



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc m21d/2022/09.05.21.28-TDI

**GEOMORFOMETRIA REGIONAL APLICADA AO
MAPEAMENTO DE FORMAS DE RELEVO NA BACIA
HIDROGRÁFICA DO RIO DEMINI - AMAZÔNIA
SETENTRIONAL**

Karolina Gameiro Cota Dias

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Márcio de Morisson
Valeriano, aprovada em 15 de
agosto de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/47J6GP8>>

INPE
São José dos Campos
2022

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc m21d/2022/09.05.21.28-TDI

**GEOMORFOMETRIA REGIONAL APLICADA AO
MAPEAMENTO DE FORMAS DE RELEVO NA BACIA
HIDROGRÁFICA DO RIO DEMINI - AMAZÔNIA
SETENTRIONAL**

Karolina Gameiro Cota Dias

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Márcio de Morisson
Valeriano, aprovada em 15 de
agosto de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/47J6GP8>>

INPE
São José dos Campos
2022

Dados Internacionais de Catalogação na Publicação (CIP)

Dias, Karolina Gameiro Cota.

D543g Geomorfometria regional aplicada ao mapeamento de formas de relevo na bacia hidrográfica do Rio Demini - Amazônia setentrional / Karolina Gameiro Cota Dias. – São José dos Campos : INPE, 2022.

xviii + 80 p. ; (sid.inpe.br/mtc m21d/2022/09.05.21.28-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2022.

Orientador : Dr. Márcio de Morisson Valeriano.

1. Modelo digital de elevação. 2. Segmentação.
3. Regionalização. 4. Classificação do relevo. 5. Análise de terreno. I.Título.

CDU 528.8:551.432(292.88)



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
Secretaria de Pós-Graduação - SEPGR

DEFESA FINAL DE DISSERTAÇÃO DE KAROLINA GAMEIRO COTA DIAS
BANCA Nº 203/2022, REG 850761/2020

No dia 15 de agosto de 2022, às 09h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestra em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

Título: “Geomorfometria Regional aplicada ao mapeamento de formas de relevo na bacia hidrográfica do Rio Demini - Amazônia Setentrional”

Membros da banca:

Dr. Thales Sehn Korting – Presidente – INPE

Dr. Márcio de Morisson Valeriano – Orientador – INPE

Dra. Rosângela Garrido Machado Botelho – Membro Externo – IBGE



Documento assinado eletronicamente por **Márcio de Morisson Valério, Tecnologista**, em 15/08/2022, às 16:09 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 16/08/2022, às 09:17 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **rosângela garrido machado botelho (E), Usuário Externo**, em 17/08/2022, às 21:29 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **10181943** e o código CRC **59C9DD94**.

AGRADECIMENTOS

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa de mestrado (processo 88887.479685/2020-00).

Ao Programa de Pós-Graduação em Sensoriamento Remoto (PGSER) do Instituto Nacional de Pesquisas Espaciais (INPE) pela capacitação técnica, estrutura e recursos fornecidos para a realização desta pesquisa. E também especialmente à equipe da Biblioteca por todo o apoio durante o curso.

Ao Dr. Márcio Valeriano pela orientação e acolhimento durante os últimos dois anos. Muito obrigada pelo apoio e incentivo a sempre continuar, ainda que os caminhos pareçam incertos, mas ótimos para serem desbravados.

À Ercília, Rita, Sheila e Marlúcia por não só zelarem pelos ambientes físicos do INPE, mas também pela convivência e companheirismo durante a realização de atividades em meio a pandemia.

Aos colegas da ABPG-INPE (2020 e 2021) pela amizade e preocupação em tornar o ambiente acadêmico mais acolhedor e saudável para alunos e bolsistas.

Aos meus colegas da PGSER-2020, por todo o aprendizado compartilhado, em especial Deborah, Philipe, Mário, Tânia, Gabriel Máximo e Lorena. Vocês foram fundamentais em todas as etapas dos últimos dois anos.

À Maíra, Isadora e Pepê por serem o melhor lar que eu poderia ter em São José dos Campos.

Ao meu companheiro Gilberto (Ba), por me ensinar nos últimos anos um significado tão grande para a palavra parceria. Me sinto honrada em compartilhar e aprender com você.

Às minhas irmãs Karina, Rafaela e Milena, e meus pais, Rosa e Vilmar, por todo incentivo e apoio, mesmo de longe, desde sempre.

RESUMO

O mapeamento de feições de terreno é eficaz quando realizado a partir de uma abordagem baseada em objetos, que pode estar relacionada à constituição de unidades do terreno. A regionalização dos parâmetros geomorfométricos permite a avaliação das características dentro das unidades do terreno e realça a heterogeneidade fora dessas. Este estudo apresenta uma metodologia de classificação para mapeamento geomorfométrico hierárquico, comparando dois métodos de classificação, visual e *Random Forest* (RF), a partir de um conjunto de treze variáveis geomorfométricas aplicadas na bacia hidrográfica do rio Demini (BHRD), norte do estado do Amazonas. Estas variáveis regionalizadas, através do cálculo de suas estatísticas para unidades de terreno derivadas de processo de segmentação multirresolução, foram avaliadas utilizando a função *Mean Decrease in Accuracy* (MDA) a fim de identificar quais tiveram maiores contribuições nas classificações RF. A caracterização das formas de relevo de ambos os métodos, visual e RF, teve considerável correspondência com os dados de mapeamento geomorfológico do Banco de Dados de Informações Ambientais (BDIA), utilizado como referência neste trabalho. A identificação de classes de subdomínios (Táxon 2) de Baixadas foi possível principalmente usando o modelo digital de elevação (MDE) e variáveis diretamente derivadas do MDE em ambas metodologias de classificação, como elevação (ZN), declividade (SN), textura (Text) e elevação residual (Res). A Acurácia Global (AG) para o resultado obtido do Táxon 1 (domínios Planaltos e Baixadas) através do RF foi de 96%. Os modelos RF para os subdomínios de Planaltos (Pediaplano, Planalto Residual, Patamar, Planalto Escarpado e Planalto Tabular) e Baixadas (Planície de Inundação e Platô Amazônico) no Táxon 2 possuíram AG de 84% e 87%, respectivamente. Mapas de Diferença realçaram as principais discrepâncias entre os resultados obtidos através dos métodos empregados. De forma geral, os métodos apresentaram resultados dissimilares apenas em áreas limites entre determinadas classes e em poucos pontos isolados dentro de classes específicas. A delimitação da Planície de Inundação, porém, apresentou diferenças significativas entre a classificação visual e RF, a última apresentou boa aderência aos dados do BDIA. Propõe-se a análise dessa última feição de terreno em escalas mais amplas na cartografia do relevo, de forma que possa ser subdividida em níveis hierárquicos de maior detalhe.

Palavras-chave: Modelo Digital de Elevação, Segmentação, Regionalização, Classificação do relevo, Análise de terreno, Aprendizagem de máquina, Geomorfometria Específica, *Random Forest*.

REGIONAL GEOMORPHOMETRY APPLIED TO LANDFORM MAPPING IN DEMUNI WATERSHED – SETENTRIONAL AMAZONIA

ABSTRACT

The mapping of terrain features is efficient when performed through an object-based approach, which may be related to the constitution of terrain units. The regionalization of the geomorphometric parameters allows the evaluation of features within the terrain units and highlights the heterogeneity outside these. This study presents a classification methodology for hierarchical geomorphometric mapping, comparing visual classification and Random Forest (RF), from a set of thirteen geomorphometric variables, applied in the Demuni River Watershed (BHRD), north of the state of Amazonas. These regionalized variables, through the calculation of their statistics for land units derived from the multi-resolution segmentation process, were evaluated using the Mean Decrease in Accuracy (MDA) function in order to identify which ones had greater contributions in the RF classifications. The characterization of landforms from both methods, visual and RF, had great correspondence with the geomorphological mapping data from the Environmental Information Database (BDIA), used as a reference in this research. The identification of subdomain classes (Taxon 2) of Lowlands was possible mainly using the digital elevation model (DEM) and variables directly derived from the DEM in both classification methodologies, such as elevation (SN), slope (SN), texture (Text) and residual elevation (Res). The Overall Accuracy (OA) for the result obtained from Taxon 1 (Highland and Lowland domains) through the RF was 96%. The RF models for the Highlands (Peneplain, Residual Highland, Dissected Highland, Steep Highland and Tabular Highland) and Lowlands (Floodplain and Amazonian Plateau) subdomains in Taxon 2 had OA of 84% and 87%, respectively. Difference Maps highlighted the main discrepancies between the results obtained through the methods used. In general, the methods presented dissimilar results only in boundary areas between certain classes and isolated points. The delimitation of the Floodplain, however, showed significant differences between the visual and RF classification, the latter showing good adherence to the BDIA data. It is proposed to analyze this last terrain feature on broader scales in relief cartography, so that it can be subdivided into hierarchical levels of detail.

Keywords: Digital Elevation Model; Segmentation; Regionalization; Landform Classification; Terrain Analysis, Machine Learning, Specific Geomorphometry, Random Forest.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Taxonomia do mapeamento geomorfológico – estrutura da geomorfologia.....	24
Figura 2.2 – Segmentação Multirresolução.....	33
Figura 2.3 – Ilustração do método de classificação <i>Random Forest</i>	35
Figura 3.1 – Mapa de Localização da Bacia Hidrográfica do rio Demini (Barcelos, AM).....	38
Figura 4.1 – Fluxograma geral do trabalho.	40
Figura 4.2 - Boxplot das variáveis utilizadas para o delineamento das classes do táxon 1.....	46
Figura 4.3 - Etapas da classificação visual.....	47
Figura 4.4 - Boxplots das métricas de elevação residual para a classificação visual dos subdomínios das Baixadas.....	48
Figura 4.5 - Boxplot das variáveis utilizadas para classificação visual dos subdomínios dos Planaltos.....	49
Figura 5.1 – Resultado da segmentação multirresolução para a bacia hidrográfica do rio Demini.	54
Figura 5.2 – Espacialização de variáveis geomorfométricas com detalhes em áreas de limite entre classes de relevo.	55
Figura 5.3 – Estatísticas de relevo residual no Domínio Baixadas da bacia do rio Demini.....	56
Figura 5.4 – Resultados dos métodos de classificação visual e RF para delineamento de formas de relevo.	59
Figura 5.5 – Mapa de Diferença – Táxon 1.....	62
Figura 5.6 – Mapa de Diferença – Táxon 2.....	63
Figura 5.7 – Ranking de Importância das Variáveis – Táxon 2: Baixadas.	64
Figura 5.8 – Ranking de Importância das Variáveis – Táxon 2: Planaltos.	65

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 4.1 - Referência e fonte utilizada para derivação das variáveis geomorfométricas utilizadas para este estudo e tipo de derivação: MDE-derivada ou Regional-nata.	44
Tabela 4.2 – Classificação hierárquica de formas de relevo elaborada e classificação geomorfológica utilizada pelo BDIA (IBGE, 2020).	45
Tabela 4.3 – Conjunto de amostras para a classificação <i>Random Forest</i> Táxon 1.	50
Tabela 4.4 - Conjunto de amostras para a classificação <i>Random Forest</i> Táxon 2, Domínio Baixadas.	51
Tabela 4.5 - Conjunto de amostras para a classificação <i>Random Forest</i> Táxon 2, Domínio Planaltos.	52
Tabela 5.1 – Matriz de Confusão dos dados de validação utilizados para classificação RF do Táxon 1.	56
Tabela 5.2 - Matriz de Confusão dos dados de validação utilizados para classificação RF dos Planaltos do Táxon 2.	57
Tabela 5.3 - Matriz de Confusão dos dados de validação utilizados para classificação RF das Baixadas do Táxon 2.	58

LISTA DE SIGLAS E ABREVIATURAS

AG	Acurácia Global
Alt	Altura
BDIA	Banco de Dados de Informações Ambientais
BHRD	Bacia Hidrográfica do Rio Demini
CPRM	Serviço Geológico do Brasil
Dis	Dissecação Topográfica
GDEM	<i>ASTER Global Digital Elevation Model</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
InSAR	Interferometria SAR
LiDAR	<i>Light Detection and Ranging</i>
MD	Mapa de Diferença
MDA	<i>Mean Decrease in Accuracy</i>
MDE	Modelo Digital de Elevação
OBIA	<i>Object-based Image Analysis</i>
P	<i>Precision</i>
Pred	Predominância Topográfica
R	<i>Recall</i>
Res	Relevo Residual
RF	<i>Random Forest</i>
RR	Relevo Relativo
SAR	<i>Synthetic Aperture Radar</i>
SIG	Sistema de Informação Geográfica
SN	Declividade
SRTM	<i>Shuttle Radar Topography Mission</i>
Text	Textura da Superfície do Terreno
USGS	<i>United States Geological Survey</i>
ZN	Elevação

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	19
1.1 Objetivo geral	21
1.1.1 Objetivos específicos	21
2 FUNDAMENTAÇÃO TEÓRICA	22
2.1 Mapeamento de formas de relevo	22
2.2 Geomorfometria	27
2.2.1 Variáveis geomorfométricas	28
2.3 Aplicações em sensoriamento remoto para a análise do relevo	30
2.3.1 Segmentação multirresolução	32
2.3.2 Classificação <i>Random Forest</i> (RF).....	34
3 Área de estudo.....	38
4 METODOLOGIA	40
4.1 Aquisição e pré-processamento dos dados.....	41
4.2 Derivação das variáveis geomorfométricas.....	41
4.3 Segmentação e regionalização das variáveis.....	42
4.4 Caracterização geomorfométrica.....	45
4.4.1 Classificação visual – táxon 1	45
4.4.2 Classificação visual – táxon 2.....	47
4.4.3 Classificação <i>Random Forest</i> – táxon 1	49
4.4.4 Classificação <i>Random Forest</i> – táxon 2	50
4.5 Análise dos resultados	52
5 RESULTADOS	54
5.1 Mapeamento geomorfométrico	58
5.2 Análise comparativa	61
6 DISCUSSÃO.....	66
7 CONCLUSÃO	69
REFERÊNCIAS BIBLIOGRÁFICAS	72

1 INTRODUÇÃO

O mapeamento de feições de terreno tem sido desenvolvido a partir de diferentes métodos em todo o mundo (CASSETI, 2005). Historicamente esse procedimento evoluiu de um método baseado em localizações pontuais dos elementos fisiográficos mais relevantes de uma determinada região para mapas contendo informações sobre morfometria, gênese, litologia, e até mesmo previsões de processos geomorfológicos (TRICART, 1965).

Em relação à morfometria, isto é, a mensuração de atributos do terreno, sua utilização pode ser aplicada em diversos estudos e análises ambientais (FLORINSKY, 2017). Nesse sentido, a disponibilidade de processamentos automatizados para mapeamentos tem aumentado o número de produtos com elevada importância. O delineamento de feições urbanas, por exemplo, como vias pavimentadas, piscinas e edificações em geral tem sido aperfeiçoado com classificações orientadas a objeto (BLASCHKE, 2010).

Na identificação de formas de relevo pode ser visto um progresso equivalente. A utilização de técnicas de segmentação tem permitido elevada acurácia no delineamento de padrões de relevo, devido à flexibilidade dos dados de entrada e parâmetros envolvidos no processo (GERENTE; VALERIANO; MOREIRA, 2018; BORTOLINI; SILVEIRA, 2021).

De maneira similar, algoritmos de aprendizado de máquina têm sido utilizados para identificar e prever, a partir de dados de sensoriamento remoto, a caracterização física de áreas, por suas características operacionais facilitadas (KARLSON et al., 2019; SIQUEIRA et al., 2022). Algoritmos de *machine learning* apresentam um potencial interessante para a geomorfometria porque são capazes de analisar um grande número de preditores e destacar a importância das diferentes métricas de terreno para o delineamento do relevo (DING et al., 2016; SIQUEIRA et al., 2022).

O estabelecimento de unidades de terreno é um passo fundamental para a delimitação de formas de relevo. Por sua própria natureza, uma forma de relevo pode ser caracterizada apenas em oposição ao seu contexto, e definida com base em seus atributos internos e sua extensão (EVANS, 1972; PIKE, 2000). Isso determina que uma forma de relevo é compreendida a partir de uma área, no mínimo, não habilitando a análise direta sobre pontos individuais, ou em *pixels*, tratando-se de análise de imagens digitais. Esse ponto

significa que métodos de classificação baseados em *pixel* são menos aderentes aos conceitos relacionados à formas de relevo, quando comparados a métodos baseados em objeto (EVANS, 2012).

Neste contexto, a regionalização se traduz como uma maneira de calcular e atribuir medidas estatísticas a uma região ou área. Na geomorfometria regional, a variável regionalizada pode assumir, então, a representação de uma medida estatística para uma área, favorecendo a caracterização deste relevo a partir de uma parte de terreno (MINÁR; EVANS, 2008).

Considerando toda sua extensão, uma boa parte das planícies amazônicas ainda não pôde ser mapeada a nível de detalhe. Isto ocorre devido à dificuldade de realização de trabalhos de campo – em decorrência da sua grande extensão, a quase total cobertura florestal, que impossibilita uma boa visualização do terreno, e também a ausência de estudos anteriores: bibliografias têm se tornado mais frequentes somente nas últimas décadas. Outra dificuldade relacionada ao mapeamento de relevo nessa área consiste no próprio relevo, de natureza predominantemente sedimentar, que apresenta poucas variações na elevação e uma expressão sutil de variações de terreno (VALERIANO; ROSSETTI, 2017).

No Processamento Digital de Imagens (PDI), algoritmos de segmentação permitem a manipulação de parâmetros com o objetivo de ajustar o processamento para atingir o resultado desejado. Na segmentação multirresolução, por exemplo, há o parâmetro de escala, que influencia diretamente o tamanho dos segmentos a serem gerados. A forma, outro parâmetro utilizado, atua em oposição ao atributo espectral. Quando o valor referente à forma é alto, a informação espectral possui menor importância no processamento. E a compacidade diz respeito ao delineamento do segmento, produzindo unidades com limites mais suaves quando são aplicados valores baixos de compacidade (BAATZ; SCHÄPE, 2000).

A regionalização de variáveis geomorfológicas pode contribuir com a delimitação de formas de relevo na análise de terreno (EVANS, 1972). Considerando que variações abruptas na elevação e em outras variáveis geomorfológicas possibilitam o delineamento correto de padrões de relevo, variações sutis, por outro lado, necessitam

um processo mais detalhado e rigoroso, tanto utilizando abordagens visuais como classificações automatizadas (VALERIANO; ROSSETTI, 2017).

Considerando o mapeamento de formas de relevo a partir de dados de sensoriamento remoto, que possui como desafio a regionalização e derivação de parâmetros topográficos, o presente trabalho busca verificar se técnicas de processamento de MDEs permitem identificar padrões topográficos e mapear formas de relevo na bacia hidrográfica do rio Demini, norte do estado do Amazonas.

1.1 Objetivo geral

Apresentar uma metodologia para classificação hierárquica de formas de relevo na bacia hidrográfica do rio Demini (BHRD), norte da Amazônia, utilizando variáveis geomorfométricas regionalizadas.

1.1.1 Objetivos específicos

- a) Elaborar uma taxonomia específica para o mapeamento geomorfométrico da bacia, baseado no mapeamento geomorfológico do Banco de Dados de Informações Ambientais (BDIA) (IBGE, 2019);
- b) Empregar uma metodologia para derivação de variáveis geomorfométricas a partir de unidades de terreno; e
- c) Identificar as variáveis mais relevantes para o delineamento das formas de relevo na bacia do rio Demini.

