



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Geologia

Pedro Rossi Cezar

**Lineamentos topográficos em modelos digitais de elevação: uma
comparação entre extração manual e computacional usando redes neurais
convolucionais com arquitetura U-Net**

Rio de Janeiro

2024

Pedro Rossi Cezar

Lineamentos topográficos em modelos digitais de elevação: uma comparação entre extração manual e computacional usando redes neurais convolucionais com arquitetura U-Net

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Geociências, da Universidade do Estado do Rio de Janeiro. Área de concentração: Reativação e Controle do Embasamento de Bacias Sedimentares.

Orientador: Prof. Dr. Júlio Cesar Horta de Almeida

Coorientadores: Dr. Antônio de Pádua Cunha Pires Filho e Dr. Mário Neto Cavalcanti de Araújo

Rio de Janeiro

2024

CATALOGAÇÃO NA FONTE
UERJ/REDE SIRIUS/CTCC

C425 Cezar, Pedro Rossi.

Lineamentos topográficos em modelos digitais de elevação: uma comparação entre extração manual e computacional usando redes neurais convolucionais com arquitetura U-Net / Pedro Rossi Cezar.– 2024.

74 f. : il.

Orientador: Júlio Cesar Horta de Almeida.

Coorientadores: Antônio de Pádua Cunha Pires Filho e Mário Neto Cavalcanti de Araújo

Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Geologia.

1. Geologia - Teses. 2. Lineamentos topográficos – Ribeira, Faixa (RJ) - Teses. 3. Redes neurais (computação) - Teses. 4. Rochas - Modelos digitais – Teses. I. Almeida, Júlio Cesar Horta de. II. Pires Filho, Antônio de Pádua Cunha. III. Araújo, Mário Neto Cavalcanti de. IV. Universidade do Estado do Rio de Janeiro. Faculdade de Geologia. V. Título.

CDU: 551(815.3)

Bibliotecária Responsável: Priscila Freitas Araujo/ CRB-7: 7322

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

Assinatura

Data

Pedro Rossi Cezar

Lineamentos topográficos em modelos digitais de elevação: uma comparação entre extração manual e computacional usando redes neurais convolucionais com arquitetura U-Net

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Geociências, da Universidade do Estado do Rio de Janeiro. Área de concentração: Reativação e Controle do Embasamento de Bacias Sedimentares.

Aprovada em 20 de março de 2024

Orientador: Prof. Dr. Prof. Dr. Júlio Cesar Horta de Almeida

Faculdade de Geologia - UERJ

Coorientadores: Dr. Antônio de Pádua Cunha Pires Filho

Petrobras

Dr. Mário Neto Cavalcanti de Araújo

Petrobras

Banca Examinadora: _____

Prof. Dr. Sérgio Williams de Oliveira Rodrigues

Universidade Federal de Goiás

Dr. César José Calderón Filho

Petrobras

Prof. Dr. Miguel Tupinambá

Faculdade de Geologia - UERJ

Rio de Janeiro

2024

DEDICATÓRIA

Dedico este trabalho ao meu filho Caetano que me permite ver, mais uma vez, o mundo pelos olhos de uma criança.

AGRADECIMENTOS

Gostaria de agradecer ao meu orientador Júlio Almeida, pelo norteamento e amizade, à Rayane Pereira Guedes por ter trabalhado comigo na interpretação dos lineamentos, ao Antônio de Pádua Pires, por embarcar nas minhas ideias, Mário Neto Cavalcanti de Araújo pelos bons conselhos e João Paulo Giro por ceder seus dados que foram de grande importância. E agradeço à Petrobras por ter apostado na minha formação.

Agradeço à visiblegeology.com por oferecer um excelente serviço gratuito para construção de estereogramas e rosetas e à Math3D pelos serviços de visualização de funções.

- Está bem-disse o computador. – A Resposta à Grande Questão...

- Sim...!

- Da Vida, o Universo e Tudo Mais...- disse o Pensador Profundo.

- Sim!

- É... – disse o Pensador Profundo, e fez uma pausa.

- Sim...! – É... -Sim...!!!...?

- Quarenta e dois – disse o Pensador Profundo, com uma majestade e uma tranquilidade infinitas.

Douglas Adams – O Guia do Mochileiro das Galáxias

RESUMO

CEZAR, Pedro Rossi. **Lineamentos topográficos em modelos digitais de elevação: uma comparação entre extração manual e computacional usando redes neurais convolucionais com arquitetura U-Net.** 2024. 75 f. Dissertação (Mestrado em Geociências) – Faculdade de Geologia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

Lineamentos topográficos presentes em modelos digitais de elevação oferecem boas indicações sobre estruturas e litotipos. Para extrair informação útil desses dados a interpretação é uma etapa crucial, tradicionalmente feita manualmente por um geocientista, em um processo repetitivo e demorado, sujeito a vieses e passível de causar lesões por esforço repetitivo. Recentes avanços na aplicação de aprendizado de máquina com redes neurais convolucionais profundas (RNCPs) têm mostrado potencial de reduzir drasticamente o tempo necessário para a obtenção de lineamentos e reduzir a subjetividade da interpretação de modelos digitais de elevação (MDE). Neste trabalho analisamos a região central da Faixa de dobramentos Ribeira, SE do Brasil e comparamos os resultados de interpretações manuais e extrações de lineamentos feitas por uma RNCP com arquitetura U-Net treinada com dados de uma região próxima. Além disso, examinamos os vieses e limitações do método manual, como variação de critérios de mapeamento, mudanças na motivação, experiência prévia, assim como as limitações relacionadas ao método computacional, como a quantidade de dados disponíveis para o treinamento, nível de ruído dos resultados e sobreajuste. Os resultados mostram que as RNCPs têm a capacidade de produzir lineamentos de forma satisfatória, em uma fração do tempo necessário para interpretação manual, no entanto, a busca de arquiteturas e hiperparâmetros adequados também pode consumir muito tempo. As RNCPs são uma poderosa ferramenta, mas não dispensam a interação com o geocientista que deve construir, treinar e criticar os resultados obtidos.

Palavras-chave: lineamentos topográficos; modelo digital de elevação; redes neurais convolucionais profundas; aprendizado de máquina; interpretação manual.

ABSTRACT

CEZAR, Pedro Rossi. **Topographic lineaments in digital elevation models**: a comparison between manual and computational degradation using convolutional neural networks with U-Net architecture. 2024. 75 f. Dissertação (Mestrado em Geociências) – Faculdade de Geologia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

Topographic lineaments seen on digital terrain models (DTM) provide good insights into geological features. To extract useful information from these data interpretation is a crucial step and is traditionally done manually by a geoscientist in a repetitive and time-consuming process, prone to human bias and repetitive stress injury. Recent developments in the application of machine learning techniques that use deep convolutional neural networks (DCNNs) have shown capability to drastically reduce the lineaments interpretation life cycle in digital elevation models (DEM), as well as reduce some bias and intrinsic subjectivity. In this work we analyze Ribeira fold belt central region, SE Brazil, and compare manual lineament interpretation with the ones obtained by a DCNN with U-Net architectures trained with data from a nearby area. Furthermore, we examine the biases and limitations regarding the manual method, such as changes in interpretation criteria, motivation and previous experience, the ones related to computers, such as the available data for the training, output noise levels and overfitting. Results show that DCNNs can be used to produce satisfactory lineaments, in fraction of the time required for manual interpretation. However, the search for ideal architectures and hyperparameters may also take a long time. DCNNs are a powerful tool but doesn't eliminate the interaction with geoscientists that must construct, train, and critically assess its results.

Keywords: lineaments; digital elevation model; convolutional neural networks; machine learning; manual interpretation.

LISTA DE FIGURAS

Figura 1 -	Localização da área de estudo sobre mapa tectônico do setor central da Faixa Ribeira e do setor meridional da Faixa Brasília.....	15
Figura 2 -	Configuração esquemática dos protólitos que constituem os compartimentos geotectônicos da Faixa Ribeira central durante o Neoproterozoico.....	16
Figura 3 -	Compartimentos geotectônicos da área estudada.....	18
Figura 4 -	Ocorrência das unidades litológicas na área de estudo.....	21
Figura 5-	Direções dos diques separados por setores.....	23
Figura 6-	Índice de similaridade de Jaccard.....	27
Figura 7-	A cena do filme “Chegada do trem na estação”.....	28
Figura 8-	Nuvem de pontos hipotéticos agrupados em 5 classes.....	30
Figura 9-	Representação esquemática de uma rede neural com muitas camadas ocultas.....	31
Figura 10-	Representação de uma rede neural e a função Perceptron.....	32
Figura 11-	Exemplo de regressão linear.....	37
Figura 12-	Mínimo global de função custo.....	37
Figura 13-	Entropia cruzada binária.....	39
Figura 14-	Entropia focal modulada.....	41
Figura 15-	Representação do método gradiente.....	43
Figura 16-	Modelo sobredeterminado.....	44
Figura 17-	Modelo 6, sorteamento aleatório.....	46
Figura 18-	Previsão de lineamentos em modelo sobreajustado.....	47
Figura 19-	Ilustração de uma convolução entre uma imagem e um filtro.....	48
Figura 20-	Arquitetura de U-Net utilizada.....	49
Figura 21-	Área de estudo e área controle.....	50
Figura 22-	Modelo digital de terreno SRTM e lineamentos anotados.....	51
Figura 23-	Fluxo esquemático do modelo 22.....	52
Figura 24-	Transformada de Hough.....	53
Figura 25-	Extração de lineamentos.....	55
Figura 26-	Índice de similaridade de Jaccard entre versões e número de	

	lineamentos não repetidos.....	56
Figura 27-	Diagramas de caixa e rosetas.....	57
Figura 28-	Lineamentos V1 separados por setores e filtrados.....	58
Figura 29-	Lineamentos V1 filtrados pelo trend da Faixa Ribeira.....	59
Figura 30-	Lineamentos V2 agrupados pós associação litológica.....	61
Figura 31-	Modelo 1.....	62
Figura 32-	Modelo 2.....	63
Figura 33-	Modelo 9.....	64
Figura 34-	Modelo 17.....	64
Figura 35-	Modelo 22.....	65
Figura 36-	Modelo 30.....	65

