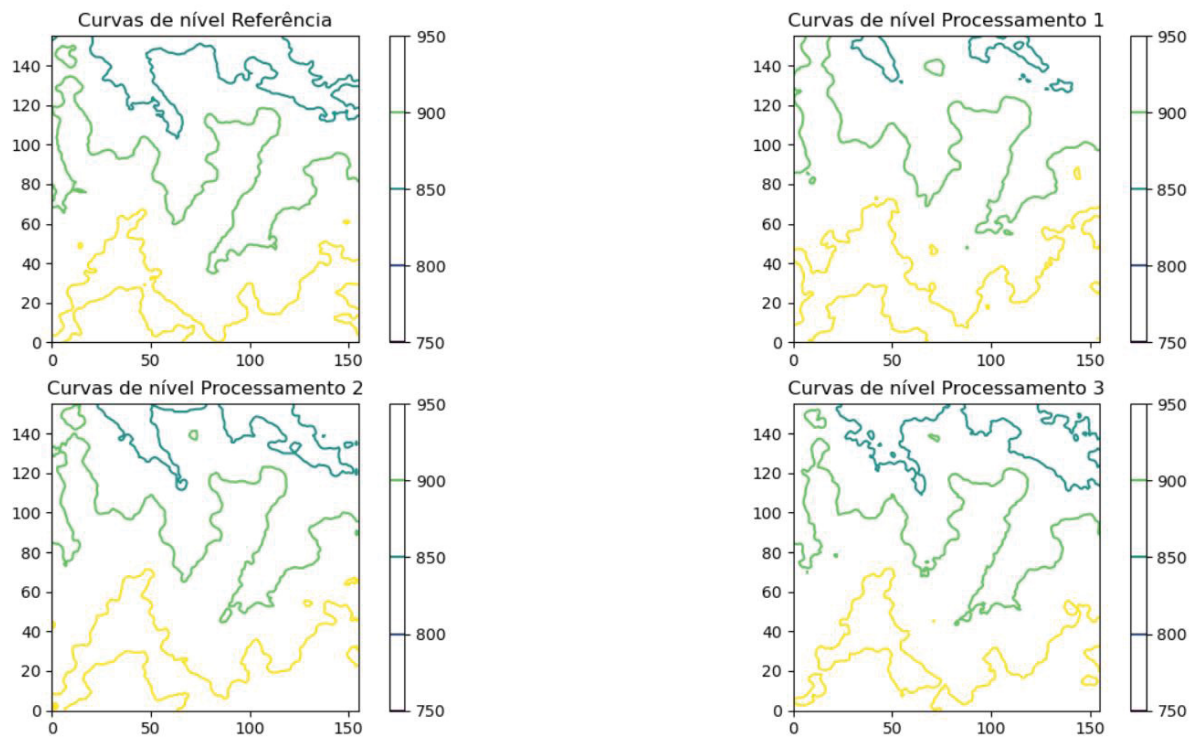


Figura 122 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 1 dos processamentos P7, P8 e P9
Fonte: O autor (2022).

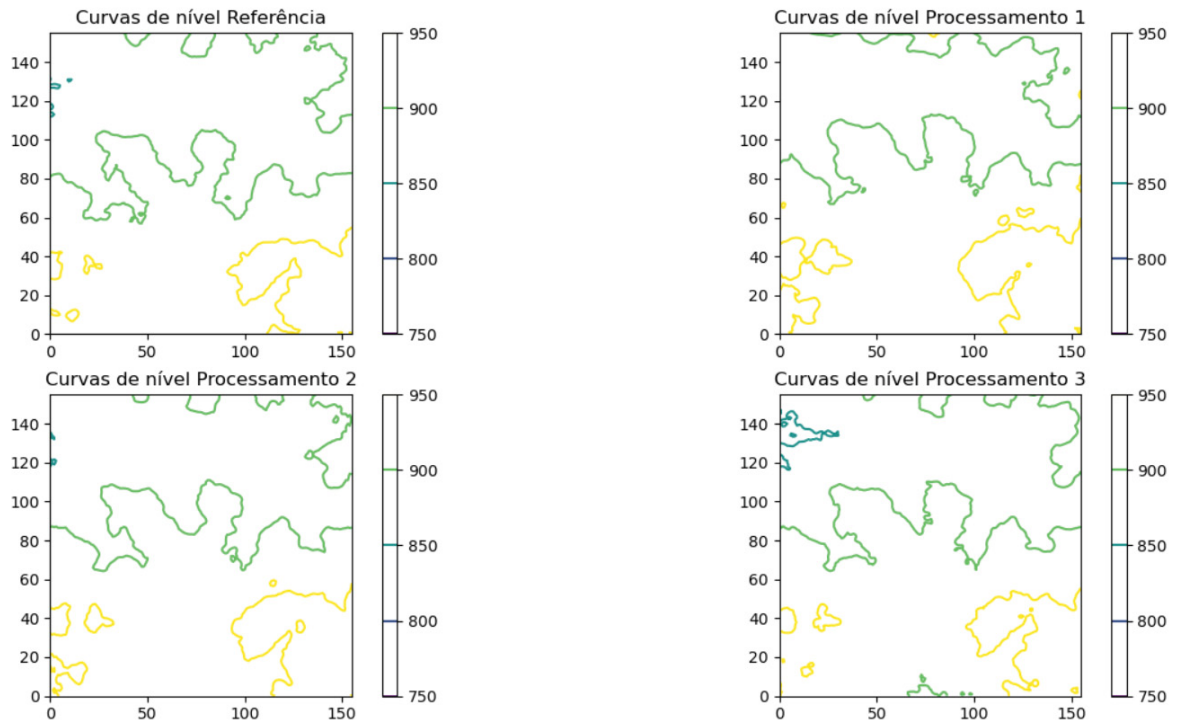


Figura 123 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 2 dos processamentos P7, P8 e P9
Fonte: O autor (2022).

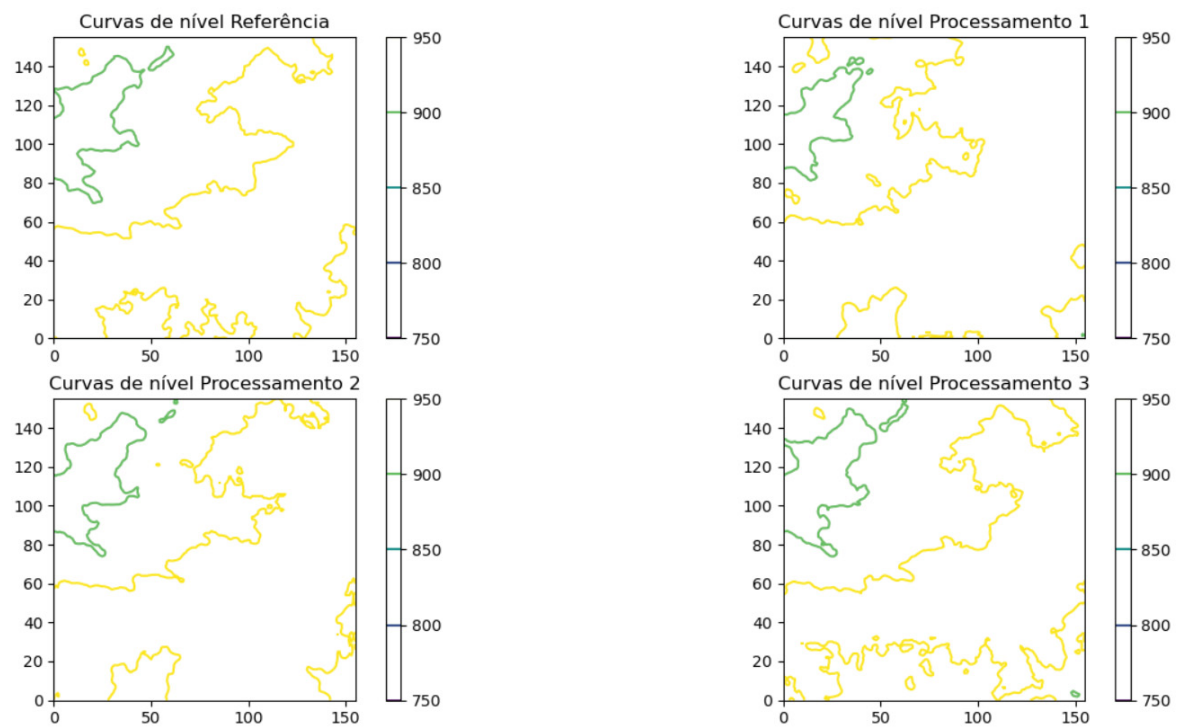


Figura 124 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 3 dos processamentos P7, P8 e P9
Fonte: O autor (2022).

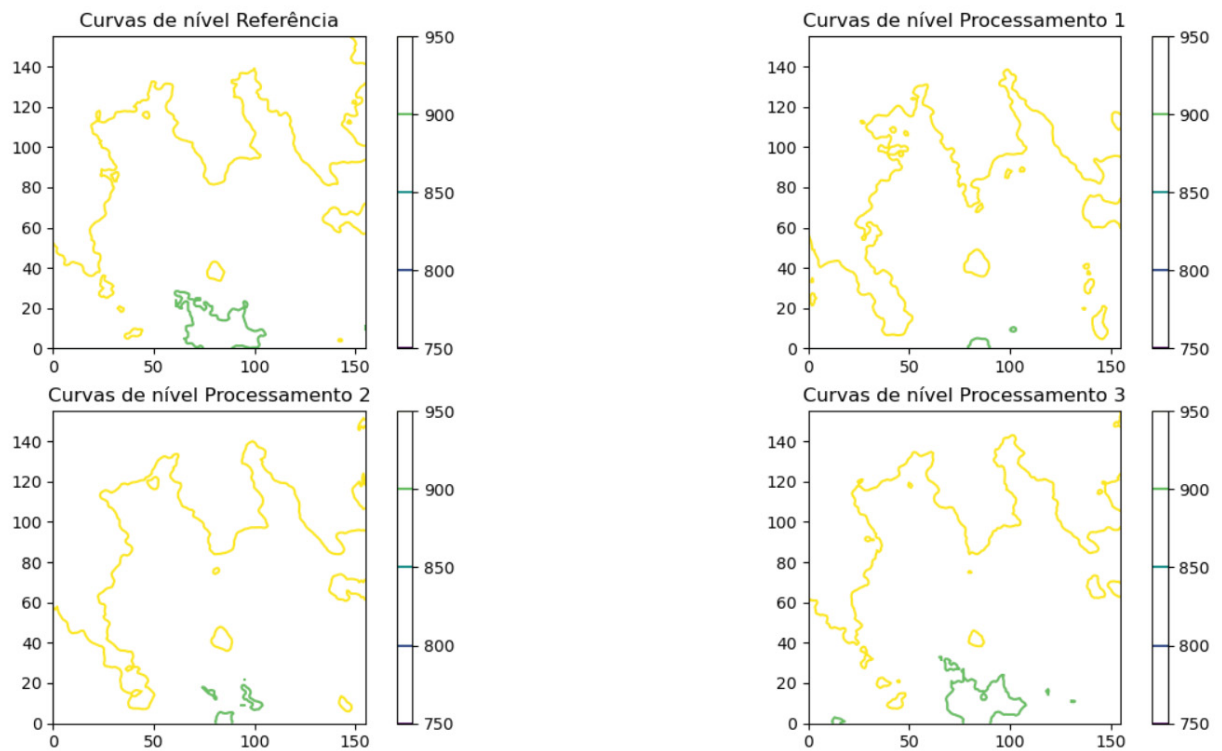


Figura 125 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 4 dos processamentos P7, P8 e P9
Fonte: O autor (2022).

A partir desta análise, verificou-se que o processamento P9 apresentou melhor desempenho na comparação com as imagens de alta resolução, seguido pelo processamento P8.

4.4.8 Análise do Padrão de Exatidão Cartográfica Altimétrica

A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto. Para a realização da análise do Padrão de Exatidão Cartográfica Altimétrico foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerada). Calculou-se em seguida o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado (Tabela 26 e Tabela 27).

Tabela 26 - Tabela dos valores calculados do Erro Médio e do Erro Padrão das imagens geradas nos respectivos processamentos

Processamento	Imagem	Resolução Inicial	Resolução final	EM	EP
P7	1	90 metros	30 metros	-1,326	8,947
	2			3,309	10,853
	3			-1,819	8,715
	4			1,373	10,806
P8	1	90 metros	30 metros	3,596	8,869
	2			6,694	9,982
	3			4,339	8,298
	4			4,210	9,229
P9	1	90 metros	30 metros	9,762	9,212
	2			13,029	10,326
	3			10,580	8,841
	4			10,624	9,483

Fonte: O autor (2022).

Tabela 27 - Tabela do PEC altimétrico atingido pelas imagens geradas nos respectivos processamentos para as escalas do mapeamento sistemático

Processamento	Imagem	1:250000	1:100000	1:50000	1:25000
P7	1	Classe A	Classe D	Classe D	Classe D
	2	Classe A	Classe D	Classe D	Classe D
	3	Classe A	Classe D	Classe D	Classe D
	4	Classe A	Classe D	Classe D	Classe D
P8	1	Classe A	Classe D	Classe D	Classe D
	2	Classe A	Classe D	Classe D	Classe D
	3	Classe A	Classe D	Classe D	Classe D
	4	Classe A	Classe D	Classe D	Classe D
P9	1	Classe A	Classe D	Classe D	Classe D
	2	Classe A	Classe D	Classe D	Classe D
	3	Classe A	Classe D	Classe D	Classe D
	4	Classe A	Classe D	Classe D	Classe D

Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que o processamento P7 alcançou os menores erros médio e erros padrão dentre as imagens avaliadas. Comparando-se ainda o P8 e P9, verificou-se melhores valores calculados no segundo.

4.4.9 Análise do Padrão de Exatidão Cartográfico Planimétrico

Para a realização da avaliação do Padrão de Exatidão Cartográfico Planimétrico foram selecionados 10 pontos homólogos em cada par de imagem utilizadas (*ground truth* e gerado). Os pontos foram distribuídos privilegiando as

regiões de maior índice de concentração de informações cartografadas, utilizando método não tendencioso de escolha dos mesmos, como o método de sorteio manual simples sem reposição.

Após o término da etapa de levantamento dos pontos de controle, realizou-se o processamento, o cálculo das coordenadas e identificação dos valores cartográficos para os pontos. Através da comparação dos dois grupos de coordenadas, realizou-se o cálculo dos resíduos.

Para examinar se os resultados estão dentro da expectativa, em relação à precisão, utilizou-se o teste *t-student*, verificando se a variância das diferenças das coordenadas levantadas, quando comparadas com as de referência possuem diferenças significativas ou não, com a variância da expectativa definida antecipadamente (Figura 126 a Figura 128, Tabela 28 a Tabela 33).




Figura 126 - Levantamento dos 10 pontos homologos selecionados na imagem 1 do processamento P9 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada).

Fonte: O autor (2022).

Tabela 28 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 1 do processamento P9

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	529036,37	6771246,24	529405,72	6771521,18	-369,35	-274,94	460,45	SIM	NÃO
2	528904,28	6771234,03	529284,66	6771515,22	-380,37	-281,19	473,02	SIM	NÃO
3	529793,01	6772335,30	529891,50	6772121,86	-98,49	213,44	235,07	SIM	NÃO
4	528614,40	6774125,31	528828,71	6773993,10	-214,31	132,21	251,81	SIM	NÃO
5	526878,39	6775449,38	526804,39	6775578,09	74,01	-128,71	148,47	SIM	NÃO
6	526199,56	6773453,92	526224,03	6773325,33	-24,47	128,59	130,90	SIM	NÃO
7	527660,64	6772306,18	527668,25	6772039,68	-7,61	266,50	266,61	SIM	NÃO
8	527691,65	6772613,34	527762,97	6772525,38	-71,32	87,96	113,24	SIM	NÃO
9	529215,21	6773408,99	529297,52	6773314,73	-82,31	94,26	125,14	SIM	NÃO
10	528171,22	6774624,88	528231,36	6774461,71	-60,14	163,17	173,90	SIM	NÃO

Fonte: O autor (2022).

Tabela 29 - Tabela do PEC planimétrico atingido pela imagem gerada 1 do processamento P9 para as escalas de 1:250000 a 1:1000

Escala	Classe
1:250000	Rejeitado
1:100000	Rejeitado
1:50000	Rejeitado
1:25000	Rejeitado
1:10000	Rejeitado
1:5000	Rejeitado
1:2000	Rejeitado
1:1000	Rejeitado

Fonte: O autor (2022).




Figura 127 - Levantamento dos 10 pontos homologos selecionados na imagem 2 do processamento P9 utilizando as redes de drenagens das imagens (onde as linhas verdes são

referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada).

Fonte: O autor (2022).

Tabela 30 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 2 do processamento P9

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E 90%	Tendência N 90%
1	530342,07	6772732,80	530379,16	6772712,32	-37,09	20,48	42,37	NÃO	NÃO
2	530422,19	6772856,42	530460,67	6772840,64	-38,48	15,78	41,59	NÃO	NÃO
3	530639,33	6773285,35	530679,03	6773208,43	-39,69	76,92	86,55	NÃO	NÃO
4	530943,69	6773397,39	530833,88	6773493,31	109,81	-95,92	145,80	NÃO	NÃO
5	532163,46	6775519,61	532190,30	6775519,92	-26,83	-0,32	26,84	NÃO	NÃO
6	532297,36	6775425,57	532324,19	6775424,32	-26,83	1,25	26,86	NÃO	NÃO
7	533220,53	6775604,76	533291,72	6775480,72	-71,20	124,04	143,02	NÃO	NÃO
8	531268,23	6775732,53	531273,23	6775550,68	-5,01	181,85	181,92	NÃO	NÃO
9	531055,66	6775493,28	531113,27	6775424,15	-57,61	69,13	89,98	NÃO	NÃO
10	530899,63	6775296,19	531004,23	6775302,18	-	-5,99	104,77	NÃO	NÃO

Fonte: O autor (2022).

Tabela 31 - Tabela do PEC planimétrico atingido pela imagem gerada 2 do processamento P9 para as escalas de 1:250000 a 1:1000.

Escala	Classe
1:250000	Classe C
1:100000	Rejeitado
1:50000	Rejeitado
1:25000	Rejeitado
1:10000	Rejeitado
1:5000	Rejeitado
1:2000	Rejeitado
1:1000	Rejeitado

Fonte: O autor (2022).




Figura 128 - Levantamento dos 10 pontos homólogos selecionados na imagem 3 do processamento P9 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada)

Fonte: O autor (2022).

Tabela 32 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 3 do processamento P9

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	535915,24	6773040,34	535970,09	6772982,17	-54,85	58,17	79,95	SIM	SIM
2	536824,53	6772582,86	536878,36	6772639,12	-53,83	-56,26	77,87	SIM	SIM
3	537909,09	6772732,93	537912,93	6772645,14	-3,84	87,80	87,88	SIM	SIM
4	535453,74	6772619,33	535504,36	6772528,25	-50,62	91,08	104,20	SIM	SIM
5	535207,77	6773604,51	535237,75	6773513,50	-29,99	91,01	95,82	SIM	SIM
6	535633,32	6773739,57	535631,76	6773678,44	1,57	61,13	61,15	SIM	SIM
7	535724,90	6774866,35	535706,99	6774861,70	17,90	4,65	18,50	SIM	SIM
8	535823,59	6774745,34	535809,80	6774735,98	13,79	9,36	16,67	SIM	SIM
9	537190,89	6775038,81	537228,03	6775035,55	-37,14	3,26	37,28	SIM	SIM
10	536757,46	6774935,18	536782,23	6774935,89	-24,77	-0,70	24,78	SIM	SIM

Fonte: O autor (2022).

Tabela 33 - Tabela do PEC planimétrico atingido pela imagem gerada 3 do processamento P9 para as escalas de 1:250000 a 1:1000

Escala	Classe
1:250000	Classe B
1:100000	Classe D
1:50000	Rejeitado
1:25000	Rejeitado
1:10000	Rejeitado
1:5000	Rejeitado
1:2000	Rejeitado
1:1000	Rejeitado

Fonte: O autor (2022).

A imagem 1 do processamento P9 apresentou como resultado PEC rejeitado em todas as classes. Já a imagem 2 do processamento P9 apresentou como resultado PEC Classe C na escala 1:250.000 e PEC rejeitado nas demais classes, enquanto a imagem 3 apresentou como resultado PEC Classe B na escala 1:250.000, PEC Classe D na escala 1:100.000 e PEC rejeitado nas demais classes.

4.4.10 Análise da diferença entre superfícies

A subtração entre duas superfícies altimétricas permite avaliar as diferenças existentes entre ambas (Figura 129).

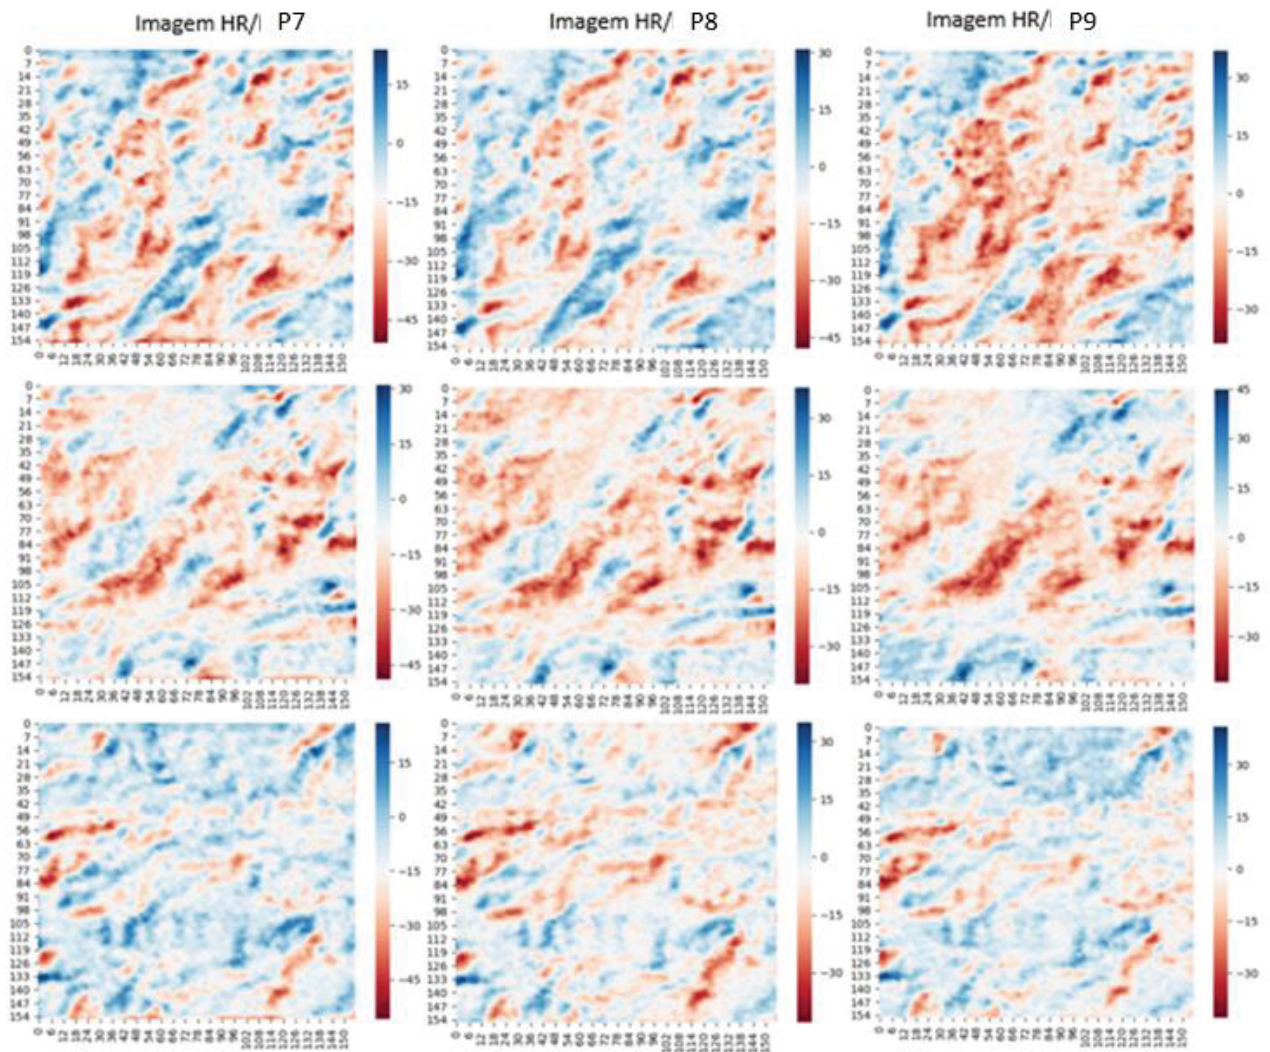


Figura 129 - Diferença entre superfícies das imagens de alta resolução e das imagens geradas pelos processamentos P7, P8 e P9 (valores em metros).