2 FUNDAMENTAÇÃO TEÓRICA

A revisão de conceitos que embasam o presente estudo é necessária para esclarecimento das etapas de análise e desenvolvimento da metodologia do trabalho. Com esse objetivo, este capítulo é dividido em três tópicos: no primeiro subcapítulo é realizada uma revisão sobre métodos de mapeamento geomorfológico e geomorfométrico. Em seguida apresentam-se definições a respeito da geomorfometria e, por último, são apresentadas técnicas e metodologias de sensoriamento remoto e geoprocessamento aplicadas à identificação de feições do terreno.

2.1 Mapeamento de formas de relevo

O mapeamento do relevo assumiu diferentes métodos e conceitos a partir das abordagens utilizadas ao redor do globo. Especificamente na cartografia geomorfológica, o processo de mapeamento busca maneiras de representar não só as formas, mas também sua gênese e relações com estrutura e processos de sua evolução (CASSETI, 2005). Recomendações da Sub-Comissão de Cartas Geomorfológicas da União Geográfica Internacional, listadas por Tricart (1965), relataram que cartas geomorfológicas de detalhe, em escala local, devem comportar quatro tipos de dados: morfométricos, morfográficos, morfogenéticos e cronológicos.

Segundo Evans (2012), mapas geomorfológicos, para muitos pesquisadores europeus, cobrem temas como morfometria, gênese, processos atuais, materiais (litologia e estrutura) e cronologia, constituindo um conjunto de múltiplas camadas. Cientistas norte-americanos e britânicos, por outro lado, preferem mapas mais simples, com foco em um determinado grupo de formas de relevo, se aproximando de mapas de geomorfometria específica, ainda que outras informações entre sistemas geomórficos sejam perdidas, como litologia e morfogênese (TRICART, 1965)

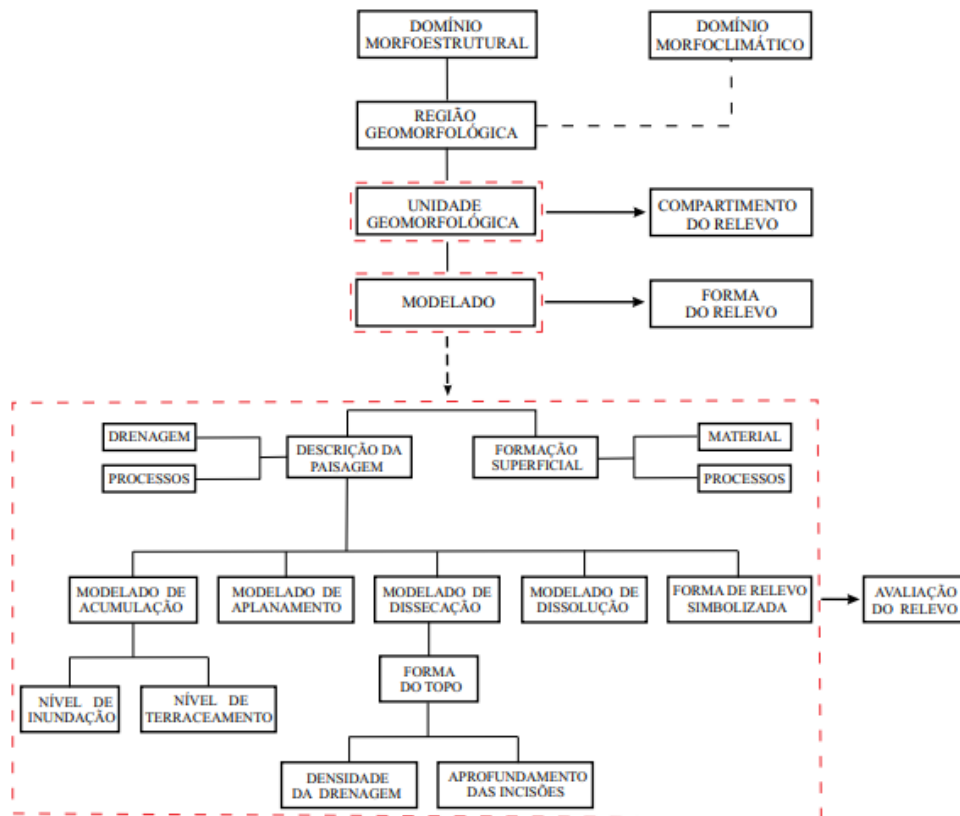
No Brasil, o mapeamento geomorfológico tem sido realizado de forma sistemática pelo Instituto Brasileiro de Geografia e Estatística (IBGE) nos últimos anos, após incorporação do projeto RADAMBRASIL, iniciado na década de 1970 (BRASIL, 1975). Este projeto realizou o levantamento de recursos naturais para todo o território brasileiro na escala 1:1.000.000, e, ainda hoje, representa uma importante fonte de informações do meio físico do país. Entre os produtos derivados do RADAMBRASIL, inclui-se o mapeamento geomorfológico, que classificou formas de relevo em todo o

território nacional a partir de um método hierárquico estruturado em táxons (PELECH et al., 2019; BOTELHO; PELECH, 2019).

Mais recentemente o IBGE publicou o mapeamento geomorfológico na escala 1:250.000 para todo o território brasileiro, com atualizações sendo disponibilizadas no BDIAWeb, portal que reúne informações temáticas sobre recursos naturais para o Brasil (IBGE, 2020). A elaboração do mapa geomorfológico utilizou metodologia derivada do RADAMBRASIL, exposta no Manual Técnico de Geomorfologia (IBGE, 2009). Paralelamente, o Serviço Geológico do Brasil (CPRM), também tem realizado levantamento das formas de relevo brasileiras, a partir de metodologia distinta, na escala 1:1.000000 (CPRM, 2010).

Botelho e Pelech (2019) esquematizaram as diferentes metodologias utilizadas em mapeamentos geomorfológicos realizados no território brasileiro, ressaltando a utilização da abordagem taxonômica e atributos utilizados para definição, organização e classificação das unidades de mapeamento. A taxonomia do mapeamento geomorfológico elaborada por IBGE (2009) aborda, como parâmetros para individualização das feições de relevo, fatores de natureza litológica, estrutural, pedológica, climática e morfodinâmica. Em termos gerais, são caracterizados como os maiores táxons, em ordem decrescente: Domínio Morfoestrutural, Região Geomorfológica, Unidade Geomorfológica e Modelado (Figura 2.1).

Figura 2.1 – Taxonomia do mapeamento geomorfológico – estrutura da geomorfologia.



Fonte: IBGE (2009).

A elaboração dos mapas geomorfológicos mais recentes em escala 1:250.000 comprovam que a disponibilidade crescente de dados possibilitou o aumento significativo da resolução da informação produzida sobre o relevo em nível nacional (IBGE, 2019). No entanto, as metodologias oficiais de classificação de formas de relevo utilizadas nos mapeamentos geomorfológicos mais recentes permanecem condicionadas à interpretação visual de produtos de sensoriamento remoto e suas derivações (PIMENTA; SARTI, 2015).

Nesse sentido, o processamento de MDEs para a identificação de padrões topográficos e elaboração de métodos para mapeamento geomorfométrico regional se apresenta como contribuição para a realização de mapeamentos do relevo. As abordagens envolvendo operações de regionalização a partir de métodos de processamento digital de imagens podem contribuir com as metodologias atuais oferecendo uma perspectiva que faça uso de processamentos automatizados, mas também de conceitos e informações presentes em bibliografias sobre o tema.

Seijmonsbergen et al. (2011) enfatizam a importância de abordagens híbridas baseadas em conhecimentos específicos da literatura e estatísticas para a extração de feições geomorfológicas. É demonstrado que informações obtidas por métodos de mapeamento “tradicionais”, como fotografias e registros históricos, informações de literatura e também as derivações de MDEs podem ser armazenados em uma mesma tabela de atributos ou banco de dados geográficos, possibilitando análises mais sofisticadas.

Algumas das críticas ao mapeamento geomorfológico tradicional dizem respeito à ausência de padrões para formalizar aspectos do mapeamento, como legendas únicas, esquemas de representação de mapas e métodos de derivação. Nesse sentido, o IBGE, junto a pesquisadores de diferentes instituições brasileiras, como CPRM e Instituições de Ensino Superior, propuseram a criação de um Sistema Brasileiro de Classificação de Relevo (SBCR). A elaboração do SBCR tem sido pautada por meio da realização de Workshops organizados pelo Comitê Executivo Nacional (CEN), a partir de debates e discussões dos Grupos de Trabalho Direcionado e Núcleos Locais Colaborativos, sendo realizados em edições do Simpósio Nacional de Geomorfologia (SINAGEO) e Simpósio Brasileiro de Geografia Física Aplicada (SBGFA) (IBGE, 2020 b).

O desenvolvimento de métodos de mapeamentos geomorfométricos, por outro lado, identificou o potencial de ferramentas de geoprocessamento na resolução de problemas conceituais. Um exemplo é a adequação ao fator de escala necessário na segmentação para delimitação de unidades de terreno em conformidade às hierarquias correspondentes. Entre as diferentes técnicas escolhidas por pesquisadores em mapeamentos geomorfométricos, uma abordagem frequentemente empregada são as técnicas de segmentação de imagens que, quando aplicadas à um MDE, possibilitam a partição deste em regiões não sobrepostas (segmentos) representativas de entidades de relevo, como realizado por Macmillan et al. (2000); Drăguț e Blaschke (2006); Anders, Seijmonsbergen e Bouten (2011).

Drăguț; Eisank (2012) apresentaram um método automático baseado em classificação orientada a objeto (OBIA) para segmentação e classificação automática do relevo global, utilizando MDE com resolução espacial de 1 km. As formas de relevo puderam ser distinguidas em diferentes feições, como por exemplo: planícies, morros, planaltos e montanhas. No entanto, os autores, mais uma vez, destacam a necessidade de adaptar o

método de OBIA para se adequar à escala e hierarquia dos padrões topográficos a serem identificados, criando algoritmos que automatizem a definição dos dois parâmetros.

É importante destacar que os processamentos realizados em MDEs e suas derivações visam a delimitação objetiva de variáveis geomorfométricas. No entanto, ainda que existam técnicas estatísticas e algoritmos automáticos, os limiares utilizados nas classificações costumam ser ajustados conforme considerações subjetivas, o que depende do conhecimento do analista sobre a paisagem a ser estudada (IWAHASHI; PIKE, 2007).

As abordagens automáticas para classificação morfométrica da paisagem possuem diversos exemplos de aplicação. Gallant, Brown e Hoffer (2005) automatizaram um método de classificação manual do relevo a partir da utilização de janelas móveis e combinação de variáveis. Ehsani e Quiel (2008) usaram redes neurais não-supervisionadas (UNN, do inglês *Unsupervised Neural Network*) para produzir uma classificação de formas de relevo utilizando as variáveis declividade e curvatura. Burrough, Van Gaans e Macmillan (2000) aplicaram técnica *fuzzy k-means* para classificação de relevo, resultando em um mapa de classificação geomorfométrica. Prima et al. (2006) utilizaram técnicas de classificação supervisionada baseada na abertura topográfica (*openness*), declividade e desvio padrão da declividade para tipificar classes de relevo em uma região vulcânica.

A classificação automatizada das formas de relevo quase sempre representa uma tentativa de replicar algum sistema manual de classificação e mapeamento do relevo pré-concebido (GALLANT; BROWN; HOFFER, 2005). Minár e Evans (2008) argumentam que os limites de unidades de terreno em mapeamentos geomorfológicos normalmente correspondem a limites morfométricos. Logo, presume-se que o desenvolvimento de metodologia de mapeamento geomorfométrico hierárquico regional pode contribuir para a identificação de formas de relevo e realização de mapeamentos geomorfológicos.

Na região amazônica, estudos anteriores apresentam esta possibilidade, como a caracterização do relevo na região de Manaus – AM a partir da geomorfometria, (SARGES; SILVA; RICCOMINI, 2011), a caracterização morfométrica da bacia hidrográfica do rio São Francisco no Acre (NASCIMENTO et al., 2013), e a cartografia

geológica e geomorfológica na porção leste de Rondônia utilizando MDEs (HERRERA et al., 2016).

2.2 Geomorfometria

A Geomorfometria corresponde à análise de dados quantitativos do relevo, e pode ser aplicada a estudos de diferentes ciências, como geomorfologia, pedologia, agronomia e engenharias (PIKE, 2002; FLORINSKY, 2017). Apesar de haver registros de sua prática desde o século XIX (CHRISTOFOLETTI, 1980), a abordagem principal associada ao termo geomorfometria (EVANS, 1972) considera a análise de Modelos Digitais de Elevação.

Os MDEs são comumente representados a partir de um arquivo digital organizado como matriz, contendo valores de elevação (cotas altimétricas) estruturadas em linhas e colunas, correspondendo à uma localização geográfica x, y. O processamento desses dados, que são utilizados como material primário para a geração de informações topográficas, é realizado através de recursos de Sistemas de Informação Geográfica (SIG) e *softwares* específicos (HENGL; REUTER, 2008).

Os diferentes fundamentos de tecnologias para estimativa e aquisição de dados referentes à elevação resultam em diferentes características e especificações do MDE produzido. Técnicas específicas de sensoriamento remoto aplicadas à produção de MDEs incluem sensores ópticos (estereoscopia e técnicas de fotogrametria); radares de abertura sintética (SAR, *Synthetic Aperture Radar*) (interferometria); e Light Detection and Ranging (LiDAR) (a partir do processamento de nuvens de pontos) (TAROLLI; MUDD, 2019).

Os principais fatores relacionados às diferenças entre MDEs gerados a partir de diferentes métodos dizem respeito à sua precisão/exatidão e resolução espacial (HENGL; REUTER, 2008). No caso de MDEs produzidos por LiDAR é possível obter alta resolução espacial, em escala centimétrica (TAROLLI; MUDD, 2019), porém sua capacidade de área de escaneamento é ainda limitada devido à estreita faixa de imageamento.

Nos últimos anos, a realização de levantamentos orbitais de cobertura quase global trouxe um impulso expressivo no desenvolvimento da geomorfometria. Alguns exemplos são missões e projetos como a *Shuttle Radar Topography Mission* (SRTM)

(USGS, 2003), *ASTER Global Digital Elevation Model* (ASTER GDEM) (ERSDAC, 2009), *World Digital Elevation Model* (WorldDEM) (RIEGLER et al., 2015) e *Copernicus Digital Elevation Model* (Copernicus DEM) (AIRBUS, 2020). Estes levantamentos forneceram MDEs sobre toda ou quase toda superfície terrestre (GUTH et al., 2021), incluindo áreas até então desprovidas de dados topográficos.

A missão SRTM (RABUS et al., 2003) foi o levantamento de maior impacto nesse sentido, por fornecer dados globais da topografia terrestre de forma acessível e gratuita sobre extensas áreas de países em desenvolvimento. Entre 11 e 22 de fevereiro de 2000, a missão SRTM produziu dados topográficos entre as latitudes 60°N e 57°S através de interferometria SAR (InSAR), utilizando duas antenas operando na banda C do espectro eletromagnético, com comprimento de onda de aproximadamente 7,5 centímetros (RABUS et al., 2003). Essa missão produziu MDEs com resolução espacial de 1 e 3 arco-segundos (aproximadamente 30 e 90 metros, respectivamente), disponibilizados de forma gratuita, globalmente, em versões com diferentes níveis de processamento.

A primeira versão dos dados SRTM disponibilizada para a América do Sul possuía resolução espacial de 3 arco-segundos. Essas informações, interpoladas através de krigagem e oferecidas na resolução espacial de 1 arco-segundo, junto a suas derivações locais, foram disponibilizadas para todo o território brasileiro através do projeto Topodata, que consiste em um banco de dados geomorfométrico para o Brasil (BRASIL, 2008). Embora novos níveis de processamento dos dados SRTM tenham sido disponibilizados após a elaboração do Topodata – inclusive a versão original com resolução de 1 arco-segundo pelo *United States Geological Survey* (USGS), os dados Topodata permanecem sendo utilizados para estudos de relevo em território brasileiro.

2.2.1 Variáveis geomorfométricas

A derivação de variáveis locais é o processamento básico do MDE, em que se produzem informações geomorfométricas referentes à geometria da superfície, como a declividade, as curvaturas e a orientação de vertentes (MOORE et al., 1993). Estas são calculadas com operação de janelas móveis. Esse tipo de análise considera uma extensão (tipicamente 3x3 ou 5x5 *pixels*) em que as diferenças de elevação são calculadas, e cujo resultado é atribuído ao *pixel* central da janela de análise. Estas variáveis caracterizam a geometria da superfície local e são aplicáveis em diferentes

campos de conhecimento, como hidrologia, solos e vegetação (GETIRANA et al., 2009; MOORE et al., 1993; FLORINSKY; KURYAKOVA, 1996).

Em contraposição, existem variáveis específicas a determinadas aplicações, cuja elaboração requer maior complexidade, como o fator topográfico da modelagem de erosão agrícola (DESMET; GOVERS, 1996), do estudo de deslizamentos (PIKE, 1988) e de cálculo da radiação solar incidente (DUBAYAH; RICH, 1995). Estas variáveis, relacionadas à geomorfometria específica (EVANS, 1972), têm significado físico mais particularizado ao contexto da aplicação do que à caracterização geométrica do terreno.

Muitas das variáveis geomorfométricas específicas não são passíveis de derivação por janelas móveis, como as variáveis locais citadas anteriormente, uma vez que requerem uma análise de dados considerando maiores extensões, ou espacialmente mais complexas (OLAYA, 2009). Referidas como variáveis regionais, estes parâmetros de terreno são calculados por formulações diversas, que envolvem estatística de dados locais (médias, modas, variação), acúmulos (áreas, distâncias, volume), ou a própria posição geográfica dos dados, conforme a finalidade da caracterização geométrica.

Exemplos mais evidentes de variáveis regionais são a área de captação, o comprimento de vertentes e aquelas relacionadas à distribuição dos valores de elevação de um relevo, como textura e rugosidade (PIKE, 1988). No caso da área de estudo deste trabalho, que apresenta expressiva variação topográfica, com a presença de extensas planícies e diferentes tipos de planalto, a partir de trabalhos desenvolvidos por Muñoz (2009a), Gerente (2018) e Valeriano e Rossetti (2020), foram selecionadas variáveis geomorfométricas que poderiam contribuir para a descrição e delimitação das feições de terreno.

O Índice de Rugosidade do Terreno (TRI, do inglês *Terrain Ruggedness Index*) se propõe a quantificar a heterogeneidade topográfica a partir da soma das diferenças da elevação a partir de uma janela móvel 3x3 (*pixels*) (RILEY; STEPHEN; ELLIOT, 1999). A Textura da Superfície do Terreno (Text) é definida como o número de picos e depressões em uma janela móvel (tipicamente 10x10 *pixels*), calculada a partir das diferenças do MDE original e filtrado (IWAHASHI; PIKE, 2007).