LISTA DE EQUAÇÕES

Equação 1 -	A função Perceptron.....	31
Equação 2 -	Mínimos quadrados.....	36
Equação 3 -	Entropia cruzada.....	39
Equação 4 -	Entropia cruzada modulada.....	40
Equação 5 -	Entropia focal.....	41
Equação 6 -	Função Dice para duas classes.....	42
Equação 7 -	Número de tiles carregados dado o paço da convolução.....	62

LISTA DE ABREVIATURAS E SIGLAS

CSF	Cráton São Francisco
FLABM	Feixe de Lineamentos Andrelândia-Barra Mansa
MDE	Modelo digital de elevação
RCSB	Rift Continental do Sudeste do Brasil
RNCP	Rede Neural Convolucional Profunda
SRTM	<i>Shuttle Radar Topography Mission</i>

SUMÁRIO

	INTRODUÇÃO.....	14
1	Contexto geológico.....	15
2	Caracterização composicional/reológica das unidades litológicas.....	17
2.1	Unidades paleoproterozoicas.....	17
2.2	Unidades neoproterozoicas.....	17
2.3	Granitoides sin-colisionais.....	19
2.4	Granitoides tarde e pós-colisionais.....	19
2.5	Dique toleíticos de idade mesozoica:.....	19
2.6	Magmatismo Alcalino:.....	20
2.7	Rift Continental do Sudeste Brasileiro.....	20
3	Principais estruturas/descontinuidades de área.....	22
4	SETORIZAÇÃO DOS DIQUES.....	24
5	LINEAMENTOS.....	25
5.1	Interpretação manual:.....	25
6	METODOLOGIA DE ANÁLISE DE RESULTADOS:.....	27
7	MÉTODO COMPUTACIONAL.....	28
7.1	Dois métodos de aprendizado de máquina.....	29
7.2	Redes neurais artificiais.....	30
7.3	A função Perceptron:.....	31
7.4	Funções de ativação:.....	32
7.5	Função custo.....	35
7.5.1	<u>Mínimos quadrados</u>.....	36
7.5.2	<u>A função custo na fase de treinamento</u>.....	38
7.5.3	<u>Entropia cruzada</u>:.....	38
7.5.3.1	Limitações da Entropia Cruzada:.....	39
7.5.4	<u>Função de custo Dice</u>:.....	41
7.6	Método do Gradiente.....	42
7.7	Métricas de desempenho:.....	43
7.8	Sobre ajuste (overfit).....	44
7.9	Redes neurais convolucionais.....	46

7.10	U-Nets	48
8	APLICAÇÃO DE RNCP NA ÁREA DE ESTUDO	50
8.1	Pré-tratamento:	51
8.2	Hiperparâmetros	51
8.3	Transformada de Hough:	53
9	RESULTADOS:	54
9.1	Manipulação dos dados obtidos manualmente	57
9.1.2	<u>Hipótese sobre controle da direção dos lineamentos:</u>	59
9.2	Resultados obtidos pela RNCP:	62
10	CONTEXTUALIZAÇÃO DO TRABALHO E DISCUSSÕES	67
10.1	Trabalhos anteriores	67
10.2	Viabilidade de aplicação das RNCPs	67
	CONSIDERAÇÕES FINAIS	69
	REFERÊNCIAS	72

INTRODUÇÃO

Lineamentos topográficos são cumes de serras ou vales encaixados que presumidamente refletem a trama do embasamento (O’Leary et al. 1976), como diques, falhas, juntas contatos litológicos, zonas de sutura e cisalhamento.

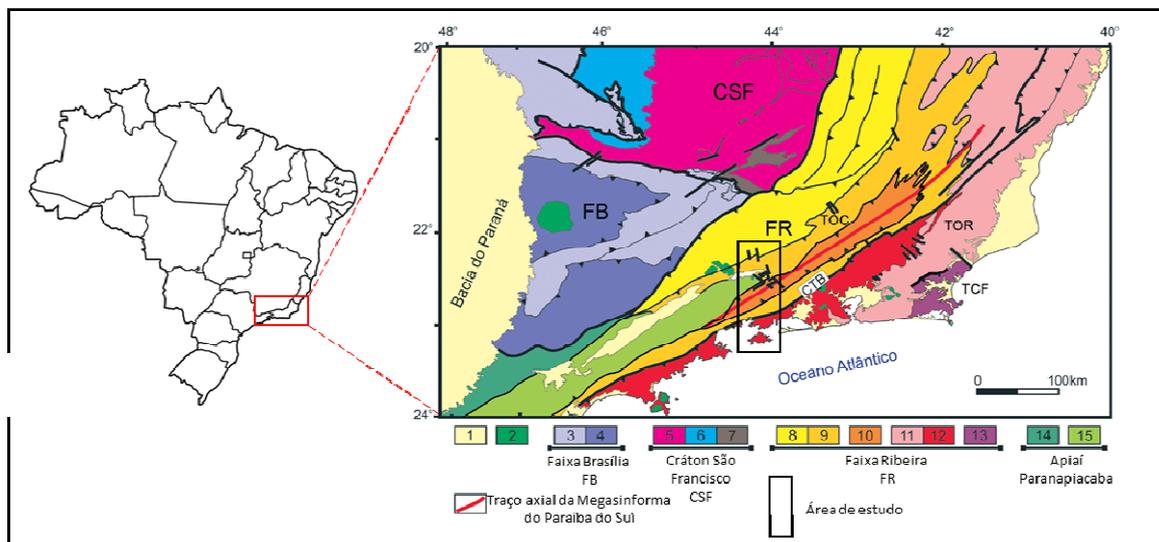
O objetivo desta dissertação é confrontar duas abordagens distintas no processo de interpretação de lineamentos em modelos digitais de elevação (MDE). A primeira é clássica: um geocientista desenha manualmente segmentos de reta sobre o MDE, seja com uma folha transparente e uma caneta, seja com um programa de computador usando o mouse. A segunda utiliza tecnologia de aprendizado de máquina e redes neurais convolucionais profundas (RNCP) com arquiteturas tipo U-Net para detectar padrões lineares, usando para o treinamento lineamentos interpretados por Giro et al. (2021) em uma área a cerca de 60 km da região estudada.

Para isso escolhemos uma região na porção central da Faixa Ribeira, SE do Brasil que contém falhas de empurrão, foliações, zonas de cisalhamento e falhas normais, características do cinturão de dobramentos Ribeira, além do Feixe de Lineamentos Andrelândia- Barra Mansa (FLABM), um conspícuo corredor de estruturas. Esta é uma área bem conhecida, coberta por mapeamento (Heilbron et al. 2016) realizados desde os anos 2000, além de ter fácil acesso pela rodovia BR-101 (Dutra).

1 CONTEXTO GEOLÓGICO

A área de estudo está inserida no contexto tectônico do cinturão orogênico de idade neoproterozoica denominado Faixa Ribeira (figura 1) que é um dos componentes da província Mantiqueira, um sistema orogênico maior que engloba também as faixas Araçuaí a norte, Apiaí e Dom Feliciano a sul (Almeida et al. 1977, 1981; Heilbron et al. 2004, 2008, 2020).