Fonte: O autor (2022).

Como conclusão parcial da avaliação, verificou-se que as imagens do processamento P9 apresentaram as menores diferenças entre superfícies, em comparação com as imagens dos processamentos P7 e P8.

4.4.11 Avaliação visual das cumeeiras

As Figura 130 a Figura 134 apresentam os resultados das linhas estruturais (cumeeiras) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Para tal, realizou-se a construção das matrizes simétricas dos valores altimétricos dos MDEs antes da realização dos processamentos.

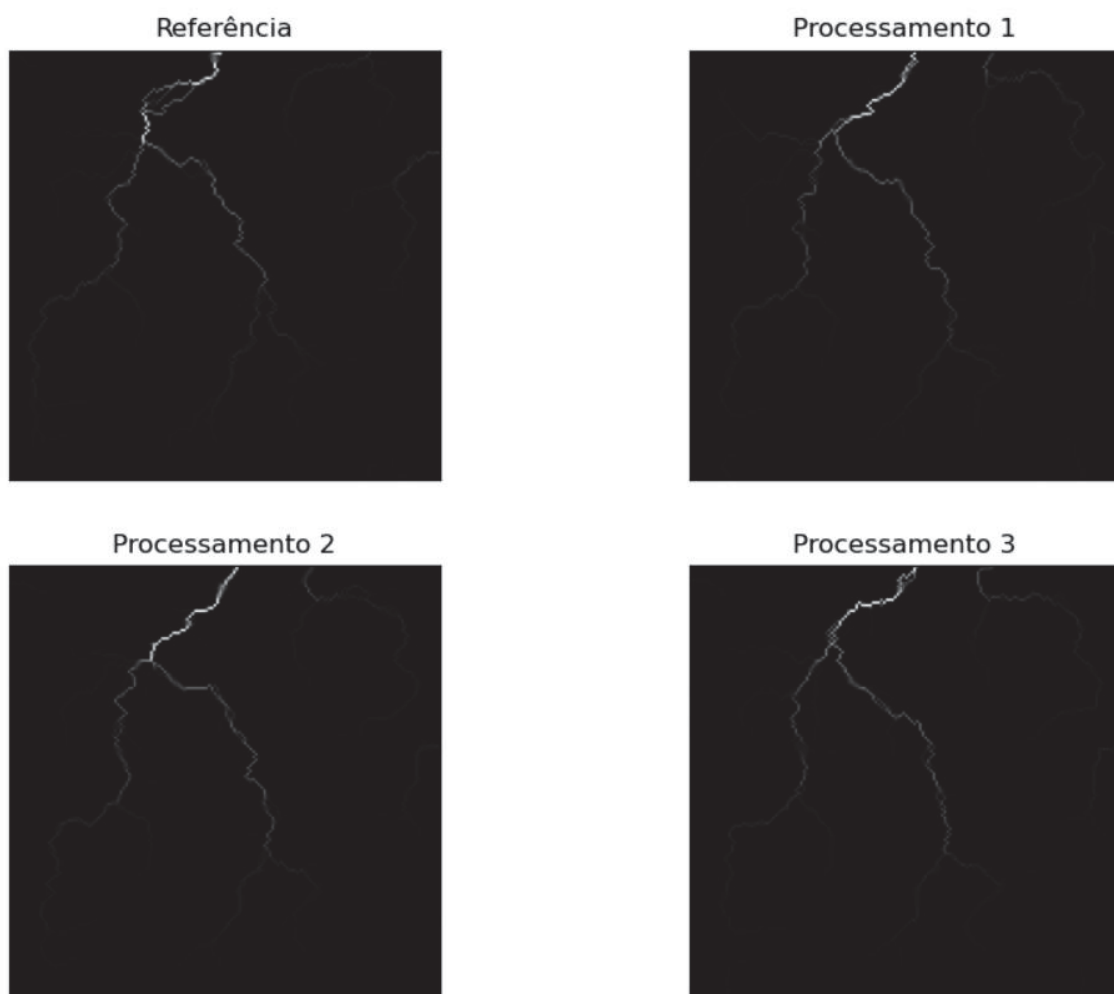


Figura 130 - Linhas de cumeeiras das imagens da imagem 1 dos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

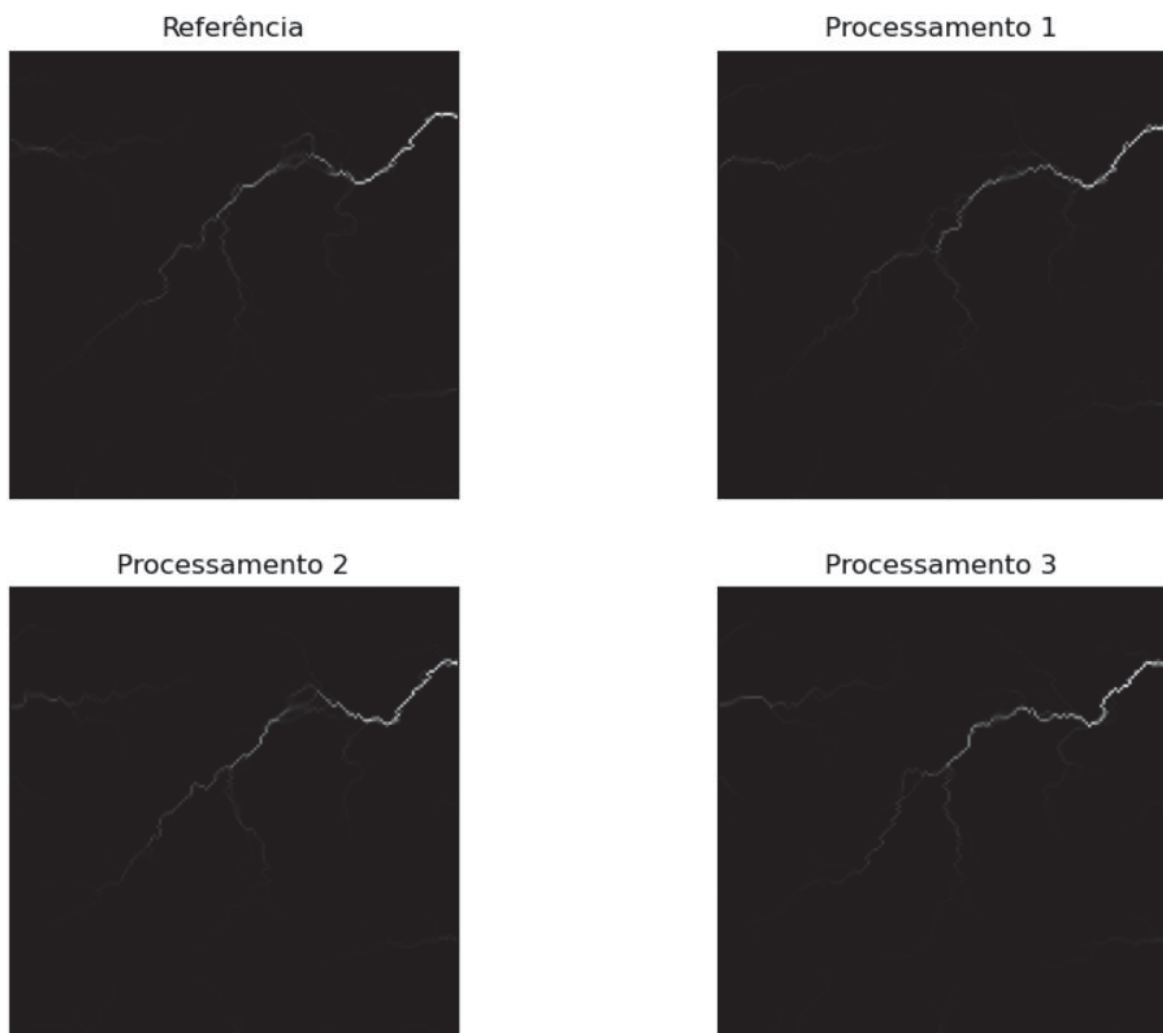


Figura 131 - Linhas de cumeeiras das imagens da imagem 2 dos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

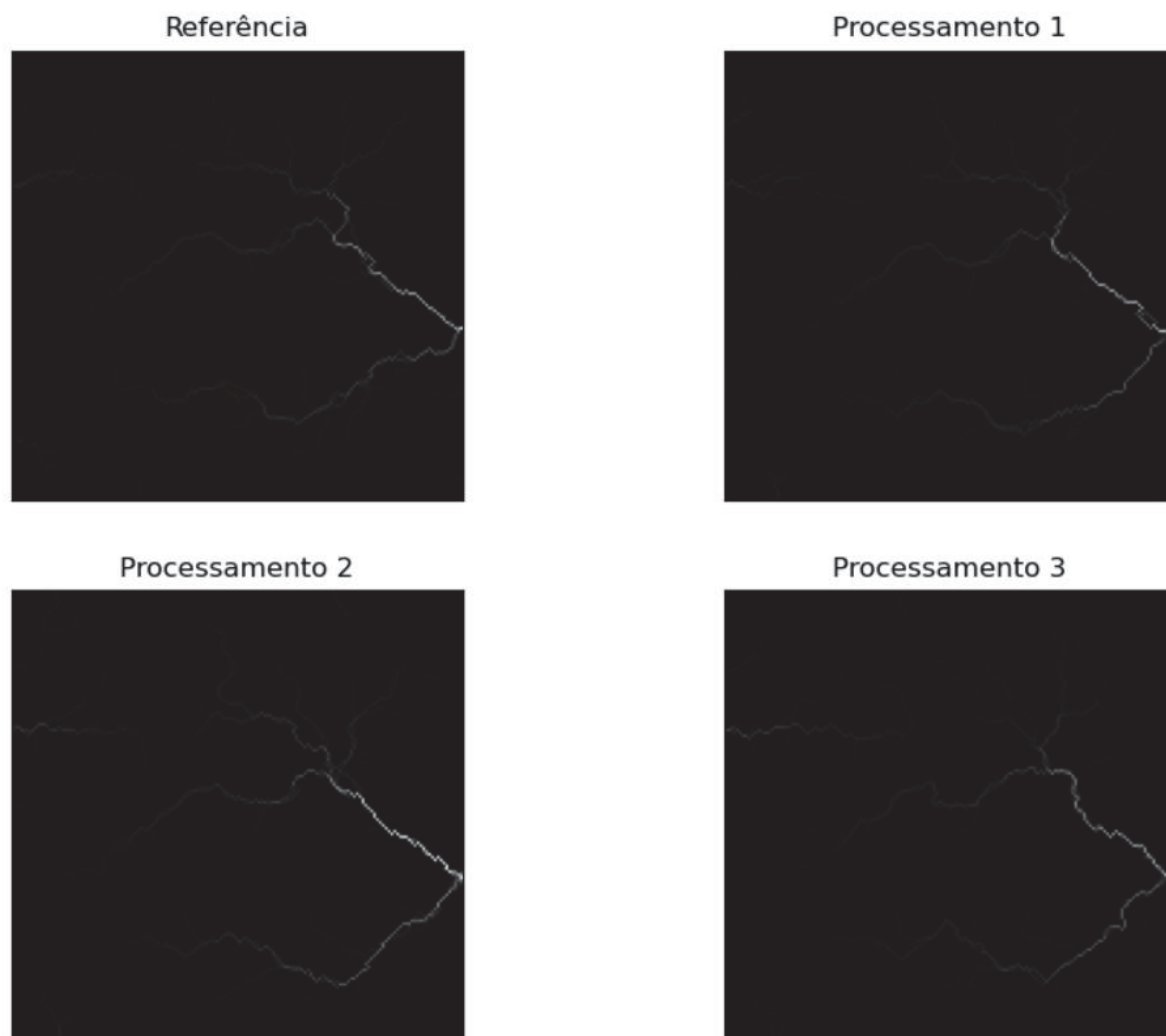


Figura 132 - Linhas de cumeeiras das imagens da imagem 3 dos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

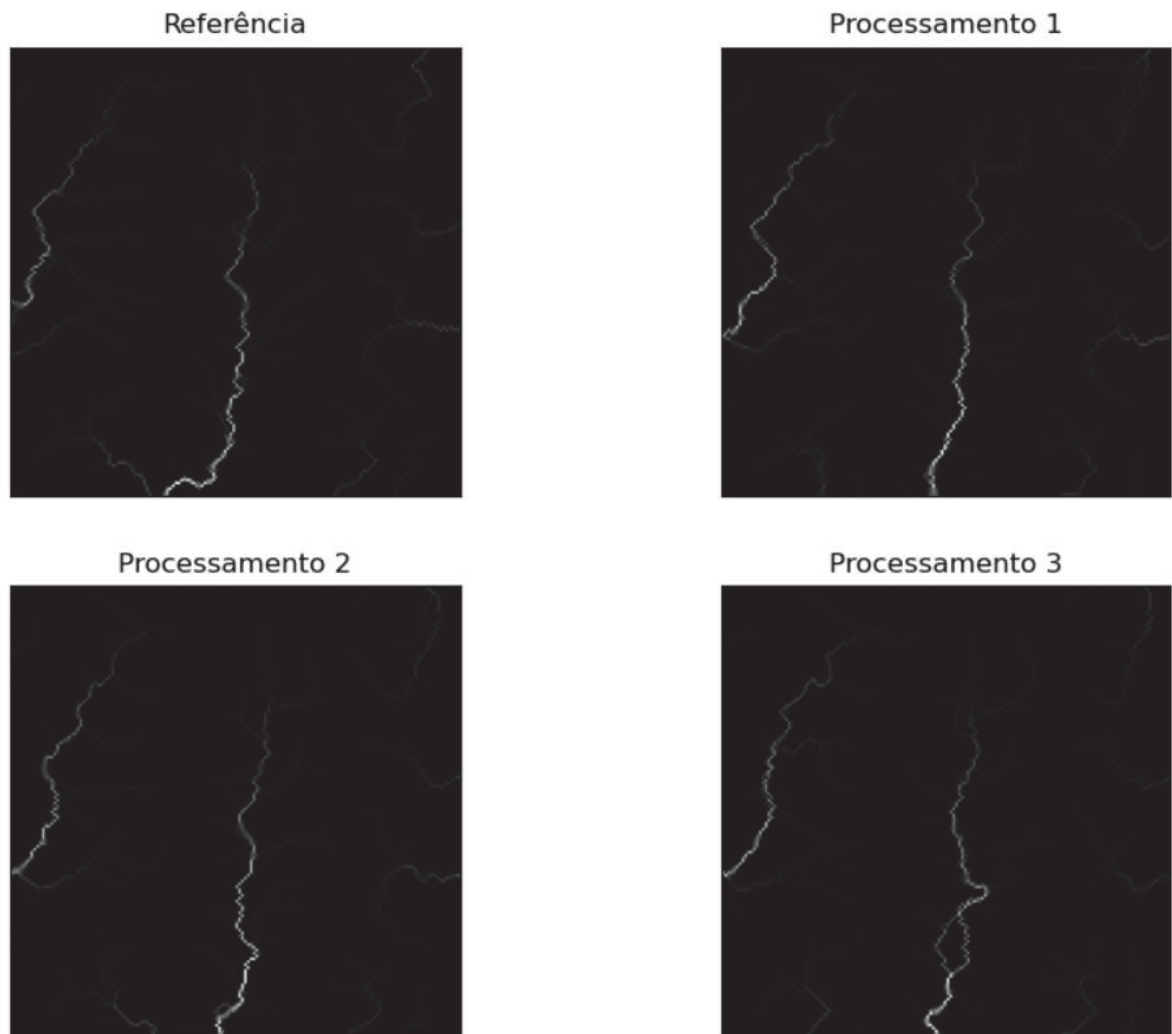


Figura 133 - Linhas de cumeeiras das imagens da imagem 4 dos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

Pode-se observar nos resultados apresentados que o P7 pode obter a melhor taxa de correspondência das características das cumeeiras. Então, o P7 supera P8 e P9 na preservação das características das cumeeiras.

4.4.12 Avaliação visual das redes de drenagens

A Figura 134 apresenta os resultados das linhas estruturais (canais de drenagem) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise.




Figura 134 - MDEs contendo o resultado dos canais de drenagens das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

Em primeiro lugar, pode-se observar que o P9 pode obter a melhor taxa de correspondência das características dos canais de drenagem. Então, o P9 supera P7 e P8 na preservação das características dos canais de drenagem.

4.4.13 Avaliação dos pontos críticos

Na presente seção, foi realizada uma investigação quanto à eficácia dos métodos utilizados na recuperação dos pontos críticos. Pelas avaliações anteriores, pode-se observar que o algoritmo DEM-ESRGAN (MDTESRGAN) gera melhores resultados em relação à geração de SR que os outros métodos. Dessa maneira, nesta avaliação, apenas os resultados do *ground truth* e as interpolações dos processamentos P7, P8 e P9 são focados.

A Figura 135 apresenta um conjunto de imagens contendo a análise visual dos *pixels* contendo altitudes máximas e mínimas das imagens de alta resolução e das imagens geradas pelos processamentos P7, P8 e P9, onde os *pixels* de altitude máxima são representados pela cor vermelha e os *pixels* de altitude mínima são representados pela cor azul. Tais *pixels* representam pontos críticos para os MDEs gerados pelo método utilizado na presente pesquisa.

Quanto à preservação de pontos críticos (Figura 135), nenhuma regra óbvia foi encontrada nos três resultados de exemplo. Nesse sentido, os resultados estatísticos podem ser a melhor solução para avaliar a preservação dos pontos críticos, e as principais conclusões podem ser obtidas a partir de uma análise das métricas obtidas das respectivas imagens.




Figura 135 - MDEs de alta resolução e MDEs gerados pelo conjunto de validação do *dataset 3* contendo suas respectivas altitudes máximas e mínimas das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9, onde os *pixels* de altitude mínima são representados pela cor azul e os *pixels* de altitude máxima são representados pela cor vermelha

Fonte: O autor (2022).

Portanto, para resumir, neste quesito, o processamento P9 supera os demais processamentos na preservação da maioria das características do terreno na SR do MDE.

4.4.14 Avaliação da declividade dos MDEs

A Figura 136 apresenta os resultados da declividade do terreno dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN P7, P8 e P9.




Figura 136 - MDEs contendo o resultado da declividade do terreno das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

Considerando a avaliação da declividade do terreno, a percepção intuitiva é de que os resultados de P9 são muito mais suaves que os de P7 e P8, e algumas texturas desaparecem nos resultados da interpolação de P8, mas ficam retidas em P7 e P9.

4.4.15 Avaliação do aspecto dos MDEs

A Figura 137 apresentam os resultados do aspecto dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN P7, P8 e P9.

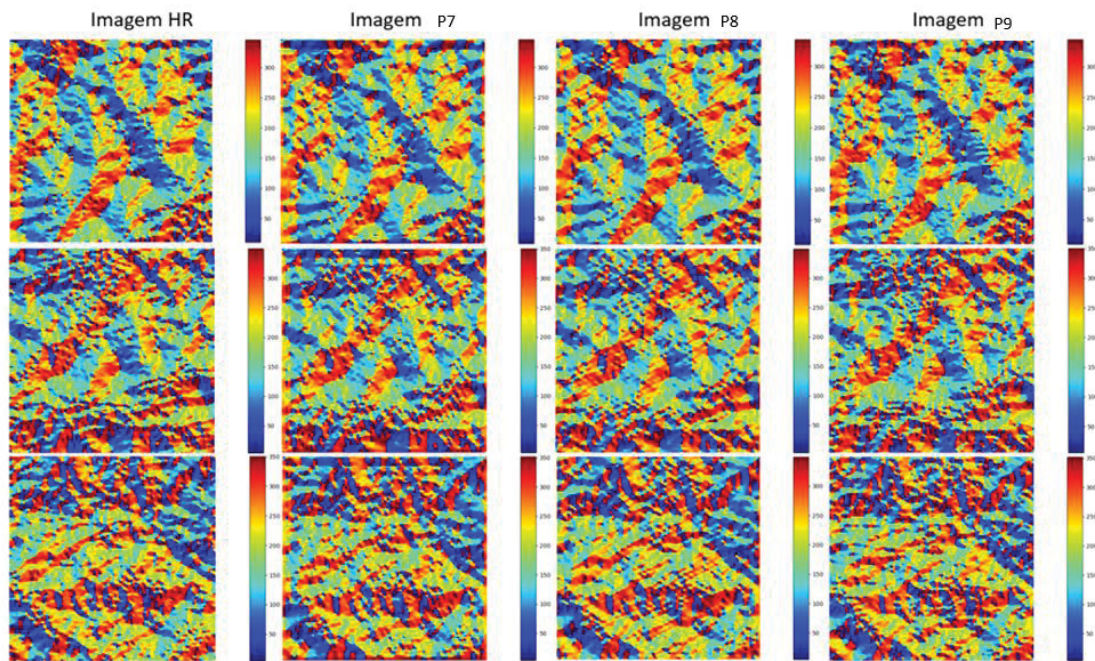


Figura 137 - MDEs contendo o resultado do aspecto das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P7, P8 e P9
Fonte: O autor (2022).

Quanto ao aspecto, intuitivamente, verifica-se que as distorções nos resultados do P7 são maiores em comparação com os resultados do P8 e do P9. No entanto, os resultados de declividade do terreno do P9 apresentam um melhor equilíbrio entre precisão global e características locais, o que pode ser a razão pela qual o P9 supera os outros métodos. Então, considerando a avaliação de aspecto, os três processamentos geram resultados comparáveis, e tal conclusão é consistente com as avaliações estatísticas.

4.5 EXPERIMENTO 4 - MODELO DEM-ESRGAN APLICADO AO DATASET 4

O processamento P10, assim como o processamento P11 e o processamento P12 utilizaram amostras de imagens do MDE SRTM de 30

metros para os arquivos de baixa resolução e amostras de imagens do MDE Alos Palsar de 12,5 metros para os arquivos de alta resolução.

4.5.1 Análise do *dataset* 4

O *dataset* 4, montado para a realização do experimento em questão, foi feito a partir de 2 MDEs (SRTM e Alos Palsar), o de alta resolução com 12,5 metros e o de baixa resolução com 30 metros. Suas características podem ser verificadas de acordo com o apresentado na Tabela 34.

Tabela 34 – Tabela das características dos MDEs de alta e baixa resolução utilizados no *dataset* 4

Características	HR	LR
Resolução espacial	12,5 metros	30 metros
Nome do arquivo	AP_23791_FBD_F6610_RT1.dem.tif	S29W051.tif
Projeção cartográfica	EPSG 32722	EPSG 4326
<i>Datum</i>	WGS84	WGS84
Largura	6589 <i>pixels</i>	3601 <i>pixels</i>
Altura	6056 <i>pixels</i>	3601 <i>pixels</i>
Tipo de dado	Int16	Int16
Número de bandas	1	1
Tipo de metadados do driver GDAL	GeoTIFF	GeoTIFF

Fonte: O autor (2022).

A Figura 138 e a Figura 139 apresentam respectivamente uma imagem do MDE Alos Palsar de alta resolução utilizado para a extração dos pares de amostras (no que tange as amostras de alta resolução) de treinamento e validação do modelo com resolução espacial de 12,5 metros visualizada no QGIS e uma imagem do MDE SRTM de baixa resolução utilizado para a extração dos pares de amostras (no que tange as amostras de baixa resolução) de treinamento e validação do modelo, com resolução espacial de 30 metros, visualizada no QGIS.

As figuras de fatiamento de densidades (na cartografia denominados de mapas coropléticos) foram construídas com o objetivo de permitir a percepção do relevo dos MDEs selecionados para o *dataset*.




Figura 138 - Imagem do MDE Alos Palsar de alta resolução utilizado para a extração dos pares de amostras (no que tange as amostras de alta resolução), com resolução espacial de 12,5 metros.

Fonte: O autor (2022).



Figura 139 - Imagem do MDE SRTM de baixa resolução utilizado para a extração dos pares de amostras (no que tange as amostras de baixa resolução), com resolução espacial de 30 metros.

Fonte: O autor (2022).

Foi necessário fazer um recorte nos MDEs para fazer a comparação estatística das duas imagens, de modo a representarem a mesma porção do terreno.