O Relevo Residual (Res) tem sido utilizado para realçar padrões de terreno em relevos sutis, com pouca variação, principalmente próximo a planícies fluviais (ZANI;

ASSINE; MCGLUE, 2012; VALERIANO; ROSSETTI, 2020). É calculado a partir da subtração entre um MDE da área de interesse e uma Superfície de Tendência gerada para a mesma área, como descrito por Valeriano e Rossetti (2020). O procedimento para seu cálculo pode ser descrito a partir das seguintes etapas: 1) escolher a área de interesse para realização da análise; 2) recortar o MDE para esta área (ZN_{clip}); 3) calcular a Superfície de Tendência (ZN_{trnd}) conforme a Equação 2.1:

$$ZN_{trnd} = f\{x, y\} \quad (2.1)$$

onde f é uma equação de regressão que corresponde ao valor de elevação em uma coordenada x, y ; 4) configurar o grau de polinômio mais apropriado para a geração da superfície de tendência de acordo com a representatividade regional do relevo para a área de interesse; 5) obter o Relevo Residual como o resultado da Equação 2.2:

$$Res = ZN_{clip} - ZN_{trnd} \quad (2.2)$$

A Altura (Alt) é descrita como a diferença entre a elevação de um ponto e a elevação mais baixa ao redor do local de interesse (Equação 2.3). O Relevo Relativo (RR), também conhecido como amplitude do terreno (EVANS, 1972), pode ser medido subtraindo-se o menor valor de elevação do mais alto em uma determinada área (Equação 2.4). A Predominância Topográfica (Pred) ressalta a frequência dos valores de elevação através da subtração do MDE a partir de sua mediatriz (Equação 2.5). A Pred assume que terrenos baixo-predominantes possuem picos isolados de elevação, ao passo que terrenos alto-predominantes possuem menor quantidade de áreas baixas e, provavelmente, estas representam a dissecação do terreno (MUÑOZ, 2009a).

$$Alt = ZN - ZN_{min} \quad (2.3)$$

$$RR = ZN_{max} - ZN_{min} \quad (2.4)$$

$$Pred = ZN - \left[\frac{(ZN_{max} + ZN_{min})}{2} \right] \quad (2.5)$$

2.3 Aplicações em sensoriamento remoto para a análise do relevo

A geomorfometria regional é um recurso de análise topográfica cujo objetivo é a migração da análise local para análise de uma região. O cálculo de variáveis regionais requer, portanto, o estabelecimento prévio de unidades de mapeamento (segmentos,

feições ou áreas) para estruturar a integração de dados locais (MEIJERINK, 1988). Estas unidades podem ser estabelecidas por diversas técnicas que promovem o agrupamento de *pixels*, sejam baseadas na uniformidade de suas características (classificação de imagens, segmentação) ou condições funcionais (como delineamento de microbacias, montanhas ou vertentes) (MOREIRA, 2018).

Evans (2012) considera que a definição de diferentes tipos de formas de relevo tem como pré-requisito a delimitação completa das feições definidas por geomorfometria específica. As características geomorfológicas só podem ser mensuradas adequadamente se formas de relevo individuais forem separadas de seu entorno. Portanto, é importante destacar que objetos geomorfométricos relacionados a formas de relevo possuem expressão espacial, ou seja, para a identificação de formas de relevo através de MDEs a abordagem contextual é primordial.

Moreira (2018) aponta quatro fases para o processo de regionalização de dados topográficos e a necessidade de aporte conceitual em todas elas: (1) consiste na definição do local e das características dos objetos de interesse; (2) a escala na qual serão medidos, como extensão geográfica e a precisão; (3) a apreciação dos dados e as ferramentas disponíveis para a operacionalização do processo; e (4) a definição da abordagem metodológica, ou seja, como os dados e ferramentas serão utilizados para definição de objetos geomorfométricos compatíveis com determinada escala. Em PDI, diferentes abordagens metodológicas se propõem a identificar e estabelecer unidades de mapeamento e a regionalizar informações. Alguns desses métodos são: segmentação, classificação e extração de bacias hidrográficas (MINÁR; EVANS, 2008).

Entre as técnicas de segmentação, o método por crescimento de regiões é identificado como um dos mais tradicionais, e pode ser utilizado para a criação de unidades de terreno. O algoritmo distribui “sementes” de forma aleatória pela imagem e promove o crescimento da região a partir da unidade mínima semeada, agregando os vizinhos que possuem atributos similares. Sua função consiste em agrupar *pixels* ou sub-regiões em regiões maiores, baseado em um critério pré-definido, estabelecido pelo analista, identificado como limiar de similaridade. A métrica de comparação entre dois elementos é a diferença entre atributos dada pela distância euclidiana condicionada pelo limiar (ZANOTTA et al., 2019).

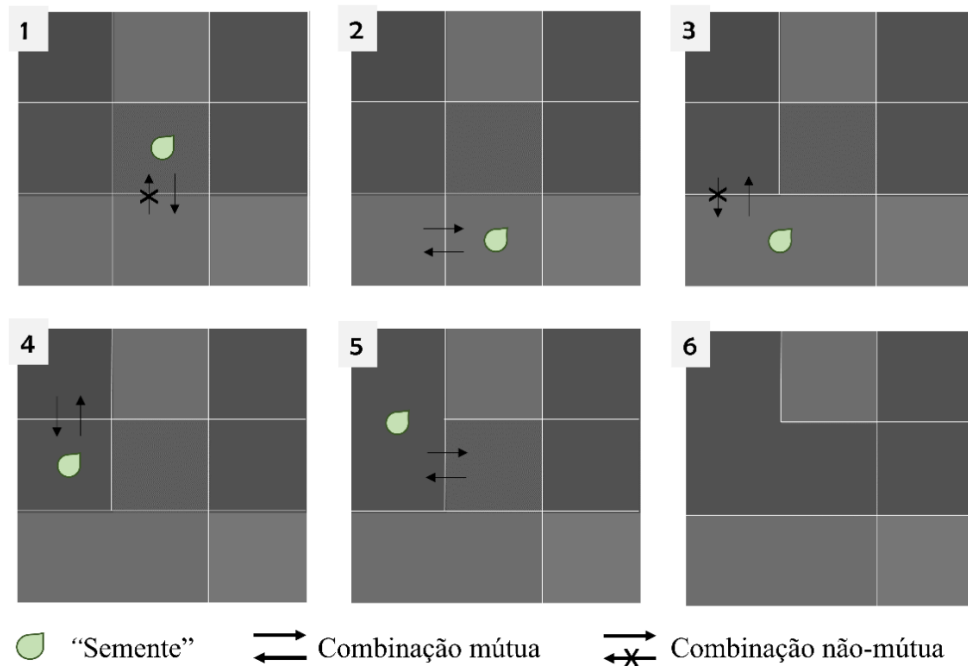
Romstad e Etzelmüller (2012) exemplificam que é possível utilizar atributos topográficos (declividade e curvatura) como variáveis de entrada para segmentadores por crescimento de regiões. O resultado deste processo constitui-se como uma unidade de terreno morfologicamente consistente.

2.3.1 Segmentação multirresolução

O algoritmo segmentação multirresolução, implementado no *software* eCognition (TRIMBLE, 2018) é baseado no método de segmentação “Crescimento de Regiões”, que cria objetos do tamanho do píxel e os une em *loops* de reprocessamentos, formando unidades cada vez maiores, até atingir os parâmetros selecionados.

O método se inicia a partir de um “*pixel* semente” que busca, em sua vizinhança, a melhor combinação para uma potencial fusão. Se a combinação não é mútua, o *pixel* de maior potencial para combinação na fase anterior se torna uma nova “semente” e repete o processo, em busca de sua melhor combinação. Quando a combinação é mútua, a fusão é realizada e o objeto é criado (Figura 2.2). A cada repetição do procedimento, todos os objetos buscarão uma nova combinação, até que nenhuma mais seja possível (BAATZ; SCHÄPE, 2000).

Figura 2.2 – Segmentação Multirresolução.



Na Figura 2.2 (1) ocorre o início da interação, quando o pixel central busca em sua vizinhança uma combinação mútua. Se esta não ocorre (1), o pixel de maior potencial da fase anterior realiza o mesmo procedimento de busca (2), até que a combinação seja mútua e ocorra a criação de objetos (3, 4, 5 e 6).

Fonte: Produzido pela autora.

Os parâmetros utilizados no algoritmo implementado no eCognition que podem ser alterados diretamente são: escala, forma, compacidade e o peso de cada banda (TRIMBLE, 2018). A escala está relacionada ao tamanho dos objetos resultantes do processo de segmentação, de forma que quanto maior o valor desse parâmetro, maior o tamanho do segmento gerado.

O parâmetro de forma é complementar à cor, que corresponde ao atributo do *pixel*. Aumentar a influência da forma no processo de segmentação significa automaticamente diminuir a influência da cor, ou seja, diminuiria a importância dos valores de elevação em um MDE. A compacidade, por sua vez, é complementar ao parâmetro de suavização. Isto significa que aumentar o valor da compacidade corresponde a diminuir a suavidade das bordas dos objetos criados, tornando-as menos sutis (TRIMBLE, 2018).

Além destes parâmetros, a ponderação pode ser ajustada conforme a importância de cada banda da imagem para a segmentação dos alvos de interesse. A atribuição dos

pesos para cada camada de informação pode ser definida através da experiência do analista ou empiricamente (BAATZ; SCHÄPE, 2000).

2.3.2 Classificação *Random Forest* (RF)

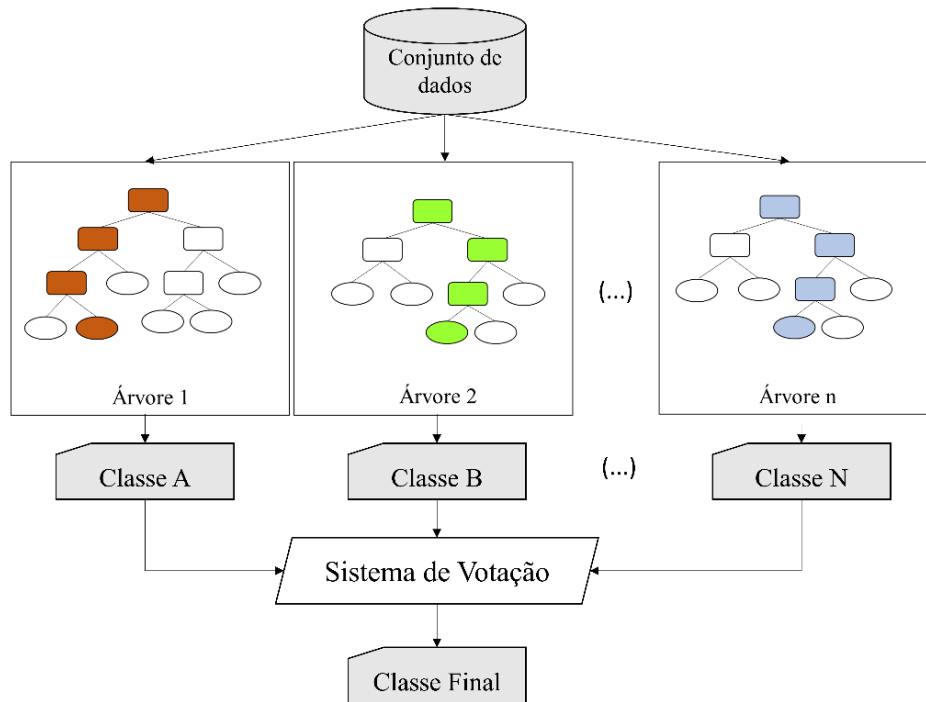
Métodos de classificação em sensoriamento remoto visam atribuir, a um dado, uma rotulação baseada em um objeto do mundo real, a partir do conjunto de atributos deste dado (ZANOTTA; FERREIRA; ZORTEA, 2019). Essa atribuição se dá a partir de dois passos principais: (i) determinar as categorias de objetos do mundo real que se pretende identificar; e (ii) atribuir rótulos (normalmente números) ao conjunto de *pixels* – ou segmentos, que se pretende caracterizar utilizando um procedimento de tomada de decisão, como uma regra de classificação (MATHER, 2004).

Na classificação supervisionada assume-se que é possível treinar um modelo estatístico a partir de um conjunto de amostras fornecidos pelo analista, através de processo de reconhecimento de padrões. Dessa forma, o modelo assume como função a predição da classe de novos conjuntos de dados a serem analisados, a partir das amostras fornecidas previamente (ZANOTTA; FERREIRA; ZORTEA, 2019).

Random Forest é um método de aprendizagem de máquina (*machine learning*) utilizado para classificação e regressão (BREIMAN, 2001) supervisionadas. Este método é caracterizado como não-paramétrico, isto é, não exige a distribuição normal dos dados para sua execução. Essa não exigência da normalidade dos dados possibilita que esse tipo de método seja bem sucedido em condições de grande conjunto de amostras de treinamento e sem conhecimento prévio da distribuição das classes a serem identificadas (ZANOTTA; FERREIRA; ZORTEA, 2019).

O RF é baseado em uma abordagem *ensemble*, ou seja, seu método utiliza o resultado de múltiplos modelos e, a partir de votação, determina os parâmetros de maior acerto. Neste caso, são utilizados múltiplos modelos de árvores de decisão para, após análise da moda e votação dos resultados, obter-se uma maior acurácia e reduzir erros individuais (Figura 2.3).

Figura 2.3 – Ilustração do método de classificação *Random Forest*.



Fonte: Adaptado de Neves (2021).

Em classificações utilizando árvores de decisão, cada nó é dividido utilizando a melhor divisão possível entre todas as variáveis. No RF, cada nó é dividido utilizando a melhor opção a partir de um conjunto de preditores aleatoriamente escolhidos para este nó (LIAW; WIENER, 2002).

O pacote *randomForest*, disponibilizado para a linguagem de programação R (LIAW; WIENER, 2002), permite a realização da análise para fins de classificação estabelecendo alguns parâmetros. O parâmetro *nree* especifica o número de árvores de decisão que será utilizado para a construção do modelo. Em estudos de sensoriamento remoto é comum ser utilizado o número 500 porque a estabilização dos resultados costuma ocorrer antes do atingimento deste número (BELGIU; DRĂGUT, 2016). Outro parâmetro de configuração necessária para o RF é o *mtry*, que especifica o número de variáveis a serem selecionadas aleatoriamente para cada divisão de nó. Por convenção, o *mtry* corresponde a raiz quadrada do total de variáveis a serem utilizadas no modelo (BREIMAN, 2001).

A partir do conjunto de amostras e parâmetros estabelecidos, o RF realiza o processo de predição. É estabelecido um padrão de divisão das amostras como sendo de aproximadamente 70% para treinamento e 30% para validação (BELGIU; DRĂGUT, 2016). As árvores são criadas a partir de um subconjunto das amostras de treinamento a partir de uma abordagem de *bagging*. O maior conjunto de amostras (referidas como amostras *in-bag*) é utilizado para treinamento das árvores, ao passo que as amostras de validação, referidas como *out-of-the-bag* (OOB) são utilizadas para validação interna da performance do modelo (BREIMAN, 2001; BELGIU; DRĂGUT, 2016).

A definição da classificação final é realizada a partir de votação realizada sobre a probabilidade de atribuição de classes considerando o resultado de cada árvore gerada. Por atingir maior exatidão face o uso da abordagem *ensemble*, esse tipo de método tem sido amplamente utilizado, uma vez que apresenta resultados superiores quando comparado a métodos que utilizam apenas uma classificação, como árvores de decisão, e também por serem mais robustos e estáveis em relação a ruídos nos dados de treinamento (BELGIU; DRĂGUT, 2016).

Adicionalmente, a função de importância das variáveis (*variable importance*) tem sido utilizada como recurso para reduzir o número de preditores e identificar os dados mais relevantes (BELGIU; DRĂGUT, 2016). No algoritmo *randomForest* a importância da variável é estimada considerando o quanto de sua acurácia é perdida a partir da exclusão desta variável, ou seja, quanto maior a perda de acurácia, maior a importância da variável para o modelo (LIAW; WIENER, 2002). O método *Mean Decrease in Accuracy* (diminuição média na exatidão, MDA) considera a diferença entre o erro OOB obtido a partir de permutações aleatórias do conjunto de preditores, com o erro OOB resultante do conjunto de dados original (BREIMAN, 2001).

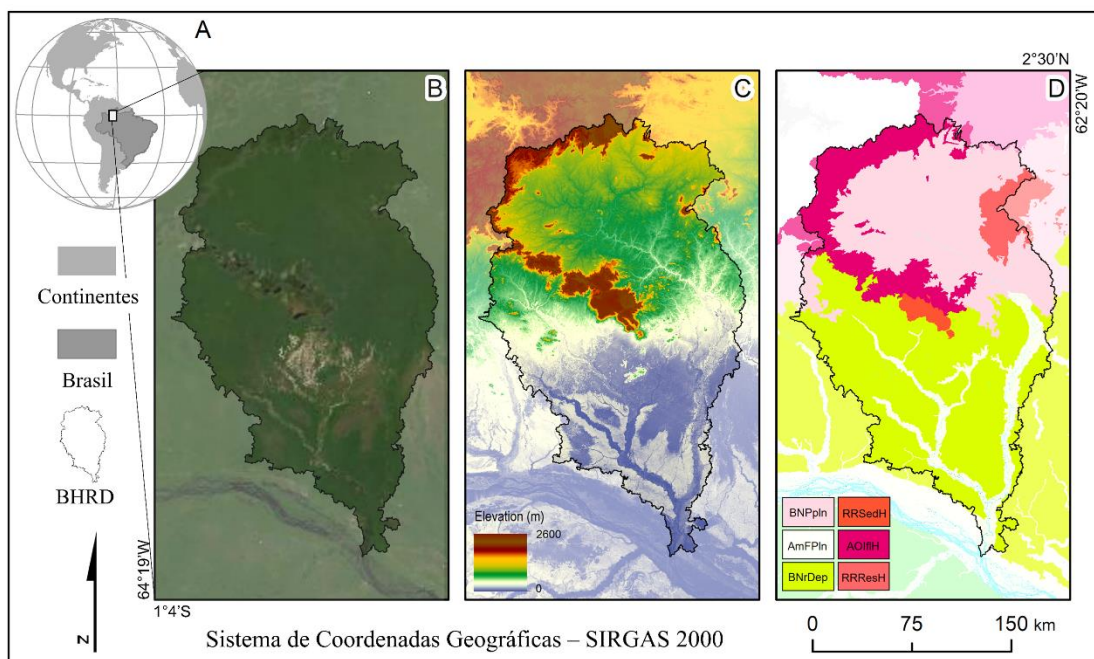
Em abordagens multissensores é possível identificar que o ranqueamento da importância das variáveis contribui para o melhor entendimento do resultado do modelo. KARLSON et al. (2019) puderam observar através do MDA, que alguns dos parâmetros de terreno mais relevantes para delineamento de áreas de turfa utilizando imagens SAR e MDEs foram: índice de elevação residual multiescalar, desvio da elevação média, índice de umidade, índice de rugosidade topográfica (TRI) e declividade. Para classificação de áreas inundáveis, Corcoran, Knight e Gallant (2013)

obtiveram, como algumas das variáveis mais importantes, a banda infravermelho próximo do Landsat 5 e as variáveis morfométricas elevação e curvatura. Siqueira et al. (2021) identificaram, entre as variáveis mais importantes para mapeamento de formas de relevo na Antártica, utilizando RF, a densidade de drenagem, índice de concentração de rugosidade e elevação.

3 ÁREA DE ESTUDO

A BHRD está localizada no município de Barcelos, no norte do estado do Amazonas (AM), Brasil. Ela se estende por aproximadamente 40 mil quilômetros quadrados, limitando-se a leste pela divisa com o estado de Roraima e, a norte, pela fronteira com Venezuela (Figura 3.1)

Figura 3.1 – Mapa de Localização da Bacia Hidrográfica do rio Demini (Barcelos, AM).