Figura 1: Localização da área de estudo sobre mapa tectônico do setor central da Faixa Ribeira e do setor meridional da Faixa Brasília



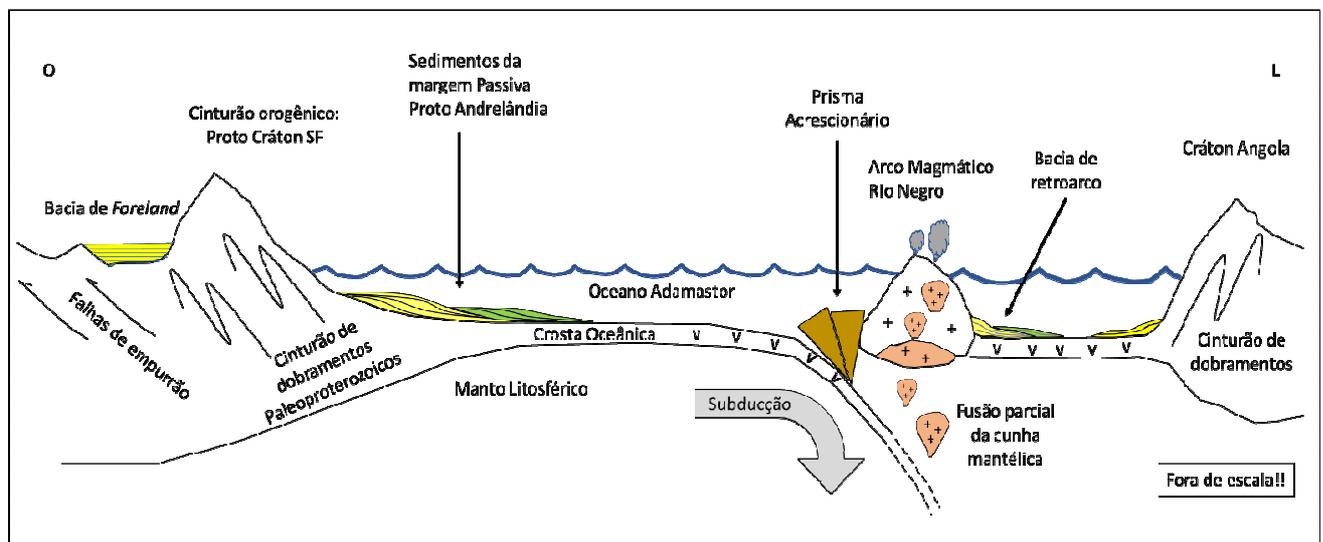
Legenda: 1- Riftes e coberturas cenozoicas; 2 – Rochas alcalinas do Cretáceo e Paleógeno; 3 - Nappes inferiores; 4 - Nappes superiores; 5 - Embasamento do CSF e Domínio Autóctone; 6 - Supergrupo São Francisco; 7 - Metassedimentos do Domínio Autóctone; 8 – Grupo Andrelândia; 9 – Complexo Juiz de Fora; 10 – Terreno Central; 11 - Terreno Oriental; 12 - Granitoides do Complexo Magmático Rio Negro; 13 - Terreno Cabo Frio; 14 – Terrenos São Roque e Açungui; 15 - Terreno Embu.

Fonte: Modificado de Heilbron et al. 2004.

A Faixa Ribeira apresenta direção NE e se estende por mais de 1400 km pelos estados do Rio de Janeiro, São Paulo e Espírito Santo (figura 1). É o resultado dos processos que culminaram na amalgamação do supercontinente Gondwana, entre 600 e 540 Ma (Trouw et al., 2000 N.E. Schmitt et al., 2004; Heilbron et al., 2020; Freitas et al., 2021), durante a orogenia Brasileira-Panafricana. Esse processo, movido pela tectônica de placas, promoveu a colisão entre os paleocontinentes (crátons) São Francisco-Congo e Angola. O que se vê aflorando, hoje, na Faixa Ribeira são as raízes desse orógeno que foi profundamente erodido e os compartimentos tectônicos que a compõem são representativos dos diferentes elementos envolvidos nessa acreção continental, como arco de ilhas e sedimentos da plataforma continental, todos deformados e metamorfozados (figura 2).

Nesta dissertação será utilizada a classificação e nomenclatura proposta por Heilbron et al. (1995, 2000, 2004, 2020) que dividiu a Faixa Ribeira em terrenos tectonoestratigráficos separados por falhas de empurrão, ou zonas de cisalhamento oblíquas transpressivas. São eles, de norte para sul: Terreno Ocidental (TOC), Terreno Central (TC), Terreno Oriental (TOR) (figura 3). Esses terrenos foram sucessivamente anexados de leste para oeste, comprimidos entre duas massas continentais estáveis (crátons).

Figura 2: Configuração esquemática dos protólitos que constituem os compartimentos geotectônicos da Faixa Ribeira central durante o Neoproterozoico.



Fonte: O autor, 2023.

2 CARACTERIZAÇÃO COMPOSICIONAL/REOLÓGICA DAS UNIDADES LITOLÓGICAS

Cada unidade litológica que compõe a Faixa Ribeira varia em composição e trama estrutural, o que possivelmente implica diferentes reologias e diferentes respostas aos esforços extensivos que resultaram nas fraturas, falhas e diques.

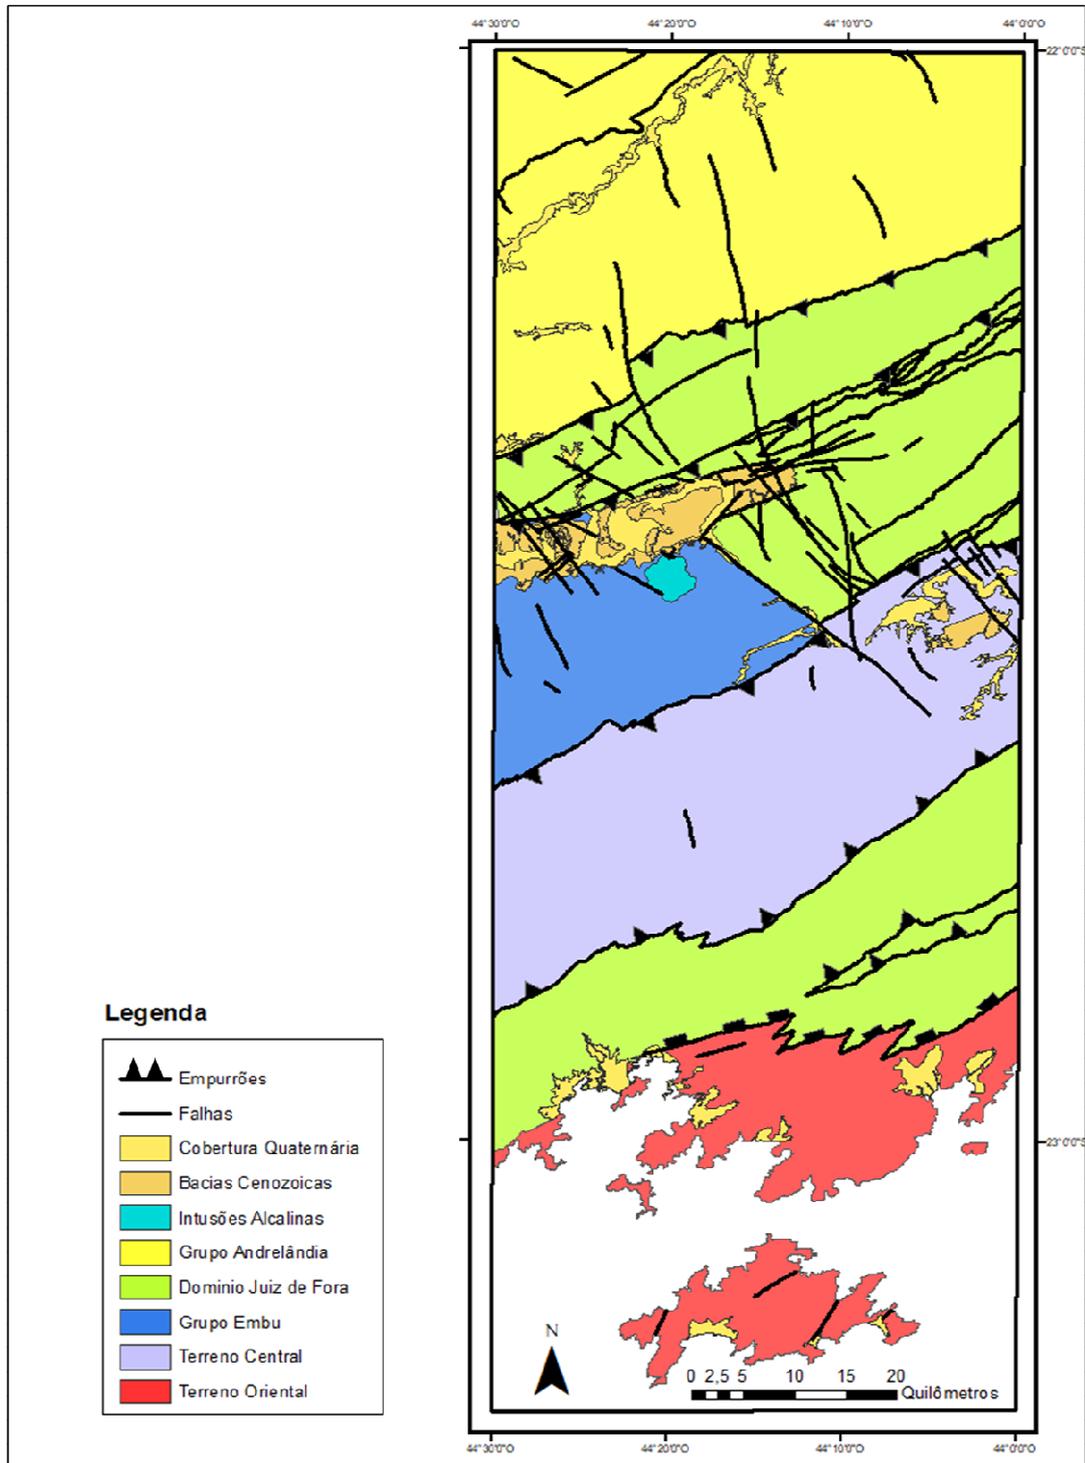
2.1 Unidades paleoproterozoicas

Trata-se de rochas que formavam o paleocontinente São Francisco e o embasamento das sequências metassedimentares neoproterozoicas. São unidades litológicas mais velhas, mais espessas e estáveis Heilbron et al. (2000, 2004, 2008).