A análise estatística das imagens utilizadas para a coleta das amostras do *dataset* 4 aponta que a média aritmética da imagem de baixa resolução é de 1000,9449 metros, enquanto a média aritmética da imagem de alta resolução é de 1006,6358 metros. Já quanto ao desvio padrão, a imagem de baixa resolução apresentou um valor de 110,0009 metros, e a imagem de alta resolução apresentou um valor de 109,6526 metros (Tabela 35).

Tabela 35 - Análise estatística das imagens utilizadas

Estatísticas	Imagem LR	Imagem HR
Número de <i>pixels</i>	6244672	33175007
Número de linhas	2104	5149
Número de colunas	2968	6443
Mínimo	586	595
Máximo	1386	1389
Mediana	996	1002
Média aritmética	1000,9449	1006,6358
Moda	940	946
Desvio padrão	110,0009	109,6526
Coefficiente de variação	0,1099	0,1089
Amplitude	144	143

Fonte: O autor (2022).

O histograma das imagens utilizadas para a coleta das amostras do *dataset* 4 permite ilustrar como uma determinada amostra de dados está distribuída (Figura 140 e Figura 141). As regiões escolhidas para a seleção das amostras foram prioritariamente de regiões mais altas, com altitudes variando entre 750 e 1030 metros. Os picos (valores mais comuns), em ambos os MDEs encontram-se próximo ao valor de altitude 950. Não se verificou a ocorrência de outliers. Não houve um bom ajuste em relação à curva de Gauss.




Figura 140 - Histograma mostrando a distribuição dos *pixels* do MDE (imagem) de baixa resolução em função de valores altimétricos
Fonte: O autor (2022).




Figura 141 - Histograma mostrando a distribuição dos *pixels* do MDE (imagem) de alta resolução modelo em função de valores altimétricos
Fonte: O autor (2022).

4.5.2 Análise dos processamentos DEM-ESRGAN P10, P11 e P12

Ao término dos processamentos DEM-ESRGAN, foram calculados os valores de suas referidas métricas PSNR. Em relação a este quesito, o primeiro processamento (P10) apresentou o PSNR de 48,779, o segundo processamento (P11) apresentou o PSNR de 49,172, enquanto o terceiro (P12) apresentou um PSNR de 51,511.

Durante os processamentos, verificou-se que ocorre uma variação oscilatória na progressão dos valores do PSNR, não ocorrendo dessa maneira um crescimento contínuo com o decorrer do tempo (Figura 142).




Figura 142 - Variação dos valores da métrica do PSNR dos processamentos DEM-ESRGAN executados (P10, P11 e P12) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)
Fonte: O autor (2022).

Ao se realizar a comparação do *loss l_g_perceptron*, percebe-se que todos partem de um pico inicial e a partir daí passam a demonstrar uma tendência de aproximação do zero. Percebe-se que os processamentos com mais épocas se aproximaram mais do zero do que os com menos épocas (Figura 143).



Figura 143 - Variação dos valores apresentados pelas funções de perda l_g_percep de cada um dos processamentos DEM-ESRGAN executados (P10, P11 e P12) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)

Fonte: O autor (2022).

Conclui-se, parcialmente, que o 3º processamento do referido experimento apresentou melhor métrica final dentre as apresentadas durante o processamento em si. Já em relação à variação da função de perda L_{percep} , o 3º processamento também apresentou menor erro final.

4.5.3 Avaliação das métricas dos processamentos DEM-ESRGAN P10, P11 e P12

Quanto à análise dos PSNR dos processamentos, verificou-se que o processamento P12 apresentou o maior valor de PSNR final dentre os processamentos realizados (Figura 144).




Figura 144 - Gráfico de análise dos PSNR dos processamentos P7, P8 e P9
 Fonte: O autor (2022).

As imagens geradas pelo processamento P12 se mostraram superiores em praticamente todas as métricas utilizadas para a avaliação, com exceção feita ao SSIM e ao NIQE (Figura 145, Figura 146, Figura 147, Figura 148 e Figura 149).




Figura 145 - Valores da métrica PSNR de 10 imagens geradas nos processamentos P10, P11 e P12
 Fonte: O autor (2022).




Figura 146 - Valores da métrica SSIM de 10 imagens geradas nos processamentos P10, P11 e P12
 Fonte: O autor (2022).




Figura 147 - Valores da métrica NIQE de 10 imagens geradas nos processamentos P10, P11 e P12

Fonte: O autor (2022).




Figura 148 - Valores da métrica MSE de 10 imagens geradas nos processamentos P10, P11 e P12

Fonte: O autor (2022).




Figura 149 - Valores da métrica RMSE de 10 imagens geradas nos processamentos P10, P11 e P12
Fonte: O autor (2022).

Conclui-se parcialmente que, em relação às métricas avaliadas (PSNR, SSIM, NIQE, MSE e RMSE), o processamento P12 apresentou melhor desempenho que P10 e P11.

4.5.4 Análise da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12

A análise da variação de erro e precisão das imagens geradas tem por objetivo mostrar a constância do comportamento dos *pixels* de cada uma das imagens geradas analisadas em relação às imagens de alta resolução de referência.




Figura 150 - Gráfico da variação do erro das imagens geradas nos processamentos DEM-ESRGAN P10, P11 e P12 (onde k equivale a 1.000)
Fonte: O autor (2022).




Figura 151 - Gráfico da variação da precisão das imagens geradas nos processamentos DEM-ESRGAN P10, P11 e P12 (onde k equivale a 1.000)
Fonte: O autor (2022).

Em relação à média do erro obtida em função da análise de 3 imagens, o processamento P10 apresentou resultados menores que os processamentos P11 e P12. Já em relação à média da precisão, o P12 obteve melhor desempenho (Figura 150 e Figura 151).

4.5.5 Avaliação estatística de imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12

Na análise do erro e da precisão da diferença das imagens geradas em relação à imagem HR dos 3 processamentos em questão, verifica-se que o desempenho das imagens do processamento de 100.000 (P12) foram superiores ao desempenho dos demais processamentos, no que tange ao erro, em 2 das 3 imagens analisadas. Em relação à precisão, P11 e P12 apresentaram desempenhos bem similares (Figura 152).




Figura 152 - Gráfico de erros e precisão das imagens geradas nos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

Quanto à análise do ganho da imagem gerada em relação a imagem LR em número de *pixels* dos 3 processamentos em questão, verifica-se que o desempenho das imagens do processamento de 100.000 foram superiores ao desempenho dos demais processamentos nas imagens 1 e 2 (Figura 153).

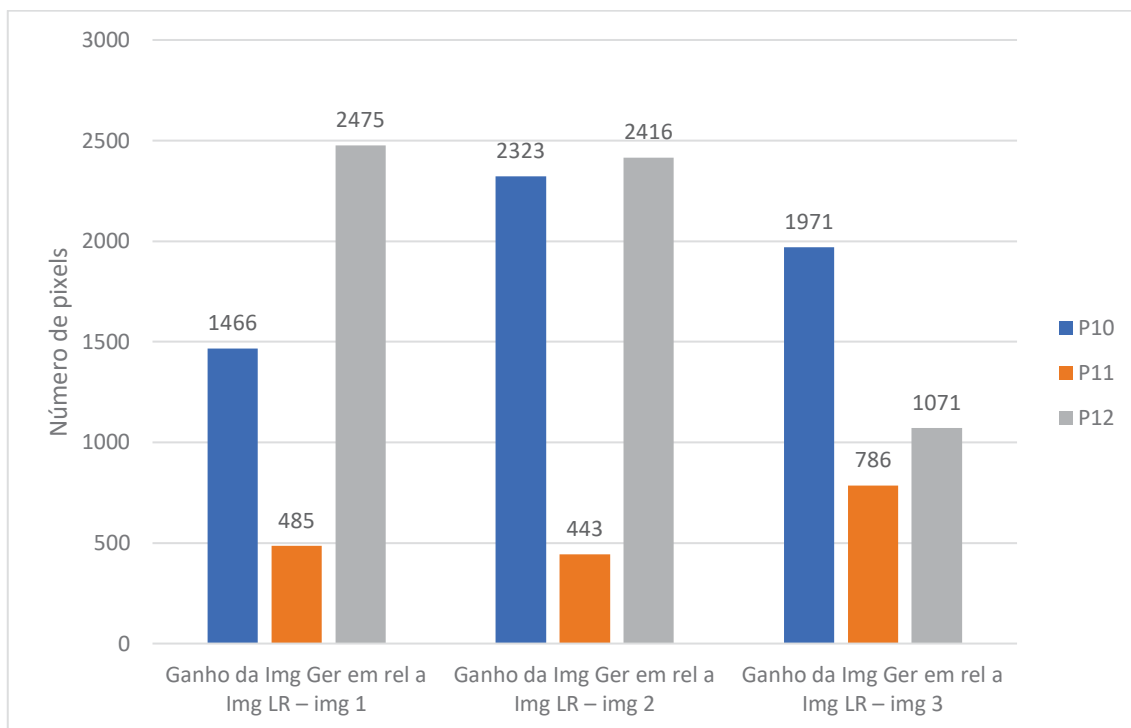


Figura 153 - Gráfico de ganho das imagens geradas em relação a imagem LR em número de *pixels* nos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2021).

Na análise dos *pixels* com erros menores nas imagens geradas em relação à imagem LR dos 3 processamentos em questão, verifica-se que o desempenho do processamento P10 foi superior ao desempenho dos demais processamentos nas três imagens analisadas (Figura 154).




Figura 154 - Gráfico da análise do número de *pixels* com erros menores nas imagens geradas nos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

Como conclusão parcial da referida avaliação, verificou-se que a avaliação estatística realizada dos produtos gerados aponta para o melhor desempenho do processamento P12.

4.5.6 Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN

Outro tipo de análise que foi realizada com o resultado dos três processamentos foi a visualização das imagens geradas. Nessa visualização, colocou-se lado a lado, para comparação, as três imagens, estando a de menor resolução à esquerda, a gerada ao centro e a de maior resolução à direita.

Dessa forma, a visualização permite a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução. Pode-se observar que todas as imagens geradas analisadas apresentaram grande semelhança com as respectivas imagens de alta resolução (Figura 155, Figura 156, Figura 157, Figura 158, Figura 159, Figura 160, Figura 161, Figura 162 e Figura 163).




Figura 155 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P10.
Fonte: O autor (2022).




Figura 156 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P10.
Fonte: O autor (2022).




Figura 157 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P10.
Fonte: O autor (2022).




Figura 158 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P11.
Fonte: O autor (2022).




Figura 159 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P11.
Fonte: O autor (2022).




Figura 160 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P11.
Fonte: O autor (2022).




Figura 161 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P12.

Fonte: O autor (2022).




Figura 162 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P12.

Fonte: O autor (2022).




Figura 163 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P12.

Fonte: O autor (2022).

Como conclusão parcial, verificou-se que as imagens do processamento P12 apresentou maior proximidade com as imagens de alta resolução do que as imagens do demais processamentos do experimento.

4.5.7 Comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação

Para possibilitar a comparação do algoritmo DEM-ESRGAN com outros métodos de interpolação típicos, verificando como os mesmos pontuam neste problema, foi realizada uma avaliação com tais métodos, viabilizando obter resultados de diferentes métricas (PSNR, SSIM, MSE e RMSE) (Tabela 20). O algoritmo DEM-ESRGAN com 100.000 épocas (P12) mostrou melhor resultado entre todos os outros métodos de interpolação típicos usados neste *benchmark*.

Tabela 36 - Tabela de comparação das métricas PSNR, SSIM, MSE e RMSE dos resultados de diferentes interpoladores

Interpoladores	PSNR	SSIM	MSE	RMSE (m)
bilinear	24,2055	0,4508	246,9050	15,7132
bicubic	25,4767	0,5306	184,2516	13,5739
lanczos	24,7469	0,5283	217,9667	14,7637
DEM-ESRGAN 10.000 (P10)	32,0653	0,8784	40,4162	6,3574
DEM-ESRGAN 50.000 (P11)	34,9551	0,8633	20,7766	4,5581
DEM-ESRGAN 100.000 (P12)	29,8438	0,8609	67,4060	8,2101

Fonte: O autor (2022).

Verificou-se, dessa forma, que o processamento P12 apresentou o melhor desempenho tanto em comparação aos interpoladores testados, como em relação aos demais processamentos do experimento.

4.5.8 Análise de curvas de nível geradas automaticamente

As seguintes figuras (Figura 164 a Figura 167) mostram a conformação das curvas de nível geradas automaticamente sem suavização, tanto para as imagens de alta resolução quanto para as imagens geradas pelos processamentos DEM-ESRGAN.

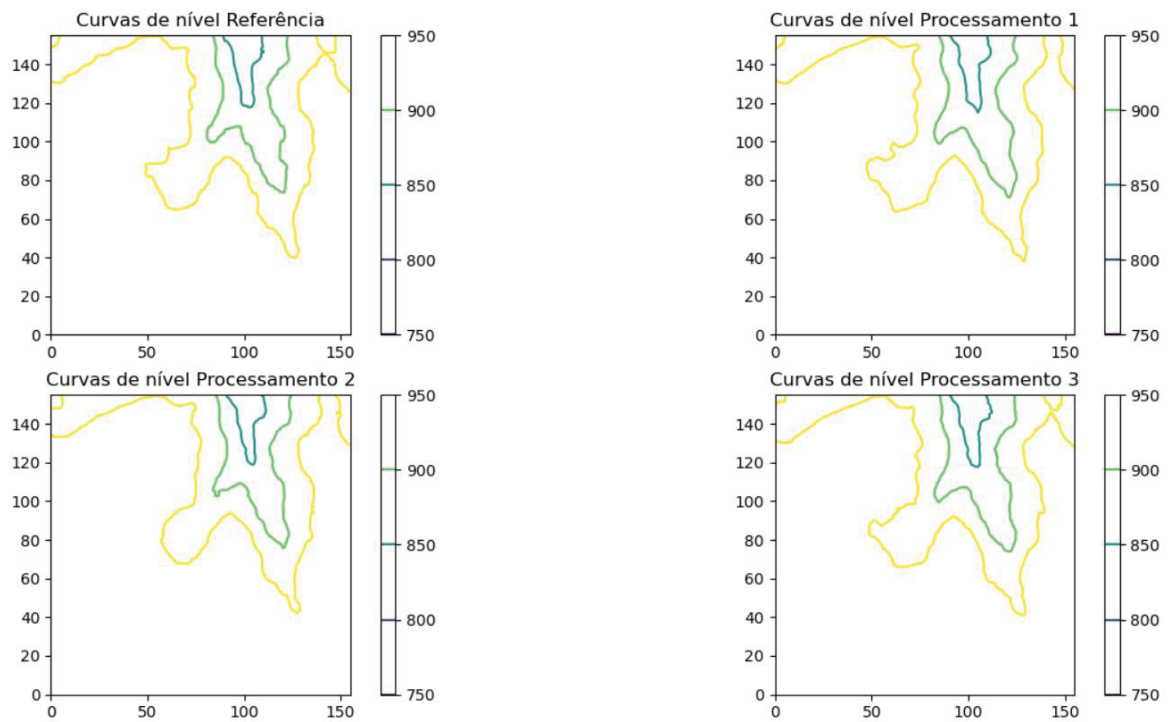


Figura 164 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 1 dos processamentos P10, P11 e P12
 Fonte: O autor (2022).

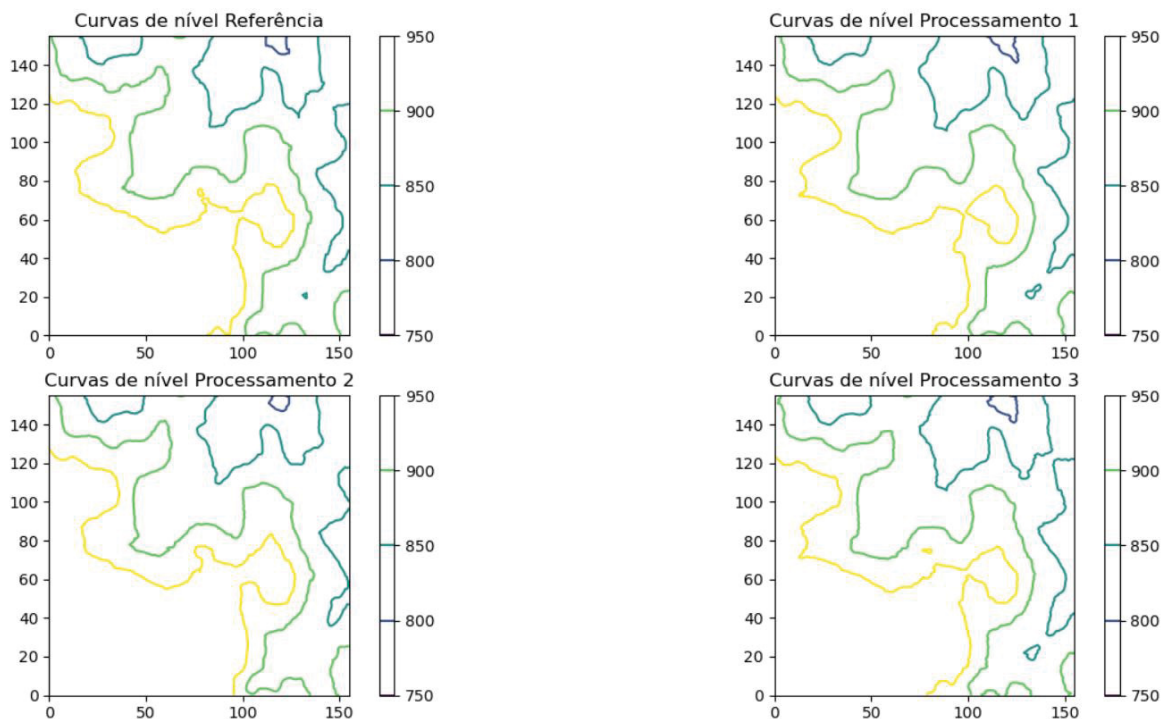


Figura 165 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 2 dos processamentos P10, P11 e P12
 Fonte: O autor (2022).

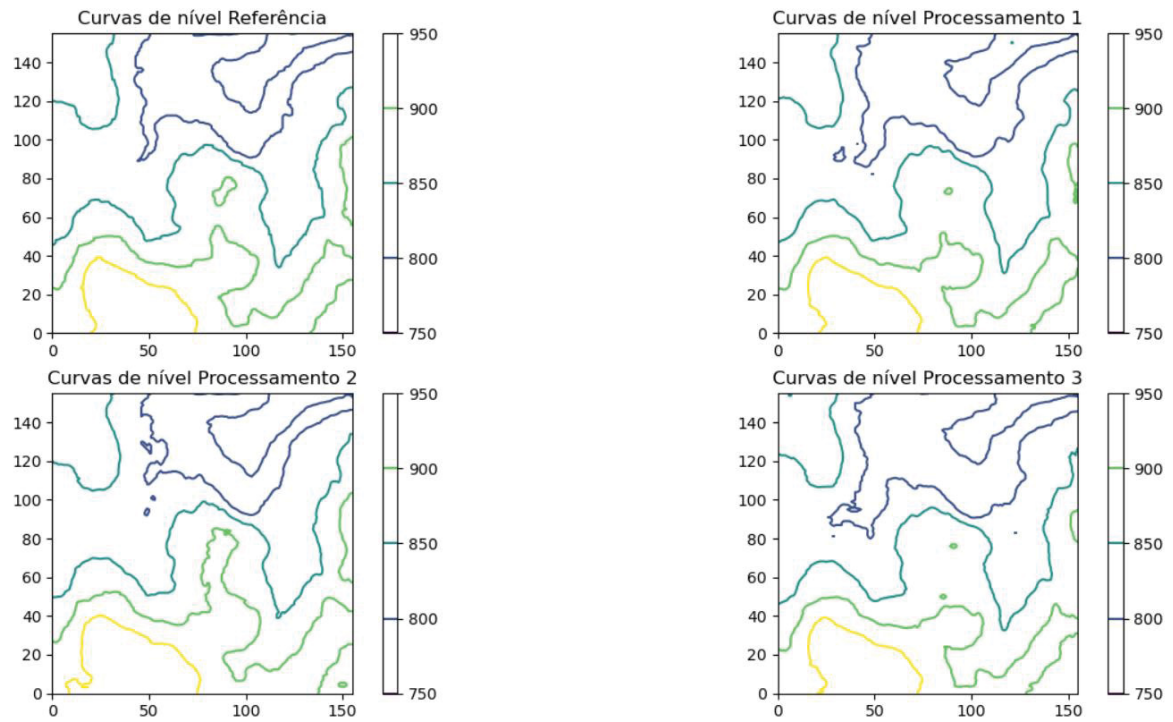


Figura 166 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 3 dos processamentos P10, P11 e P12
 Fonte: O autor (2022).

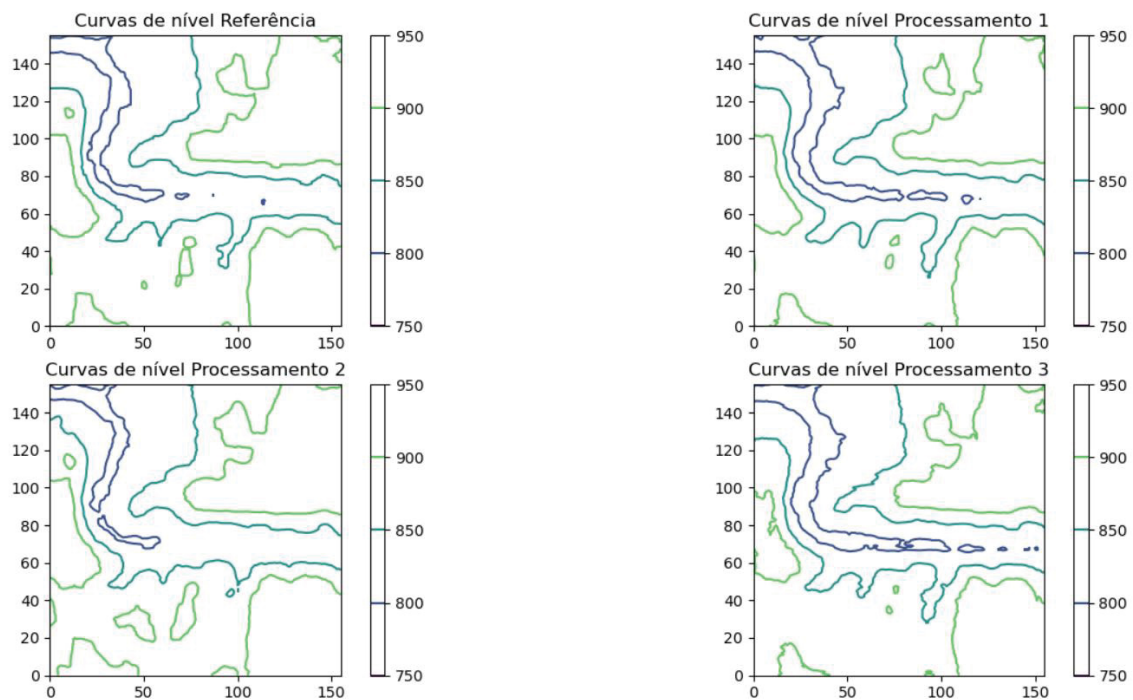


Figura 167 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 4 dos processamentos P10, P11 e P12
 Fonte: O autor (2022).

A partir desta análise, verificou-se que o processamento P10 apresentou melhor desempenho na comparação com as imagens de alta resolução, seguido pelo processamento P11.

4.5.9 Análise do Padrão de Exatidão Cartográfico Altimétrico

A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto. Para a realização da análise do Padrão de Exatidão Cartográfico Altimétrico foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerado). Calculou-se em seguida o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado (Tabela 37 a Tabela 38).

Tabela 37 - Tabela dos valores calculados do Erro Médio e do Erro Padrão das imagens geradas nos respectivos processamentos

Processamento	Imagem	Resolução Inicial	Resolução final	EM	EP
P10	1	30 metros	12,5 metros	-0,925	4,148
	2			-1,517	3,237
	3			-3,482	3,204
	4			-3,768	3,063
P11	1	30 metros	12,5 metros	5,115	4,279
	2			5,273	3,223
	3			3,824	3,257
	4			4,062	2,876
P12	1	30 metros	12,5 metros	-2,317	3,931
	2			-1,557	2,921
	3			-2,329	3,148
	4			-2,186	2,577

Fonte: O autor (2022).

Tabela 38 - Tabela do PEC altimétrico atingido pelas imagens geradas nos respectivos processamentos para as escalas do mapeamento sistemático

Processamento	Imagem	1:250000	1:100000	1:50000	1:25000
P10	1	Classe A	Classe A	Classe A	Classe C
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A
P11	1	Classe A	Classe A	Classe A	Classe C
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A
P12	1	Classe A	Classe A	Classe A	Classe B
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A

Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que o processamento P12 alcançou os menores erros médio e erros padrão dentre as imagens avaliadas. Comparando-se ainda o P10 e P11, verificou-se melhores valores calculados no primeiro.