Localização da Bacia Hidrográfica do rio Demini no norte do Brasil (A). São exibidas três representações da BHRD, sendo (B) a localidade vista a partir de dados ópticos, (C) o Modelo Digital de Elevação da área (Topodata) e (D) unidades geomorfológicas apresentadas no BDIA: BNpPIn – Pediplano Branco-Negro, AmFPIn – Planície de Inundação Amazônica, BNrDep – Depressão Branco-Negro, RRSedH – Planalto Sedimentar de Roraima, AOIfIH – Planalto do Interflúvio Amazonas-Orenoco, RRResH – Planalto Residual de Roraima (IBGE, 2020).

Fonte: Produzido pela autora.

A bacia do rio Demini possui uma variância topográfica bastante significativa, com valores de elevação entre 10 a aproximadamente 2500 metros. É possível identificar diferentes paisagens, correspondendo às planícies e planaltos da Amazônia (SOMBROEK, 2000). BHRD é uma sub-bacia do sistema fluvial do Médio Rio Negro. Os principais afluentes que contribuem são os rios Araçá, Cuieiras, Toototobi e Ananaliua.

O clima é caracterizado como tropical úmido, sem estação seca, correspondente ao tipo “Af”, de acordo com a classificação de Köppen. A temperatura média anual é entre 24 e

26 graus celsius. O acumulado de precipitação atinge valores superiores a 2500 mm por ano (ALVARES et al., 2013).

As nascentes do rio Demini encontram-se sobre rochas ígneas e metamórficas pré-cambrianas do escudo das Guianas (CREMON; ROSSETTI; ZANI, 2014; ALVES; ROSSETTI; VALERIANO, 2020), onde a altimetria atinge aproximadamente 2500 metros no planalto a norte. A área apresenta outros locais com valores também significativos de elevação a oeste, no prolongamento do planalto do interflúvio Amazonas-Orenoco e também em rochas sedimentares do grupo Roraima, localizadas a oeste, que correspondem a estruturas soerguidas e apresentam um tipo específico de relevo de topo plano, conhecido regionalmente como *tepuys* (CPRM, 2010; IBGE, 2019). O rio Demini estende-se então, em seu meio-curso no pediplano, ainda sobre o substrato do escudo das Guianas, porém em uma superfície levemente ondulada. O rio segue nesta superfície, com eventuais inselbergs, até atingir contato com o Pantanal Setentrional, que se estende no baixo-curso até a foz, no rio Negro (IBGE, 2019; CREMON; ROSSETTI; ZANI, 2014)

Pantanal Setentrional (PS) é uma bacia sedimentar localizada a noroeste da Bacia Solimões, no contexto do rift intracratônico da Amazônia (ROSSETTI; MOLINA; CREMON, 2016). Essa região apresenta uma considerável área inundável, originada por atividade tectônica e subsidência (ALVES; ROSSETTI; VALERIANO, 2020). Durante o quaternário, o PS se desenvolveu como uma área rebaixada, com acúmulo de sedimentos em feições triangulares, correspondentes a sistemas deposicionais de megaleques. Os megaleques do Demini e Viruá, bem como seus hidroperíodos foram documentados por Rossetti et al. (2012), Zani e Rossetti (2012), e Cremon, Rossetti e Zani (2014).

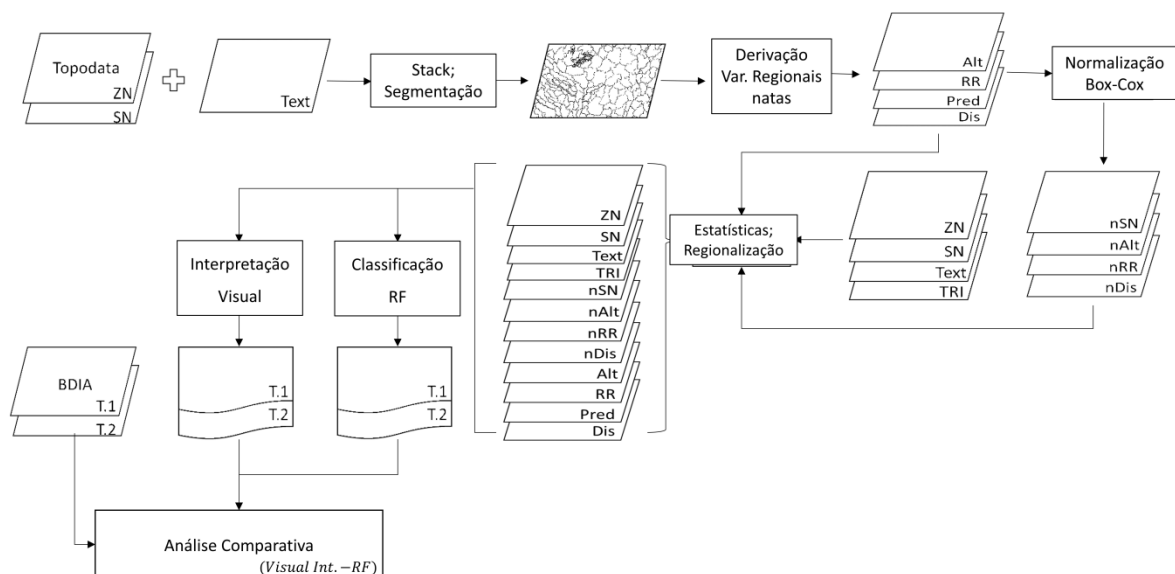
4 METODOLOGIA

Para a extensão da BHRD e seu entorno foram obtidas quatorze folhas articuladas com dados de elevação (ZN), através do banco de dados geomorfométricos do Brasil, o Topodata (BRASIL, 2008). Essas folhas, que são resultado de um processo de interpolação que resultou em um MDE com resolução de 1 arco-segundo (aproximadamente 30m), são resultado de uma metodologia desenvolvida especificamente para realização de análises morfométricas.

Mapeamentos Geomorfológicos, Geológicos, Pedológicos e de Vegetação foram obtidos do Banco de Dados de Informações Ambientais (BDIA), produzidos pelo IBGE (2020) e do RADAMBRASIL (BRASIL, 1975). Esses dados foram utilizados como fonte geral de informações sobre a área de estudo. Adicionalmente, imagens do sensor *Operational Land Imager* (OLI) da missão Landsat 8 e imagens disponibilizadas pelo serviço Bing Maps foram consultadas para análise de detalhe sobre dados ópticos.

As etapas envolvidas na elaboração deste trabalho podem ser vistas na Figura 4.1. Os processos foram realizados através do ArcGIS (mosaicagem, reamostragem, álgebra de mapas, rasterização, normalização e *layouts*); QGIS (cálculo das variáveis TRI e Text); eCognition (Segmentação Multirresolução); Idrisi (Superfície de Tendência, extração de estatísticas) e R (extração de estatísticas, gráficos e *Random Forest*).

Figura 4.1 – Fluxograma geral do trabalho.



Fonte: Produzido pela autora.

4.1 Aquisição e pré-processamento dos dados

As quatorze folhas contendo dados ZN foram mosaicadas e subamostradas para a resolução de 3 arco-segundos, além de convertidas para o formato 16-bit inteiro, com o objetivo de eliminar gaps e valores negativos. Adicionalmente, o relevo sombreado e declividade (SN) foram obtidos através do Topodata e executados os mesmos pré-processamentos com o objetivo de otimizar armazenamento e processamentos subsequentes. Este primeiro conjunto de dados foi organizado para servir de entrada ao cálculo das variáveis geomorfométricas e processo de segmentação.

A derivação das variáveis geomorfométricas ocorreu de acordo com suas especificidades. Em um primeiro momento foram calculadas as variáveis diretamente derivadas do MDE: Índice de Rugosidade do Terreno (TRI) e Textura da Superfície do Terreno (Text). Estas foram agrupadas à ZN e SN, já obtidas a partir do Topodata. No segundo momento, as variáveis regionais-natas foram calculadas, correspondendo a: Altura (Alt), Relevo Relativo (RR), Predominância (Pred) e Dissecação (Dis). Por último, foi realizada a normalização dos dados de Declividade (nSN), Altura (nAlt), Relevo Relativo (nRR) e Dissecação (nDis), utilizando a transformação Box-Cox. Esse processo de normalização visa reduzir os efeitos da assimetria e *outliers* na regionalização e análise estatística dos dados (CSILLIK; EVANS; DRĂGUȚ, 2015).

4.2 Derivação das variáveis geomorfométricas

As variáveis utilizadas neste trabalho podem ser identificadas como MDE, MDE-Derivada ou Regional-Nata. O MDE e SN foram obtidas a partir do banco de dados Topodata no formato “pronto para uso”. Através dos módulos Análise Morfométrica e Análise de Terreno, implementados no *plugin* SAGA GIS para QGIS, as também MDE-Derivadas, variáveis TRI e Text, foram calculadas para a bacia do Demini.

O Res, que também é uma variável MDE-Derivada, foi obtido através do cálculo de uma Superfície de Tendência com polinômio de grau 9. Esta superfície foi escolhida por ter apresentado o maior valor de coeficiente de determinação (r^2) quando comparada às demais, de menor grau. A superfície de tendência foi obtida a partir do IDRISI (EASTMAN, 2012) e as operações de recorte e álgebra de mapas foram realizadas no ArcGIS (ESRI, 2016).

As variáveis Regionais-Natas foram calculadas após o processo de segmentação, utilizando a unidade de terreno (segmento) como área para efetuação dos cálculos. Um exemplo é o relevo relativo, calculado a partir da subtração do Plano de Informação (PI) de máximos valores de ZN do PI de mínimos valores de ZN.

Estudos anteriores (GERENTE, 2018; ALVES, 2021) mencionam que a transformação Box-Cox pode ser aplicada para SN, Alt, RR e Dis com o objetivo de transformar sua distribuição para mais próxima a uma normal (Gaussiana), como sugerido por EISANK, SMITH e HILLIER (2014). Esse processo de normalização foi realizado com a ferramenta “Normalization Toolbox” desenvolvida por Csillik, Evans e Drăguț (2015). Esta ferramenta indica o expoente mais apropriado (em um intervalo de -5 a 5) para reduzir a assimetria na distribuição do dado.

O Relevo Residual, que também é uma variável MDE-derivada, foi o último parâmetro de terreno a ser calculado, porque sua representação depende do estabelecimento de uma área específica de análise (ZANI; ASSINE; MCGLUE, 2012). Nessa pesquisa, a área de análise corresponde à delimitação de Baixadas no Táxon 1. O baixo contraste nos valores de elevação torna difícil o delineamento entre áreas inundáveis e não-inundáveis. Nesse sentido, o Res possibilita o realce desses padrões de terreno.

4.3 Segmentação e regionalização das variáveis

Para iniciar a classificação visual das formas de relevo do primeiro táxon foram analisadas as variáveis MDE-derivadas, que contribuiriam como dado de entrada para o processo de segmentação. Posteriormente essas variáveis, junto aos segmentos gerados, foram utilizados para a derivação das variáveis regionais-natas.

Os produtos geomorfológicos do BDIA demonstraram uma divisão significativa dos padrões de relevo na BHRD mais especificamente relacionados à predominância de processos geomorfológicos. Esta divisão pode ser analisada observando, por exemplo, ambientes erosivos versus deposicionais, ou, como na classificação geomorfológica do primeiro táxon, Domínios Sedimentares versus Cratônicos. Por esta razão, o parâmetro ideal para a criação das unidades de terreno deveria ser capaz de retratar esta diferença. Dentre as variáveis geradas, Text possibilitou uma distinção significativa entre as áreas mais próxima à delimitação do BDIA, para suas classes mais representativas no primeiro táxon.

Uma vez selecionados como principais variáveis para a delimitação de unidades de terreno, os PIs referentes ao MDE, SN e Text foram empilhados de forma a compor um único arquivo raster. Este raster contendo três bandas foi utilizado como dado de entrada para o algoritmo de segmentação multirresolução implementado no *software* eCognition. Para este procedimento, os parâmetros selecionados foram: Escala = 50, Forma = 0.1 e Compacidade = 0.9, e todas as bandas tiveram o mesmo peso para a execução do processo.

Após o estabelecimento das unidades de terreno a partir dos segmentos, o processo de regionalização iniciou. Primeiramente foi realizada uma análise estatística das variáveis já calculadas, obtendo-se os valores mínimo, máximo, moda, média e amplitude para cada segmento de cada variável geomorfométrica. Após, foram calculadas as variáveis regionais-natas. Este grupo de variáveis é calculado a partir da análise de uma área em específico, sem considerar apenas um ponto (*pixel*). Com os segmentos é possível criar essas variáveis e, em sequência, calcular suas estatísticas, tornando-as variáveis regionalizadas.

Tabela 4.1 - Referência e fonte utilizada para derivação das variáveis geomorfométricas utilizadas para este estudo e tipo de derivação: MDE-derivada ou Regional-nata.

Variável	Referência / Fonte	Tipo	Abreviatura
Elevação	Topodata	MDE	ZN
Declividade	Topodata	MDE-derivada	SN
Declividade Normalizada	Topodata com Box-Cox	MDE-derivada	nSN
Altura	Muñoz (2009) - Segmento	Regional-nata	Alt
Altura Normalizada	Muñoz (2009) – Segmento e Box-Cox	Regional-nata	nAlt
Relevo Relativo	Muñoz (2009) - Segmento	Regional-nata	RR
Relevo Relativo Normalizado	Muñoz (2009) – Segmento e Box-Cox	Regional-nata	nRR
Textura Superfície do Terreno	Iwahashi, Pike (2007)	MDE-derivada	Text
Índice de Rugosidade do Terreno	Riley et al. (1999)	MDE-derivada	TRI
Predominância Topográfica	Muñoz (2009) - Segmento	Regional-nata	Pred
Dissecação	Muñoz (2009) - Segmento	Regional-nata	Dis
Dissecação Normalizada	Muñoz (2009) – Segmento e Box-Cox	Regional-nata	nDIS
Relevo Residual	Valeriano; Rossetti (2020)	MDE-derivada	Res

Fonte: Produzido pela autora.

Após a derivação das variáveis regionais-natas, os valores mínimo, máximo, média, moda e amplitude foram calculados a partir do IDRISI e R para as unidades de terreno obtidas durante a segmentação. Cada uma dessas medidas estatísticas gerou um PI, de forma que foram obtidos, ao total, 60 PIs para o Táxon 1 (5 medidas estatísticas de cada uma das 12 variáveis geomorfométricas, exceto resíduo) e 65 PIs para o Táxon 2 (estatísticas das 13 variáveis geomorfométricas).

Ressalta-se que durante os processos de classificação utilizaram-se 56 variáveis para o Táxon 1 e 61 para o Táxon 2. Isto ocorreu pois, devido a própria natureza das variáveis,

algumas delas possuíram variância nula, como por exemplo no caso da amplitude do Relevo Residual e valor mínimo da Altura.

4.4 Caracterização geomorfométrica

Para as classificações de Táxon 1, as classes resultantes deste trabalho foram denominadas Domínios; para as classificações do Táxon 2, as classes resultantes foram denominadas Subdomínios. Como Domínios foram estabelecidas as classes (1) Planaltos e (2) Baixadas. Os subdomínios foram divididos entre as classes (4) Planícies de Inundação, (5) Platô Amazônico, (6) Pediplano, (7) Planalto Residual, (8) Patamar, (9) Planalto Escarpado, (10) Planalto Tabular (Tabela 4.2). A classe 3 foi utilizada para mascarar corpos d'água.

Tabela 4.2 – Classificação hierárquica de formas de relevo elaborada e classificação geomorfológica utilizada pelo BDIA (IBGE, 2020).

Classes		Classes BDIA (adaptado)	
Domínios		Domínios Morfoestruturais	
(1) Planaltos	(2) Baixadas	Domínio Cratônico (agrupado)	Domínio Sedimentar (agrupado)
Subdomínios		Unidades Geomorfológicas	
(6) Pediplano	(4) Planície de Inundação	Pediplano Rio Branco – Rio Negro	Planície Amazônica
(7) Planalto Residual	(5) Platô Amazônico	Planaltos Residuais de Roraima	Depressão Rio Branco – Rio Negro
(8) Patamar		Patamar Dissecado de Roraima	
(9) Planalto Escarpado		Planalto do Interflúvio Amazonas - Orenoco	
(10) Planalto Tabular		Planalto Sedimentar de Roraima	

Fonte: Produzido pela autora.


4.4.1 Classificação visual – táxon 1

Os valores máximos de elevação e média de dissecção foram os mais relevantes para o delineamento do limite entre Planaltos e Baixadas no método de classificação visual. Considerando o contraste de valores de elevação próximos às escarpas dos planaltos do

Interflúvio, Sedimentar e Residual, foi importante elencar um parâmetro de terreno que pudesse contribuir para a divisão das Baixadas, que apresentavam, visualmente, um padrão suave e alongado. O fatiamento utilizando valores próximos às escarpas poderia levar à classificação errônea do pediplano como parte das Baixadas. Isto poderia levar a futuros erros também na delimitação dos subdomínios, como, por exemplo, na derivação da Superfície de Tendência.

Ressaltando a necessidade de delimitação das classes de terreno por seus processos atuais, a Dissecação foi considerada como solução para delimitar o que mais à frente seria o Pediplano dos Planaltos e o Platô das Baixadas. O Platô é caracterizado como um terreno sedimentar ligeiramente irregular (IBGE, 1959), ao passo que o Pediplano é descrito como um terreno dissecado que conta, eventualmente, com a presença de inselbergs (IBGE, 2009), o que pode causar algumas variações pontuais em medidas de declividade, textura e, principalmente, elevação e dissecação (Figura 4.2).

Figura 4.2 - Boxplot das variáveis utilizadas para o delineamento das classes do táxon 1.



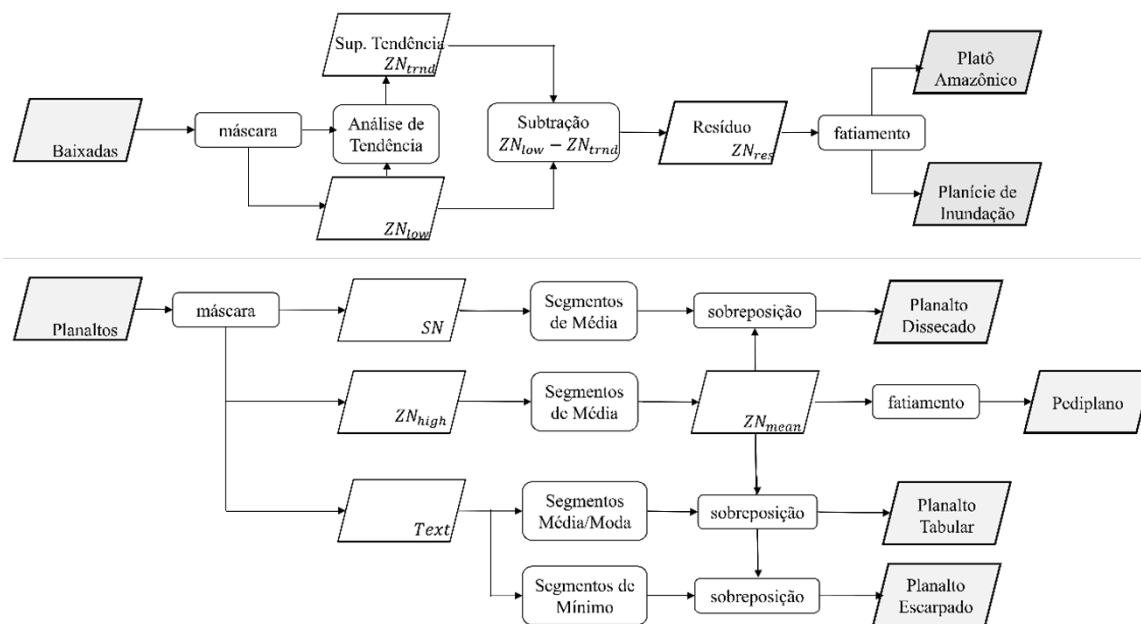
Neste método foram utilizados o máximo da elevação e média da dissecação. Ambos foram utilizados para definir os limites entre Planaltos (1) e Baixadas (2). Esses gráficos foram produzidos a partir de amostras caracterizadas a partir do mapeamento geomorfológico do BDIA.