2.2 Unidades neoproterozoicas

Durante o Neoproterozoico, na região estudada, terrenos tectônicos convergiram formando o supercontinente Gondwana (Trouw et al. 2000 N.E. Schmitt et al. 2004; Heilbron et al. 2020; Freitas et al. 2021). Nessa colisão, os sedimentos que constituem tipicamente a plataforma continental de margem passiva e que se encontravam entre os terrenos acrescidos (figura 2), foram comprimidos, deformados e metamorfizados. O resultado desse processo são as unidades metassedimentares e metavulcanossedimentares.

Figura 3 - Compartimentos geotectônicos da área estudada



Fonte: O autor, 2023.

2.3 Granitoides sin-colisionais

São granitoides tipo-S, resultado da fusão parcial das rochas mais hidratadas durante as fases mais intensas da orogênese neoproterozoica formadora do supercontinente Gondwana.

2.4 Granitoides tardi e pós-colisionais

Conjunto de rochas formadas durante os últimos estágios do orógeno, quando há um decréscimo da tensão atuante. Essa descompressão a temperaturas ainda altas faz com que haja fusão parcial das rochas mais hidratadas, formando batólitos, *stocks e plugs*.

2.5 Dique toleíticos de idade mesozoica

Durante a era mesozoica, a região estudada experimentou intensa atividade ígnea e esforços distensivos que resultaram no alojamento do enxame de diques e *sills* toleíticos da Serra do Mar (Almeida, 1976) e cuja evolução culminou, ao longo do período Cretáceo, na quebra do supercontinente Gondwana. O mesmo evento é relacionado aos derrames de lava basáltica que constituem as formações basais Cabiúnas e Camboriú nas bacias de Campos e Santos respectivamente.

Os diques máficos têm geralmente espessura entre 2 e 12 metros, mas podem chegar a 200 metros. Sua orientação geral no Estado do Rio de Janeiro segue o *trend* NE da Faixa Ribeira, mas na região na qual esta dissertação é focada, os diques assumem uma direção NW e NS (figura 5). Almeida et al. (2013^a2013a) denominaram a ocorrência desses como “Enxame de Diques de Resende-Ilha Grande”.

A utilização de métodos geocronológicos permitiu a datação dos diques. Guedes et al. (2016) determinou as idades dos diques nas regiões costeiras de Parati e Ilha Grande com o método $^{40}\text{Ar}/^{39}\text{Ar}$ como variando entre $155,4 \pm 4,6$ e $126,3 \pm 4,5$ Ma (Jurássico). Esses dados sugerem um magmatismo mais velho que o enxame de diques da Serra do Mar, de idade

129,4-133,0 Ma (Cretáceo), definidas pelo mesmo método. A ocorrência de diques mais velhos, de direção N-S pode indicar que esforços distensionais de direção W-E atuaram de forma precoce na região de Parati e Resende.