4.5.10 Análise do Padrão de Exatidão Cartográfico Planimétrico

Para a realização da avaliação do Padrão de Exatidão Cartográfico Planimétrico foram selecionados 10 pontos homólogos em cada par de imagem utilizadas (*ground truth* e gerado). Os pontos foram distribuídos privilegiando as regiões de maior índice de concentração de informações cartografadas, utilizando método não tendencioso de escolha dos mesmos, como o método de sorteio manual simples sem reposição.

Após o término da etapa de levantamento dos pontos de controle, realizou-se o processamento, o cálculo das coordenadas e identificação dos valores cartográficos para os pontos. Através da comparação dos dois grupos de coordenadas, realizou-se o cálculo dos resíduos.

Para examinar se os resultados estão dentro da expectativa, em relação à precisão, utilizou-se o teste *t-student*, verificando se a variância das diferenças das coordenadas levantadas, quando comparadas com as de referência possuem diferenças significativas ou não, com a variância da expectativa definida antecipadamente (Figura 168 a Figura 170, Tabela 39 a Tabela 44).




Figura 168 - Levantamento dos 10 pontos homólogos selecionados na imagem 1 do processamento P12 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada)

Fonte: O autor (2022).

Tabela 39 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 1 do processamento P12

Fonte: O autor (2022).

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	536953,12	6875742,32	536932,44	6875742,06	20,68	0,26	20,68	SIM	NÃO
2	536859,32	6875632,27	536868,38	6875632,56	-9,06	-0,29	9,07	SIM	NÃO
3	537067,91	6873864,57	537069,90	6873867,12	-1,99	-2,55	3,24	SIM	NÃO
4	536892,70	6873980,89	536889,86	6873978,34	2,84	2,55	3,82	SIM	NÃO
5	538026,04	6874258,76	537905,99	6874265,54	120,05	-6,78	120,24	SIM	NÃO
6	537130,52	6875684,35	537130,67	6875687,55	-0,15	-3,20	3,20	SIM	NÃO
7	537452,80	6875272,84	537385,44	6875284,57	67,37	-11,73	68,38	SIM	NÃO
8	537360,86	6875395,31	537320,04	6875383,28	40,82	12,03	42,56	SIM	NÃO
9	537705,82	6874681,32	537606,85	6874729,61	98,97	-48,29	110,12	SIM	NÃO
10	537526,73	6875006,19	537483,65	6874994,81	43,08	11,38	44,56	SIM	NÃO

Tabela 40 - Tabela do PEC planimétrico atingido pela imagem gerada 1 do processamento P12 para as escalas de 1:250000 a 1:1000

Escala	Classe
1:250000	Classe B
1:100000	Classe C
1:50000	Rejeitado
1:25000	Rejeitado
1:10000	Rejeitado
1:5000	Rejeitado
1:2000	Rejeitado
1:1000	Rejeitado

Fonte: O autor (2022).




Figura 169 - Levantamento dos 10 pontos homólogos selecionados na imagem 2 do processamento P12 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada)

Fonte: O autor (2022).

Tabela 41 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 2 do processamento P12

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	539823,91	6874186,02	539718,52	6874174,86	105,38	11,16	105,97	SIM	NÃO
2	539830,08	6874338,24	539721,31	6874332,21	108,77	6,03	108,93	SIM	NÃO
3	539453,51	6874531,40	539401,25	6874486,79	52,26	44,60	68,70	SIM	NÃO
4	539832,10	6874603,05	539754,05	6874635,30	78,05	-32,24	84,45	SIM	NÃO
5	539246,30	6874814,81	539246,57	6874811,29	-0,27	3,52	3,53	SIM	NÃO
6	539112,63	6874815,57	539113,21	6874819,09	-0,58	-3,52	3,56	SIM	NÃO
7	538979,19	6874799,38	538981,18	6874801,61	-1,99	-2,23	2,99	SIM	NÃO
8	538859,49	6874915,87	538854,40	6874916,53	5,10	-0,66	5,14	SIM	NÃO
9	539020,34	6873877,82	539011,84	6873877,21	8,50	0,61	8,52	SIM	NÃO
10	540217,48	6875506,23	540160,83	6875506,42	56,64	-0,19	56,64	SIM	NÃO

Fonte: O autor (2022).

Tabela 42 - Tabela do PEC planimétrico atingido pela imagem gerada 2 do processamento P12 para as escalas de 1:250000 a 1:1000

Escala	Classe
1:250000	Classe B
1:100000	Classe C
1:50000	Rejeitado
1:25000	Rejeitado
1:10000	Rejeitado
1:5000	Rejeitado
1:2000	Rejeitado
1:1000	Rejeitado

Fonte: O autor (2022).

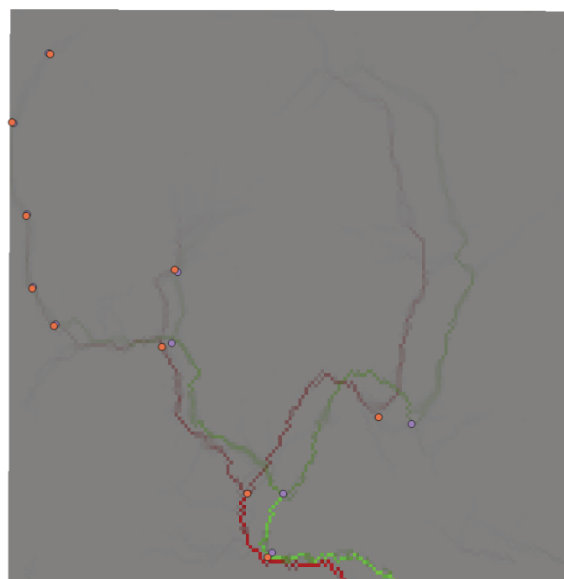


Figura 170 - Levantamento dos 10 pontos homólogos selecionados na imagem 3 do processamento P12 utilizando as redes de drenagens das imagens (onde as linhas verdes são referentes à rede de drenagem da imagem *ground truth* e as linhas vermelhas são referentes à rede de drenagem da imagem gerada)

Fonte: O autor (2022).

Tabela 43 - Tabela dos valores calculados das diferenças em E e N, das distâncias euclidianas e das existências de tendência em E e N da imagem gerada 3 do processamento P12

id	E_ref	N_ref	E_aval	N_aval	dif_E	dif_N	Dist. Euclidiana	Tendência E_90%	Tendência N_90%
1	540798,98	6874696,68	540795,00	6874692,21	3,98	4,46	5,98	SIM	NÃO
2	540722,39	6874824,23	540718,41	6874820,41	3,98	3,82	5,52	SIM	NÃO
3	540701,72	6875074,41	540698,31	6875069,95	3,41	4,47	5,62	SIM	NÃO
4	540655,22	6875388,00	540651,26	6875389,94	3,96	-1,93	4,40	SIM	NÃO
5	540776,69	6875626,82	540780,07	6875622,97	-3,39	3,85	5,13	SIM	NÃO
6	541197,79	6874632,30	541164,61	6874620,26	33,18	12,04	35,29	SIM	NÃO
7	541541,90	6873911,80	541527,13	6873897,78	14,77	14,02	20,37	SIM	NÃO
8	541580,56	6874115,07	541456,52	6874114,23	124,04	0,85	124,04	SIM	NÃO
9	541218,18	6874876,25	541209,14	6874882,68	9,04	-6,43	11,09	SIM	NÃO
10	542020,07	6874355,32	541906,87	6874378,11	113,20	-22,79	115,47	SIM	NÃO

Fonte: O autor (2022).

Tabela 44 - Tabela do PEC planimétrico atingido pela imagem gerada 3 do processamento P12 para as escalas de 1:250.000 a 1:1.000

Escala	Classe
1:250.000	Classe B
1:100.000	Classe D
1:50.000	Rejeitado
1:25.000	Rejeitado
1:10.000	Rejeitado
1:5.000	Rejeitado
1:2.000	Rejeitado
1:1.000	Rejeitado

Fonte: O autor (2022).

A imagem 1 do processamento P12 apresentou como resultado PEC Classe B na escala 1:250.000, PEC Classe C na escala 1:100.000 e PEC rejeitado nas demais classes. Já a imagem 2 do processamento P12 apresentou como resultado PEC Classe B na escala 1:250.000, PEC Classe C na escala 1:100.000 e PEC rejeitado nas demais classes, enquanto a imagem 3 apresentou como resultado PEC Classe B na escala 1:250.000, PEC Classe D na escala 1:100.000 e PEC rejeitado nas demais classes.

4.5.11 Análise da diferença entre superfícies

A subtração entre duas superfícies altimétricas permite avaliar as diferenças existentes entre ambas (Figura 171).

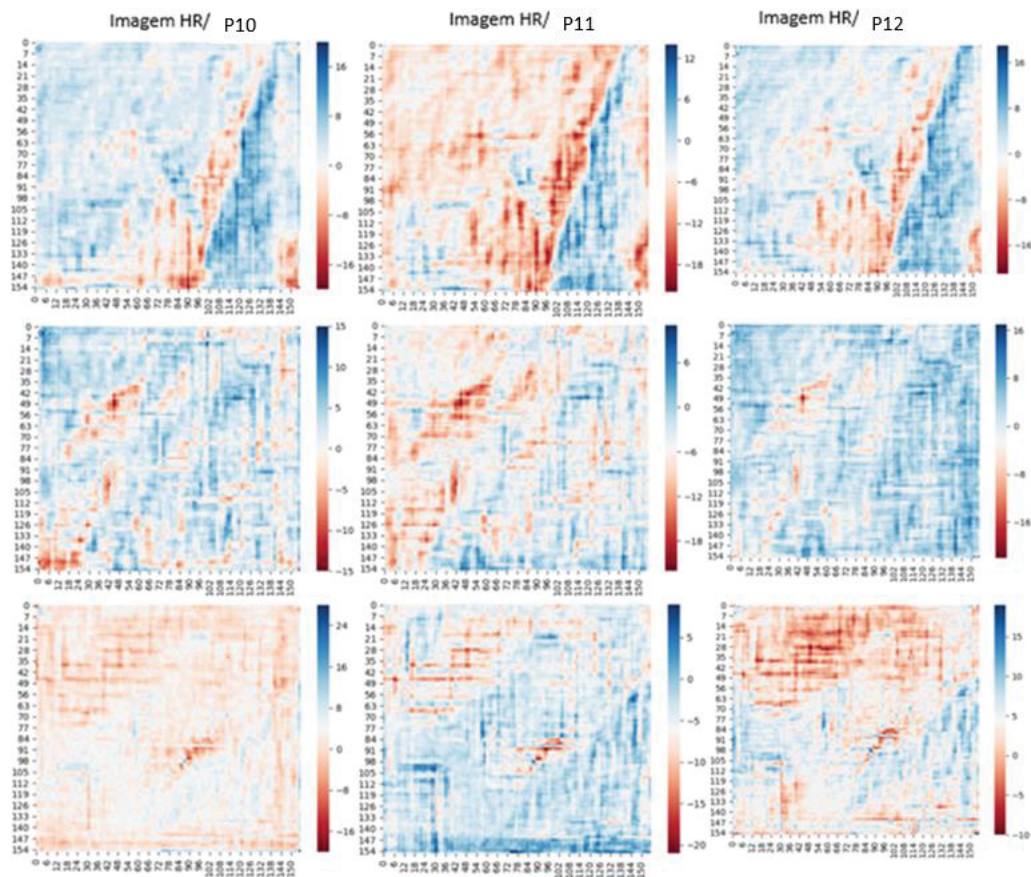


Figura 171 - Diferença entre superfícies das imagens de alta resolução e das imagens geradas pelos processamentos P10, P11 e P12
Fonte: O autor (2022).

Como conclusão parcial da avaliação, verificou-se que as imagens do processamento P12 apresentaram as menores diferenças entre superfícies, em comparação com as imagens dos processamentos P10 e P11.

4.5.12 Avaliação visual das cumeeiras

As figuras a seguir (Figura 172 a Figura 175) apresentam os resultados das linhas estruturais (cumeeiras) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Para tal, realizou-se a construção das matrizes simétricas dos valores altimétricos dos MDEs antes da realização dos processamentos.

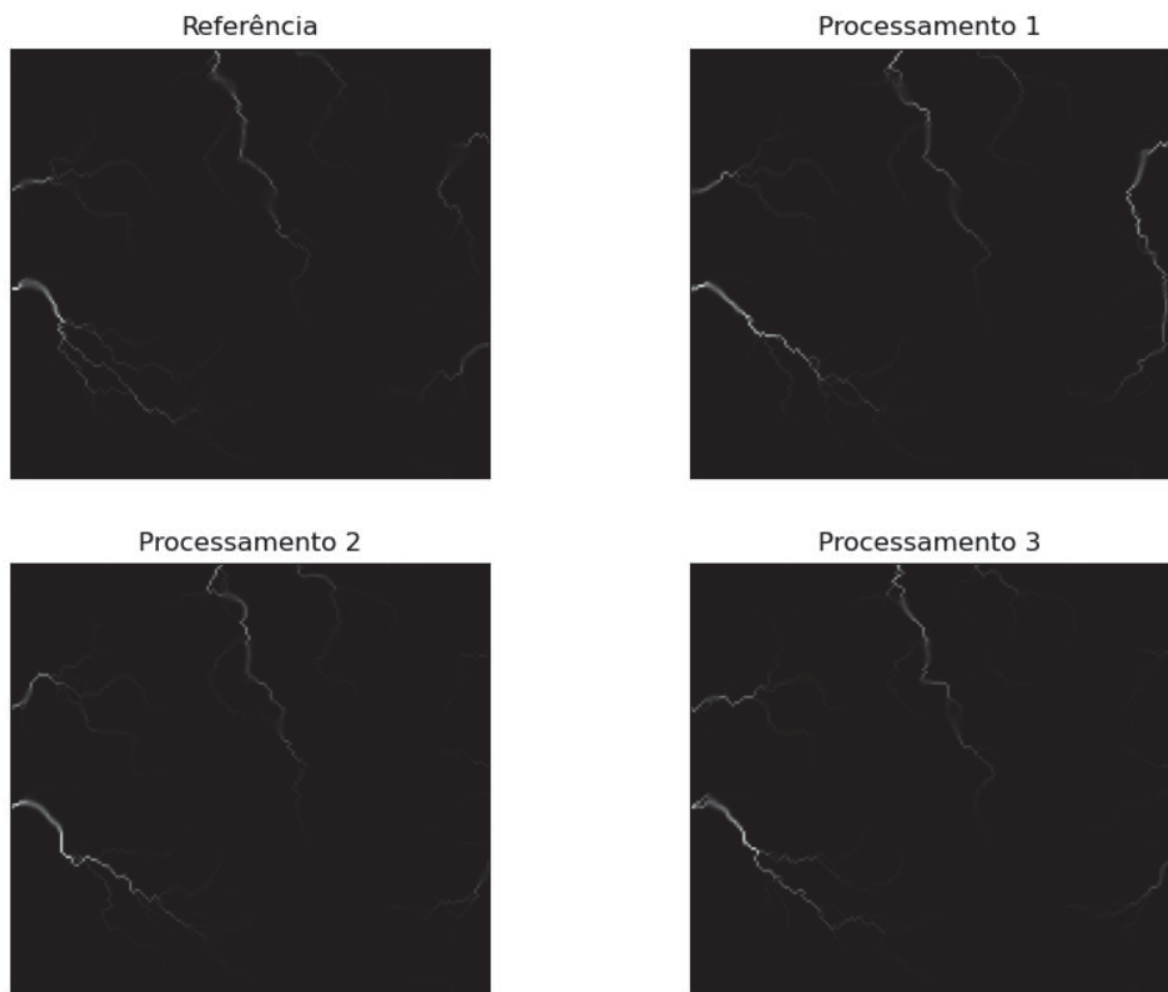


Figura 172 - Linhas de cumeeiras das imagens da imagem 1 dos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

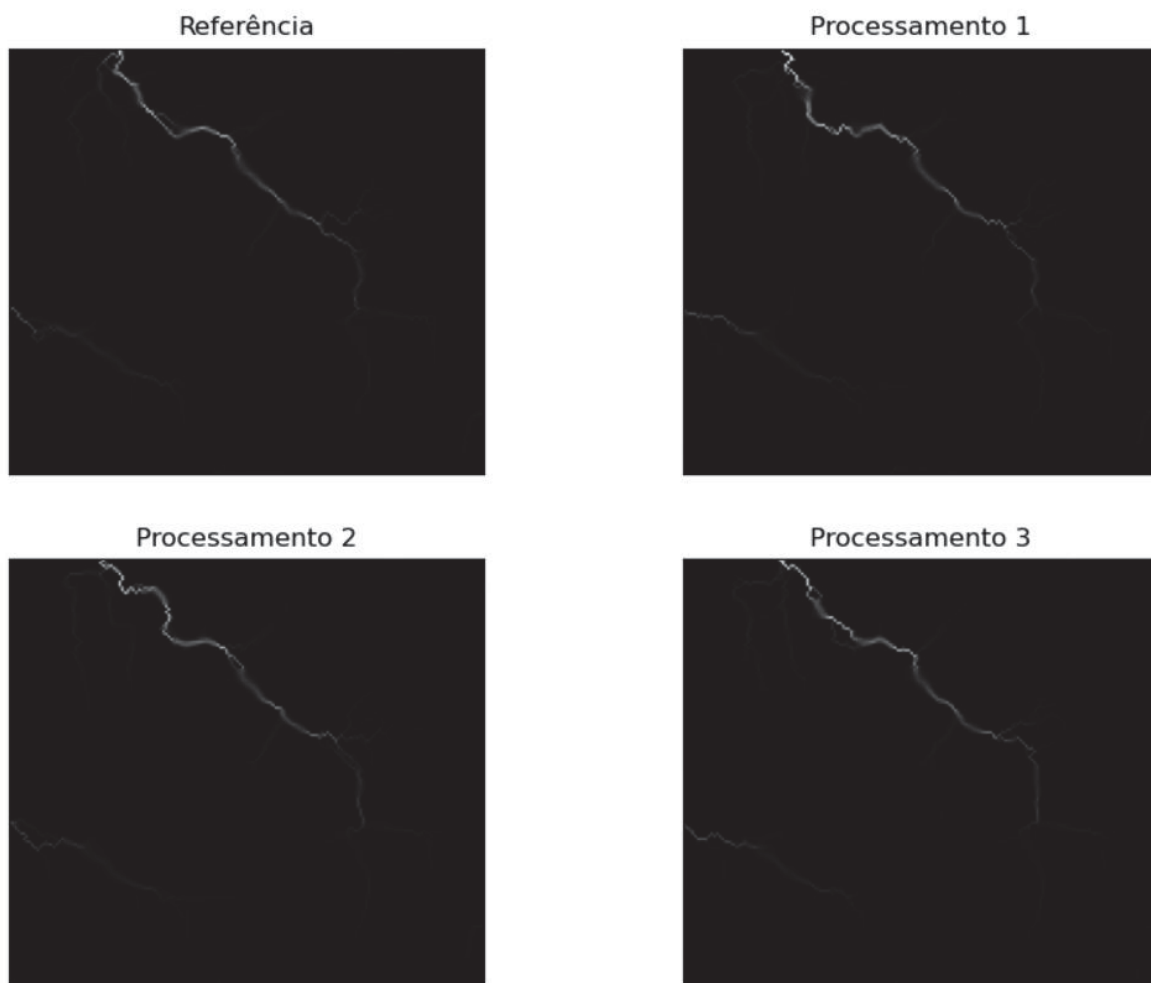


Figura 173 - Linhas de cumeeiras das imagens da imagem 2 dos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

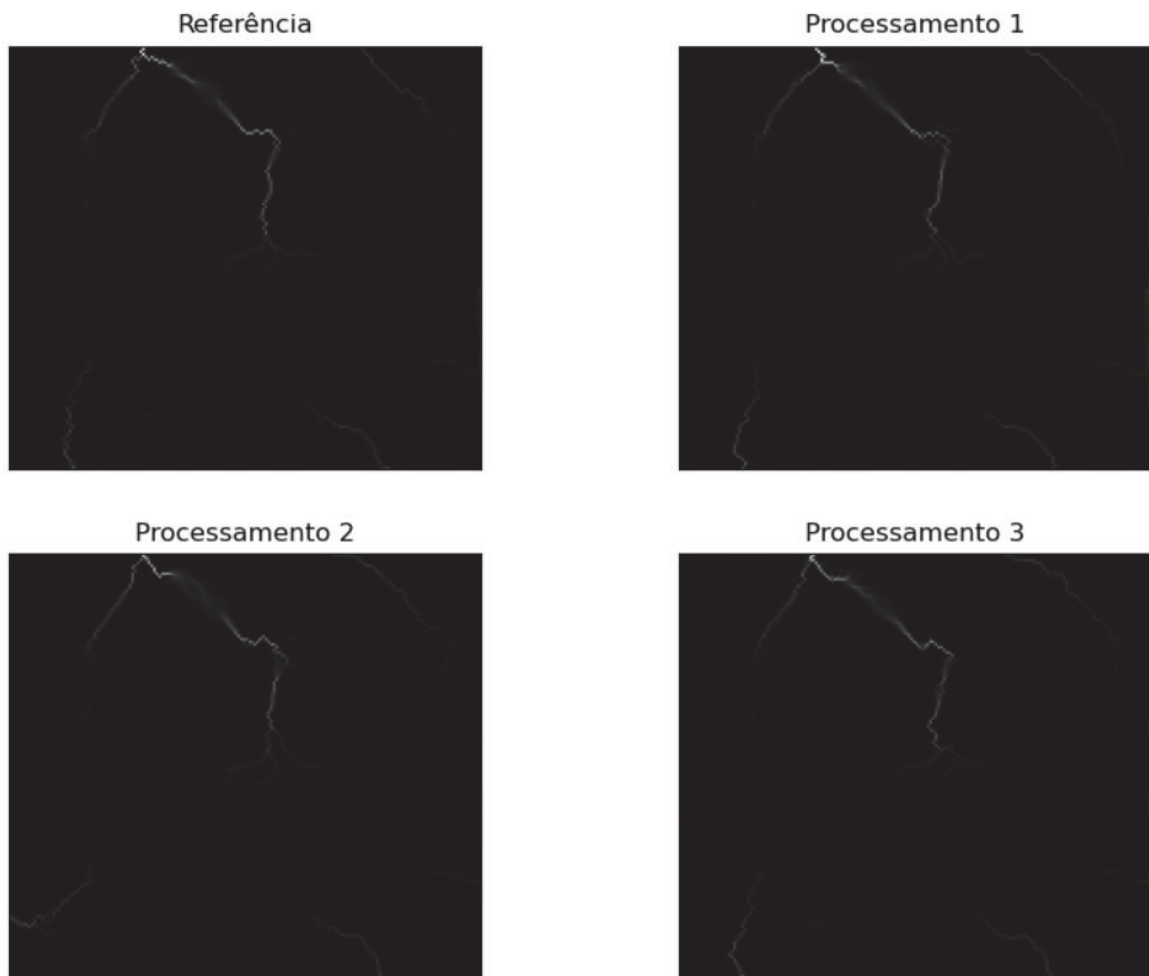


Figura 174 - Linhas de cumeeiras das imagens da imagem 3 dos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

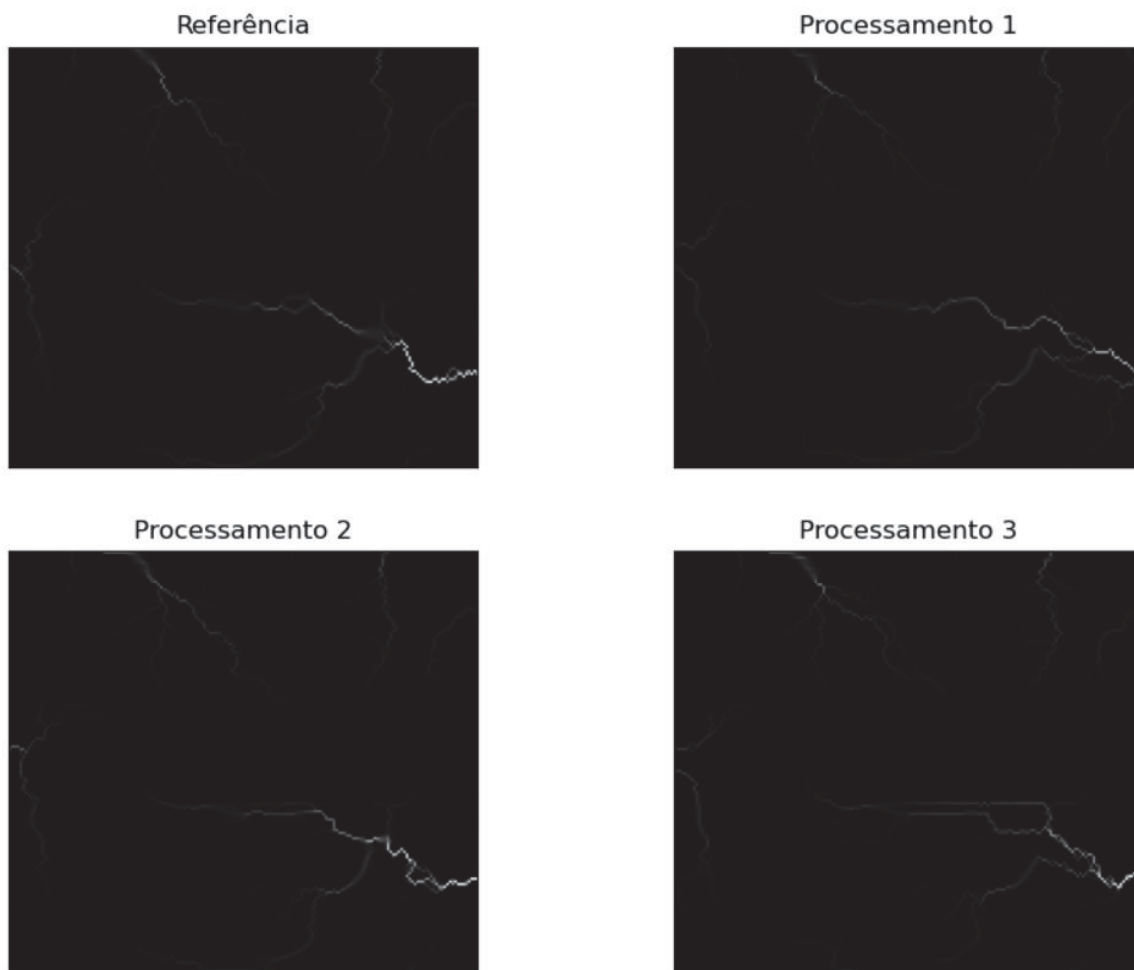


Figura 175 - Linhas de cumeeiras das imagens da imagem 4 dos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

Pode-se observar nos resultados apresentados que o P12 pode obter a melhor taxa de correspondência das características das cumeeiras. Então, o P12 supera P10 e P11 na preservação das características das cumeeiras.