Fonte: Produzido pela autora.

4.4.2 Classificação visual – táxon 2

Para obtenção dos subdomínios dos Planaltos e Baixadas, a classificação visual foi realizada para cada domínio individualmente. A Figura 4.3 mostra as variáveis utilizadas para o delineamento de cada subdomínio.

Figura 4.3 - Etapas da classificação visual.



No método de classificação visual foram utilizados textura, elevação, declividade e resíduo para identificar os subdomínios dos Planaltos e Baixadas.

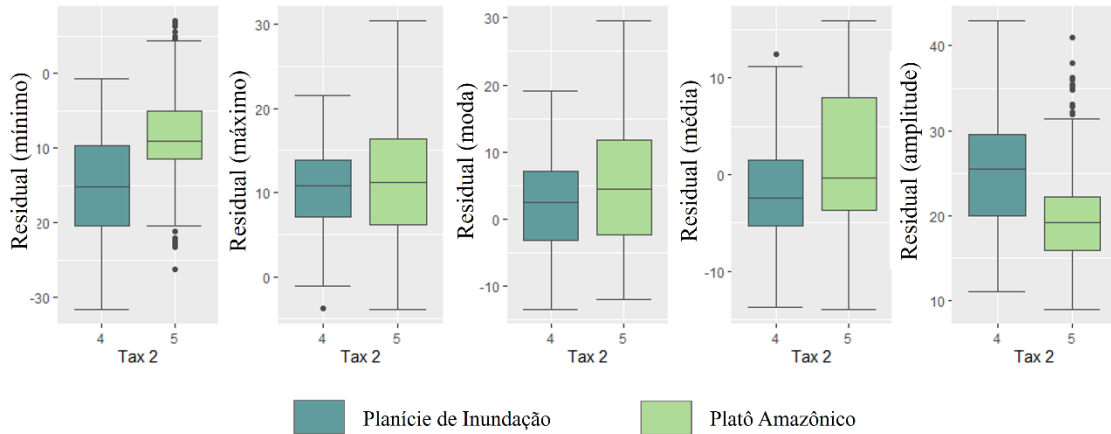
Fonte: Produzido pela autora.

Em relação à área de Baixadas, foi obtido um MDE (ZN_{low}) recortado para o limite obtido na classificação do primeiro táxon. O MDE-low foi utilizado como dado de entrada para obtenção da superfície de tendência (ZN_{trnd}) e foram testados diferentes graus de polinômio até ser obtido o resultado de melhor aderência. A ZN_{trnd} obtida a partir de um polinômio de nona ordem obteve um ajuste (R^2) de 59,32%, apresentando o melhor resultado entre os polinômios de menor ordem. Este resultado ressalta que quase 40% do relevo regional pode ser explicado por razões externas ao próprio relevo (tendência), e possivelmente relacionado a tectonismo e processos e feições sobrepostos.

Após a derivação da ZN_{trnd} , foi realizada a subtração deste PI a partir do ZN_{low} , de forma a obter o PI de elevação residual (ZN_{Res}). ZN_{Res} é um PI que contém valores positivos e negativos, e zero corresponde a uma divisão equitativa entre volumes

positivos e negativos. O ZN res também foi regionalizado para sua análise no contexto dos segmentos. Para esta área de interesse, o valor de ZN res que melhor correspondeu ao delineamento das Planícies de inundação foi por volta de 1.5 (Figura 4.4).

Figura 4.4 - Boxplots das métricas de elevação residual para a classificação visual dos subdomínios das Baixadas.

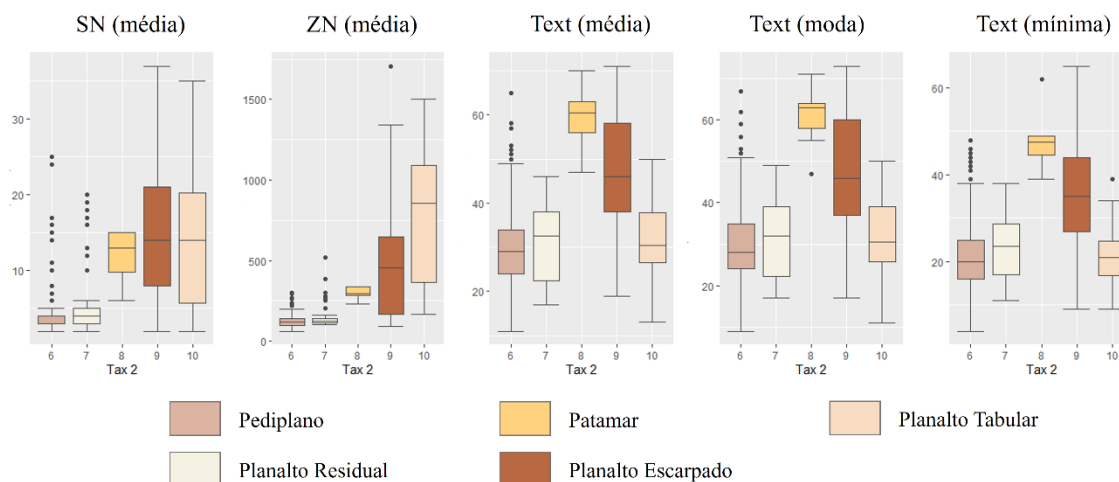


Fonte: Produzido pela autora.

Para obter os subdomínios dos Planaltos, foi realizado um processo de classificação por etapas. No primeiro momento, foi identificado que valores médios de ZN abaixo de 200 metros correspondiam à área de Pediplano. Em sequência, combinando os valores de ZN entre 200 e 400 metros e a média de SN abaixo de 17 graus de declividade, foi possível identificar o Patamar.

O Planalto Escarpado foi delimitado utilizando a média da ZN maior que 420 metros e valor mínimo de Text acima de 25. O Planalto Tabular foi identificado com valor similar de média de ZN, porém sua Textura era menor, quando comparado com o Planalto Escarpado (Figura 4.5).

Figura 4.5 - Boxplot das variáveis utilizadas para classificação visual dos subdomínios dos Planaltos.



Foram utilizadas média da SN, ZN e média, moda e mínimo da Text. Todas foram utilizadas para definir os limites entre as classes (6) Pediplano, (7) Planalto Residual, (8) Patamar, (9) Planalto Escarpado e (10) Planalto Tabular. Esses boxplots foram produzidos com amostras aleatórias classificadas a partir dos dados BDIA.

Fonte: Produzido pela autora.

4.4.3 Classificação *Random Forest* – táxon 1

O pacote *randomForest*, disponibilizado para a linguagem de programação R, foi o algoritmo utilizado para realizar a classificação neste trabalho. O algoritmo estabelece alguns parâmetros a serem preenchidos, como *ntree*, *mtry* e definição de conjunto de amostras como treinamento e validação.

O processo de amostragem para a classificação RF utilizou como referência para atribuição de classes o mapeamento geomorfológico disponibilizado pelo BDIA (Domínios Morfoestruturais e Unidades Geomorfológicas). O primeiro passo consistiu em agrupar os quatro domínios morfoestruturais presentes na área de estudo em duas grandes classes: Domínios Cratônico e Sedimentar. A análise da área através de SIG demonstrou que ambos domínios apresentavam extensões similares: o Domínio Cratônico correspondia a uma área de aproximadamente 20.542 quilômetros quadrados (correspondendo a 50,3% da bacia), e o Domínio Sedimentar correspondia a aproximadamente 20.051 quilômetros quadrados (49,07% da área da BHRD). Corpos d'água correspondiam ao restante da área (0,63%).

Considerando a similaridade de representação das grandes classes na BHRD, foram geradas 1000 amostras aleatórias para cada Domínio, totalizando 2000 amostras para toda a bacia. Para minimizar efeitos de autocorrelação espacial, foi estabelecida uma distância mínima de 250 metros (aproximadamente 3 *pixels*) na geração dos pontos amostrais. As mesmas amostras foram também identificadas de acordo com as Unidades Geomorfológicas do BDIA em etapa posterior.

Para a construção do modelo de classificação RF para o Táxon 1, foi determinado que 70% das 2000 amostras seriam utilizadas para treinamento e 30% para validação (Tabela 4.2). O *n_{tree}* foi estabelecido como 500 e, considerando que foram utilizadas 56 variáveis, o *mtry* foi 7. As variáveis utilizadas no modelo foram mínimo, máximo, moda, média e amplitude de todos os 12 parâmetros de terreno citados anteriormente (excluindo o Res), exceto o mínimo da Altura, Dissecação, Dissecação Normalizada e amplitude do Relevo Relativo, pois possuíam variância nula.

Tabela 4.3 – Conjunto de amostras para a classificação *Random Forest* Táxon 1.

Resumo das amostras - Táxon 1					
Classes	Total de Amostras			% Amostras	
	Treinamento	Validação	Total	Treinamento	Validação
Planaltos	700	300	1000	70	30
Baixadas	700	300	1000	70	30
Total	1400	600	2000	70	30

Fonte: Produzido pela autora.

Após a classificação do primeiro táxon, as classes Planaltos e Baixadas, relativas aos Domínios Cratônico e Sedimentar, respectivamente, foram obtidas. A análise dessas classes se deu de forma individual para identificação de seus subdomínios no Táxon 2.

4.4.4 Classificação *Random Forest* – táxon 2

Para a classificação dos subdomínios da área de Baixadas, utilizando o classificador RF, os parâmetros estabelecidos foram: 70% das 1072 amostras foram utilizadas para treino e 30% para validação (do conjunto inicial de 2000 amostras, 1072 foram classificadas como pertencentes ao domínio Baixadas) (Tabela 4.3). O parâmetro *n_{tree}* foi estabelecido como 500 e para *mtry* foi considerado o valor 7. Este modelo utilizou as 56 variáveis aplicadas na classificação RF para o Táxon 1 e, adicionalmente, os valores de

mínimo, máximo, moda, média e amplitude do Relevo Residual. O Res foi calculado através da Superfície de Tendência elaborada especificamente para o domínio Baixadas na classificação RF de táxon superior.

Tabela 4.4 - Conjunto de amostras para a classificação *Random Forest* Táxon 2, Domínio Baixadas.

Resumo das amostras - Táxon 2: Baixadas					
Classes	Total de Amostras			% Amostras	
	Treinamento	Validação	Total	Treinamento	Validação
Planície de Inundação	105	45	150	70	30
Platô Amazônico	590	253	843	70	30
Pediplano	50	24	74	68	32
Planalto Escarpado	3	2	5	60	40
Total	748	324	1072	70	30

Fonte: Produzido pela autora.

Os subdomínios da classe Planaltos foram identificados, através da classificação RF, utilizando os seguintes parâmetros: 70% das 928 amostras foram utilizadas para treinamento do modelo e 30% foram utilizadas para validação (das 2000 amostras iniciais, apenas 928 foram classificadas como Planaltos) (Tabela 4.4). O ntree estabelecido foi 500 e o mtry corresponde a 7, considerando as 56 variáveis utilizadas pelo modelo. Para esta classificação, foram utilizadas as mesmas variáveis mencionadas no procedimento de classificação do primeiro táxon.

Tabela 4.5 - Conjunto de amostras para a classificação *Random Forest* Táxon 2, Domínio Planaltos.

Resumo das amostras - Táxon 2: Baixadas					
Classes	Total de Amostras			% Amostras	
	Treinamento	Validação	Total	Treinamento	Validação
Platô Amazônico	5	2	7	71	29
Pediplano	383	164	547	70	30
P. Residual	49	21	70	70	30
Patamar	6	2	8	75	25
P. Escarpado	188	80	268	70	30
P. Tabular	20	8	28	71	29
Total	651	277	928	70	30

Fonte: Produzido pela autora.

4.5 Análise dos resultados

Os resultados obtidos através da classificação RF foram comparados com as classes geomorfológicas do BDIA através de análise visual. Os grupos de *pixels* selecionados como conjunto de validação durante o RF foram utilizados para análise da matriz de confusão e métricas de classificação, como, por exemplo, Acurácia Global (AG), Recall (R), Precision (P) e F1-score (F).

A AG corresponde à possibilidade de um *pixel* ser corretamente identificado. É calculada através da divisão da soma dos *pixels* classificados corretamente (verdadeiros positivos e verdadeiros negativos) por todos os *pixels* de validação (Equação 4.1)

$$AG = \frac{VP + VN}{VP + FP + VN + FN} \quad (4.1)$$

Onde VP corresponde a valores Verdadeiros Positivos, VN é igual a Verdadeiros Negativos, FP significa Falso Positivo, e FN corresponde a Falso Negativo.

R é calculado a partir da Equação 4.2:

$$R = \frac{VP}{VP + FN} \quad (4.2)$$

E corresponde ao quanto uma classe foi identificada corretamente pelo classificador.

Precision pode ser calculada como:

$$P = \frac{VP}{VP + FP} \quad (4.3)$$

E representa o número de *pixels* classificados corretamente, dividido por todos os *pixels* que o classificador identificou como a classe alvo, certo ou erroneamente.

F1-score é calculado a partir da razão entre P e R usando a Equação 4.4:

$$F1 \text{ score} = 2 \times \frac{(P \times R)}{(P + R)} \quad (4.4)$$

A partir do pacote *randomForest*, no R, foi possível calcular também a importância das variáveis. A importância é medida utilizando a métrica MDA, que representa a importância da variável para cada modelo. Se uma variável apresenta um alto valor de MDA, significa que essa variável possui uma grande importância para o modelo.

Com o objetivo de identificar as principais diferenças entre as classificações (visual e RF), foi também empregada a análise visual, comparando os resultados entre si e também com as classes geomorfológicas do BDIA. Adicionalmente, foi calculado um Mapa Diferença (MD) entre as classificações para cada táxon, utilizando a seguinte equação:

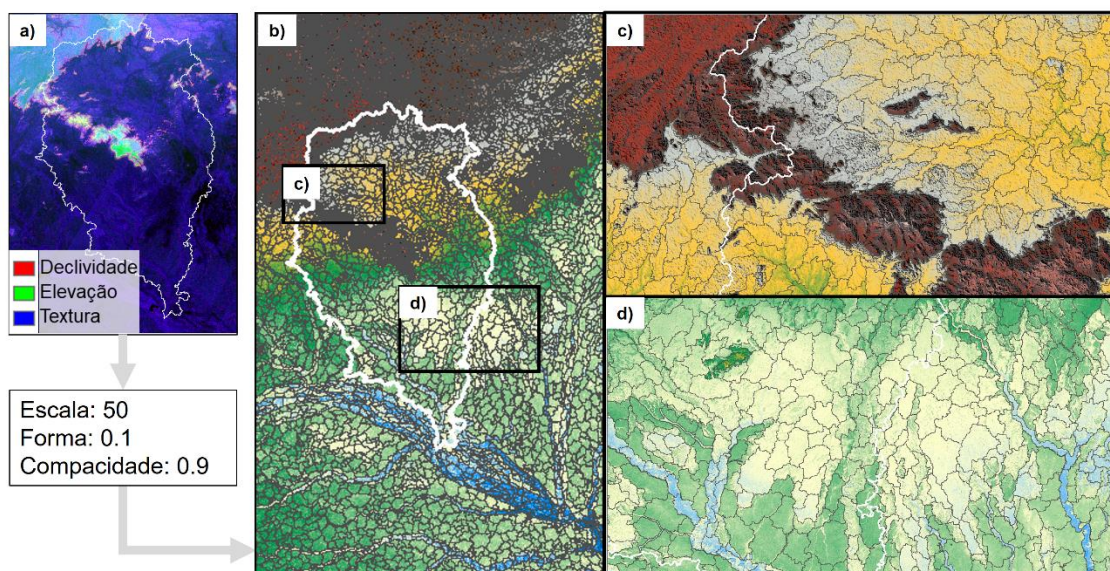
$$MD = \text{Class.V}_{Taxon} - \text{Class.RF}_{Taxon} \quad (4.5)$$

Onde Class.V corresponde a classificação visual resultante do táxon N, e Class. RF é o resultado da classificação Random Forest para as mesmas classes analisadas da Classificação Visual. O MD permite realçar a visualização dos diferentes segmentos enfatizando os contrastes entre os resultados.

5 RESULTADOS

As unidades de terreno obtidas a partir da segmentação multirresolução possibilitaram a identificação visual de formas de terreno através do agrupamento de áreas com características semelhantes e divisão entre áreas distintas. Embora tenha sido realizada para toda a área de estudo, a segmentação resultou em unidades de terreno com aspectos distintos: sendo menores e em maior quantidade na região dos Planaltos, e maiores e em menor quantidade na região das Baixadas. Estes diferentes padrões de segmentos denotam a espacialidade da ZN, SN e Text nos dois grandes domínios da bacia do rio Demini (Figura 5.1).

Figura 5.1 – Resultado da segmentação multirresolução para a bacia hidrográfica do rio Demini.



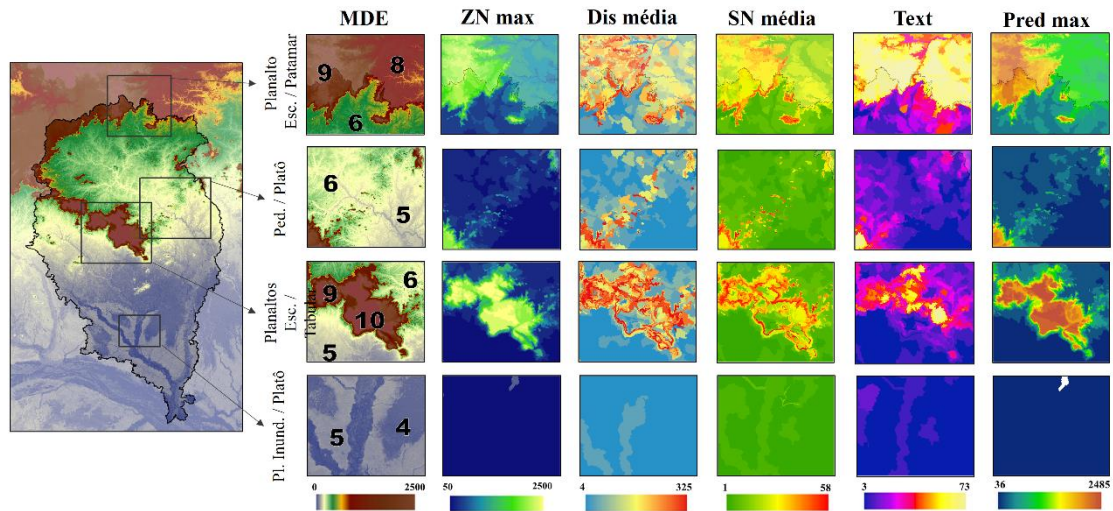
Na figura (A) as variáveis utilizadas para o processo de segmentação são visualizadas através de uma composição RGB. Em (B) o resultado da segmentação demonstra maior número de segmentos (mais tonalidades de cinza) em áreas de maior elevação e dissecção, ao norte da área de estudo. Nas figuras (C) e (D) os segmentos gerados para as áreas de Planaltos e Baixadas, respectivamente. É possível visualizar também segmentos alongados, representando os rios da região.

Fonte: Produzido pela autora.