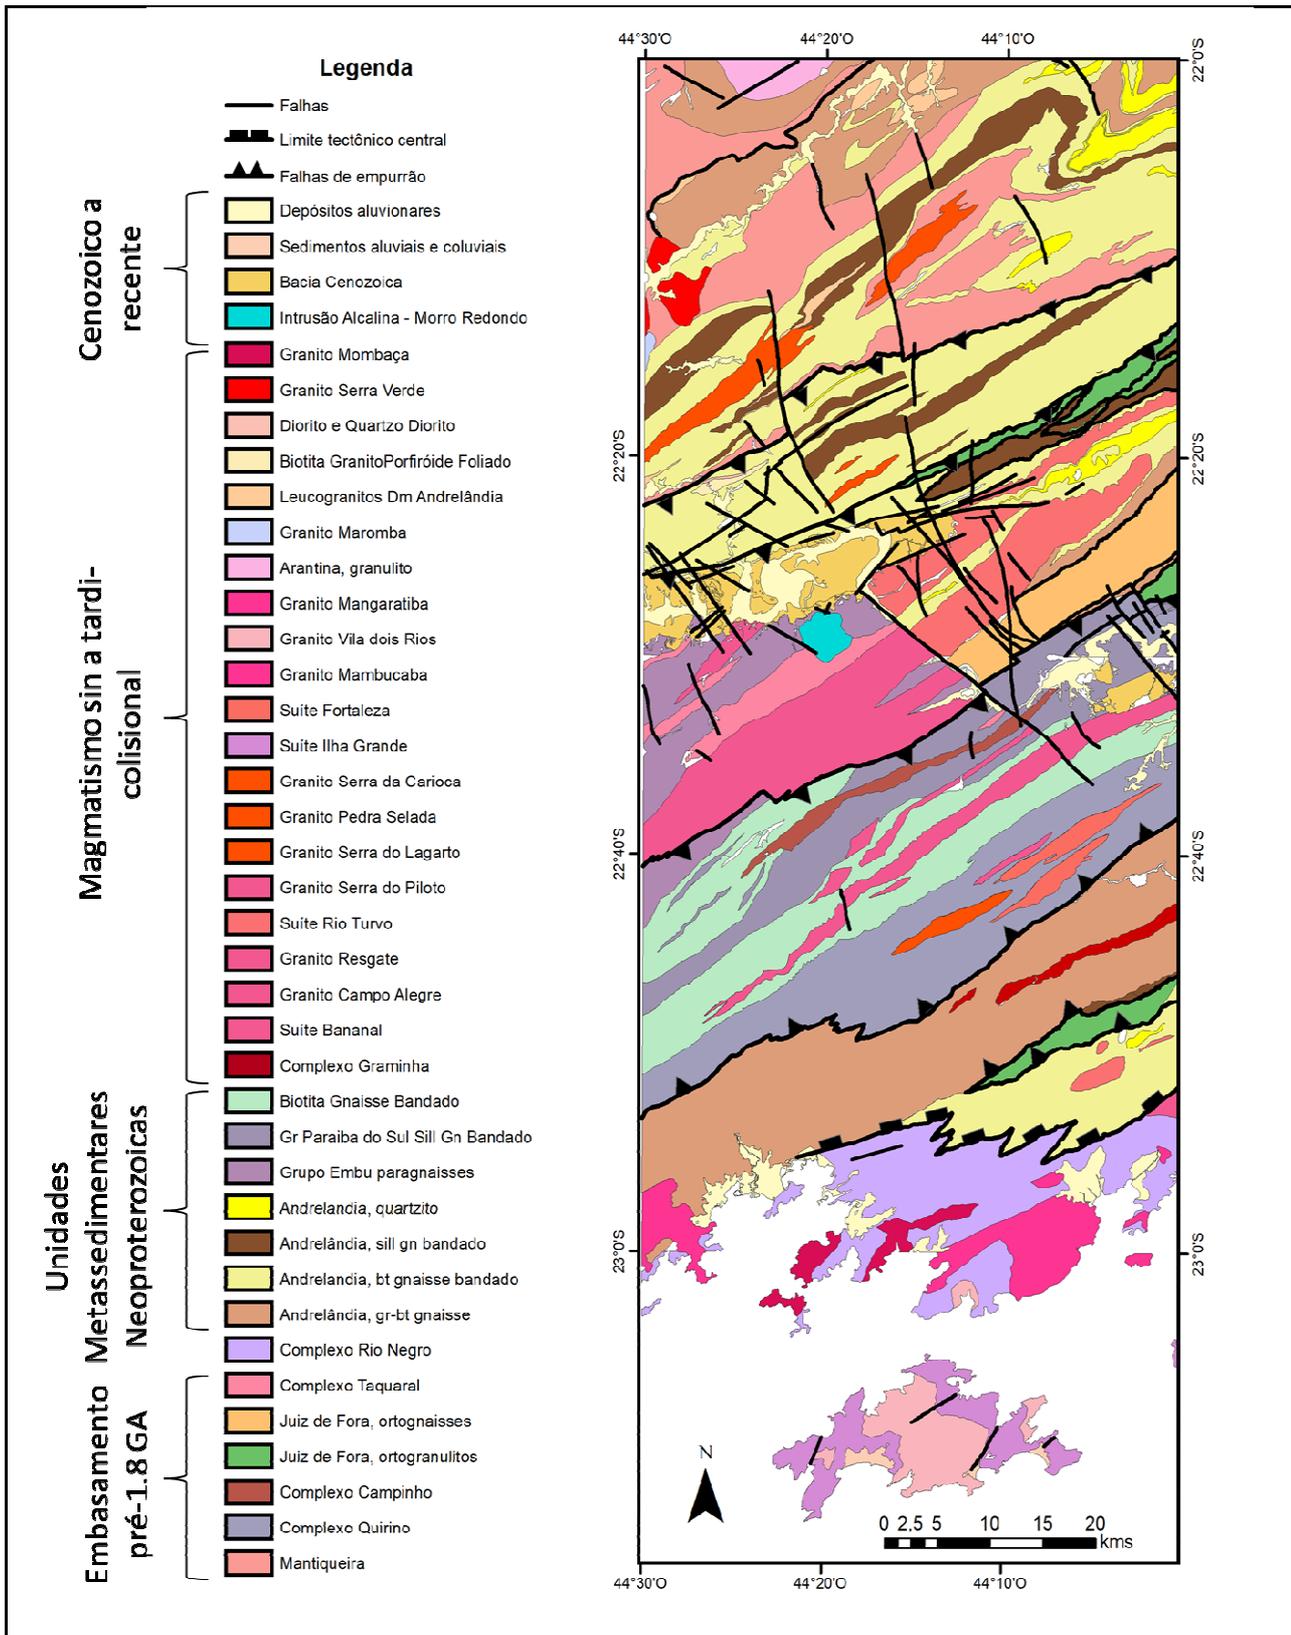
2.6 Magmatismo Alcalino

A ocorrência de corpos alcalinos na região sudeste do Brasil é relacionada por Almeida et al. (1967) ao evento distensivo responsável pela implementação do Rift Continental do Sudeste do Brasil (RCSB).

2.7 O Rift Continental do Sudeste Brasileiro

Entre os estados do Paraná e Rio de Janeiro, pouco mais de 900 km, grosseiramente paralelo à atual linha de costa, ocorre uma longa depressão denominada Rift Continental do Sudeste do Brasil (RCSB). Segundo Riccomini et al. (2004) os eventos formadores da depressão do segmento central do RCSB, contido na área de estudo e o subsequente preenchimento vulcano sedimentar se deu no Paleógeno, sob um campo de esforços predominantemente distensivo de direção NNW-SSE que reativou zonas de cisalhamento proterozóicas. Registros de tectônica holocênica mostram que eventos deformacionais atuam sobre o RCSB até os dias atuais. Na área estudada essa longa depressão se manifesta como as bacias de Resende e Volta Redonda, de maneira escalonada (*en echelón*) (Cogné et al., 2013). A intrusão de corpos magmáticos alcalinos nas bordas do rift estão relacionados à sua formação, como o Morro Redondo, localizado na região centro-norte da área de estudo.

Figura 4 - Ocorrência das unidades litológicas na área de estudo



Fonte: O autor, 2023.

3 PRINCIPAIS ESTRUTURAS / DESCONTINUIDADES DA ÁREA

A seguir uma breve descrição das mais importantes estruturas presentes na área de estudo (figura 5). Elas representam descontinuidades que marcam limites entre domínios tectônicos (Almeida et al. 2000).

a) Fumaça - Rio Preto

Trata-se da zona de sutura entre os domínios Juiz de Fora e Andrelândia. Uma faixa milonítica que chega a ter centenas de metros de espessura. Mergulha predominantemente para SE e lineações minerais e de estiramento locais tem mergulhos suaves para NE, E ou SE, o que indica uma movimentação reversa dextral.

b) Quatis – Serra das Coroas:

Uma zona milonítica caracterizada por um empurrão oblíquo dextral, com topo subindo para W-NW.

c) Valença

Uma complexa zona de cisalhamento de alto ângulo, cuja deformação se concentra na lapa. Seus limites são de difícil determinação, pois as feições de deformação variam de milonitos, bandamento gnáissico, até uma simples xistosidade, a depender do litotipo.