4.5.13 Avaliação visual das redes de drenagens

A Figura 176 apresenta os resultados das linhas estruturais (canais de drenagem) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise.




Figura 176 - MDEs contendo o resultado dos canais de drenagens das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12
 Fonte: O autor (2022).

Em primeiro lugar, pode-se observar que o P12 pode obter a melhor taxa de correspondência das características dos canais de drenagem. Então, o P12 supera P10 e P11 na preservação das características dos canais de drenagem.

Verifica-se, ainda, na segunda imagem de P10, assim como na terceira imagem de P10, P11 e P12 uma diferença de espessura dos canais de drenagens em relação à imagem de alta resolução, com pontos mais baixos gerando canais mais longos.

4.5.14 Avaliação dos pontos críticos

Na presente seção, foi realizada uma investigação quanto à eficácia dos métodos utilizados na recuperação dos pontos críticos. Pelas avaliações anteriores, pode-se observar que o algoritmo DEM-ESRGAN (MDTESRGAN) gera melhores resultados em relação à geração de SR que os outros métodos.

Dessa maneira, nesta avaliação, apenas os resultados do *ground truth* e as interpolações dos processamentos P10, P11 e P12 são focados.

A Figura 177 apresenta um conjunto de imagens contendo a análise visual dos *pixels* contendo altitudes máximas e mínimas das imagens de alta resolução e das imagens geradas pelos processamentos P10, P11 e P12, onde os *pixels* de altitude máxima são representados pela cor vermelha e os *pixels* de altitude mínima são representados pela cor azul. Tais *pixels* representam pontos críticos para os MDEs gerados pelo método utilizado na presente pesquisa.




Figura 177 - MDEs de alta resolução e MDEs gerados pelo conjunto de validação do *dataset 4* contendo suas respectivas altitudes máximas e mínimas das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12, onde os *pixels* de altitude mínima são representados pela cor azul e os *pixels* de altitude máxima são representados pela cor vermelha

Fonte: O autor (2022).

Quanto à preservação de pontos críticos (Figura 177), nenhuma regra óbvia foi encontrada nos três resultados de exemplo. Nesse sentido, os resultados estatísticos podem ser a melhor solução para avaliar a preservação dos pontos críticos, e as principais conclusões podem ser obtidas a partir de uma análise das métricas obtidas das respectivas imagens. Portanto, para resumir,

neste quesito, o processamento P12 supera os demais processamentos na preservação da maioria das características do terreno na SR do MDE.

4.5.15 Avaliação da declividade dos MDEs

A Figura 178 apresenta os resultados da declividade do terreno dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN P10, P11 e P12.

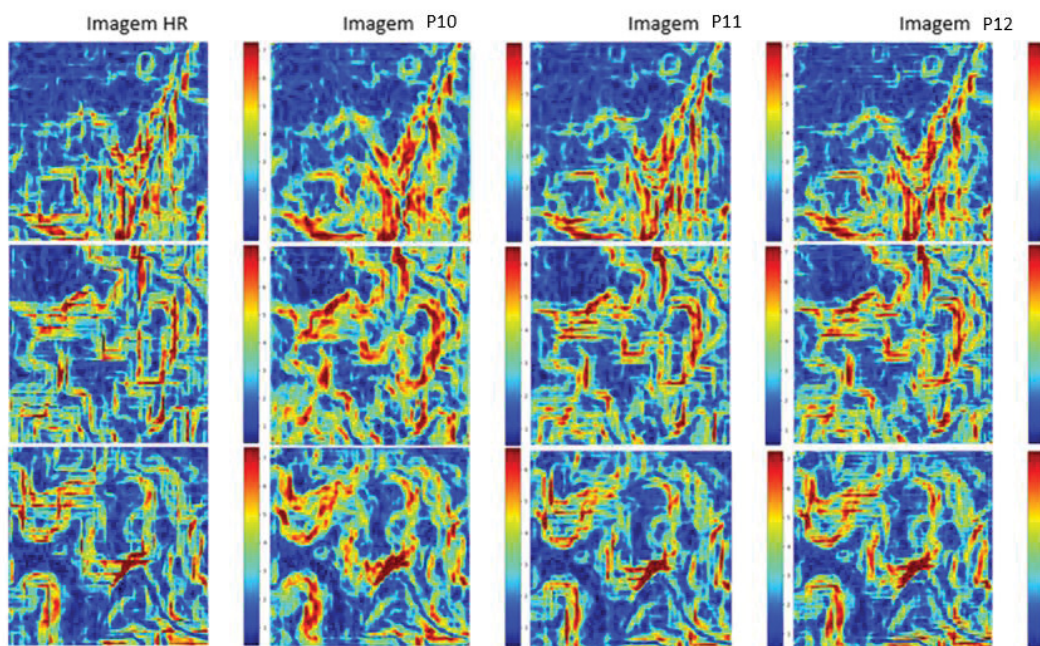


Figura 178 - MDEs contendo o resultado da declividade do terreno das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

Considerando a avaliação da declividade do terreno, a percepção intuitiva é de que os resultados de P12 são muito mais suaves que os de P10 e P11, e algumas texturas são mais reforçadas nos resultados da interpolação de P10, mas ficam retidas em P11 e P12.

4.5.16 Avaliação do aspecto dos MDEs

A Figura 179 apresentam os resultados do aspecto dos MDEs originais de alta resolução e dos MDEs gerados pelos processamentos DEM-ESRGAN P10, P11 e P12.

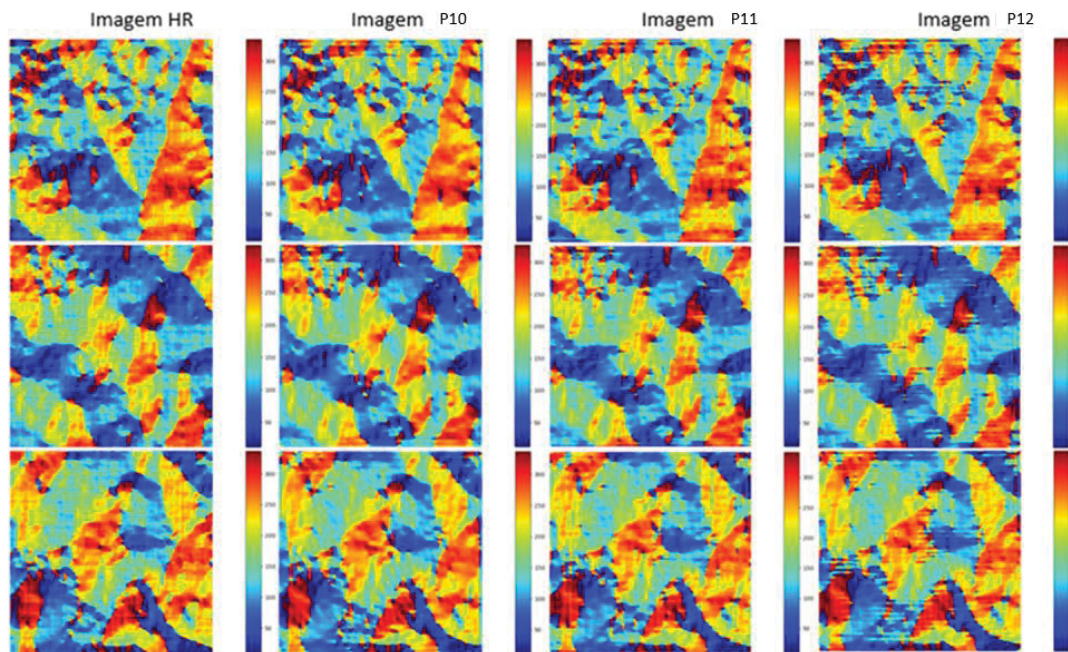


Figura 179 - MDEs contendo o resultado do aspecto das imagens de alta resolução e das imagens geradas pelos processamentos DEM-ESRGAN P10, P11 e P12
Fonte: O autor (2022).

Quanto ao aspecto, intuitivamente, verifica-se que as distorções nos resultados do P10 são maiores em comparação com os resultados do P11 e do P12. No entanto, os resultados de declividade do terreno do P12 apresentam um melhor equilíbrio entre precisão global e características locais, o que pode ser a razão pela qual o P12 supera os outros métodos. Então, considerando a avaliação de aspecto, os três processamentos geram resultados comparáveis, e tal conclusão é consistente com as avaliações estatísticas.

4.6 EXPERIMENTO 5 - MODELO DEM-ESRGAN APLICADO AO DATASET 5

O processamento P13, assim como o processamento P14 e o processamento P15 utilizaram amostras de imagens do MDE Alos Palsar de 12,5 metros para os arquivos de baixa resolução e amostras de imagens do MDE ESC de 1 metro para os arquivos de alta resolução.

4.6.1 Análise do *dataset* 5

O *dataset* 5, montado para a realização do experimento em questão, foi feito a partir de 2 MDEs (Alos Palsar e ESC), o de alta resolução com 1 metro e o de baixa resolução com 12,5 metros. Suas características podem ser verificadas de acordo com o apresentado na Tabela 45.

Tabela 45 - Características do dataset 5

Características	HR	LR
Resolução espacial	1 metro	12,5 metros
Nome do arquivo	img_DEM_ESC_dataset.tif	AP_23791_FBD_F6610_RT1.dem.tif
Projeção cartográfica	EPSG 31982	EPSG 32722
<i>Datum</i>	WGS84	WGS84
Largura	6379 <i>pixels</i>	6589 <i>pixels</i>
Altura	3601 <i>pixels</i>	6056 <i>pixels</i>
Tipo de dado	Float32	Int16
Número de bandas	1	1
Tipo de metadados do driver GDAL	GeoTIFF	GeoTIFF

Fonte: O autor (2022).

A Figura 180 apresenta uma imagem do MDE ESC de alta resolução utilizado para a extração dos pares de amostras (no que tange as amostras de alta resolução) de treinamento e validação do modelo com resolução espacial de 1 metro visualizada no QGIS.




Figura 180 - Imagem do arquivo de alta resolução do MDT ESC de resolução de 1 metro.
Fonte: O autor (2022).

Foi necessário fazer um recorte nos MDEs para fazer a comparação estatística das duas imagens, de modo a representarem a mesma porção do terreno.

A análise estatística das imagens utilizadas para a coleta das amostras do *dataset 5* aponta que a média aritmética da imagem de alta resolução é de 932,4298 metros, enquanto a média aritmética da imagem de baixa resolução é de 938,9251 metros. Já quanto ao desvio padrão, a imagem de alta resolução apresentou um valor de 46,8325 metros, e a imagem de baixa resolução apresentou um valor de 48,4115 metros (Tabela 46).

Tabela 46 - Análise estatística das imagens utilizadas

Estatísticas	Imagem LR	Imagem HR
Número de <i>pixels</i>	198900	30867981
Número de linhas	390	4839
Número de colunas	510	6379
Mínimo	744	737,8091
Máximo	1030	1027,8633
Mediana	949	941,3867
Média aritmética	938,9251	932,4298
Moda	946	954,5060
Desvio padrão	48,4115	46,8325
Coefficiente de variação	0,0516	0,1205
Amplitude	62,0000	63,9493

Fonte: O autor (2022).

O histograma das imagens utilizadas para a coleta das amostras do *dataset* 5 permite ilustrar como uma determinada amostra de dados está distribuída (Figura 181 e Figura 182). As regiões escolhidas para a seleção das amostras foram prioritariamente de regiões mais altas, com altitudes variando entre 750 e 1030 metros. Os picos (valores mais comuns), em ambos os MDEs encontram-se próximo ao valor de altitude 950. Não se verificou a ocorrência de *outliers*. Não houve um bom ajuste em relação à curva de Gauss.




Figura 181 - Histograma mostrando a distribuição dos *pixels* do MDE (imagem) de baixa resolução em função de valores altimétricos
Fonte: O autor (2022).




Figura 182 - Histograma mostrando a distribuição dos *pixels* do MDE (imagem) de alta resolução modelo em função de valores altimétricos
Fonte: O autor (2022).

4.6.2 Análise dos processamentos DEM-ESRGAN P13, P14 e P15

Ao término dos processamentos, foram calculados os valores de suas referidas métricas PSNR. Em relação a este quesito, o primeiro processamento (P13) apresentou o PSNR de 39,441, o segundo processamento (P14) apresentou o PSNR de 39,681, enquanto o terceiro (P15) apresentou um PSNR de 45,820.

Durante os processamentos, verificou-se que ocorre uma variação oscilatória na progressão dos valores do PSNR, não ocorrendo dessa maneira um crescimento contínuo com o decorrer do tempo (Figura 183).




Figura 183 - Variação dos valores da métrica do PSNR dos processamentos executados (P13, P14 e P15) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)

Fonte: O autor (2022).

Ao se realizar a comparação do *loss* *l_g_perceptron*, percebe-se que todos partem de um pico inicial e a partir daí passam a demonstrar uma tendência de aproximação do zero. Percebe-se que os processamentos com mais épocas se aproximaram mais do zero do que os com menos épocas (Figura 184). O Processamento P15 apresentou um pico de 1,089 no valor da perda após passar as 40.000 épocas.



Figura 184 - Variação dos valores apresentados pelas funções de perda *l_g_percep* de cada um dos processamentos executados (P13, P14 e P15) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)

Fonte: O autor (2022).

Conclui-se, parcialmente, que o 3º processamento do referido experimento apresentou melhor métrica final dentre as apresentadas durante o processamento em si. Já em relação à variação da função de perda *Lpercep*, o 3º processamento também apresentou menor erro final.

4.6.3 Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN

Outro tipo de análise que foi realizada com o resultado dos três processamentos foi a visualização das imagens geradas. Nessa visualização, colocou-se lado a lado, para comparação, as três imagens, estando a de menor resolução à esquerda, a gerada ao centro e a de maior resolução à direita.

Dessa forma, a visualização permite a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução. Pode-se observar que todas as imagens geradas analisadas não conseguiram

se aproximar em semelhança com as respectivas imagens de alta resolução (Figura 185, Figura 186, Figura 187, Figura 188, Figura 189, Figura 190, Figura 191, Figura 192, Figura 193).




Figura 185 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P13.
Fonte: O autor (2022).




Figura 186 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P13.
Fonte: O autor (2022).




Figura 187 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P13.
Fonte: O autor (2022).




Figura 188 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P14.
Fonte: O autor (2022).




Figura 189 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P14.
Fonte: O autor (2022).




Figura 190 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P14.
Fonte: O autor (2022).




Figura 191 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P15.

Fonte: O autor (2022).




Figura 192 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P15.
Fonte: O autor (2022).




Figura 193 - Exemplo da imagem gerada (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P15.
Fonte: O autor (2022).

Como conclusão parcial, verificou-se que as imagens do processamento P15 apresentaram maior proximidade com as imagens de alta resolução do que as imagens dos demais processamentos do experimento. Os resultados alcançados se deram em função da diferença de resolução espacial entre as imagens de alta e baixa resolução (1m e 12,5m).

4.6.4 Análise de curvas de nível geradas automaticamente

As seguintes figuras (Figura 194 a Figura 196) mostram a conformação das curvas de nível geradas automaticamente sem suavização, tanto para as imagens de alta resolução quanto para as imagens geradas pelos processamentos DEM-ESRGAN.

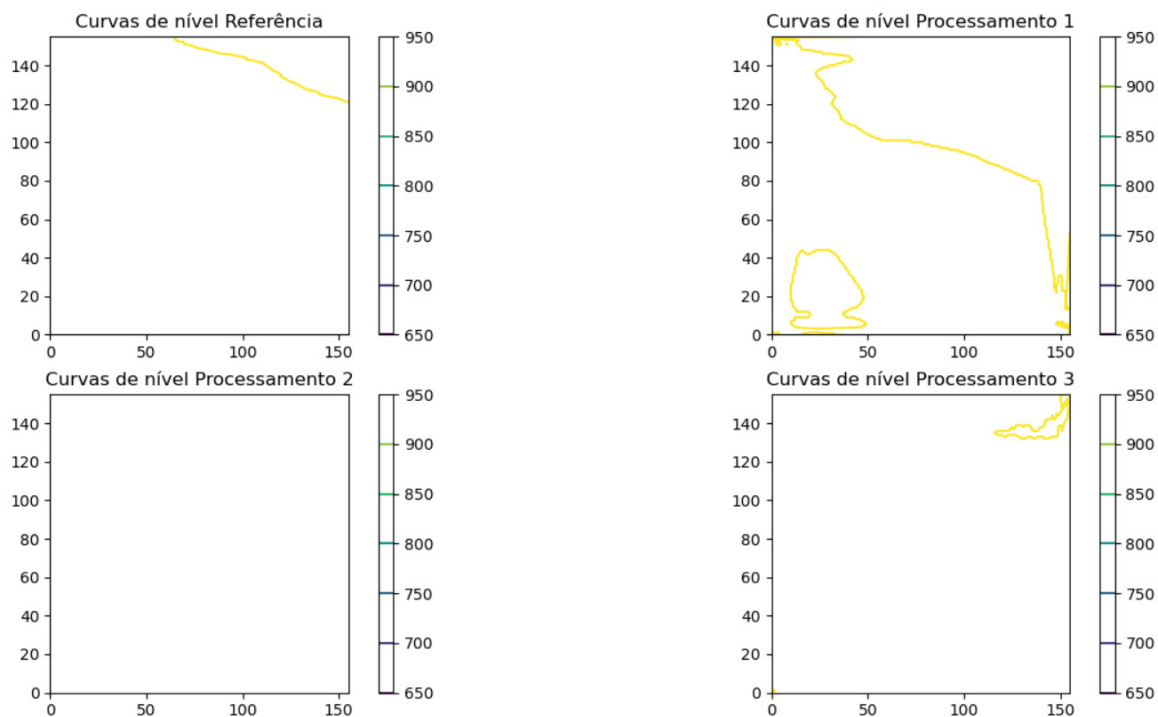


Figura 194 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 1 dos processamentos P13, P14 e P15
 Fonte: O autor (2022).




Figura 195 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 2 dos processamentos P13, P14 e P15
 Fonte: O autor (2022).

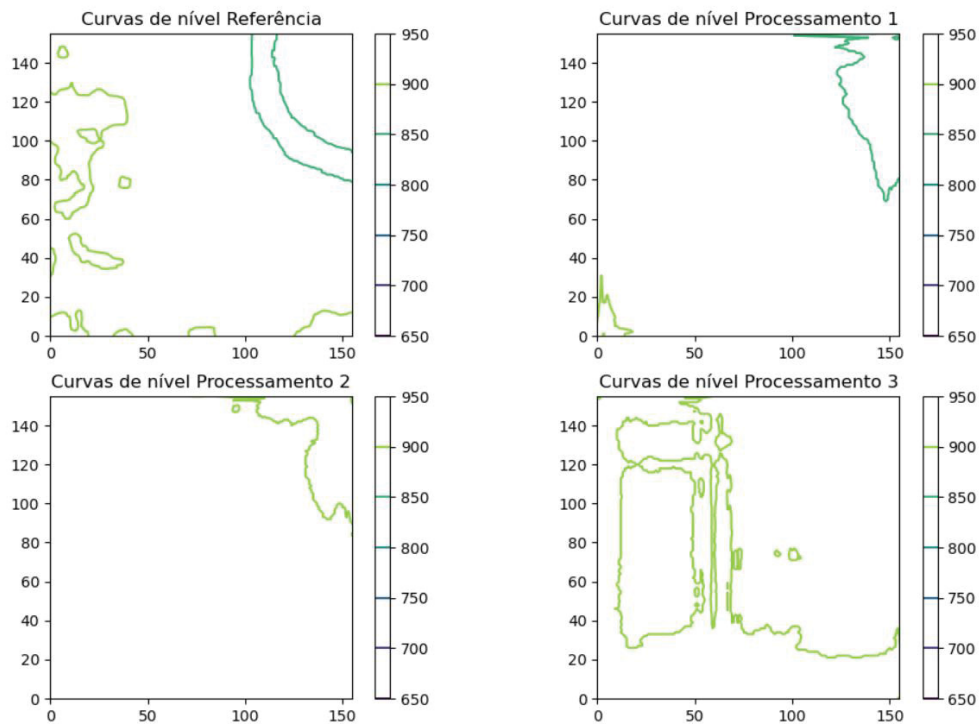


Figura 196 - Curvas de nível da imagem de alta resolução e das imagens geradas pelo algoritmo DEM-ESRGAN da imagem 3 dos processamentos P13, P14 e P15
 Fonte: O autor (2022).

A partir desta análise, verificou-se que o processamento P15 apresentou melhor desempenho na comparação com as imagens de alta resolução, seguido pelo processamento P13.

4.6.5 Análise do Padrão de Exatidão Cartográfica Altimétrica

A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto. Para a realização da análise do Padrão de Exatidão Cartográfica Altimétrico foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerado). Calculou-se em seguida o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado (Tabela 47 a Tabela 48).

Tabela 47 - Tabela dos valores calculados do Erro Médio e do Erro Padrão das imagens geradas nos respectivos processamentos

Processamento	Imagem	Resolução Inicial	Resolução final	EM	EP
---------------	--------	-------------------	-----------------	----	----

P13	1	12,5 metros	1 metro	14,514	11,105
	2			-2,279	7,615
	3			-0,738	5,079
P14	1	12,5 metros	1 metro	32,213	10,000
	2			4,612	6,736
	3			11,212	8,396
P15	1	12,5 metros	1 metro	-13,221	8,524
	2			-21,883	5,667
	3			-17,369	5,060

Fonte: O autor (2022).

Tabela 48 - Tabela do PEC altimétrico atingido pelas imagens geradas nos respectivos processamentos para as escalas do mapeamento sistemático

Processamento	Imagem	1:250000	1:100000	1:50000	1:25000
P13	1	Classe A	Classe A	Classe D	Classe D
	2	Classe A	Classe A	Classe A	Classe D
	3	Classe A	Classe A	Classe A	Classe D
P14	1	Classe A	Classe C	Classe C	Classe D
	2	Classe A	Classe A	Classe A	Classe D
	3	Classe A	Classe A	Classe C	Classe D
P15	1	Classe A	Classe A	Classe C	Classe D
	2	Classe A	Classe A	Classe D	Classe D
	3	Classe A	Classe A	Classe D	Classe D

Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que o processamento P13 alcançou os menores erros médio e erros padrão dentre as imagens avaliadas. Comparando-se ainda o P14 e P15, verificou-se melhores valores calculados no primeiro.