Após a derivação das variáveis geomorfométricas, cálculo das variáveis regionais-natas e suas estatísticas, foi possível observar a espacialização desses atributos de terreno, considerando a classificação de relevo do BDIA. Para a análise dos atributos que seriam utilizados nos processos de segmentação, priorizou-se uma análise focada em regiões de limites entre classes, conforme Figura 5.2. É possível identificar que as variáveis

derivadas possuem significativa capacidade de diferenciação entre as classes de Planaltos, ao passo que os subdomínios das Baixadas aparecem pouco discerníveis.

Figura 5.2 – Espacialização de variáveis geomorfométricas com detalhes em áreas de limite entre classes de relevo.

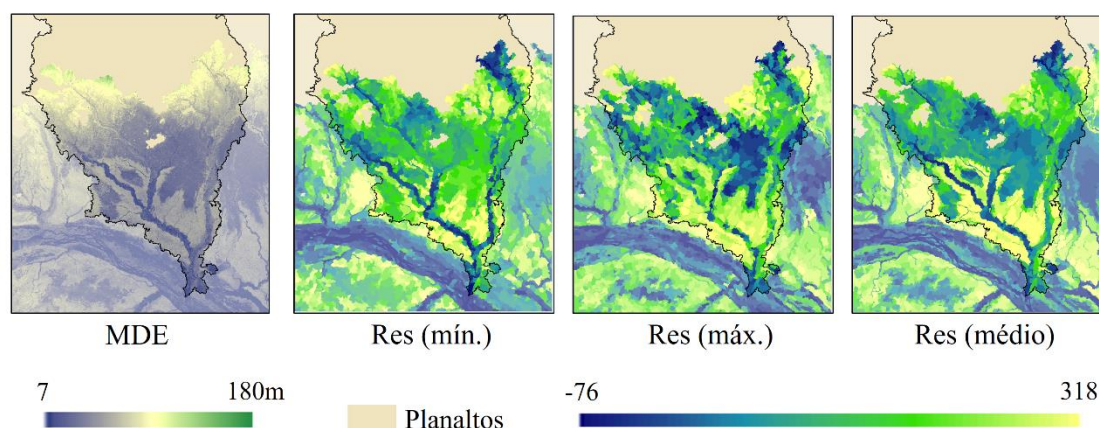


À esquerda é possível identificar a localização das áreas destacadas que foram representadas através das variáveis geomorfométricas. De cima para baixo: na primeira linha é representado o limite entre as classes (6) Pediplano, (8) Patamar e (9) Planalto Escarpado. Na segunda linha observa-se o limite entre (5) Platô Amazônico e (6) Pediplano. Na terceira linha identificam-se as feições (5) Platô Amazônico, (6) Pediplano, (9) Planalto Escarpado e (10) Planalto Tabular. E na quarta linha, os limites entre (4) Planícies de Inundação e (5) Platô Amazônico.

Fonte: Produzido pela autora.

A derivação do relevo residual, porém, se mostrou efetiva para a delimitação dos subdomínios das Baixadas. Na Figura 5.3 é possível identificar o contraste entre as áreas de Planícies de Inundação e Platô Amazônico, apresentando menores e maiores valores de Res, respectivamente.

Figura 5.3 – Estatísticas de relevo residual no Domínio Baixadas da bacia do rio Demini.



Fonte: Produzido pela autora.

A matriz de confusão obtida a partir da classificação RF para o Taxon 1 detalhou que a AG foi de 96%. O modelo, que considerou 56 variáveis (todas, exceto Res e aquelas sem variância), apresentou boa correspondência ao dado agrupado do BDIA. A métrica F1-score atingiu 96,2% para Planaltos e 96,1% para Baixadas (Tabela 5.1).

Tabela 5.1 – Matriz de Confusão dos dados de validação utilizados para classificação RF do Taxon 1.

Matriz de Confusão - Taxon 1				
		Referência		
		Planaltos	Baixadas	N
Predict	Planaltos	293	16	309
	Baixadas	7	284	291
N		300	300	
Recall		0.9767	0.9467	
Precision		0.9482	0.9759	
F1-score		0.9622	0.9611	

Fonte: Produzido pela autora.

As métricas de avaliação da classificação RF para os subdomínios dos Planaltos, no Taxon 2, apresentou AG de 84,4%. O modelo também considerou as 56 variáveis utilizadas na classificação para o Taxon 1 e atingiu valores de F1-score de 89% para a classe 6 (Pediaplano), 55% para classe 7 (Planalto Residual), 80% para a classe 8

(Patamar), 81% para a classe 9 (Planalto Escarpado) e 77% para classe 10 (Planalto Tabular). Na matriz de confusão (Tabela 5.2) dessa classificação RF para Planaltos também é possível identificar amostras correspondentes a classe 5 (Platô). Esses *pixels* foram anteriormente (no Táxon 1) classificados como Planaltos mas correspondem, na verdade, ao Platô do Domínio Baixadas.

Tabela 5.2 - Matriz de Confusão dos dados de validação utilizados para classificação RF dos Planaltos do Táxon 2.

		Matriz de Confusão - Táxon 2: Planaltos						N
		Platô Amazôn.	Pediapl.	Plan. Residual	Referência			
	Patam.				Plan. Escarpado	Plan. Tabular		
Predict	Platô Amazôn.	0	0	0	0	0	0	0
	Pediapl.	2	154	12	0	14	0	182
	Plan. Residual	0	0	8	0	0	0	8
	Patam.	0	0	0	2	1	0	3
	Plan. Escarpado	0	10	1	0	65	3	79
	Plan. Tabular	0	0	0	0	0	5	5
	N	2	164	21	2	80	8	
Recall		0.0000	0.9390	0.3810	1.0000	0.8125	0.6250	
Precision		x	0.8462	1.0000	0.6667	0.8228	1.0000	
F1-score		x	0.8902	0.5517	0.8000	0.8176	0.7692	

Fonte: Produzido pela autora.

A classificação dos subdomínios de Baixadas apresentou AG igual a 87%, e F1-score de 72% para a classe 4 (Planícies de Inundação) e 92% para a classe 5 (Platô Amazônico). Para este modelo, 61 variáveis foram analisadas, correspondendo às 56 mencionadas anteriormente, e as 5 estatísticas calculadas da elevação Residual para Baixadas. Na matriz de confusão para os subdomínios de Baixadas é possível também identificar *pixels* correspondendo às classes 6 e 9, que foram anteriormente identificadas na classificação do Táxon 1 como Baixadas, porém correspondem, na verdade, a afloramentos ou morros isolados relacionados ao Pediplano e Planalto Escarpado.

Tabela 5.3 - Matriz de Confusão dos dados de validação utilizados para classificação RF das Baixadas do Táxon 2.

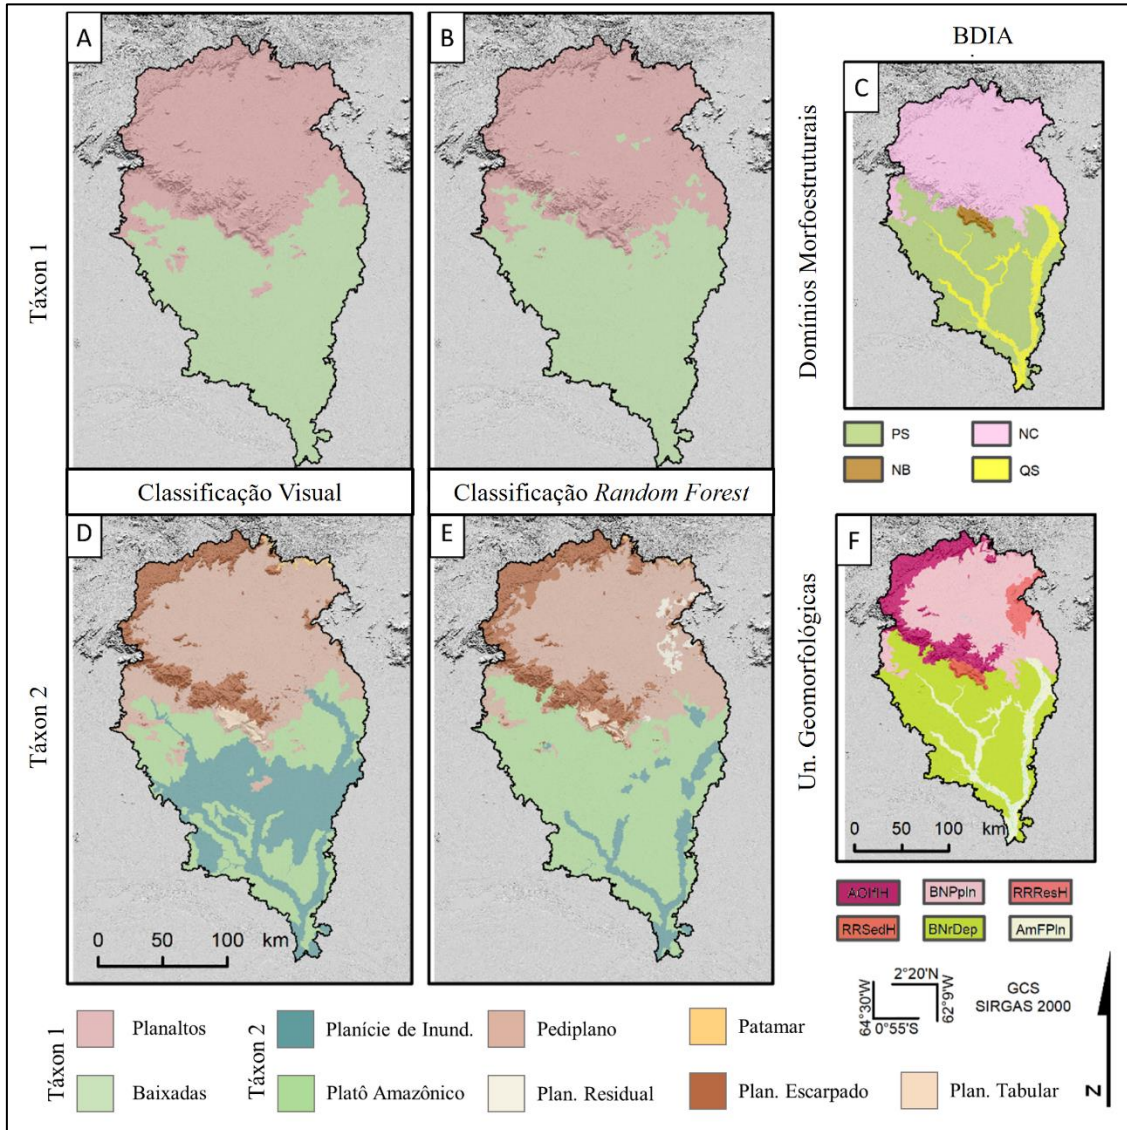
Matriz de Confusão - Táxon 2: Baixadas						
		Referência				N
		Planície Inundação	Platô Amazônico	Pediaplano	Plan. Escarpado	
Predict	Planície Inundação	31	10	0	0	41
	Platô Amazônico	14	236	8	0	258
	Pediaplano	0	7	16	1	24
	Plan. Escarpado	0	0	0	1	1
	N	45	253	24	2	
<i>Recall</i>		0.6889	0.9328	0.6667	0.5000	
<i>Precision</i>		0.7561	0.9147	0.6667	1.0000	
<i>F1-score</i>		0.7209	0.9237	0.6667	0.6667	

Fonte: Produzido pela autora.

5.1 Mapeamento geomorfométrico

Os resultados obtidos pela classificação visual e *Random Forest* podem ser vistos na Figura 5.4, com a classificação geomorfológica do BDIA para comparação. Os mapas foram alinhados na imagem conforme o método de classificação empregado no trabalho e seu correspondente Táxon.

Figura 5.4 – Resultados dos métodos de classificação visual e RF para delineamento de formas de relevo.



Na imagem é possível identificar feições de terreno obtidas através de classificação visual (A) e (D), classificação RF (B) e (E), e Domínios Morfoestruturais (C) e Unidades Geomorfológicas (F) do BDIA. As classes identificadas em (A), (B), (D) e (E) são: 1 - Planaltos, 2 - Baixadas, 4 - Planícies de Inundação, 5 - Platô Amazônico, 6 - Pediplano, 7 - Planalto Residual, 8 - Patamar, 9 - Planalto Escarpado e 10 - Planalto Tabular. Figuras (C) e (F) representam: OS - Bacias e Coberturas Sedimentares Fanerozóicas, NB - Cinturões Móveis Neoproterozóicos, NC - Crátoms Neoproterozóicos, QS - Sedimentos Quaternários, BNPpIn - Pediplano Branco-Negro, AmFPln - Planície de Inundação Amazônica, BNrDep - Depressão Branco-Negro, RRSedH - Planalto Sedimentar de Roraima, AOIfH - Planalto do Interflúvio Amazonas-Orenoco, RRResH - Planalto Residual de Roraima (IBGE, 2020).

Fonte: Produzido pela autora.

As duas classes do Táxon 1 obtidas pelos métodos visual e RF apresentaram similaridades com o delineamento das classes do BDIA, considerando a agregação dos

4 domínios em 2 classes. Ainda que seja possível identificar segmentos de Baixadas no centro de Planaltos, conforme retratado em Figura 5.4 (B), possivelmente devido a valores menores de elevação ou pequena variação de textura, o limite entre Planaltos e Baixadas corresponde significativamente ao limite entre os Domínios Cratônico e Sedimentar do BDIA.

Também é possível identificar segmentos isolados de Planaltos próximos ao centro da área de Baixadas na Figura 5.4 (A). Essa área foi particularmente identificada como Planaltos pois seus elevados valores de Dissecação e ZN estão mais relacionados a um ambiente erosivo, ao contrário de seu entorno, com características predominantemente deposicionais.

A Figura 5.4 (E) apresenta o mesmo número de classes quando comparada às Unidades Geomorfológicas do BDIA. O classificador RF pôde distinguir o topo plano do Planalto Sedimentar das serranias escarpadas do Planalto do Interflúvio Amazonas-Orenoco. O Planalto Residual no nordeste da área também foi identificado através do RF, apesar de sua delimitação ter sido mais restrita a unidades de terrenos elevadas, em comparação às unidades do BDIA.

A análise visual sobre as variáveis elevação, declividade e textura não foi capaz de identificar o Planalto Residual, conforme Figura 5.4 (D). No entanto, a distinção entre os Planaltos Tabular e Escarpado foi facilmente definida a partir das estatísticas da textura.

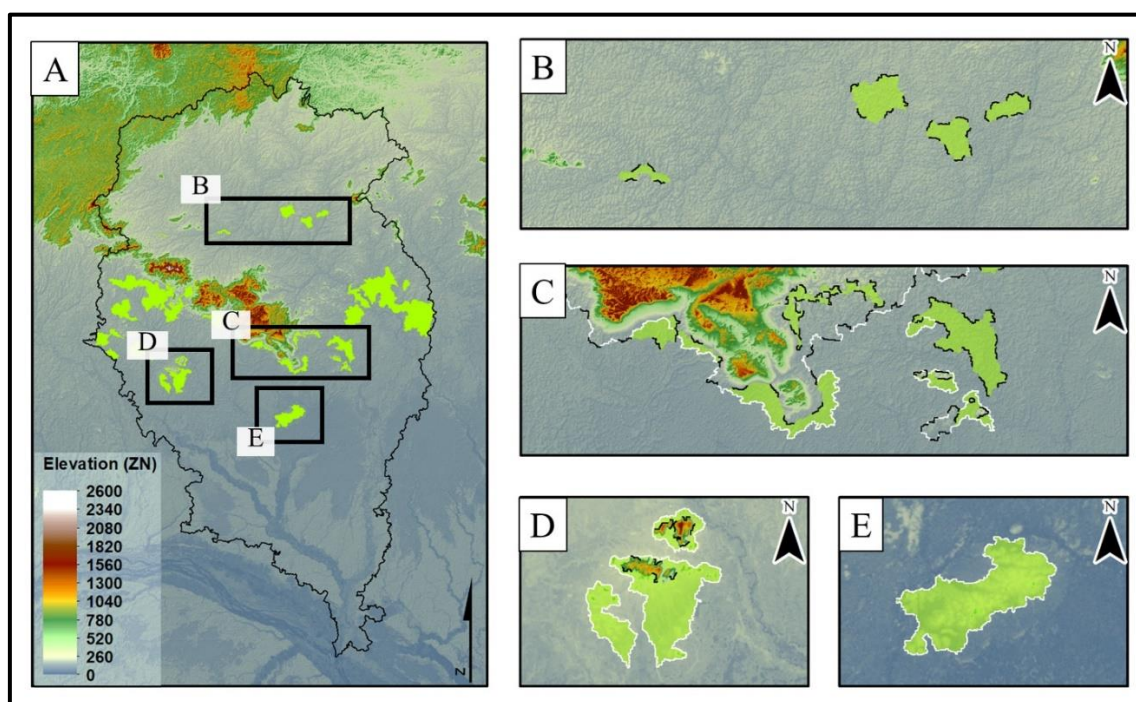
A principal diferença na Figura 5.4 (D), quando comparada às outras, representando formas de relevo do Táxon 2, consiste na extensão das Planícies de Inundação. As Planícies de Inundação representadas nas Unidades Geomorfológicas do BDIA ocorrem adjacentes aos principais rios da bacia do Demini, em suas Baixadas com valores escassos de textura. Sua identificação através do RF (Figura 5.4 (E)) foi possível especialmente nas áreas de menor elevação e mais largas, próximas à foz da bacia. Tendo em vista o acúmulo de sedimentos, que pode ocorrer nas margens dos rios próximos ao limite entre Planaltos e Baixadas, alguns dos segmentos correspondentes a áreas inundáveis podem ser identificados como áreas não-inundáveis. Isto ocorre visto que a variação da textura e declividade aumenta nesses locais.

O principal parâmetro de terreno utilizado para delinear os subdomínios das Baixadas, utilizando a classificação visual, foi o Resíduo da Elevação, que foi capaz de realçar sutis mudanças na topografia. A longa extensão de áreas inundáveis classificadas visualmente nesse trabalho aparece em contraste com seu entorno em todas as estatísticas do Resíduo regionalizado, e em outras bibliografias, como os mapas de vegetação, pedologia e geologia do BDIA, mapeamento de Geodiversidade do estado do Amazonas (CPRM, 2010) e em imagens ópticas de sensoriamento remoto.

5.2 Análise comparativa

Para analisar de forma comparativa os resultados, foram elaborados Mapas de Diferença. No Mapa Diferença do Táxon 1 é possível visualizar, através da Figura 5.5 (A), as áreas de diferença entre os resultados visual e RF, em verde claro. Essas áreas estão concentradas no limite entre Planaltos e Baixadas (Figura 5.5 (C)) e ocorrem majoritariamente próximas às escarpas e inselbergs (Figuras 5.5 (D) e (E)). Essas formas de relevo possuem valores mais altos de elevação e alto contraste com as feições ao redor. Em oposto, segmentos de terreno com menor elevação na região de Planaltos foram identificados como Baixadas através do RF.

Figura 5.5 – Mapa de Diferença – Táxon 1.