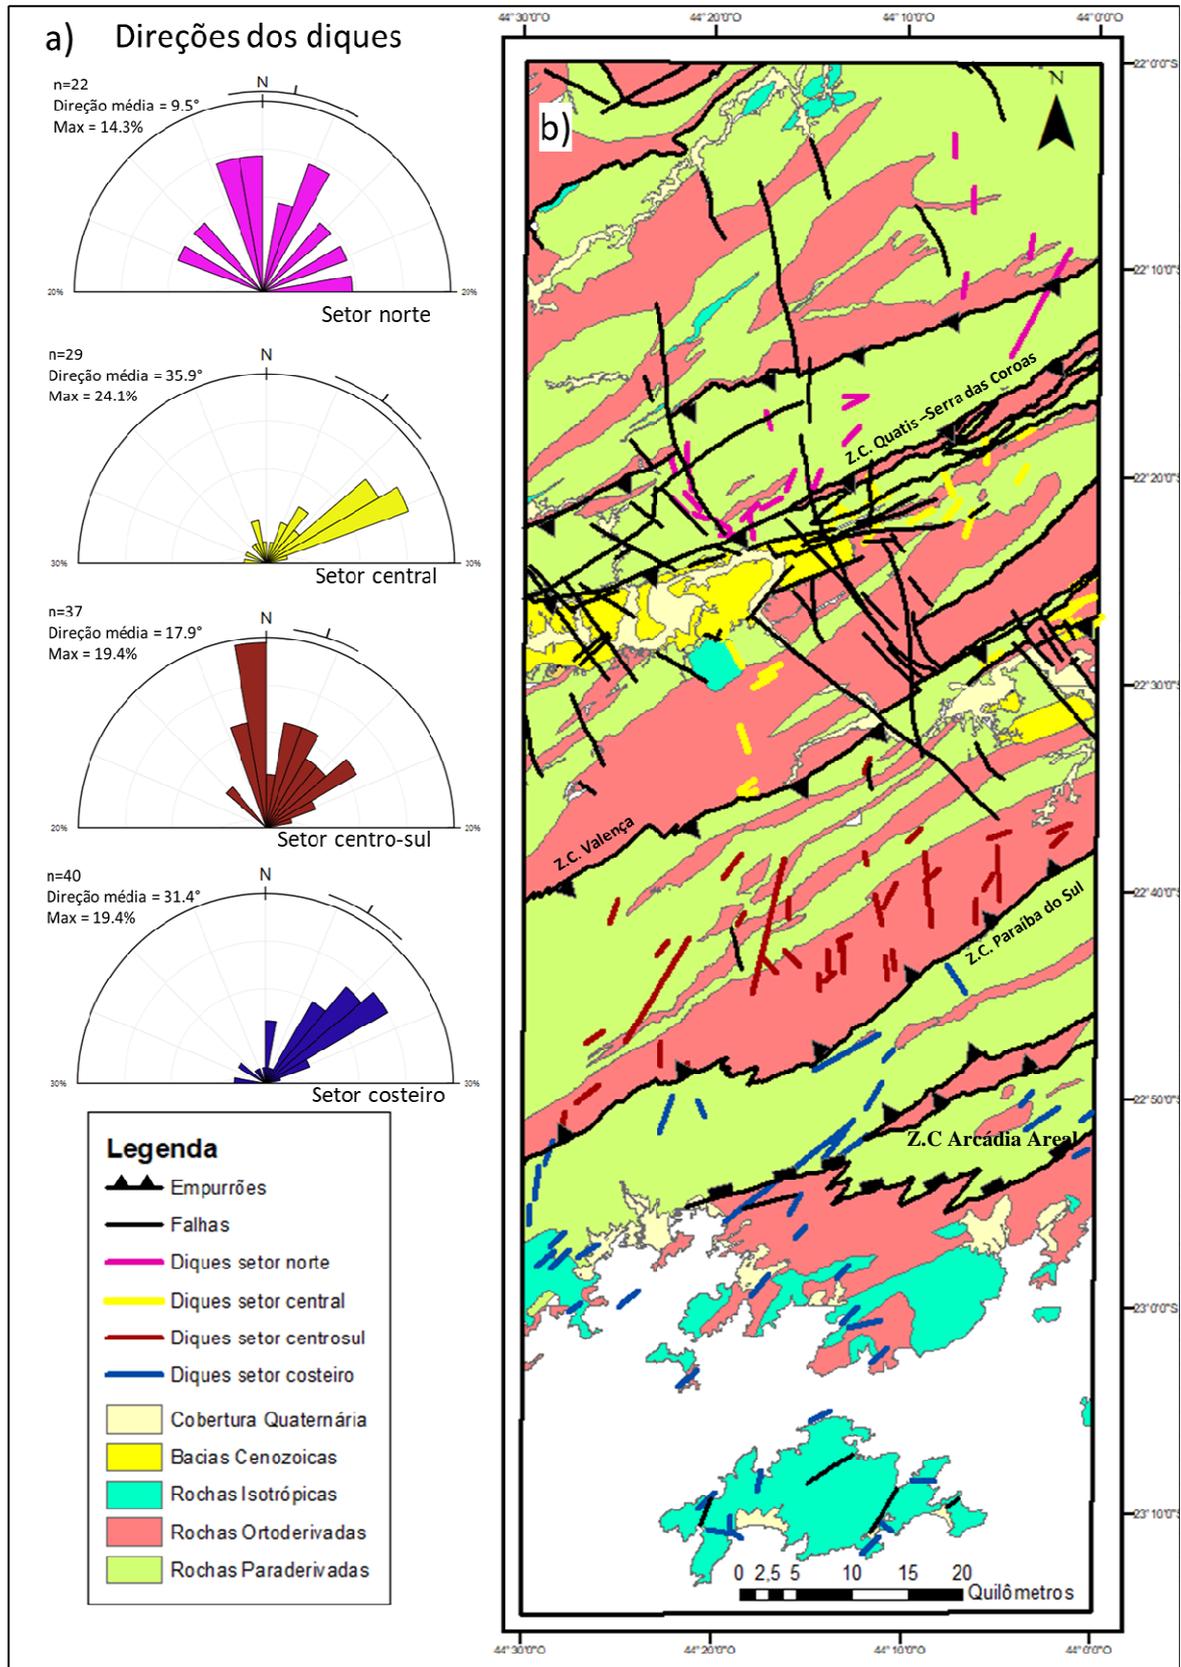
d) Arrozal – Paraíba do Sul

Um conjunto de feixes miloníticos de dezenas de metros de espessura. Apresenta altos mergulhos para SE e NW e lineações de baixa a média obliquidade, com predomínio de caimento para NE.

e) Arcádia -Areal (CTB)

Caracteriza-se por predomínio de foliações miloníticas com mergulhos baixos a médios para NW, afetadas por dobras posteriores e lineações de estiramento entre N e NE com obliquidades baixas a médias.

Figura 5: a) Direções dos diques separados por setores norte, central, centro-sul e costeiro. B) unidades litológicas agrupadas em associações litológicas



4 SETORIZAÇÃO DOS DIQUES

Os diques na Figura 5 foram agrupados em setores, segundo critério sugerido parcialmente por Guedes et al. (2016). Nesse trabalho, a autora chama a atenção para o fato de que a falha que limita a bacia de Resende ao norte (a falha se desenvolve ao longo da zona de cisalhamento Quatis-Serra das Coroas (Heilbron et al., 2016) que separa populações de diques com direções distintas. Ao norte, (setor norte) com ocorrência em amplo espectro e predomínio N-NW. Ao sul, (setor central) as direções dos diques têm uma forte tendência NE. Os setores centro-sul e costeiro foram limitados, neste trabalho, com critérios visuais e levando em conta as falhas de empurrão que representam grandes descontinuidades crustais. O setor central faz limite com o setor centro-sul pela zona de cisalhamento de Valença, o setor centro-sul limita o setor costeiro pela zona de cisalhamento Paraíba do Sul.

5 LINEAMENTOS

O termo lineamento foi originalmente proposto por Hobbs et al. (1904) para descrever feições “retiformes na paisagem causadas por juntas e falhas, revelando a arquitetura do embasamento rochoso”. O’Leary et al. (1976) propõe uma definição que é mais amplamente aceita: uma feição linear de uma superfície cujas partes estão alinhadas de maneira retiforme ou ligeiramente curvilínea que difere do padrão de feições adjacentes e que, presumidamente, reflete algum fenômeno em subsuperfície (apud Ramli et al. 2009). Nesta dissertação adotamos a definição de O’Leary que exclui feições consideradas como “pano de fundo”, contabilizando apenas aquelas que se destacam.

Em geologia, morfologias lineares incluem: a) vales ou depressões lineares, b) cristas lineares c) quebras de taludes lineares, d) drenagens retilíneas, (Jordan et al. 2005; Clark et al. 1996) e são expressões superficiais de estruturas planares como diques, falhas, zonas de cisalhamento, foliações e limites entre unidades litológicas, truncadas pela superfície topográfica. Por isso são de grande importância em diversas áreas do conhecimento e interesse econômico. Podem controlar depósitos minerais, gestão de água subterrânea e reservatórios de petróleo, ou controlar a estabilidade de taludes além de outras aplicações na construção civil. É importante notar que apenas feições planares de alto ângulo de inclinação resultarão em feições lineares quando truncadas pela superfície topográfica. Estruturas que mergulham com baixos ângulos tendem a formar feições curvilíneas que acompanham as irregularidades do terreno.

5.1 Interpretação manual

Os lineamentos na área de estudo foram interpretados manualmente, sobre o modelo digital de elevação SRTM (*Shuttle Radar Topography Mission*). Os dados SRTM foram adquiridos em fevereiro de 2000, pelo ônibus espacial Endeavour da agência espacial norte americana NASA, em missão que recobriu cerca de 80% da massa continental da Terra (<https://www2.jpl.nasa.gov/srtm>). Os dados brutos foram, em seguida, processados no INPE (Instituto Nacional de Pesquisas Espaciais) e disponibilizados no portal TOPODATA na

resolução de 1 arco-segundo, ou 30 metros por pixel e 1 metro de resolução vertical. (<http://www.dsr.inpe.br/topodata>).

Para a interpretação manual os dados foram carregados na plataforma Esri® ArcMap 10.5 e aplicado o efeito “revelo sombreado”, com duas diferentes direções de pseudoiluminação: 315 de azimute e 45 graus de inclinação e 265 de azimute com 45 graus de inclinação. O uso de diferentes direções de pseudoiluminação tem o objetivo de mitigar o efeito de feições no terreno que se tornam pouco evidentes por estarem paralelas à fonte de iluminação.

Os lineamentos foram interpretados em duas escalas diferentes: 1:500.000 que realça as principais feições, como grandes zonas de cisalhamento e 1:250.000 em que feições menores aparecem. Foi decidido que apenas feições com mais de 50 mm (em sua respectiva escala) seriam representadas. No total, cinco versões de interpretação de lineamentos foram produzidas (figura 25), quatro delas pelo autor, com um intervalo de, pelo menos, duas semanas entre rodadas de mapeamento e uma produzida por uma aluna do primeiro ano de graduação em geografia que trabalhou, na medida do possível, sob as mesmas condições.

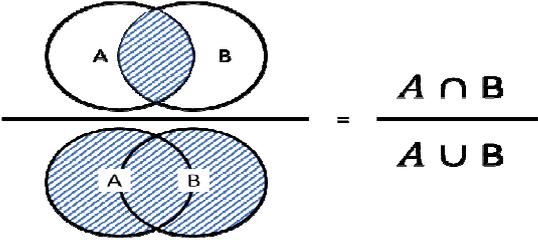
6 METODOLOGIA DE ANÁLISE DE RESULTADOS

A interpretação manual de lineamentos pode variar significativamente, mesmo quando feitas pelo mesmo intérprete, sob as mesmas condições. Esse é um processo intrinsecamente subjetivo. Mabee et al. (1994) sugere um método de interpretação manual de lineamentos baseado na repetição de sessões de mapeamento pelo mesmo observador, ou por diferentes observadores, com o objetivo de reduzir a subjetividade associada ao mapeamento de lineamentos. O conceito de repetibilidade proposto por esse autor foi incorporado neste trabalho e as diferentes versões de mapeamento são comparadas.

Para avaliar a repetibilidade dos resultados aplicamos o índice de similaridade de Jaccard, uma métrica consolidada para a comparação de dois conjuntos de dados (Fletcher et al. 2018) que neste caso é a razão entre lineamentos que ocorrem nos dois conjuntos analisados e o total de lineamentos, subtraindo-se os lineamentos coincidentes (figura 6-b). As diferentes sessões de mapeamento foram agrupadas de dois em dois (figura 26) e sua similaridade foi avaliada visualmente segundo critérios propostos por Mabee et al. (1994) que sugere que lineamentos devam ser considerados coincidentes quando seus azimutes variam

Figura 6: a) Índice de similaridade de Jaccard, A e B são os dois conjuntos de dados analisados. b) índice de Jaccard para conjuntos dados sobrepostos

a)



$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

b)

$$J(a, b) = \frac{|a \cap b|}{|a \cup b|} = \frac{|a \cap b|}{|a| + |b| - |a \cap b|}$$

.Fonte: O autor, 2023.

até $\pm 5^\circ$ e a distância entre eles não seja maior que 2mm na escala adotada. Por último, como $J(a, b)$ é diferente de $J(b, a)$, os resultados exibidos na figura 26 são uma média simples entre os dois.