4.6.6 Avaliação visual das cumeeiras

As figuras a seguir (Figura 197 a Figura 199) apresentam os resultados das linhas estruturais (cumeeiras) nos MDEs de alta resolução e nos MDEs gerados pelos processamentos em análise. Para tal, realizou-se a construção das matrizes simétricas dos valores altimétricos dos MDEs antes da realização dos processamentos.

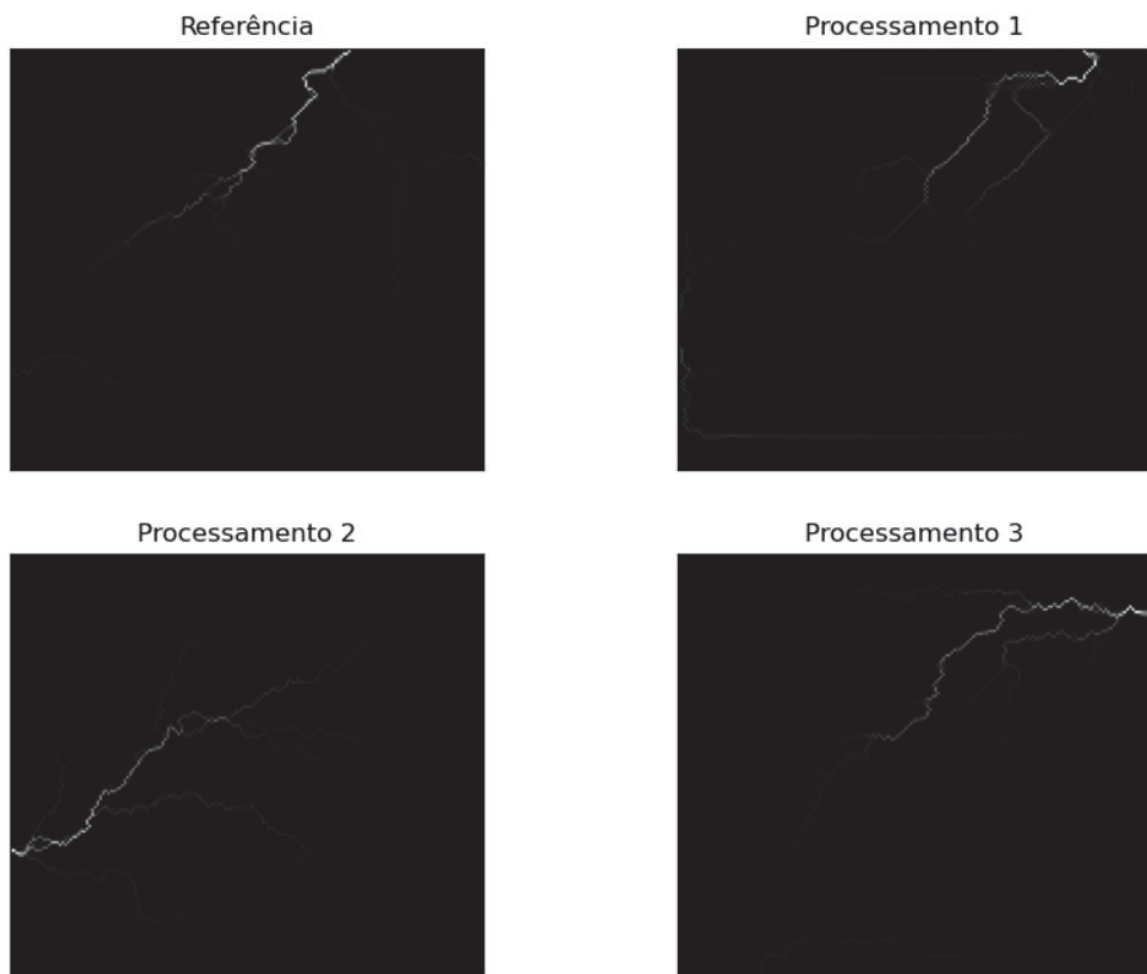


Figura 197 - Linhas de cumeeiras das imagens da imagem 1 dos processamentos DEM-ESRGAN P13, P14 e P15
Fonte: O autor (2022).

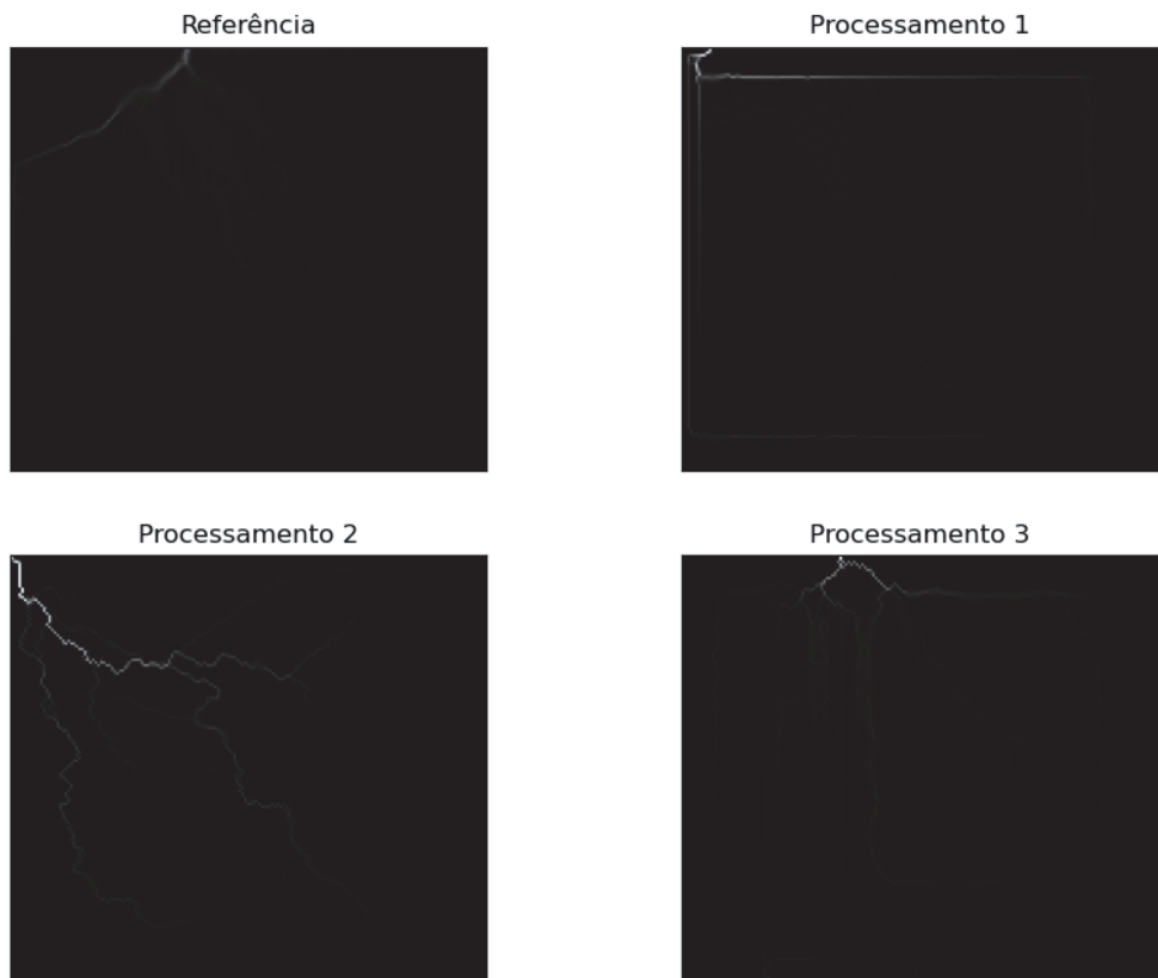


Figura 198 - Linhas de cumeeiras das imagens da imagem 2 dos processamentos DEM-ESRGAN P13, P14 e P15
Fonte: O autor (2022).

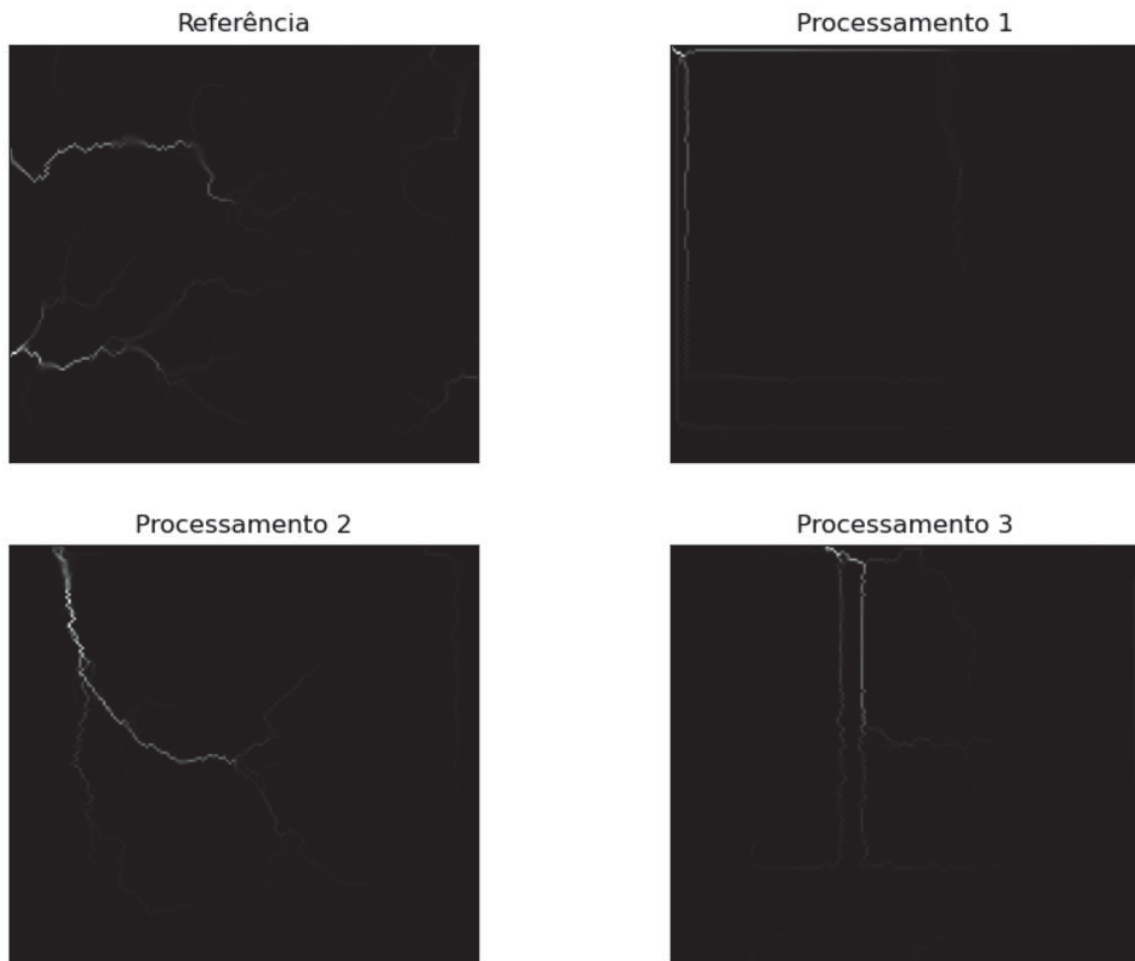


Figura 199 - Linhas de cumeeiras das imagens da imagem 3 dos processamentos DEM-ESRGAN P13, P14 e P15
Fonte: O autor (2022).

Pode-se observar nos resultados apresentados que o P15 pode obter a melhor taxa de correspondência das características das cumeeiras. Então, o P15 supera P13 e P14 na preservação das características das cumeeiras.

4.7 EXPERIMENTO 6 - MODELO DEM-ESRGAN APLICADO AO *DATASET 6*

O processamento P16, assim como o processamento P17 e o processamento P18 utilizaram amostras de imagens do MOG MAPGEO2015 de 90 metros para os arquivos de baixa resolução e amostras de imagens do MOG ICGEM de 30 metros para os arquivos de alta resolução.

4.7.1 Análise do *dataset 6*

O *dataset* 6, montado para a realização do experimento em questão, foi feito a partir de um MOG e de um MGG (MAPGEO2015 e ICGEM), sendo o MGG de alta resolução com 30 metros e o MOG de baixa resolução com 90 metros. Suas características podem ser verificadas de acordo com o apresentado na Tabela 49.

Tabela 49 - Tabela das características do MGG de alta resolução e do MOG de baixa resolução utilizados no *dataset* 6

Características	HR	LR
Resolução espacial	30 metros	90 metros
Nome do arquivo	ICGEM.tif	MAPGEO.tif
Projeção cartográfica	EPSG 4326	EPSG 4326
<i>Datum</i>	WGS84	WGS84
Largura	3112 <i>pixels</i>	1038 <i>pixels</i>
Altura	2520 <i>pixels</i>	841 <i>pixels</i>
Tipo de dado	Float64	Float64
Número de bandas	1	1
Tipo de metadados do driver GDAL	GeoTIFF	GeoTIFF

Fonte: O autor (2022).

As duas figuras seguintes (Figura 200, Figura 201) apresentam respectivamente uma imagem do MGG ICGEM de alta resolução utilizado para a extração dos pares de amostras (no que tange as amostras de alta resolução) de treinamento e validação do modelo com resolução espacial de 30 metros visualizada no QGIS e uma imagem do MOG MAPGEO de baixa resolução utilizado para a extração dos pares de amostras (no que tange as amostras de baixa resolução) de treinamento e validação do modelo, com resolução espacial de 90 metros, visualizada no QGIS.



Figura 200 - Imagem do arquivo ICGEM.TIF de resolução de 30 metros.
Fonte: O autor (2022).



Figura 201 - Imagem do arquivo MAPGEO.TIF do IBGE de resolução de 90 metros.
Fonte: O autor (2022).

A análise estatística das imagens utilizadas para a coleta das amostras do *dataset* aponta que a média aritmética da imagem de baixa resolução é de 6,2884 metros, enquanto a média aritmética da imagem de alta resolução é de 6,7304 metros. Já quanto ao desvio padrão, a imagem de baixa resolução apresentou um valor de 0,2069 metros, e a imagem de alta resolução apresentou um valor de 0,1735 metros (Tabela 50).

Tabela 50 – Apresentação das estatísticas do MGG de alta resolução e do MOG baixa resolução utilizados para a extração dos pares de amostras das imagens de treinamento e validação do *dataset 6*

Estatísticas	Imagem LR	Imagem HR
Número de <i>pixels</i>	872958	7842240
Número de linhas	841	2520
Número de colunas	1038	3112
Mínimo	5,6462	6,2368
Máximo	6,8129	7,2387
Mediana	6,289	6,7182
Média aritmética	6,2884	6,7304
Desvio padrão da população	0,2069	0,1735
Desvio padrão da amostra	0,2069	0,1735
Coefficiente de variação	0,0329	0,0258
Amplitude	0,3046	0,2539

Fonte: O autor (2022).

Os histogramas do MGG e do MOG utilizados apresentados permitem ilustrar suas respectivas distribuições de *pixels* por intervalos de altitudes (Figura 202 e Figura 203), se caracterizando por grande similaridade. Os picos primários do histograma (valores mais comuns) do MGG de alta resolução encontram-se entre os valores de altitude 6,3 e 6,9 metros. Já os picos primários do histograma do MOG de baixa resolução encontram-se entre os valores de altitude de 6,1 metros e 6,5 metros. Não se verificou a ocorrência de *outliers*. Não houve um bom ajuste em relação à curva de Gauss.




Figura 202 - Histograma mostrando a distribuição dos *pixels* do MOG (imagem) de baixa resolução em função de valores altimétricos
Fonte: O autor (2022).




Figura 203 - Histograma mostrando a distribuição dos *pixels* do MGG (imagem) de alta resolução modelo em função de valores altimétricos
Fonte: O autor (2022).

4.7.2 Análise dos processamentos DEM-ESRGAN P16, P17 e P18

Ao término dos processamentos DEM-ESRGAN P16, P17 e P18, verificou-se que os resultados obtidos, após a realização de análise visual, não

atenderam ao comportamento esperado de super-resolução do algoritmo utilizado. Assim sendo, se executou dois processamentos adicionais com dois *datasets* aditivos, onde os valores das imagens de alta e baixa resolução foram multiplicados por 100 e por 1000. Da realização de tais processamentos adicionais, com 10.000 épocas cada um, verificou-se que o *dataset* com valores multiplicados por 100 apresentou comportamento esperado de super-resolução verificado com a realização de análise visual.

Dessa forma, utilizando-se o *dataset* com valores multiplicados por 100, foram realizados 3 (três) processamentos DEM-ESRGAN com 10.000, 50.000 e 100.000 épocas.

Ao término dos processamentos, foram calculados os valores de suas referidas métricas PSNR. Em relação a este quesito, o primeiro processamento (P16) apresentou o PSNR de 41,934, o segundo processamento (P17) apresentou o PSNR de 49,492, enquanto o terceiro (P18) apresentou um PSNR de 45,101.

Durante os processamentos, verificou-se que ocorre uma variação oscilatória na progressão dos valores do PSNR, não ocorrendo dessa maneira um crescimento contínuo com o decorrer do tempo (Figura 204).




Figura 204 - Variação dos valores da métrica do PSNR dos processamentos executados (P16, P17 e P18) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)
Fonte: O autor (2022).

Ao se realizar a comparação do loss l_g perceptron, percebe-se que todos partem de um pico inicial e a partir daí passam a demonstrar uma tendência de aproximação do zero. Percebe-se que os processamentos com mais épocas se aproximaram mais do zero do que os com menos épocas (Figura

205). O Processamento P15 apresentou um pico de 1,089 no valor da perda após passar as 40.000 épocas.



Figura 205 - Variação dos valores apresentados pelas funções de perda l_g_percep de cada um dos processamentos executados (P16, P17 e P18) em função da progressão das épocas dos mesmos (onde k equivale a 1.000)

Fonte: O autor (2022).

Conclui-se, parcialmente, que o 2º processamento do referido experimento apresentou melhor métrica final dentre as apresentadas durante o processamento em si. Já em relação à variação da função de perda L_{percep} , o 3º processamento apresentou menor erro final.

4.7.3 Visualização dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN

A presente análise foi efetuada com os resultados dos 3 (três) processamentos realizados, resultando na visualização das imagens geradas pelo algoritmo DEM-ESRGAN, das imagens de baixa resolução e das imagens de alta resolução. Nessa visualização, colocou-se lado a lado, para comparação, as três imagens equivalentes, estando a de menor resolução à esquerda, a gerada ao centro e a de maior resolução à direita.

Dessa forma, a visualização permite a comparação perceptiva da imagem gerada com a imagem original de baixa resolução e o alvo de alta resolução. Pôde-se observar que todas as imagens geradas analisadas apresentaram grande semelhança com as respectivas imagens de alta resolução (Figura 206 a Figura 214).




Figura 206 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P16.
Fonte: O autor (2022).




Figura 207 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P16.
Fonte: O autor (2022).




Figura 208 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P16.
Fonte: O autor (2022).




Figura 209 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P17.
Fonte: O autor (2022).




Figura 210 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P17.
Fonte: O autor (2022).




Figura 211 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P17.
Fonte: O autor (2022).




Figura 212 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 1 do processamento P18.
Fonte: O autor (2022).




Figura 213 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 2 do processamento P18.
Fonte: O autor (2022).




Figura 214 - Exemplo da imagem gerada pelo algoritmo DEM-ESRGAN (centro), da imagem de alta resolução (direita) e da imagem de baixa resolução (esquerda) da imagem 3 do processamento P18.
Fonte: O autor (2022).

Como conclusão parcial, verificou-se que as imagens do processamento P17 apresentaram maior proximidade com as imagens de alta resolução do que as imagens do demais processamentos do experimento.

4.7.4 Análise do Padrão de Exatidão Cartográfico Altimétrico

A avaliação da exatidão posicional altimétrica tem como base a análise dos resíduos entre as coordenadas de pontos retirados de um produto cartográfico e seus homólogos observados em outro produto. Para a realização da análise do Padrão de Exatidão Cartográfico Altimétrico foi calculada, inicialmente, a matriz de diferença dos *pixels* de cada par de imagens (*ground truth* e gerado). Calculou-se em seguida o Erro Médio (EM) e o Erro Padrão (EP), para então verificar as escalas adequadas a serem utilizadas pelo produto avaliado (Tabela 51 e Tabela 52).

Tabela 51 - Tabela dos valores calculados do Erro Médio e do Erro Padrão das imagens geradas nos respectivos processamentos

Processamento	Imagem	Resolução Inicial	Resolução final	EM	EP
P16	1	90 metros	30 metros	-4,257	2,291
	2			-2,523	2,680
	3			3,985	2,466
	4			5,179	2,166
P17	1	90 metros	30 metros	-2,361	2,333
	2			-1,591	2,243
	3			-1,142	7,752
	4			2,145	5,988
P18	1	90 metros	30 metros	-0,601	0,449
	2			-1,051	0,454
	3			-1,320	1,033
	4			-0,742	1,213

Fonte: O autor (2022).

Tabela 52 - Tabela do PEC altimétrico atingido pelas imagens geradas nos respectivos processamentos para as escalas do mapeamento sistemático

Processamento	Imagem	1:250000	1:100000	1:50000	1:25000
P16	1	Classe A	Classe A	Classe A	Classe A
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A
P17	1	Classe A	Classe A	Classe A	Classe A
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe B
	4	Classe A	Classe A	Classe A	Classe A
P18	1	Classe A	Classe A	Classe A	Classe A
	2	Classe A	Classe A	Classe A	Classe A
	3	Classe A	Classe A	Classe A	Classe A
	4	Classe A	Classe A	Classe A	Classe A

Fonte: O autor (2022).

Como conclusão parcial do experimento, verificou-se que o processamento P18 alcançou os menores erros médio e erros padrão dentre as imagens avaliadas. Comparando-se ainda o P16 e P17, verificou-se melhores valores calculados no primeiro.

4.8 SÍNTESE DOS EXPERIMENTOS ANALISADOS

Quanto às análises dos processamentos DEM-ESRGAN, verificou-se que os processamentos com um maior número de épocas tendem a apresentar maiores valores da métrica PSNR e menores valores dos *losses*.

Quanto às análises da variação de erro e precisão das imagens geradas pelos processamentos DEM-ESRGAN, verificou-se que os processamentos com um maior número de épocas tendem a apresentar menores médias de erro e precisão das imagens avaliadas.

Quanto às avaliações estatísticas de imagens geradas pelos processamentos DEM-ESRGAN, verificou-se que os ganhos de erro e precisão de imagens geradas (em metros), os erros e precisões de imagens geradas (em metros), os ganhos das imagens geradas em relação a imagem LR em número de *pixels*, e as análises do número de *pixels* com erros menores nas imagens geradas foram superiores nos processamentos com maior número de épocas.

Quanto às avaliações das métricas dos processamentos DEM-ESRGAN, os processamentos com maior número de épocas apresentaram melhores desempenhos em relação a tais índices.

Quanto às visualizações dos MDEs de baixa resolução, alta resolução e gerados pelo DEM-ESRGAN, verificou-se que, em sua grande maioria, as imagens geradas se assemelharam com as imagens de alta resolução.

Quanto às comparações do algoritmo DEM-ESRGAN com outros métodos de interpolação, verificou-se que o desempenho do algoritmo DEM-ESRGAN com o maior número de épocas foi superior a todos os demais métodos avaliados.

Quanto às avaliações da preservação das feições do terreno das imagens geradas pelo algoritmo DEM-ESRGAN, verificou-se que, em relação à

preservação de pontos críticos (valores altimétricos máximos e mínimos do terreno), em relação à declividade do terreno e do aspecto dos MDEs originais de alta resolução e dos MDEs gerados, em relação às linhas estruturais (canais de drenagem e cumeeiras) nos MDEs de alta resolução e nos MDEs gerados, em relação à subtração entre superfícies altimétricas, e em relação ao traçado de curvas de nível, os processamentos mostraram grandes similaridades tanto em relação aos *datasets* quanto em relação ao número de épocas dos processamentos em si.

O Experimento 4 apresentou elementos diferentes em seus canais de drenagens, sendo verificados alguns canais mais largos nos MDEs gerados. Já em relação ao Experimento 5, não foram alcançados resultados comparáveis às imagens de alta resolução.