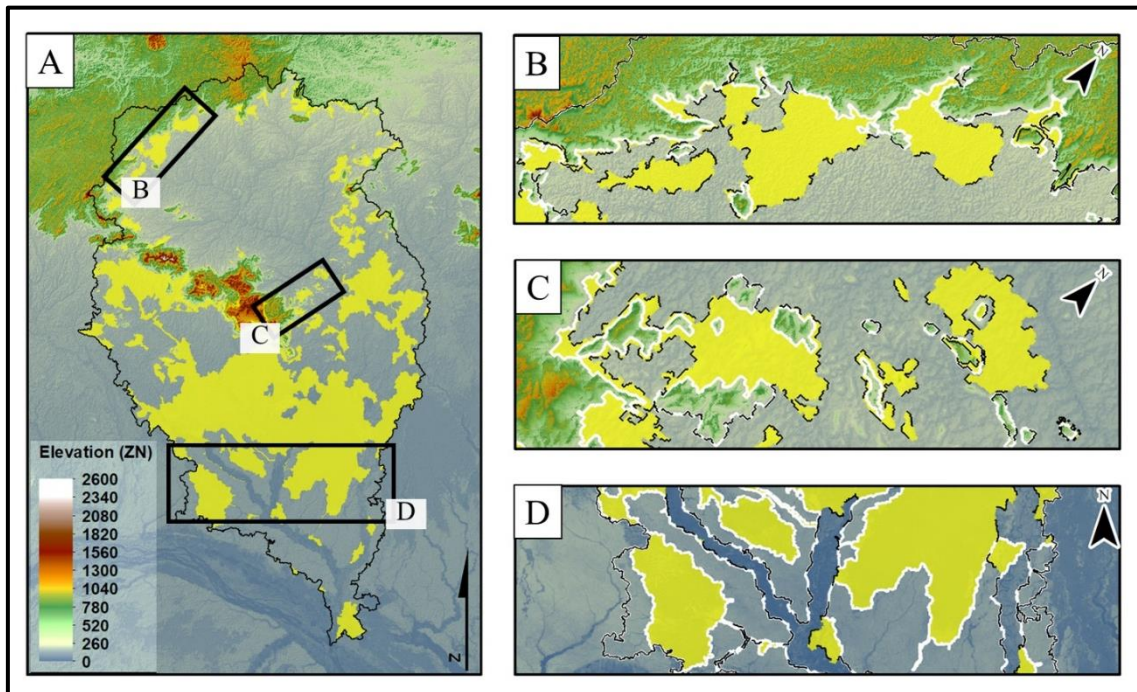


O Mapa de Diferença mostra em (A), (B), (C), (D), e (E) os principais contrastes entre as classificações para o Táxon 1 com as diferenças sendo representadas em verde claro. Linhas tracejadas em preto representam os limites da classe no resultado do RF, a linha branca representa o limite do resultado de classificação visual.

Fonte: Produzido pela autora.

O MD produzido para as classificações do Táxon 2 (Figura 5.6) exibe polígonos amarelos representando as discrepâncias entre os mapeamentos geomorfométricos para a BHRD. Novamente, algumas alterações aparecem próximas às escarpas do Planalto Tabular e Escarpado, como visto nas Figuras 5.6 (B) e 5.6 (C). Também é possível identificar contrastes próximos aos limites entre Planaltos e Baixadas e, principalmente, nas Planícies de Inundação ao sul (Figura 5.6 (D)).

Figura 5.6 – Mapa de Diferença – Táxon 2.



O Mapa de Diferença do Táxon 2 (A) representa as variações nos resultados em amarelo. Figura (B) mostra as diferenças na delimitação entre Planalto e Pediplano. Figura (C) resalta áreas próximas à inselbergs no centro da bacia. E as planícies de inundação não consideradas pela classificação RF podem ser vistas sobre o MDE em (D). Linhas tracejadas em preto representam os limites da classe no resultado do RF, a linha branca representa o limite do resultado de classificação visual.

Fonte: Produzido pela autora.

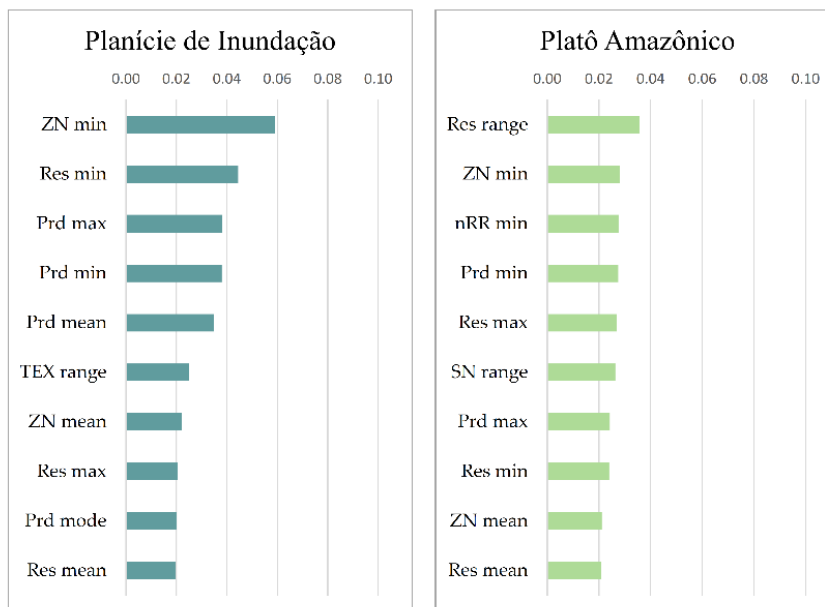
A Figura 5.6 (B) demonstra que a classificação visual identificou de forma mais restrita o limite entre o Planalto Escarpado e o Pediplano. Na Figura 5.6 (C) é possível identificar um padrão similar: RF apresenta uma delimitação mais abrangente, se comparado ao método visual. Na Figura 5.6 (D), as planícies de inundação aparecem realçadas em amarelo, sobreposta e em contraste à camada do MDE.

As diferenças de classificação em unidades de terreno localizadas nas margens dos rios podem ser explicadas através do fenômeno dos “rios suspensos” (IBGE, 1955). Em alguns trechos de rio as margens assumem maior elevação e altura devido ao acúmulo de sedimentos, o que pode causar dúvidas na análise em contexto mais amplo, visto que essas margens assumem características de feições de terreno alto-predominantes.

Como resultado do processo de classificação RF, também é possível verificar o ranqueamento das variáveis por predição, considerando sua importância para cada classe. Para a classificação dos subdomínios das Baixadas, foi possível identificar que

ZN, Res, Pred e RR foram as mais importantes para o delineamento de Planícies de Inundação e Platô (Figura 5.7).

Figura 5.7 – Ranking de Importância das Variáveis – Táxon 2: Baixadas.




Os gráficos exibem as 10 variáveis mais importantes para a classificação de planícies de inundação e platô utilizando o método RF.

Fonte: Produzido pela autora.

Na classificação dos subdomínios de Planaltos, as estatísticas da ZN se mostraram entre as mais importantes. Exceto pelo Patamar, que foi delineado principalmente a partir da Text, Pediplano e os Planaltos Residual e Tabular obtiveram ótima resposta a partir dos dados de ZN e Pred. O Planalto Escarpado recebeu grande contribuição de ZN, Text e Pred para sua caracterização (Figura 5.8).

Figura 5.8 – Ranking de Importância das Variáveis – Taxon 2: Planaltos.



Os gráficos mostram as 10 variáveis mais importantes para a classificação RF do Pediplano, Patamar e Planaltos Escarpado, Tabular e Residual.

Fonte: Produzido pela autora.

6 DISCUSSÃO

A Planície de Inundação identificada nos resultados – apresentando-se de forma mais significativa na classificação visual, está inserida na Bacia Sedimentar do Pantanal Setentrional (ROSSETTI; MOLINA; CREMON, 2016). Essa bacia sedimentar corresponde a uma extensa área no norte da Amazônia, onde a subsidência ocasionou a acumulação de sedimentos durante épocas mais chuvosas, e a variação de períodos com baixa ou alta precipitação levou alguns pontos a manterem uma cobertura d'água rasa, periodicamente. Esse substrato raso e periodicamente alagável, associado ao tectonismo nessa área proporcionou o acúmulo de sedimentos e desenvolvimento de sistemas de megaleques, com extensas áreas completamente cobertas por sedimentos de areia branca (ROSSETTI et al., 2019).

Estas áreas, realçadas na Figura 5.3 (D), foram caracterizadas por Cremon (2012) de acordo com a frequência de inundação e classes de vegetação associadas a essas áreas (CREMON; ROSSETTI; ZANI, 2014). Considerando a topografia predominantemente plana, o resíduo da elevação permitiu um melhoramento em seu delineamento, conforme relatado por Zani, Assine e McGlue (2012) no megaleque do Taquari e Valeriano e Rossetti (2020) na Amazônia Central.

As Planícies de Inundação representadas no resultado da classificação visual foram identificadas desta forma em razão da concentração significativa de baixos valores de elevação Residual na Depressão dos Rios Branco e Negro. Como identificado por Hess et al., (2015), Fluet-Chouinard et al. (2015), Yamazaki, Trigg e Ikeshima (2015), Pekel et al., (2016), Aires et al. (2017), Parrens et al. (2019), Rosenqvist et al. (2020) e Mapbiomas (2022), essas áreas podem ser identificadas como áreas alagáveis, inundáveis ou planícies de inundação por diferentes produtos e análises de sensoriamento remoto. De acordo com Fleischmann et al. (2022), as áreas classificadas visualmente como Planícies de Inundação no presente trabalho possuem mais de 2 diferentes métodos classificando-as como áreas inundáveis em períodos de máxima extensão de inundação, considerando uma escala de detalhe de 1km.

Estudos futuros podem propor uma subdivisão das Planícies de Inundação no nível hierárquico de classificação correspondendo ao 3º Táxon. As áreas inundáveis poderiam ser separadas em subgrupos, como por exemplo várzeas e planícies em forma de cunha,

uma vez que suas dinâmicas temporais dependem de diferentes condições e frequências de inundação.

O mapeamento geomorfológico do BDIA serviu como referência para o estabelecimento do arranjo hierárquico das feições de terreno, considerando a Taxonomia do Mapeamento Geomorfológico detalhada por IBGE (2009). No presente estudo foram considerados os níveis: Domínios Morfoestruturais (1º táxon - IBGE) e Unidades Geomorfológicas (3º táxon - IBGE) como referências para as classificações visual e RF dos Domínios e Subdomínios Geomorfométricos (1º e 2º Táxon deste trabalho).

O 2º Táxon da classificação do IBGE, correspondente às Regiões Geomorfológicas não foi utilizado pois sua expressão, para a área de estudo, possui delimitação similar ao Táxon 1. Outra abordagem para o Táxon 3, chamada Compartimentos de Relevo, também não foi utilizada pois possui um maior nível de abrangência quando comparado às Unidades Geomorfológicas. Esta abordagem agrupa as classes Pediplano e Platô (do presente trabalho), ou Pediplano e Depressão (na classificação de Unidades Geomorfológicas) em uma única classe denominada Depressões. Por outro lado, a classe de Patamares identificada neste trabalho encontra correspondência nos Patamares identificados pelo IBGE como Compartimento de Relevo.

Em geral, para a BHRD, os primeiros dois Táxons possuíram correspondência entre o mapeamento geomorfológico utilizado como referência e o mapeamento geomorfométrico realizado neste trabalho. Isto significa que o estabelecimento de uma taxonomia específica, elaborada a partir de padrões de processos geomorfológicos, realçados por variáveis geomorfométricas regionalizadas pode delinear domínios e subdomínios de terreno em uma área com topografia diversificada.

A regionalização das variáveis permitiu um resultado bem definido, evitando efeitos de “sal e pimenta”, comuns na classificação *Random Forest*, e correspondendo mais diretamente a formas de relevo. A regionalização também possibilitou a análise da homogeneidade intra-segmentos, bem como contrastes externos, como mencionado por Minár e Evans (2008). Especificamente para a sutil topografia amazônica, a regionalização permitiu um realce de padrões, e contribuiu para minimizar o efeito

dossel, reduzindo as limitações da análise de dados SRTM sobre terrenos densamente florestados (VALERIANO; ROSSETTI, 2017).

O uso das métricas de Textura e TRI para limitar o Pediplano e Platô Amazônico se mostrou efetivo. Ambos subdomínios apresentavam baixos valores de elevação e declividade. No entanto, a frequência de picos e fossos era maior na área do Pediplano, permitindo o delineamento dessas duas áreas baixas, porém com padrões de dissecação dissimilares.

As variáveis regionais-natas utilizadas nesse trabalho haviam sido calculadas em pesquisas anteriores através do recurso de janelas-móveis (MUÑOZ; VALERIANO, 2008; MUÑOZ, 2009). Considerando o resultado da segmentação como uma unidade de terreno em si, foi escolhido adaptar o método de derivação utilizando esses segmentos como área de análise, e não janelas-móveis – por exemplo, o Relevo Relativo foi calculado subtraindo o PI de mínimos valores de ZN do PI de máximo. Esse método apresentou resultados aderentes para a descrição dos padrões de terreno em ambos os táxons e metodologias aplicadas (visual e RF).

O MDA permitiu a identificação das variáveis mais importantes utilizadas para cada modelo de classificação RF. Essa métrica permitiu uma análise detalhada das feições de terreno e seus processos, que eram retratados através de uma expressão de valores maiores ou menores das variáveis.

7 CONCLUSÃO

A presente classificação de domínios e subdomínios geomorfométricos na bacia do rio Demini propôs-se a delinear feições de terreno utilizando operações rápidas em SIGs. Adicionalmente, foi testado um método de aprendizagem de máquina que contribuiu para identificar e mensurar a importância das variáveis utilizadas nos modelos, bem como permitiu identificar essas feições em um método semi-automático. A utilização do RF se mostrou satisfatória quando comparada à classificação visual e aos dados do BDIA. A regionalização das variáveis possibilitou uma análise focada na homogeneidade de características intra-segmentos, bem como a heterogeneidade entre eles.

Em relação aos objetivos específicos, foi visto que:

- a) O estabelecimento de uma classificação hierárquica de domínios e subdomínios permitiu o desenvolvimento de uma taxonomia específica para a bacia do Demini, a partir dos dados do BDIA. Essa metodologia pode contribuir para o delineamento de feições de terreno em áreas extensas, como essa bacia hidrográfica, e para a identificação de planícies de inundação em regiões de topografia sutil, com pouca variação;
- b) O método de regionalização das variáveis, utilizando os segmentos como unidade de área para realização dos cálculos estatísticos, apresentou resultados aderentes à descrição dos padrões de terreno em ambos os táxons e metodologias aplicadas (visual e RF); e
- c) O método MDA possibilitou identificar as variáveis mais importantes para a classificação das formas de relevo nos Táxons 1 e 2, utilizando o método RF.

A classificação visual e resultados do RF para o Táxon 1 possuem relevante correspondência com os Domínios Morfoestruturais definidos pelo IBGE através do BDIA (IBGE, 2020). As principais variáveis geomorfométricas utilizadas para a obtenção desses resultados foram o máximo da ZN e média da Dis, no método visual; e estatísticas da ZN, Pred, RR e Text na classificação RF.

Os resultados do Táxon 2 para os subdomínios de Planaltos possuíram similaridade com as Unidades Geomorfológicas do BDIA. As variáveis utilizadas pela classificação RF

elencadas como as mais importantes foram: ZN, Pred, Text, TRI e SN. Em contrapartida, a classificação visual utilizou de forma mais pontual as médias de ZN, SN e Text, além do mínimo e moda da última. Essas variáveis permitiram o delineamento das feições de terreno de forma correspondente às Unidades Geomorfológicas definidas pelo BDIA, exceto pelo Planalto Residual, que não foi distinguido do Planalto Escarpado utilizando o método visual.

Os subdomínios das Baixadas foram delineados na classificação visual utilizando estatísticas de Res e, na classificação RF, essa variável também possuiu grande relevância, adicionalmente a ZN e Pred. O Mapa de Diferenças ressaltou a grande extensão de áreas inundáveis, eventualmente identificadas como planícies de inundação ou áreas alagáveis, e sugere a representação dessa feição de terreno como significante relevo, associado a um nível hierárquico mais abrangente, em relação à classificação do relevo. A esse respeito, estudos futuros podem contribuir para elucidar os processos e dinâmicas das extensas planícies amazônicas, possibilitando sua subdivisão em táxons de maior detalhe.

As variáveis mais relevantes para o delineamento de Planícies de Inundação, Platô e Patamar eram do grupo MDE-derivadas. Isto implica que essas classes poderiam provavelmente ser identificadas utilizando apenas a elevação e variáveis diretamente derivadas do MDE, simplificando a necessidade de outras derivações. A normalização das variáveis (nSN, nAlt, nRR e nDis) não possuiu grande relevância nos resultados, uma vez que a classificação visual não necessitava dessa condição, e o RF é um método não-paramétrico.

O processo de amostragem com 1000 pontos gerados aleatoriamente para cada domínio geomorfológico se mostrou apropriado para o primeiro nível taxonômico de classificação geomorfométrica, porém não para o segundo táxon. Uma alternativa seria gerar mais amostras na segunda etapa de classificação (referente aos subdomínios), para atingir uma melhor representação das classes de menor expressão espacial.

O presente estudo ressalta a necessidade de análise das Planícies de Inundação (ou áreas alagáveis) como uma feição de maior relevância, em um Táxon superior. Isto pois é importante a possibilidade de sua subdivisão em um contexto mais amplo, considerando a Bacia Hidrográfica Amazônica, e também sua própria extensão e considerável

representação. Sugere-se ainda a necessidade de estudos mais detalhados sobre o sistema de áreas alagáveis no interflúvio dos rios Branco e Negro e nos megaleques do Pantanal Setentrional, bem como seus hidroperíodos e dinâmicas de evolução da paisagem.

REFERÊNCIAS BIBLIOGRÁFICAS

AIRBUS. **Copernicus DEM copernicus digital elevation model product handbook**. [S.l.]: Airbus, 2020.

AIRES, F.; MIOLANE, L.; PRIGENT, C.; PHAM, B.; FLUET-CHOUINARD, E.; LEHNER, B.; PAPA, F. A global dynamic long-term inundation extent dataset at high spatial resolution derived through downscaling of satellite observations. **Journal of Hydrometeorology**, v. 18, n. 5, p. 1305–1325, 2017.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

ALVES, F. C. **DEM-bases morphotectonic analysis of a passive continental margin of South America: northern Paraíba basin, NE Brazil**. 2021. 139 p. Thesis (Doctor in Remote Sensing) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021. Disponível em: <<http://urlib.net/8JMKD3MGP3W34R/449LS8B>>.

ALVES, F. C.; ROSSETTI, D. DE F.; VALERIANO, M. DE M. Detecting neotectonics in the lowlands of Amazonia through the analysis of river long profiles. **Journal of South American Earth Sciences**, v. 100, 2020.

ANDERS, N. S.; SEIJMONSBERGEN, A. C.; BOUTEN, W. Segmentation optimization and stratified object-based analysis for semi-automated geomorphological mapping. **Remote Sensing of Environment**, v. 115, n. 12, p. 2976–2985, 2011.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: STROBL, J. (Ed.). **Angewandte geographische informations-verarbeitung**. Karlsruhe: Wichmann, 2000. v. XIIp. 12–23.

BELGIU, M.; DRĂGUT, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2–16, 2010.

BORTOLINI, W.; DA SILVEIRA, C. T. Multiresolution segmentation applied in digital mapping of landforms. **Revista Brasileira de Geomorfologia**, v. 22, n. 4, p. 899–921, 2021.

BOTELHO, R. G. M.; PELECH, A. S. Do mapeamento geomorfológico do IBGE a um Sistema Brasileiro de Classificação do Relevo. **Revista Brasileira de Geografia**, v. 64, p. 183–201, 2019.