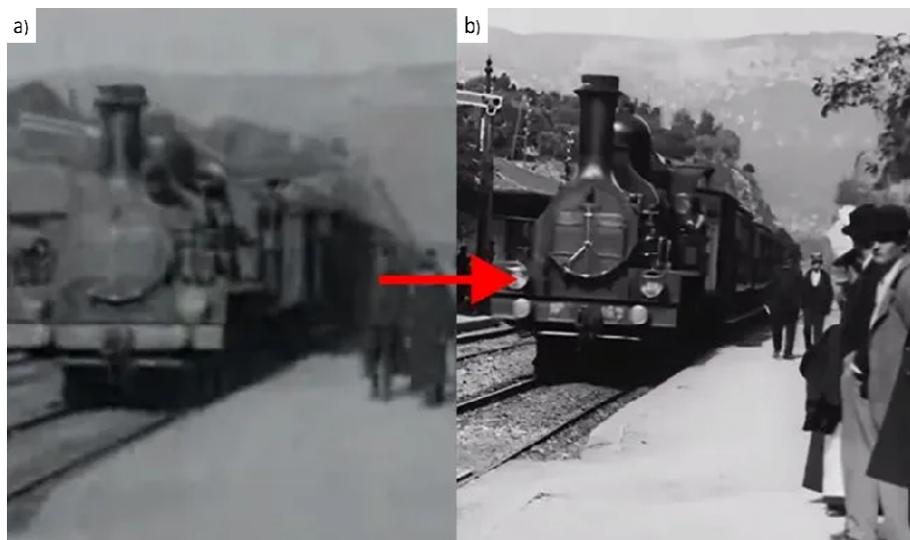
7 MÉTODO COMPUTACIONAL

O aprendizado de máquina (*machine learning*), foi definido por Arthur Samuel, empregado da IBM no final dos anos de 1950 da seguinte forma:

Aprendizado de máquina é a área de estudo que dá aos computadores a habilidade de aprender sem terem sido explicitamente programados para isso.

A técnica de extração de lineamentos é baseada em segmentação semântica que é a habilidade do computador de segmentar uma imagem desconhecida em diferentes objetos a nível de pixel (Guo et al. 2018). Em nosso estudo, fazemos a classificação em duas populações: lineamentos e não-lineamentos. Para isso utilizamos uma rede neural convolucional profunda (RNCP) com arquitetura U-Net.

Figura 7) a) Cena do filme “Chegada do trem na estação Ciotat” pelos irmãos Lumière de 1895, creditada como marco inicial da indústria cinematográfica, b) imagem aprimorada por Denis Shiryayev usando técnicas de aprendizado de máquina que analisou outras imagens trens



Fonte: techgrabyte.com

7.1 Dois métodos de aprendizado de máquina

Existem muitos métodos de aprendizado de máquina, mas daremos enfoque apenas aos dois mais populares:

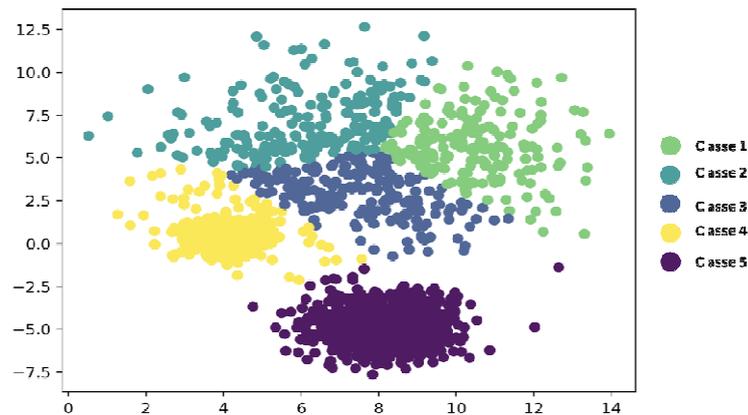
a) Método supervisionado:

É o método mais utilizado atualmente em geociências e no reconhecimento de imagens, além de ser empregado em redes neurais convolucionais (Schuster et al. 2021). Trata-se de encontrar um modelo que seja capaz de prever da melhor maneira possível um resultado \mathbf{y} a partir de uma entrada \mathbf{x} .

Uma de suas aplicações mais populares é determinar os coeficientes de ponderação \mathbf{w} que otimizam os resultados de uma rede neural. Esse método é chamado de supervisionado porque para que os coeficientes sejam corretamente definidos é preciso fornecer um conjunto de dados de treinamento antes que o algoritmo seja capaz de fornecer previsões assertivas.

b) Aprendizado não supervisionado

O aprendizado não supervisionado é quando o algoritmo não tem objetivo definido, mas apenas procura padrões nos dados fornecidos, utilizando técnicas estatísticas e de geometria analítica. Um exemplo simples é o método *k-means*, ou agrupamento *k-means* que computa a distância euclidiana entre os pontos de uma nuvem de maneira iterativa e forma grupos de pontos mais próximos de um centróide.

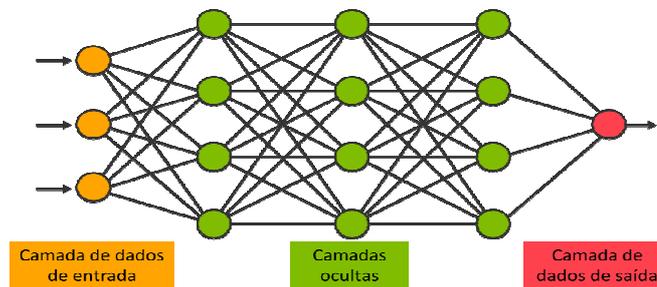
Figura 8 - Nuvem de pontos hipotéticos agrupados em 5 classes pelo algoritmo *k-means*

Fonte: O autor, 2023.

7.2 Redes neurais artificiais

É comumente atribuída à McCulloch & Pitts (McCulloch, 1943) a criação da primeira rede neural artificial e alguns conceitos propostos por eles ainda são utilizados. Nos anos 1950 Rosenblatt (1958) apresentou o algoritmo que modela o funcionamento dos neurônios no cérebro e o chamou de Perceptron, o que nada mais é do que a forma mais simples de uma rede neural artificial. Cada neurônio realiza uma simples computação. Ele recebe um conjunto de sinais de entrada, soma esses sinais e os entrega à sua função de ativação que retorna um valor que, se maior que um determinado limite, dispara um sinal para o próximo neurônio. Se menor que o limite, permanece inativo. Entre um neurônio e outro os sinais são ponderados por um coeficiente, ou seja, multiplicados por um valor que pode tanto lhe conferir maior importância, como inibir sua continuidade.

Figura 9 - representação esquemática de uma rede neural com muitas camadas ocultas, utilizada em processos de aprendizado profundo (*deep learning*)



Fonte: Tibco, 2023.

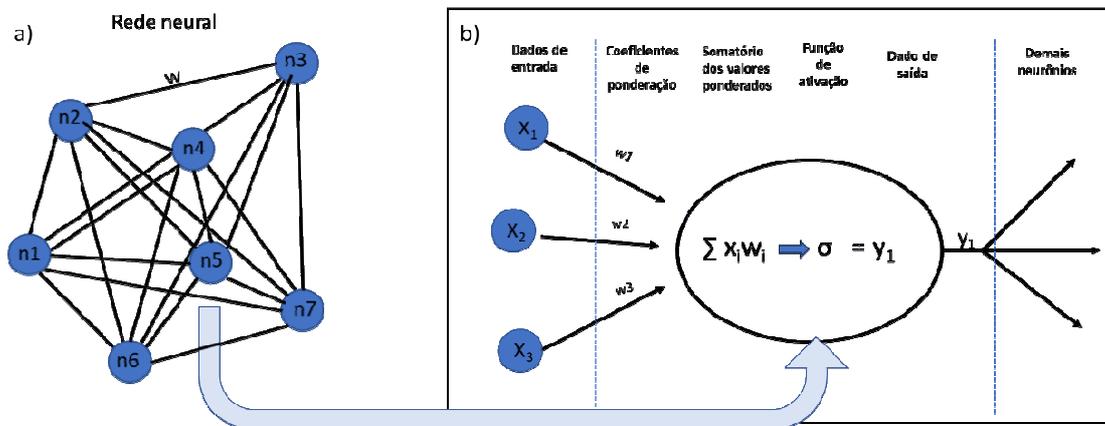
7.3 A função Perceptron

A função Perceptron representa uma rede neural muito simples, com apenas uma camada de um neurônio. As redes neurais usadas em tarefas mais sofisticadas apresentam uma arquitetura complexa, com muitas camadas de neurônios, as “camadas ocultas” (figura 9). Recebem esse nome porque operam sem interface com o programador que analisa as entradas (*inputs*) e as saídas (*outputs*) do sistema. Processos que utilizam redes neurais com muitas camadas são chamados de “aprendizado profundo” (*deep learning*).

Equação 1) a Função perceptron; onde: w_i = fator de ponderação do valor de entrada x_i , e σ é a função de ativação, e y = valor de saída.

$$y = \sigma \left(\sum_{k=0}^i w_i x_i \right)$$

Figura 10 - a) Uma representação esquemática de uma rede neural, b) representação gráfica da função Perceptron.