Quanto à utilização das métricas para avaliação dos produtos geoespaciais gerados, verifica-se maior adequação ao emprego do RMSE, seguido do MSE, por expressarem valores métricos em seus resultados, diferentemente do PSNR, do SSIM e do NIQE. Os valores apresentados por essas métricas (PSNR, SSIM e NIQE) não permitem intuir o comportamento das modelagens.

Considera-se que, embora utilizado na avaliação das superfícies geradas, o aspecto e a declividade são apenas passíveis de uma avaliação qualitativa visual. Para uma avaliação quantitativa, não realizada no trabalho, seria necessário obter métricas de cada porção da superfície.

5 CONCLUSÕES E RECOMENDAÇÕES

A super-resolução de imagens é um tema clássico dentro do campo da visão computacional, que pode ser amplamente aplicado em tarefas relevantes. Tal técnica tem atraído a atenção de pesquisadores de diferentes áreas por permitir recuperar detalhes de textura de alta qualidade a partir de imagens de baixa resolução. Hoje em dia, com o desenvolvimento do *deep learning*, tal técnica tem feito bastante progresso.

5.1 CONCLUSÕES

A presente pesquisa procurou efetuar a adaptação e o treinamento de algoritmo de aprendizagem profunda (GAN) para que fosse capaz de melhorar a resolução espacial de superfícies com informações altimétricas (MDEs, MOGs e MGGs) e avaliar os resultados obtidos, criando para isso *datasets* que permitissem a efetiva inserção dos modelos digitais de elevação em estudos de super-resolução de imagens. Dessa forma, apresentou uma análise do aumento de resolução espacial efetivamente obtido nos experimentos e verificou a potencialidade da utilização dos modelos digitais de elevação gerados utilizando o *Generative Adversarial Network* na produção cartográfica para a extração de dados altimétricos.

Realizar o aumento de resolução de um MDE pode parecer idêntico à super-resolução de uma imagem ou fotografia, entretanto as características peculiares do primeiro o tornam muito mais complexos, como as características do terreno e as diferenças de elevação maiores do que das imagens naturais. Outra dificuldade encontrada é a falta de dados de MDE para a realização de treinamento.

Considerando as análises e comparações estatísticas apresentadas neste trabalho, verificou-se que aumentar o número de iterações é favorável ao desempenho do modelo gerado e à qualidade da imagem gerada. Isso indica que a metodologia proposta é construtiva e cumpre a tarefa do SISR ao gerar uma imagem MDE de alta resolução a partir de uma única imagem MDE de baixa resolução.

Embora tenha sido observada uma variação oscilatória do PSNR ao longo do tempo, esse resultado conflitante também pode ser um indicativo de que, apesar do PSNR ser a métrica de pontuação no algoritmo GAN, o PSNR sozinho pode não ser um indicador de qualidade suficiente, justificando a busca de alternativas para as abordagens tradicionais baseadas em PSNR.

Além disso, o DEM-ESRGAN mostrou uma melhoria substancial nas métricas de qualidade em comparação com os métodos tradicionais de interpolação nas execuções de benchmark. Portanto, o desenvolvimento de modelos digitais de elevação de super-resolução é oportuno, dados os avanços tecnológicos nas áreas de inteligência artificial, sensores orbitais e recursos computacionais. Nesse contexto, pesquisas futuras estão previstas para aprofundar as investigações aqui apresentadas, incluindo estudos com MDEs de diferentes resoluções espaciais.

A escala de aumento de resolução das imagens configurada para o algoritmo DEM-ESRGAN foi de quatro vezes (4x) o valor da imagem de pior resolução em relação à imagem de maior resolução, o que influenciou na qualidade dos processamentos realizados nos diferentes *datasets*. Assim sendo, um fator importante para a melhora na resolução espacial dos MDEs de menor resolução não foi o fato do insumo de maior resolução utilizado ser de alta resolução espacial, mas sim a proporcionalidade entre os seus *pixels* (relação de proporção entre os *pixels* de alta e de baixa resolução).

As métricas são medidas quantificáveis que servem para avaliar os resultados dos processamentos realizados. Quanto à análise das métricas de tais processamentos, verificou-se que a implementação de cinco diferentes métricas de avaliação das imagens geradas permitiu maior poder de análise à pesquisa. Destaca-se que, dentre as métricas utilizadas (PSNR, SSIM, NIQE, MSE e RMSE), a duas primeiras apresentam valores diretamente proporcionais e as 3 (três) últimas apresentam valores inversamente proporcionais. Ainda quanto à utilização das métricas para avaliação dos produtos geoespaciais gerados, verificou-se maior adequação ao emprego do RMSE, seguido do MSE, por expressarem valores métricos em seus resultados, diferentemente do PSNR, do SSIM e do NIQE. Os valores apresentados por essas métricas (PSNR, SSIM e NIQE) não permitem intuir o comportamento das modelagens.

Outra métrica importante usada foi a checagem de PEC planimétrico e PEC altimétrico, sendo uma contribuição bastante importante para as comparações realizadas na presente pesquisa.

Como ponto forte, o DEM-ESRGAN apresentou grande possibilidade de modelar superfícies altimétricas com grandes variações de altitude. Já em relação a superfícies com pouca variação de altitudes, o algoritmo em questão não apresentou tão bom desempenho quanto em relação às superfícies citadas anteriormente.

Da análise visual das imagens geradas, imagens de baixa resolução e imagens de alta resolução utilizadas na pesquisa, percebeu-se a grande semelhança entre as imagens geradas e suas respectivas imagens de alta resolução.

Verificou-se, ainda, que o contexto atual para o estudo de super-resolução de modelos digitais de elevação é oportuno, tendo em vista os avanços tecnológicos nas áreas de inteligência artificial, sensores orbitais e recursos computacionais definidos na referida conjuntura.

5.2 RECOMENDAÇÕES

Resultam dessa pesquisa as seguintes recomendações para trabalhos futuros permitindo novos e diferentes estudos em super-resolução de imagens com modelos digitais de superfície:

- Construir novos *datasets*, com diferentes modelos digitais de elevação não utilizados nessa pesquisa, novos *datasets* considerando as imagens originais sendo as de alta resolução, e as suas respectivas degradações como as de baixa resolução, novos *datasets* com diferentes modelos digitais de elevação de diferentes resoluções espaciais e novos *datasets* em diferentes áreas de estudo;

- Desenvolver novas metodologias utilizando diferentes algoritmos de super-resolução de imagens GAN;

- Desenvolver novas metodologias para superfícies com pequenas variações altimétricas;

- Variar os experimentos realizados nessa tese alterando o número de iterações do algoritmo de aprendizagem profunda;
- Variar o tamanho dos *datasets* construídos para a realização dos treinamentos das máquinas de aprendizagem, de forma a verificar se há correlação entre o tamanho dos mesmos e os resultados dos experimentos;
- Variar os hiperparâmetros do modelo, entre eles o tamanho do *batch size* das imagens dos *datasets*, de forma a verificar os seus efeitos no treinamento do modelo;
- Verificar a viabilidade de modelar com o DEM-ESRGAN MDEs que contenham extensões territoriais maiores que o experimento;
- Verificar o potencial de aplicabilidade das superfícies geradas nas escalas de mapeamento sistemático 1:250000, 1:100000, 1:50000 e 1:25000;
- Desenvolver uma metodologia para a realização do cálculo da diferença de declividade de cada um dos pixels dos modelos avaliados;
- Desenvolver uma metodologia para a realização da medição das distâncias entre as cumeeiras de alta resolução e geradas pelo algoritmo;
- Desenvolver uma metodologia para a realização da medição das distâncias entre as linhas de drenagem de alta resolução e geradas pelo algoritmo;
- Desenvolver uma metodologia para verificação da tendenciosidade das diferenças entre superfícies utilizando o teste T de Student e apresentando os referidos histogramas.

Por fim, acredita-se que os conceitos e metodologia apresentados possibilitaram explorar a utilização de dados geoespaciais em ambientes de inteligência artificial com técnicas de super-resolução de imagens (no caso, MDEs), contribuindo para o avanço da discussão sobre o tema. No campo computacional, as inovações metodológicas apresentadas são originais na área das ciências geodésicas e apresentam soluções que podem ser utilizadas por especialistas das áreas de fotogrametria, sensoriamento remoto, cartografia, geodésia, com possibilidade de extensão para outros contextos diferentes.

REFERÊNCIAS BIBLIOGRÁFICAS

ANGAR, Vinícius et al. **Verificação Altimétrica Dos MDEs SRTM, Alos-Palsar E Astergdem Em Uma Linha De Talvegue Em Vale Escarpado Na Serra Gaúcha.** 2019.

ALOM, Md Zahangir et al. **A state-of-the-art survey on deep learning theory and architectures.** Electronics, v. 8, n. 3, p. 292, 2019.

ALOM, M. Z., TAHA, T. M., YAKOPCIC, C., WESTBERG, S., SIDIKE, P., NASRIN, M. S., ASARI, V.K.; 2018. **The history began from AlexNet: A comprehensive survey on deep learning approaches.** arXiv preprint arXiv:1803.01164 [cs.CV].

ARAKI, H. **Filtro de matriz 3x3.** Algoritmo que faz a filtragem de *pixels* negativos de uma imagem. 2021.

ARAKI, H., MOREIRA, L. A. **Statistics_maker.** Algoritmo que faz as análises estatísticas das imagens de alta resolução, baixa resolução e a imagem gerada pelo algoritmo MDTESRGAN. 2021.

Berthier, E., Y. Arnaud, C. Vincent, and F. Remy. 2006. **“Biases of SRTM in High-Mountain Areas: Implications for the Monitoring of Glacier Volume Changes.”** Geophysical Research Letters 33 (8): L08502. doi:10.1029/2006GL025862.

Bhang, K. J., and F. Schwartz. **“Limitations in the Hydrologic Applications of C-Band SRTM DEMs in Low-Relief Settings.”** IEEE Geoscience. Remote Sensing. Letter 5 (3): 497–501. doi:10.1109/ LGRS.2008.920712. 2008.

BARR, A.; FEIGENBAUM, E. A; 1981. **The Handbook of Artificial Intelligence (v. I-II).** Los Altos: Willian Kaufmann Inc.

BITTENCOURT, G.; **Breve História da Inteligência Artificial.** Disponível em:

<<http://www.das.ufsc.br/gia/history/history.html>>. Acesso em: 03 jul. 2000.

BLAU, Y., MICHAELI, T.; **The perception-distortion tradeoff**. Cornell University. 2018. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 6228-6237. DOI: 10.1109/CVPR.2018.00652.

Bourgine, B., and N. Baghdadi. 2005. **“Assessment of C-Band SRTM DEM in a Dense Equatorial Forest Zone.”** Comptes Rendus Geoscience 337 (14): 1225–1234. doi:10.1016/j.crte.2005.06.006.

BRASIL. **Decreto nº 89.817, de 20 de junho de 1984**. Estabelece as Instruções Reguladoras das Normas Técnicas da Cartografia Nacional. 1984. Disponível em: . Acesso em: 5 nov. 2012.

BROOKS, R.; TEGMARK; Max.Discovery Brasil. **Inteligência Artificial**. IBM. 2018.

Brown, C. G., K. Sarabandi, and L. E. Pierce. 2010. **“Model-Based Estimation of Forest Canopy Height in Red and Austrian Pine Stands Using Shuttle Radar Topography Mission and Ancillary Data: A Proof-Of-Concept Study.”** IEEE Transactions on Geoscience and Remote Sensing 48 (3): 1105–1118. doi:10.1109/TGRS.2009.2031635.

BRUBACHER, João Paulo et al. **Avaliação de bases SRTM para extração de variáveis morfométricas e de drenagem**. Geosciences. Geociências, v. 31, n. 3, p. 381-393, 2012.

CHANG, H., YEUNG, D. Y. e XIONG, Y., **“Super-Resolution through Neighbor Embedding”**. In IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 275–282, 2004.

CHAPLOT, V.; DARBOUX, F.; BOURENNANE, H.; LEGUÉDOIS, S.; SILVEIRRA, N.; PHACOMPHON, K. **Accuracy of interpolation techniques for**

the derivation of digital elevation models in relation to landform types and data density. *Geomorphology*, v. 77, n. 1, p. 126-141, 2006.

CHARNIAK, E.; MCDERMOTT, D.; **A Bayesian Model of Plan Recognition.** Massachusetts: Addison-Wesley, 1985.

CHAUDHURI, S., **Super-Resolution Imaging.** Kluwer Academic Publishers, 2001.

CHEON, M., KIM, J., CHOI, J., LEE, J.; **Generative Adversarial Network-based Image Super-Resolution using Perceptual Content Losses.** Computer Vision Foundation. 2018.

CHOPPIN, B.; **Inteligência artificial.** Rio de Janeiro: LTC, 2010.

CRUZ, C. B. M.; BARROS, R. S.; CARDOSO, F. V.; REIS, F. B.; ROSÁRIO, L. S.; BARBOSA, S. S.; RABACO, L. M. L.; LOURENÇO, J. S. Q. 2011. **Avaliação da exatidão planialtimétrica dos modelos digitais de superfície (MDS) e do terreno (MDT) obtidos através do LIDAR.** Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba: INPE 2011. p. 5463.

DA SILVA CELESTINO, Vivian; PHILIPS, Jürgen Wilhelm. **Avaliação Altimétrica Srtm E Aster Gdem Em Áreas De Relevos Diferenciados.** Revista Brasileira de Cartografia. 2016.

OUYDEAN, Thomas; ALLEN, James; ALOIMONOS, Yiannis. **Artificial intelligence: theory and practice.** Addison-Wesley Publishing Company, Menlo Park, 1995. 563p.

DA SILVA JÚNIOR, Juarez Antônio et al. **Análise de acurácia altimétrica para dados ALOS PALSAR e ASTER GDEM para o município do Recife-PE.** Revista Brasileira de Geomática, v. 10, n. 2, p. 117-139, 2022.

DANTAS, Maria Jorgiana Ferreira. **Evapotranspiração na sub-bacia do Riacho Jardim–CE, por sensoriamento remoto**. 2013.

DEMIRAY, B. Z., SIT, M., DEMIR, I. **D-SRGAN: DEM Super-Resolution with Generative Adversarial Networks**. 2020.

DE OLIVEIRA, Guilherme Garcia; GUASSELLI, Laurindo Antonio; SALDANHA, Dejanira Luderitz. **Avaliação Da Qualidade Da Drenagem Extraída A Partir De Dados Srtm**. 2009.

DUARTE, Gustavo Garcia Fontes; ASSAD, Maria Leonor Lopes. **Avaliação de MDE obtidos por meio de SRTM**. XIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Florianópolis, Brasil, p. 21-26, 2007.

DSG. Diretoria de Serviço Geográfico, 2011. **Especificação Técnica para Aquisição de Dados Geoespaciais Vetoriais (ET-EDGV)**, Brasília.

DSG. **Norma da especificação técnica para controle de qualidade de dados geoespaciais**. 2a. Edição. Brasília, 2016.

EMBRAPA. **ALOS – Advanced Land Observing Satellite**. Disponível em: <https://www.embrapa.br/satelites-de-monitoramento/missoes/alos>. Acessado em: 04 Jul 2021.

FARR, T. G., ROSEN, P.A., CARO, E., CRIPPEN, R., DUREN, R., HENSLEY, S., KOBRICK, M.; **The Shuttle Radar Topography Mission**. Reviews of Geophysics: 2007.

FERNANDES, A. M. R.; **Inteligência artificial: noções gerais**. Florianópolis: Visual Books, 2003.

FREITAS, S. R. C. de; BLITZKOW, D., **Altitudes e geopotencial**. IGeS Bulletin N, p. 47-62, 1999.

GAIDHANI, Pradeep. **Super-resolution**. from Education Information UK, CVonline, 2020.

GOODFELLOW, I. J., POUGET-ABADIE, J., MIRZA, M., XU, B., WARDEFARLEY, OZAIRY, D. S., COURVILLE, A. e BENGIOZ, Y.; **Generative Adversarial Nets**. Veterinary Immunology and Immunopathology, vol. 155, no. 4, 2013.

HAENLEIN, M; KAPLAN, A; **A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence**. California Management Review. First Published July 17, 2019. <https://doi.org/10.1177/0008125619864925>

IBGE. **MAPGEO2015 – Modelo de ondulação geoidal**. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/10855-modelo-de-ondulacao-geoidal.html?=&t=o-que-e>. Acessado em: 05 Jul 2021.

IBGE. **Mapa índice Digital**. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/31409-mapa-indice-digital.html?=&t=acesso-ao-produto>. Acessado em: 05 Jul 2021.

ISO. ISO 19157: 2013. **Geographic information - Data quality**. International Organization for Standardization (ISO), 2013.

IWASHITA, Fábio; SOUZA FILHO, CR de. **Avaliação da interpolação de dados SRTM 90 m através de dados SRTM 30 m do território americano**. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, v. 14, p. 3927-3934, 2009.

JIANG, Junjun et al. **Noise robust face image super-resolution through smooth sparse representation**. IEEE transactions on cybernetics, v. 47, n. 11, p. 3991-4002, 2016.

JUNIOR, M. A. B. G. T., **Super-resolução de imagens de sensoriamento remoto**. Tese. Universidade de Brasília. Brasília, 2008. 123 p.

KURZWEIL, R.; **The Age of Spiritual Machines**. Massachusetts: The MIT Press, 1990.

LECUN, Y., BOTTOU, L., BENGIO, Y., e HAFFNER, P.; **Gradient-based learning applied to document recognition**. Proceedings of the IEEE, 86(11):2278–2324, 1998.

LEDIG, C.; THEIS, L.; HUSZ, F.; CABALLERO, J.; CUNNINGHAM, A.; ACOSTA, A.; AITKEN, A.; TEJANI, A.; TOTZ, J.; WANG, Z.; WENZHE SHITWEETER. **Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network**. maio 2017.

Li, Z., Zhu, Q., Gold, C., 2005. **Digital Terrain Modeling: Principles and Methodology**. CRC Press, Boca Raton, Florida, p. 319.

LIMA, D. F. V. D., **Desenvolvimento do modelo geoidal local de recife com base em estruturas geodésicas altimétricas: RRNN e GNSS**. Universidade Federal de Pernambuco. Recife, 2017.

LEMOS, M. C.; SOUZA, S. F.; ROCHA, R. S. **Avaliação da qualidade dos dados altimétricos derivado do Shuttle Radar Topographic Mission (SRTM): resultados preliminares**. Anais I Simpósio em Ciências Geodésicas e Tecnologias da Geoinformação, Recife, p. 01-03, 2004.

LUCIEN W. **“Definitions and Terms of Reference in Data Fusion”**. IEEE Transactions on Geosciences and Remote Sensing, vol. 37, no. 3, pp. 1190–1193, 1999.

LUGER, George F. **Inteligência artificial – estruturas e estratégias para a resolução de problemas complexos**. Bookman, Porto Alegre, 2004. 774p.

LUKIM, J. e LEE, J.; "**Deep Residual Network with Enhanced Upscaling Module for Super-Resolution**". 2018, IEEE/CVF Conference on Computer

LUNARDI, O.A.; A.L.T. PENHA e W. CERQUEIRA.; **O Exército Brasileiro e os Padrões de Dados Geospaciais para a INDE**. IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. 2012.

MARANHÃO, V. C. **Modelagem e controle de qualidade de uma infraestrutura de dados espaciais para o Estado de Pernambuco**. Dissertação (Mestrado). Universidade Federal de Pernambuco (UFPE). Recife, 2013.

MARGULIS, Sergio. **Causas do desmatamento da Amazônia brasileira**. 2003.

MÉTRICA. **MAPGEO 2015 - Modelo De Ondulação Geoidal**. Disponível em: <https://metrica.zendesk.com/hc/pt-br/articles/205673019-MAPGEO-2015-Modelo-de-Ondula%C3%A7%C3%A3o-Geoidal>. Acessado em: 05 Jul 2021.

MICELI, B. S., DIAS, F. M., SEABRA, F. M., SANTOS, P. R. A., FERNANDES, M. C.; 2011. **Avaliação vertical de Modelos Digitais de Elevação (MDEs) em diferentes configurações topográficas para médias e pequenas escalas**. Revista Brasileira de Cartografia.

MORAIS JD. 2017. **Avaliação de modelos digitais de elevação provenientes de dados de sensoriamento remoto de distribuição gratuita**. Dissertação (Mestrado em Análise e Modelagem de Sistemas Ambientais). Belo Horizonte: UFMG. 94p.

MOURA, Leonardo Zandonadi; BIAS, EdS; BRITES, Ricardo. **Avaliação da acurácia vertical de modelos digitais de elevação (MDES) nas bacias do Paranoá e São Bartolomeu**. Revista Brasileira de Cartografia, v. 66, n. 01, p. 1-14, 2014.

MOURA-BUENO JM et al. 2016. **Assessment of Digital Elevation Model for Digital Soil Mapping in a Watershed with Gently Undulating Topography**. Revista Brasileira de Ciência do Solo 40: 1-15.

NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 4ª edição revista. Impresso. ISBN: 9788521205401. São Paulo. 2010. 388 páginas.

NUWER, R. **Os lugares do planeta que não estão no mapa**. BBC Future. 4 de dezembro 2014.

OUYANG, W.; WANG, X. **Joint deep learning for pedestrian detection**. IEEE International Conference on Computer Vision (ICCV). 2013.

PAPARODITIS, N.; POLIDORI, L.; **DSM quality: internal and external validation**. In: EGELS, Y.; KASSER, M. Digital Photogrammetry. 1. ed. New York: Taylor & Francis, 2002. 351p.

PASSOS, E. P.; **Inteligência Artificial e Sistemas Especialistas ao Alcance de todos**. 1ª ed., Rio de Janeiro, Livros Técnicos e Científicos Editora Ltda., 1989.

PATHAK, N.; **Artificial Intelligence for .NET: Speech, Language, and Search**. Pauri Garhwal. Apress. 2017.

PEREIRA, Hugo Lopes et al. **Qualidade de Modelos Digitais de Elevação Utilizando Dados do SIGEF: Estudo de Caso para as Sub-Bacias do Ribeirão dos Mangues e Rio Soninho no Estado do Tocantins (Quality of digital elevation models using SIGEF data: Case study for the sub-basins of dos Mangues Stream and Soninho River in the state of Tocantins)**. Revista Brasileira de Geografia Física, v. 12, n. 1, p. 187-200, 2019.

PEREIRA, Gustavo Eduardo; TEN CATEN, Alexandre. **Exatidão cartográfica de três MDE disponíveis para o Estado de Santa Catarina**. Revista de Ciências Agroveterinárias, v. 18, n. 2, p. 258-262, 2019.

PINHEIRO ES. 2006. **Comparação entre dados altimétricos Shuttle Radar Topography Mission, Cartas Topográficas e GPS: numa área com relevo escarpado.** Revista Brasileira de Cartografia 58: 1-9.

PHILLIP, I.; JUN-YAN, Z.; ZHOU, T.; EFROS, A.; **Image-to-Image Translation with Conditional Adversarial Nets.** Computer Vision and Pattern Recognition. 2017.

POOLE, D.; MACKWORTH, A. K.; GOEBEL, R.; **Computational Intelligence: A Logical Approach.** Oxford: Oxford University, 1998.

RÉZIO, A. C. C.; SCHWARTZ, W. R.; PEDRINI, H., **Super-resolução de imagens baseada em aprendizado utilizando descritores de características.** X Congresso Brasileiro de Inteligência Computacional. Nov 2011. Fortaleza, Ceará.

RODRIGUES TG et al. 2011. **Evaluation of the altimetry from SRTM-3 and planimetry from high-resolution PALSAR FBD data for semi-detailed topographic mapping in the Amazon Region.** Anais da Academia Brasileira de Ciências 83: 953-966.

ROSSO, M. P. D., SEBASTIANELLI, A., ULLO, S. L. **Artificial intelligence applied to satellite-based remote sensing data for Earth Observation.** Editora: The Institution of Engineering and Technology, London, United Kingdom. 2021. ISBN 978-1-83953-213-9

RUSSELL, S.; NORVIG, P.; **Artificial intelligence: A modern approach.** Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs, 1995.

SAMPAIO, Tony Vinicius Moreira; RODRIGUES, Tiago Lima; GONÇALVES, José Eduardo. **Acurácia Vertical De Modelos Digitais De Elevação Produzidos Com Diferentes Resoluções Espaciais, Áreas De Abrangência**

E, Processos De Geração—Caso De Estudo Para O Estado Do Paraná-Br. Raega-O Espaço Geográfico em Análise, v. 53, p. 160-181, 2021.