BRASIL. MINISTÉRIO DAS MINAS E ENERGIA. **Projeto RADAMBRASIL: folha NA.20 Boa Vista e parte das folhas NA.21 Tumucumaque, NB.20 Roraima e NB.21: geologia, geomorfologia, pedologia, vegetação e uso potencial da terra**. Rio de Janeiro: Projeto RADAMBRASIL, 1975. 427 p. (Levantamento de Recursos Naturais, v. 8).

BRASIL. **Topodata: banco de dados geomorfométricos do Brasil**. São José dos Campos: INPE, 2008. Disponível em: <http://www.dsr.inpe.br/topodata>.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.

BURROUGH, P. A.; VAN GAANS, P. F. M.; MACMILLAN, R. A. High-resolution landform classification using fuzzy k-means. **Fuzzy Sets and Systems**, v. 113, p. 37–52, 2000.

CASSETI, V. Cartografia geomorfológica. **Observatório Geográfico de Goiás**, v. 20, n. 8, 2005.

CHRISTOFOLETTI, A. **Geomorfologia**. 2.ed. São Paulo: Edgard Blucher, 1980.

COMPANHIA DE PESQUISA DE RECURSOS MINERAIS (CPRM). **Geodiversidade do estado do Amazonas**. Manaus: CPRM, 2010. 275 p.

CORCORAN, J. M.; KNIGHT, J. F.; GALLANT, A. L. Influence of multi-source and multi-temporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in northern Minnesota. **Remote Sensing**, v. 5, n. 7, p. 3212–3238, 2013.

CREMON, É. H. **Caracterização morfológica do sistema fluvial do Rio Demini (Amazônia setentrional) com base em sensoriamento remoto**. 2012. 141p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

CREMON, É. H.; ROSSETTI, D. DE F.; ZANI, H. Classification of vegetation over a residual megafan landform in the amazonian lowland based on optical and SAR imagery. **Remote Sensing**, v. 6, n. 11, p. 10931–10946, 2014.

CSILLIK, O.; EVANS, I. S.; DRĂGUȚ, L. Transformation (normalization) of slope gradient and surface curvatures, automated for statistical analyses from DEMs. **Geomorphology**, v. 232, p. 65–77, 2015.

DESMET, P. J. J.; GOVERS, G. A GIS procedure for automatically calculating the USLE LS factor on topographically complex landscape units. **Journal of Soil and Water Conservation**, v. 51, n. 5, 1996.

DING, H.; TAO, F.; ZHAO, W.; NA, J.; TANG, G. An object-based method for Chinese landform types classification. In: INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES, 2016. **Proceedings...** International Society for Photogrammetry and Remote Sensing, 2016

DRĂGUȚ, L.; BLASCHKE, T. Automated classification of landform elements using object-based image analysis. **Geomorphology**, v. 81, n. 3–4, p. 330–344, 2006.

DRĂGUȚ, L.; EISANK, C. Automated object-based classification of topography from SRTM data. **Geomorphology**, v. 141–142, p. 21–33, 2012.

DUBAYAH, R.; RICH, P. M. Topographic solar radiation models for GIS. **International Journal of Geographical Information Systems**, v. 9, n. 4, p. 405–419, 1995.

EARTH REMOTE SENSING DATA ANALYSIS CENTER (ERSDAC).. **ASTER GDEM**. 2009. Disponível em: <http://www.gdem.aster.ersdac.or.jp/index.jsp>.

IDRISI selva tutorial. Worcester. 2012. Disponível em: <www.clarklabs.org>.

EHSANI, A. H.; QUIEL, F. Geomorphometric feature analysis using morphometric parameterization and artificial neural networks. **Geomorphology**, v. 99, n. 1–4, p. 1–12, 2008.

EISANK, C.; SMITH, M.; HILLIER, J. Assessment of multiresolution segmentation for delimiting drumlins in digital elevation models. **Geomorphology**, v. 214, p. 452–464, 2014.

ESRI. **ArcGIS desktop**: release 10.3. Redlands, CA: Environmental Systems Research Institute, 2015.

EVANS, I. S. General geomorphometry, derivatives of altitude, and descriptive statistics. In: CHORLEY, R. J. (Ed.). **Spatial analysis in geomorphology**. London: Methuen & Co., 1972. p. 17–90.

EVANS, I. S. Geomorphometry and landform mapping: what is a landform? **Geomorphology**, v. 137, n. 1, p. 94–106, 2012.

FLEISCHMANN, A. S.; PAPA, F.; FASSONI-ANDRADE, A.; MELACK, J. M.; WONGCHUIG, S.; PAIVA, R. C. D.; HAMILTON, S. K.; FLUET-CHOUINARD, E.; BARBEDO, R.; AIRES, F.; AL BITAR, A.; BONNET, M. P.; COE, M.; FERREIRA-

FERREIRA, J.; HESS, L.; JENSEN, K.; MCDONALD, K.; OVANDO, A.; PARK, E.; PARRENS, M.; PINEL, S.; PRIGENT, C.; RESENDE, A. F.; REVEL, M.; ROSENQVIST, A.; ROSENQVIST, J.; RUDORFF, C.; SILVA, T. S. F.; YAMAZAKI, D.; COLLISCHONN, W. How much inundation occurs in the Amazon River basin? **Remote Sensing of Environment**, v. 278, 2022.

FLORINSKY, I. V. An illustrated introduction to general geomorphometry. **Progress in Physical Geography**, v. 41, n. 6, p. 723–752, 2017.

FLORINSKY, I. V.; KURYAKOVA, G. A. Influence of topography on some vegetation cover properties. **Catena**, v. 27, p. 123–141, 1996.

FLUET-CHOUINARD, E.; LEHNER, B.; REBELO, L. M.; PAPA, F.; HAMILTON, S. K. Development of a global inundation map at high spatial resolution from topographic downscaling of coarse-scale remote sensing data. **Remote Sensing of Environment**, v. 158, p. 348–361, 2015.

GALLANT, A. L.; BROWN, D. D.; HOFFER, R. M. Automated mapping of hammond's landforms. **IEEE Geoscience and Remote Sensing Letters**, v. 2, n. 4, p. 384–388, 2005.

GERENTE, J. **Aplicação de variáveis geomorfológicas ao mapeamento de padrões de relevo na bacia do Rio Itajaí-Açu/SC**. 2018. 105p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018. Disponível em: <http://urlib.net/8JMKD3MGP3W34R/3RGR3NL>.

GERENTE, J.; VALERIANO, M. D. M.; MOREIRA, E. P. Regionalização de variáveis geomorfológicas para o mapeamento dos domínios morfoestruturais da bacia hidrográfica do Rio Itajaí-Açu (SC). **Revista Brasileira de Geomorfologia**, v. 19, n. 3, p. 433–446, 2018.

GETIRANA, A. C. V.; BONNET, M. P.; ROTUNNO FILHO, O. C.; MANSUR, W. J. Improving hydrological information acquisition from DEM processing in floodplains. **Hydrological Processes**, v. 23, n. 3, p. 502–514, 2009.

GUTH, P. L.; VAN NIEKERK, A.; GROHMANN, C. H.; MULLER, J. P.; HAWKER, L.; FLORINSKY, I. V.; GESCH, D.; REUTER, H. I.; HERRERA-CRUZ, V.; RIAZANOFF, S.; LÓPEZ-VÁZQUEZ, C.; CARABAJAL, C. C.; ALBINET, C.; STROBL, P. Digital elevation models: terminology and definitions. **Remote Sensing**, v. 13, n. 18, 2021.

HENGL, T.; REUTER, H. I. **Geomorphometry: concepts, software, applications**. 33. ed. Amsterdam: Newnes, 2008. v. 33 p.-775 p. ISBN(1865843830).

HERRERA, I. L. I. E.; SILVA FILHO, E. P.; IZA, E. R. H. F.; COIMBRA HORBE, A. M. Cartografia geológica e geomorfológica de crostas lateríticas na porção norte do estado de Rondônia. **Revista Brasileira de Geomorfologia**, v. 17, n. 1, 2016.

HESS, L. L.; MELACK, J. M.; AFFONSO, A. G.; BARBOSA, C.; GASTIL-BUHL, M.; NOVO, E. M. L. M. Wetlands of the lowland Amazon basin: extent, vegetative cover, and dual-season inundated area as mapped with JERS-1 Synthetic Aperture Radar. **Wetlands**, v. 35, n. 4, p. 745–756, 2015.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Estudo geográfico do território do Acre**: biblioteca geográfica brasileira. Rio de Janeiro: IBGE, 1955. 379 p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Geografia do Brasil**. Rio de Janeiro: IBGE, 1959. v. 1 1–422 p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual técnico de geomorfologia**. Rio de Janeiro: IBGE, 2009.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Macrocaracterização dos recursos naturais do Brasil: províncias estruturais, compartimentos de relevo, tipos de solos, regiões fitoecológicas e outras áreas**. Rio de Janeiro: IBGE, 2019. 176 p. ISBN(9788524044878).

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **1º Workshop sobre o Sistema Brasileiro de Classificação de Relevo**. Rio de Janeiro: IBGE, 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Banco de dados de informações ambientais**. Versão 2.7.0. IBGE, 2020. Disponível em: <http://bdiaweb.ibge.gov.br/#/home>.

IWAHASHI, J.; PIKE, R. J. Automated classifications of topography from DEMs by an unsupervised nested-means algorithm and a three-part geometric signature. **Geomorphology**, v. 86, n. 3–4, p. 409–440, 2007.

KARLSON, M.; GÅLFALK, M.; CRILL, P.; BOUSQUET, P.; SAUNOIS, M.; BASTVIKEN, D. Delineating northern peatlands using Sentinel-1 time series and terrain indices from local and regional digital elevation models. **Remote Sensing of Environment**, v. 231, 2019.

LIAW, A.; WIENER, M. Classification and regression by randomForest. **R-news**, v. 2, n. 3, p. 18–22, 2002.

MACMILLAN, R. A.; PETTAPIECE, W. W.; NOLAN, S. C.; GODDARD, T. W. A generic procedure for automatically segmenting landforms into landform elements using

- DEMs, heuristic rules and fuzzy logic. **Fuzzy Sets and Systems**, v. 113, p. 81–109, 2000.
- MAPBIOMAS. **Algorithm Theoretical Basis Document (ATBD): Collection 6**. [S.l.]: MAPBIOMAS, 2022.
- MATHER, P. M. **Computer processing of remotely-sensed images**. 3.ed. Chichester: John Wiley & Sons, 2004. 324 p.
- MEIJERINK, A. M. J. Data acquisition and data capture through terrain mapping units. **ITC Journal**, v.1988, n. 1, p.23-44, 1988.
- MINÁR, J.; EVANS, I. S. Elementary forms for land surface segmentation: the theoretical basis of terrain analysis and geomorphological mapping. **Geomorphology**, v. 95, n. 3–4, p. 236–259, 2008.
- MOORE, I. D.; GESSLER, P. E.; NIELSEN, G. A.; PETERSON, G. A. Soil Attribute prediction using terrain analysis. **Soil Science Society of America Journal**, v. 57, n. 2, p. 443–452, 1993.
- MOREIRA, P. **Análise regional da geomorfometria de microbacias hidrográficas**. 2018. 151p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018. Disponível em: <http://urlib.net/8JMKD3MGP3W34R/3R8ES4L>.
- MUÑOZ, V. A. **Análise geomorfológica de dados SRTM aplicada ao estudo das relações solo-relevo**. 2009a. 114p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <http://urlib.net/sid.inpe.br/mtc-m18@80/2009/03.25.15.09>.
- MUÑOZ, V. A.; VALERIANO, M. DE M. **Mapeamento da predominância topográfica através do processamento de dados SRTM como contribuição ao mapeamento de solos**. Belo Horizonte, 2008. Disponível em: <https://www.researchgate.net/publication/329365914>.
- NASCIMENTO, F. I. C.; SANTOS, W. L.; LIRA, E. M.; ARCOS, F. O. Caracterização morfométrica como base para o manejo da Bacia Hidrográfica do Rio São Francisco-Acre. **Revista Brasileira de Geografia Física**, v. 6, n. 2, p. 170–183, 2013.
- NEVES, A. K. **Hierarchical mapping of brazilian Savanna (Cerrado) physiognomies based on deep learning**. 2021. 98 p. Thesis (Doctor in Remote Sensing) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021. Disponível em: <http://urlib.net/8JMKD3MGP3W34R/44DTSUS>.

- OLAYA, V. Basic land-surface parameters. In: HENGL, T.; REUTER, H. I (Ed.). **Geomorphometry: concepts, software, applications**. Oxford, UK: Elsevier, 2009. p. 141-169.
- PARRENS, M.; BITAR, A. AL; FRAPPART, F.; PAIVA, R.; WONGCHUIG, S.; PAPA, F.; YAMASAKI, D.; KERR, Y. High resolution mapping of inundation area in the Amazon basin from a combination of L-band passive microwave, optical and radar datasets. **International Journal of Applied Earth Observation and Geoinformation**, v. 81, p. 58–71, 2019.
- PEKEL, J. F.; COTTAM, A.; GORELICK, N.; BELWARD, A. S. High-resolution mapping of global surface water and its long-term changes. **Nature**, v. 540, n. 7633, p. 418–422, 2016.
- PELECH, A. S.; DE ALMEIDA NUNES, B. T.; GATTO, L. C. S.; BOTELHO, R. G. M. Considerations on geomorphological mapping of the Brazilian territory: some approaches in regional representation. **Revista Brasileira de Geomorfologia**, v. 20, n. 3, p. 681–690, 2019.
- PIKE, R. J. The geometric signature: quantifying landslide-terrain types from Digital Elevation Models. **Mathematical Geology**, v. 20, p. 491–511, 1988.
- PIKE, R. J. Geomorphometry -diversity in quantitative surface analysis. **Progress in Physical Geography: Earth and Environment**, v. 24, n. 1, p. 1–20, 2000.
- PIKE, R. J. **A bibliography of terrain modeling (geomorphometry) the quantitative representation of topography**. [S.l.]: USGS, 2002.
- PIMENTA, M. L. D. F.; THERENCE, P. D. S. O mapeamento geomorfológico no IBGE e suas perspectivas metodológicas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. Disponível em: <http://downloads.ibge.gov.br>.
- PRIMA, O. D. A.; ECHIGO, A.; YOKOYAMA, R.; YOSHIDA, T. Supervised landform classification of Northeast Honshu from DEM-derived thematic maps. **Geomorphology**, v. 78, n. 3–4, p. 373–386, 2006.
- RABUS, B.; EINEDER, M.; ROTH, A.; BAMLER, R. The shuttle radar topography mission: a new class of digital elevation models acquired by spaceborne radar. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 57, n. 4, p. 241–262, 2003.
- RIEGLER, G., HENNIG, S. D., WEBER, M. WorldDEM – a novel global foundation layer. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, n. W2, 183-187, 2015

- RILEY, S. J.; STEPHEN, D. D.; ELLIOT, R. A Terrain ruggedness index that quantifies topographic heterogeneity. **Intermountain Journal of Sciences**, v. 5, p. 23–27, 1999.
- ROMSTAD, B.; ETZELMÜLLER, B. Mean-curvature watersheds: a simple method for segmentation of a digital elevation model into terrain units. **Geomorphology**, v. 139–140, p. 293–302, 2012.
- ROSENQVIST, J.; ROSENQVIST, A.; JENSEN, K.; MCDONALD, K. Mapping of maximum and minimum inundation extents in the amazon basin 2014–2017 with ALOS-2 PALSAR-2 scan SAR time-series data. **Remote Sensing**, v. 12, n. 8, 2020.
- ROSSETTI, D. DE F.; MOLINA, E. C.; CREMON, É. H. Genesis of the largest Amazonian wetland in northern Brazil inferred by morphology and gravity anomalies. **Journal of South American Earth Sciences**, v. 69, p. 1–10, 2016.
- ROSSETTI, D. F.; BERTANI, T. C.; ZANI, H.; CREMON, E. H.; HAYAKAWA, E. H. Late quaternary sedimentary dynamics in western Amazonia: implications for the origin of open vegetation/forest contrasts. **Geomorphology**, v. 177–178, p. 74–92, 2012.
- ROSSETTI, D. F.; MOULATLET, G. M.; TUOMISTO, H.; GRIBEL, R.; TOLEDO, P. M.; VALERIANO, M. M.; RUOKOLAINEN, K.; COHEN, M. C. L.; CORDEIRO, C. L. O.; RENNÓ, C. D.; COELHO, L. S.; FERREIRA, C. A. C. White sand vegetation in an Amazonian lowland under the perspective of a young geological history. **Anais da Academia Brasileira de Ciências**, v. 91, n. 4, 2019.
- SARGES, R. R.; SILVA, T. M. DA; RICCOMINI, C. Caracterização do relevo da região de Manaus, Amazônia Central. **Revista Brasileira de Geomorfologia**, v. 12, n. 1, p. 95–104, 2011.
- SEIJMONSBERGEN, A. C.; HENGL, T.; ANDERS, N. S. Semi-automated identification and extraction of geomorphological features using digital elevation data. In: SMITH, M. J.; PARON, P.; GRIFFITHS, J. S. (Ed.). **Geomorphological mapping: methods and applications**. Oxford, UK: Elsevier, 2011. p. 297–329.
- SIQUEIRA, R. G.; VELOSO, G. V.; FERNANDES-FILHO, E. I.; FRANCELINO, M. R.; SCHAEFER, C. E. G. R.; CORRÊA, G. R. Evaluation of machine learning algorithms to classify and map landforms in Antarctica. **Earth Surface Processes and Landforms**, v. 47, n. 2, p. 367–382, 2022.
- SOMBROEK, W. Amazon landforms and soils in relation to biological diversity. **Acta Amazonica**, v. 30, n. 1, p. 81–100, 2000.
- TAROLLI, P.; MUDD, S. M. **Remote sensing of geomorphology**. [S.l.]: Elsevier, 2019. v. 23

TRICART, J. **Principes et méthodes de la géomorphologie**. [S.l.]: Soil Science, 1965. v. 100

TRIMBLE. **eCognition developer for Windows operating system user guide**. 2018. Disponível em: www.eCognition.com.

UNITED STATES GEOLOGICAL SURVEY (USGS). **Shuttle Radar Topography Mission documentation: SRTM topo**. 2003. Disponível em: http://edcftp.cr.usgs.gov/pub/data/srtm/Documentation/SRTM_Topo.txt.

VALERIANO, M. M.; ROSSETTI, D. F. Regionalization of local geomorphometric derivations for geological mapping in the sedimentary domain of central Amazônia. **Computers and Geosciences**, v. 100, p. 46–56, 2017.

VALERIANO, M. M.; ROSSETTI, D. F. Delineation of main relief subdomains of central Amazonia for regional geomorphometric mapping with SRTM data. **Journal of South American Earth Sciences**, v. 104, 2020.

YAMAZAKI, D.; TRIGG, M. A.; IKESHIMA, D. Development of a global ~90m water body map using multi-temporal Landsat images. **Remote Sensing of Environment**, v. 171, p. 337–351, 2015.

ZANI, H.; ASSINE, M. L.; MCGLUE, M. M. Remote sensing analysis of depositional landforms in alluvial settings: method development and application to the Taquari megafan, Pantanal (Brazil). **Geomorphology**, v. 161–162, p. 82–92, 2012.

ZANI, H.; ROSSETTI, D. F. Multitemporal Landsat data applied for deciphering a megafan in northern Amazonia. **International Journal of Remote Sensing**, v. 33, n. 19, p. 6060–6075, 2012.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. São Paulo, BR: Oficina de Textos, 2019. 320 p. ISBN 978-85-7975-316-9.