SANTOS, C. N. D.; **Aprendizado de máquina na identificação de sintagmas nominais: o caso do português brasileiro.** Rio de Janeiro, 2005. Disponível em: http://www2.comp.ime.eb.br/dissertacoes/2005-Cicero_Santos.pdf>Acesso em: 29 maio 2012.

SOUZA JOP. 2015. **Análise da precisão altimétrica dos modelos digitais de elevação para área semiárida do nordeste brasileiro.** Revista do Departamento de Geografia 30: 56-64.

SANTOS, PRA dos; GABOARDI, Clovis; OLIVEIRA, LC de. **Avaliação da precisão vertical dos modelos SRTM para a Amazônia.** Revista Brasileira de Cartografia, v. 58, n. 1, p. 101-107, 2006.

SANTOS, S. S.; **O significado da Inteligência Artificial.** Disponível em: <http://www.globalsite.com.br/~sssantos/historic.htm>>. Acesso em: 15 jul 2000.

SCHULTER, S.; LEISTNER, C.; BISCHOF, H.; **Fast and accurate image upscaling with super-resolution forests.** In Conference on Computer Vision and Pattern Recognition. 2015.

SCHIETTI, Juliana et al. **Avaliação do uso de dados SRTM para estudos ecológicos na Amazônia central.** Anais Online do XIII Simpósio Brasileiro de Sensoriamento Remoto (XIII SBSR), INPE, São José dos Campos, SP, 2007.

SEBASTIANELLI, Alessandro et al. **Spatio-Temporal SAR-Optical Data Fusion for Cloud Removal via a Deep Hierarchical Model.** arXiv preprint arXiv:2106.12226, 2021.

SIGSC. **SIGSC – Sistema de Informações Geográficas.** Disponível em: <http://sigsc.sc.gov.br/>. Acessado em: 04 Jul 2021.

SIMÕES, Philipe Souza et al. **Avaliação da acurácia vertical de modelos digitais de elevação derivados de diferentes sensores orbitais para Belém-PA.** 2019.

SIMÕES, Margareth Gonçalves. **Modeladores digitais de terreno em sistemas de informação geográfica.** UFRJ, 1993.

SIRGAS. **Grupo de Trabalho III.** Disponível em: <https://sirgas.ipgh.org/pt/organizacao/grupos-de-trabalho/grupo-de-trabalho-iii/>. Acessado em: 04 Jul 2022.

STERNE, J. **Artificial Intelligence for Marketing – Practical Applications.** Wiley. New Jersey, 2017.

TEIXEIRA J.; GONZALEZ M.; **Inteligência artificial e teoria de resolução de problemas.** 2019.

TSAI, R. Y., HUANG, T. S. 1984. **Multiframe image restoration and registration.** *Advances in Computer Vision and Image Processing.* pp. 317-339, JAI Press Inc.

VARGAS, A. C. G.; CARVALHO, A. M. P.; VASCONCELOS, C. N.; **Um estudo sobre Redes Neurais Convolucionais e suas aplicações em detecção de pedestres.** Instituto de Computação. Universidade Federal Fluminense. Niterói, Brasil. 2016.

VIEL, Jorge Antônio; ROSA, Kátia Kellem da; MENDES JUNIOR, Claudio Wilson. **Avaliação da Acurácia Vertical dos Modelos Digitais de Elevação SRTM, ALOS World 3D e ASTER GDEM um estudo de caso no Vale dos Vinhedos, RS, Brasil.** *Revista Brasileira de Geografia Física.* Recife. Vol. 13, n. 5 (2020), p. 2255-2268, 2020.

WANG, X.; YU, K., WU, S.; GU, J.; LIU, Y.; DONG, C; QIAO, Y.; LOY, C. C.;
ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks.
2018.

Weydahl, D. J., J. Sagstuen, O. B. Dick, and H. Ronning. 2007. **“SRTM DEM Accuracy Assessment over Vegetated Areas in Norway.”** International Journal of Remote Sensing 28 (16): 3513–3527. doi:10.1080/01431160600993447.

YAN, L., TANG, X., ZHANG, Y. **High Accuracy Interpolation of DEM Using Generative Adversarial Network.** Remote Sensing MDPI. 2021. <https://doi.org/10.3390/rs13040676>.

YU, H., XIANG, M., HUA, H. e CHUN, Q., **“Face Image Super-Resolution through POCS and Residue Compensation”.** IET Conference Publications, pp. 494–497, 2008.

ZHANG, Yifan; YU, Wenhao. **Comparison of DEM Super-Resolution Methods Based on Interpolation and Neural Networks.** Sensors, v. 22, n. 3, p. 745, 2022.

Zhang, Q., Q. Yang, and C. Wang. 2016. **“SRTM Error Distribution and Its Associations with Landscapes across China.”** Photogrammetric Engineering & Remote Sensing 82 (2): 135–148. doi:10.14358/PERS.83.2.135.

ZEILER, M. D. e FERGUS, R.; **Computer Vision – ECCV 2014:** 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I. Springer International Publishing, 2014, ch. Visualizing and Understanding Convolutional Networks, pp. 818–833.

ZHOU, Qiming; LIU, Xuejun. **Analysis of errors of derived slope and aspect related to DEM data properties.** Computers & Geosciences, v. 30, n. 4, p. 369-378, 2004.

ANEXO 1

SÍNTESE DA *PIPELINE*

A *pipeline* é uma sequência, um processo ou procedimentos seguidos pelo Data Science com a destinação de se alcançar os objetivos específicos, e que requer do pesquisador determinados passos na preparação, análise e apresentação dos dados. Eles são dispostos de maneira que a saída de cada elemento seja a entrada do próximo. Com o intuito de sintetizar tais procedimentos adotados, foi construído um fluxograma com todas as etapas abarcadas (Figura 215). O termo também é bastante utilizado com o intuito de se entender um determinado ciclo, como um mapa das etapas que compõem esse ciclo do seu início ao fim. Ele possibilita ainda o *follow up* do processo, ou seja, o acompanhamento de todas as fases do mesmo.

Foi desenvolvido também para o acompanhamento da presente pesquisa a pipeline das análises estatísticas, análises visuais e análise dos padrões cartográficos desenvolvidas para serem aplicadas após os processamentos realizados pelo algoritmo DEM-ESRGAN (Figura 216). Finalmente, foram elaborados fluxogramas-síntese das análises visuais adotadas na pesquisa e das análises do PEC (Figura 217 e Figura 218).

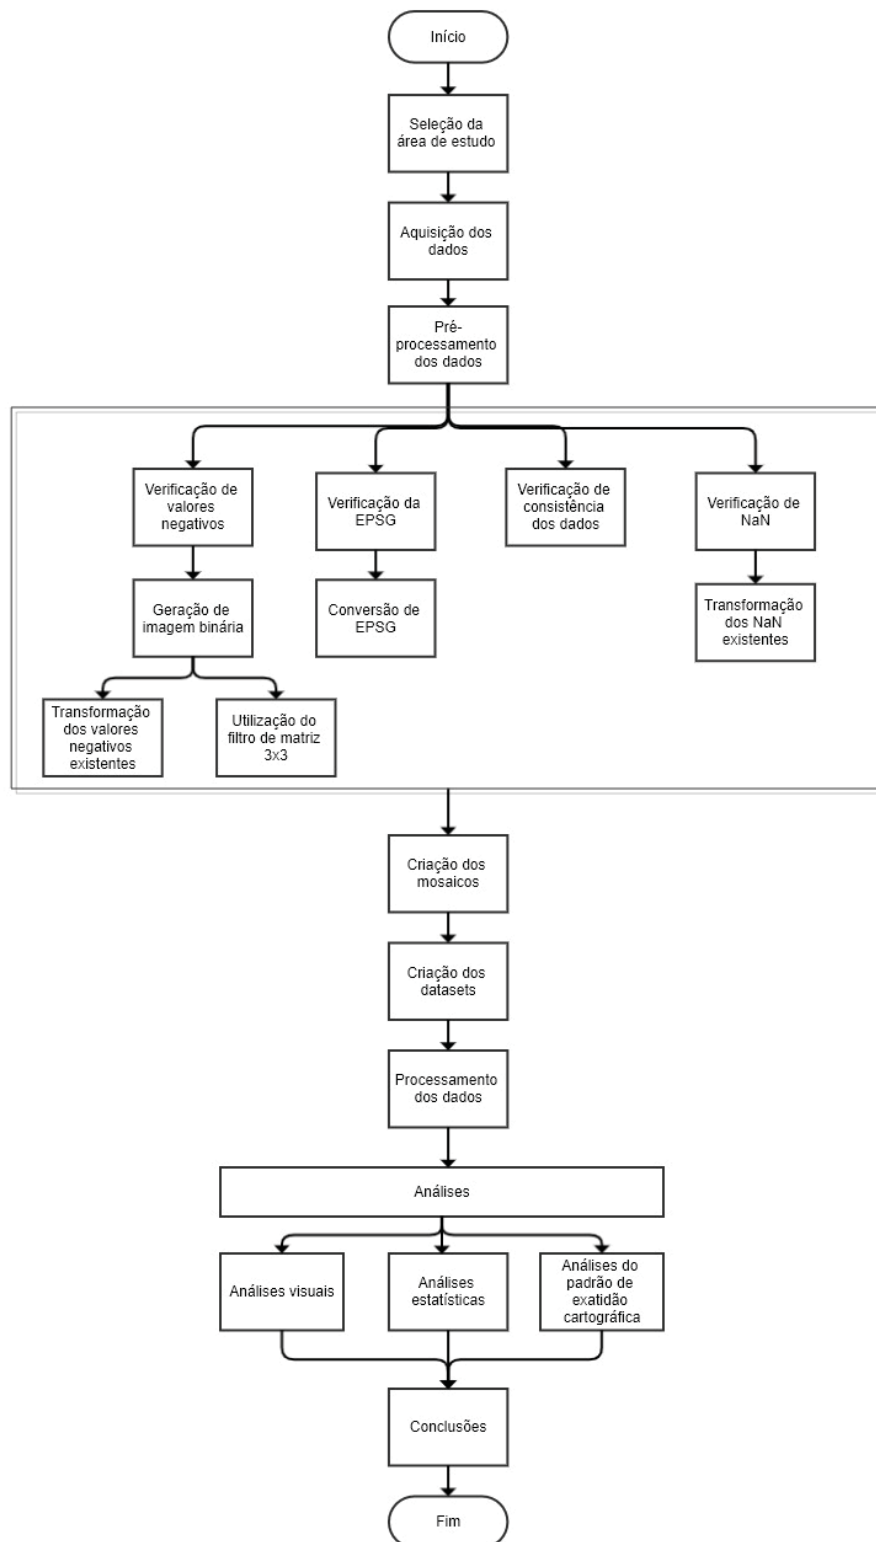


Figura 215 - Fluxograma-síntese da pipeline adotada na pesquisa.
Fonte: O autor (2022).

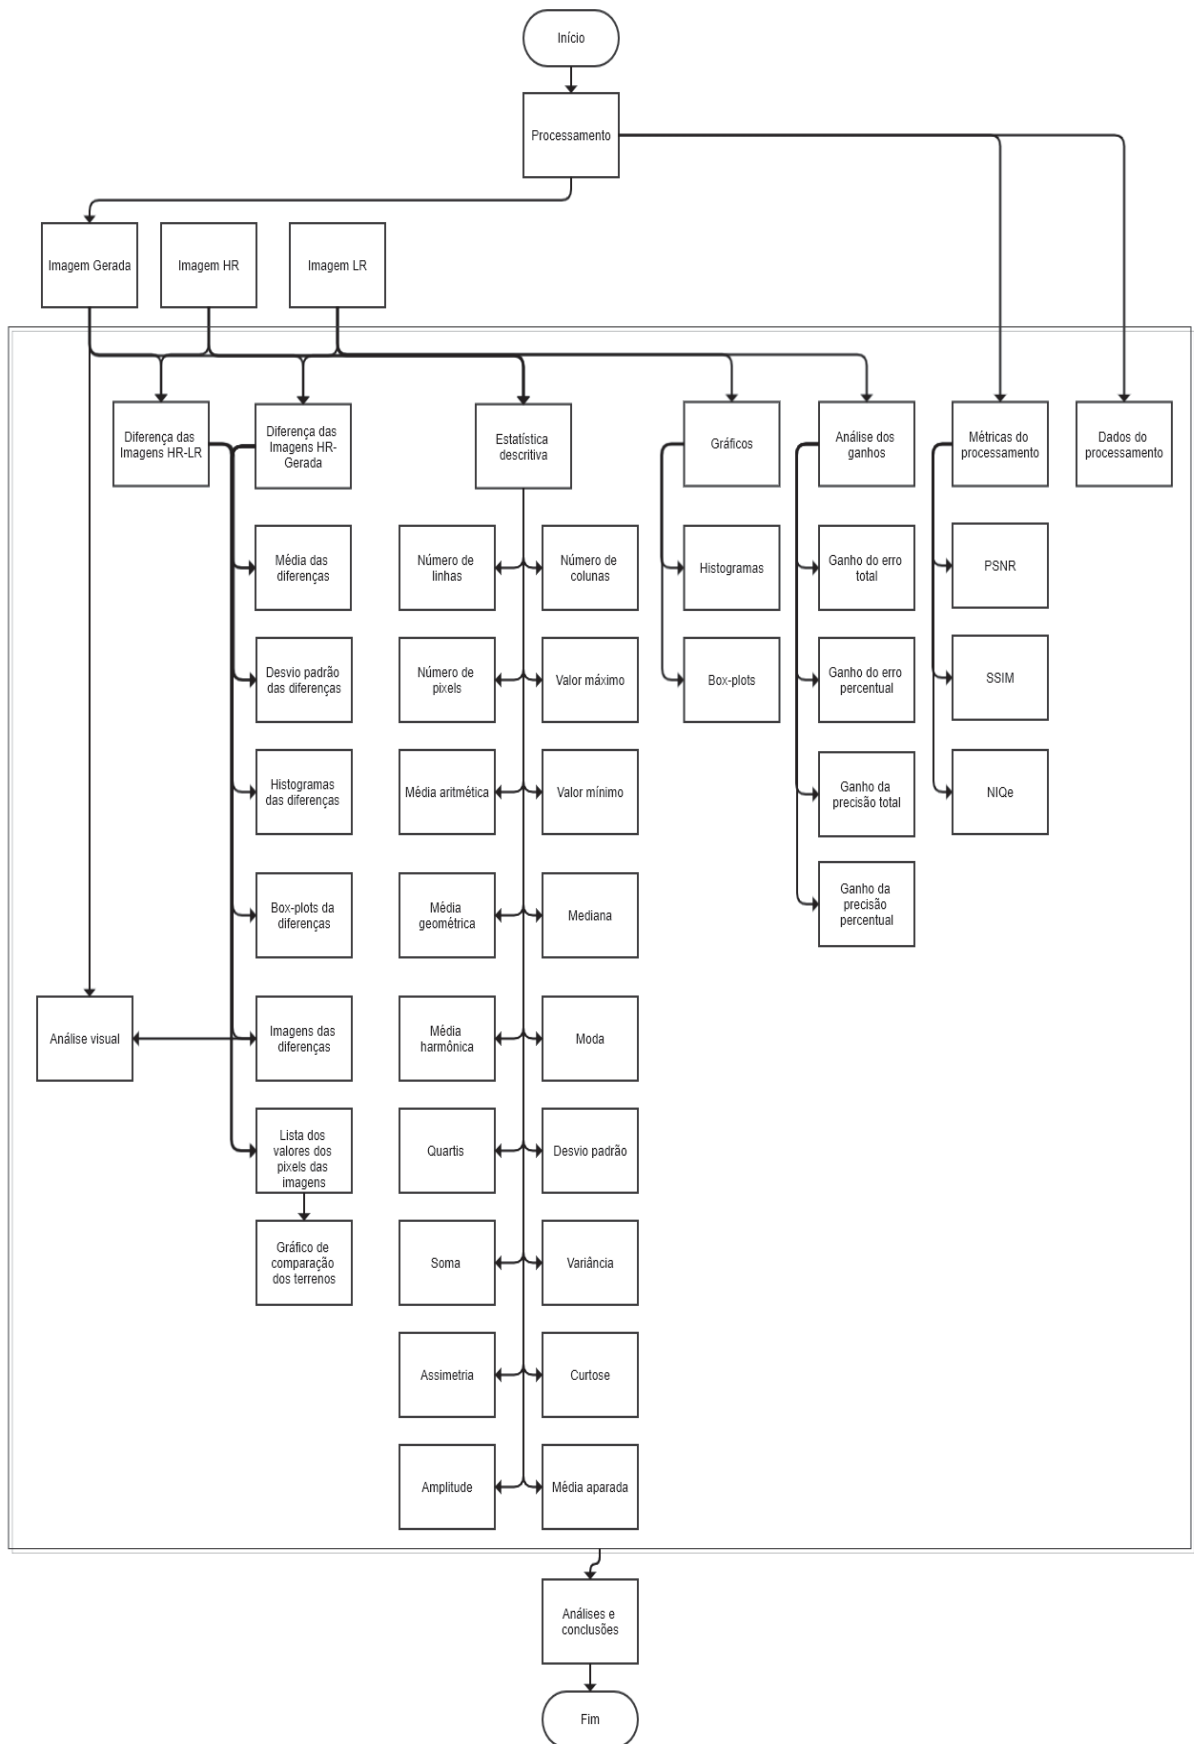


Figura 216 - Fluxograma-síntese da pipeline adotada nas análises estatísticas da pesquisa. Fonte: O autor (2022).

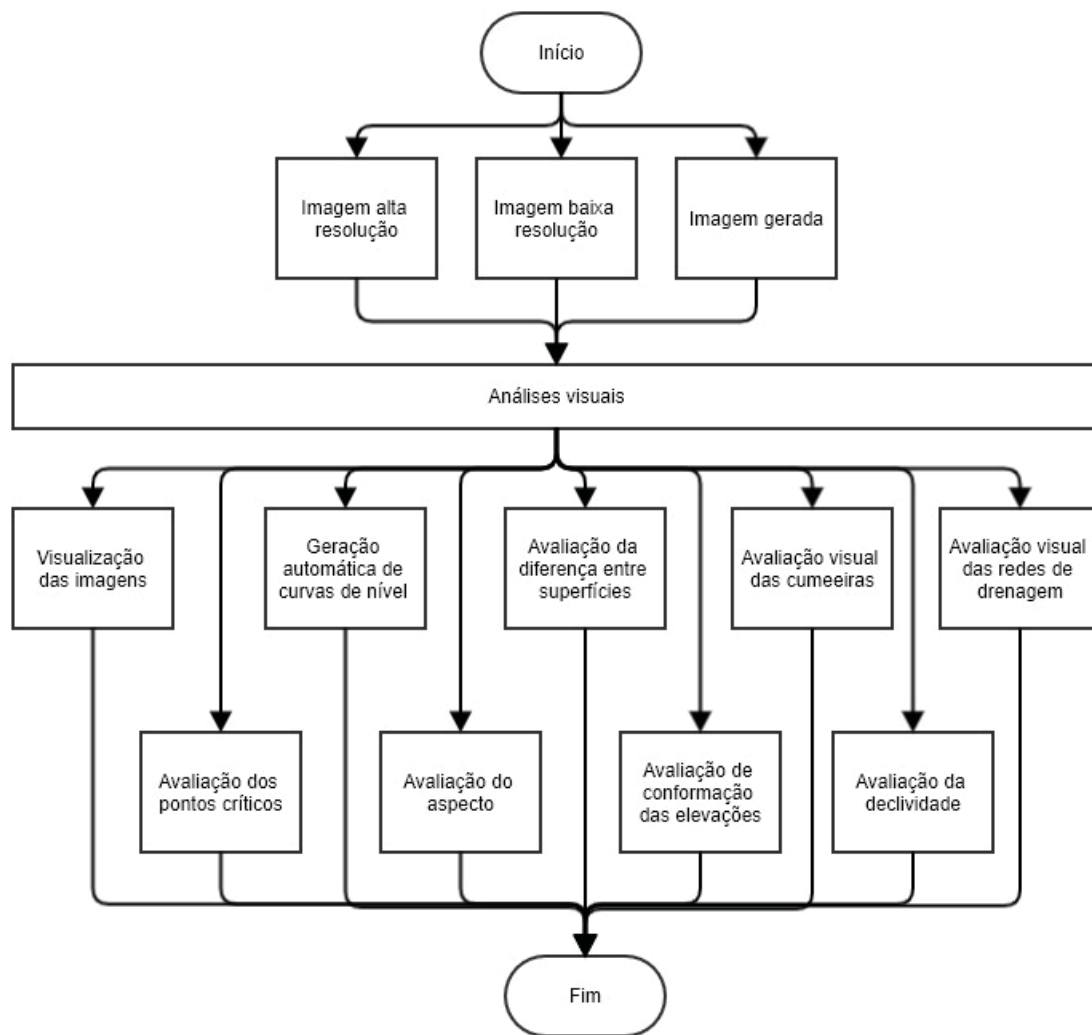


Figura 217 - Fluxograma-síntese da pipeline adotada nas análises visuais da pesquisa.
Fonte: O autor (2022).

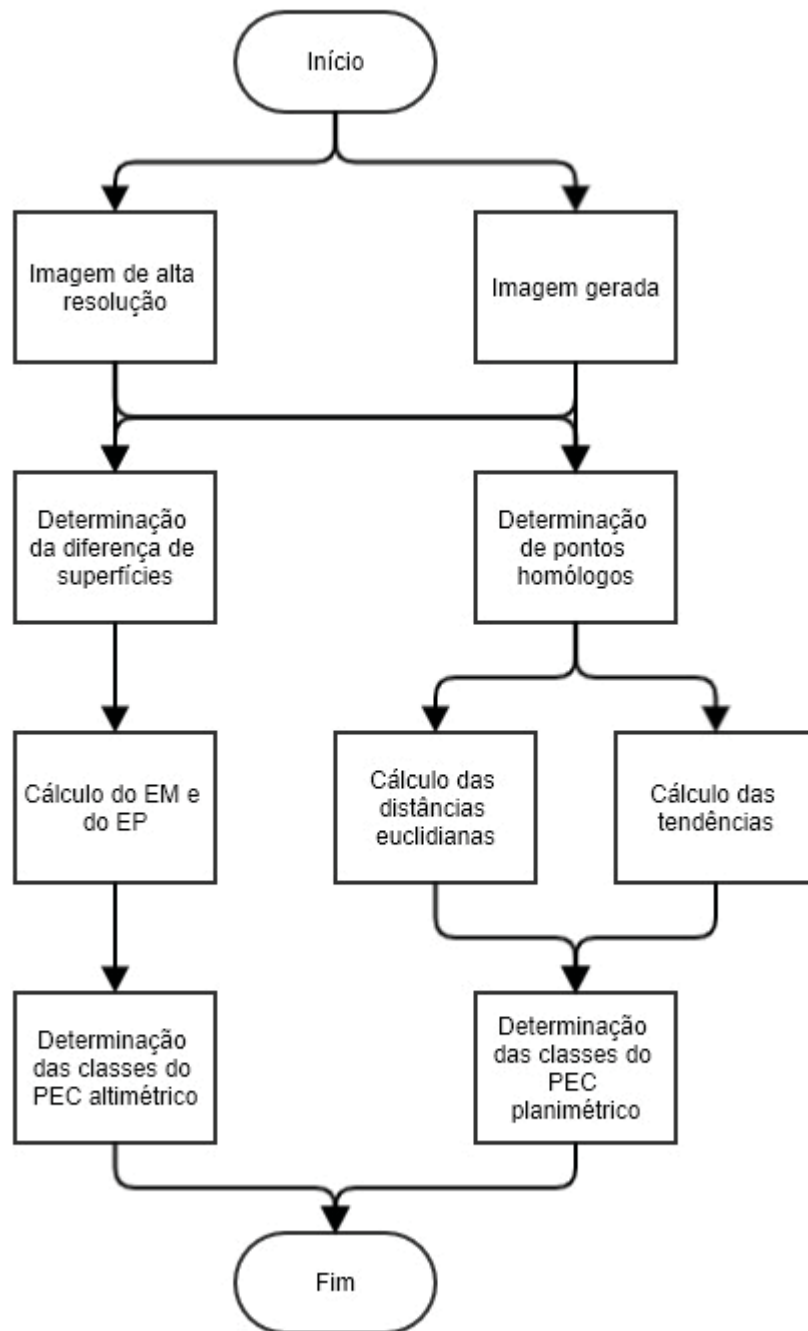


Figura 218 - Fluxograma-síntese da pipeline adotada nas análises do padrão de exatidão cartográfica da pesquisa.
Fonte: O autor (2022).