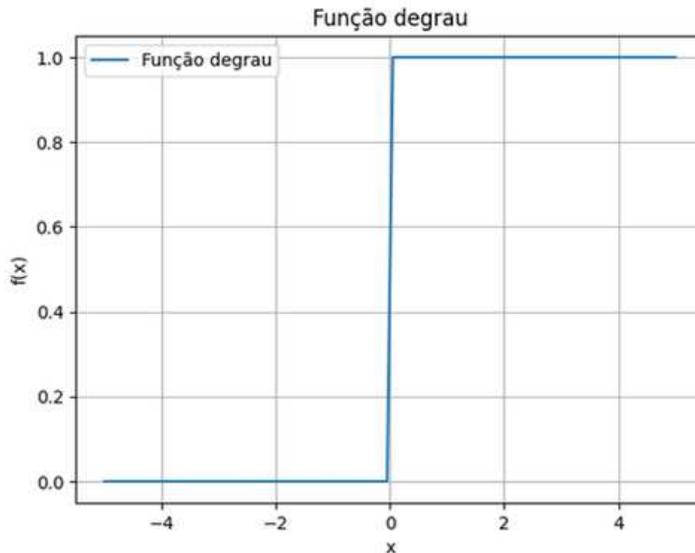
Fonte: O autor, 2023.

7.4 Funções de ativação

No sistema nervoso dos mamíferos informação é processada a transmitida de um neurônio a outro através de junções neuro sinápticas. Na região intersináptica que fica entre os dendritos de um neurônio e o terminal axiônico de outro, existem substâncias chamadas neurotransmissores. Os neurotransmissores podem estimular ou inibir as sinapses (Kovács et al. 2006). De maneira similar, a função de ativação em redes neurais artificiais intermedeia a transmissão de informação entre um neurônio e o próximo e por isso tem um papel central no treinamento de redes neurais profundas (Ramachandran et al. 2017).

Ao longo das últimas décadas muitos tipos de função de ativação foram empregados em redes neurais artificiais. As mais comumente usadas são função não lineares, pois são capazes de reconhecer padrões complexos nos dados. A ausência da função de ativação ou o emprego de uma função de ativação linear limita a performance do modelo que se comportará como um modelo de regressão linear (Sharma, S. 2017). Além disso é desejável que uma função de ativação seja diferenciável, pois o método gradiente será calculado em função dela. A seguir são apresentadas algumas funções de ativação mais comuns:

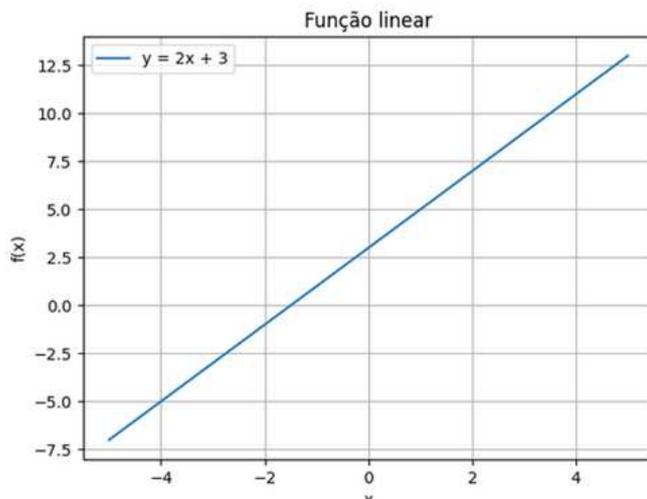
Degrau: a mais simples das funções de ativação. Dado um valor limite, ela dispara a sinapse se o sinal de entrada for maior que esse valor, caso contrário a sinapse é inibida. Não pode ser usada em problemas de classificação multiclases.



$$f(x) = 1, x \geq 0$$

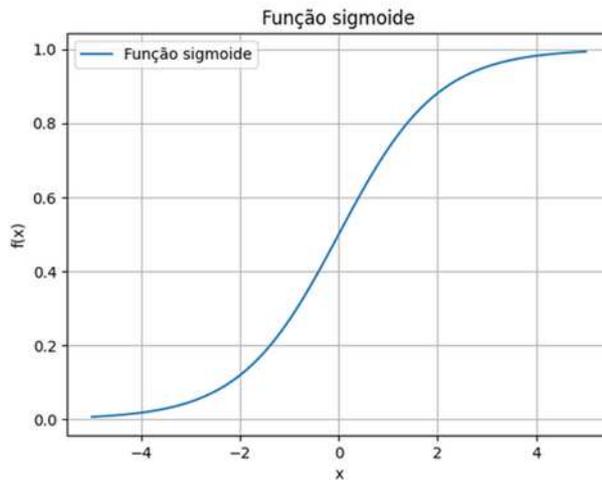
$$f(x) = 0, x < 0$$

Linear: a função de ativação linear cria um sinal de saída diretamente proporcional ao de entrada. Ideal pra tarefas simples.



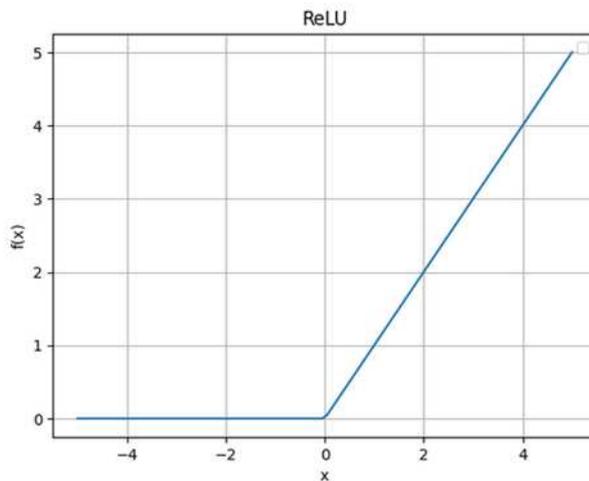
$$f(x) = 2x + 3$$

Sigmoide: uma das mais utilizadas em tarefas de classificação devido a sua não linearidade, diferenciação contínua e suavidade.



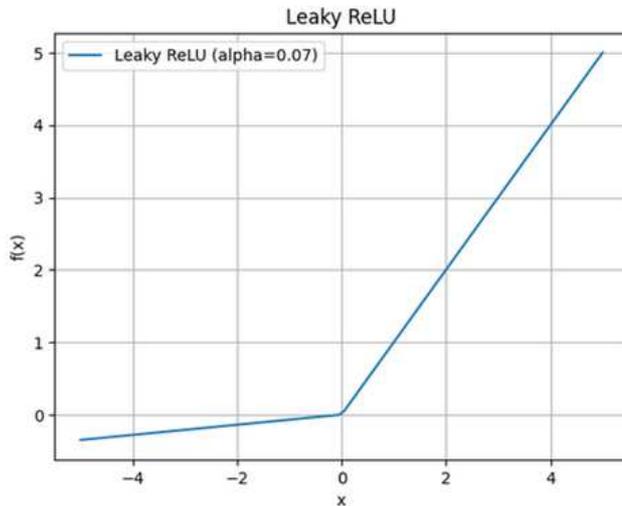
$$f(x) = 1/(1 + e^{-x})$$

ReLU: da sigla em inglês *rectified liner unit*, essa é uma função não linear amplamente utilizada e a escolhida para construir a RNCP usada neste trabalho. A ReLU é mais eficiente que outras funções pois nem todos os neurônios são ativados ao mesmo tempo.



$$f(x) = 0, x < 0$$
$$f(x) = x, x \geq 0$$

Leaky ReLU: uma versão modificada da ReLU, em que valores negativos de “x”, ao invés serem definidos como zero, são definidos como pequenos valores negativos.



$$f(x) = 0.07x, x < 0$$

$$f(x) = x, x \geq 0$$

Não existe uma regra na escolha da função de ativação para uma determinada tarefa. Cada escolha tem prós e contras e a tentativa e erro é frequentemente o método mais apropriado.

7.5 Função custo

Função custo, função erro, função de perda, ou distância são traduções livres do termo em inglês *Loss function*. A função custo tem grande importância nas técnicas de aprendizado de máquina. Ela é uma equação matemática que descreve a performance da previsão realizada por um modelo e serve como guia para que a previsão se torne cada vez mais próxima dos valores esperados. Altos valores da função custo indicam que o modelo está errando muito, enquanto valores pequenos mostram que as previsões estão acuradas.

Diversas funções podem ser utilizadas como função custo em redes neurais, cada uma com suas vantagens e desvantagens. A seguir um detalhamento de três importantes funções de ativação: i) mínimos quadrados, por ser uma das mais simples, ii) Entropia focal cruzada que é utilizada comumente empregada em tarefas de classificação de imagens e iii) similaridade Dice, que foi usada na nossa RNCP.

7.5.1 Mínimos quadrados

A utilização de mínimos quadrados como função custo nos oferece uma visão bastante didática de como um modelo pode se ajustar aos dados disponíveis, através da determinação de parâmetros ótimos.

$$S = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Equação 2 - Mínimos quadrados. A diferença quadrática entre um dado observado e um valor previsto pelo modelo. Quanto menor a diferença melhor o modelo.

Onde:

S = função custo

n = número de valores observados (quantidade de dados disponíveis)

y_i = valor medido do i -ésimo exemplo

\hat{y}_i = valor previsto pelo modelo no i -ésimo exemplo

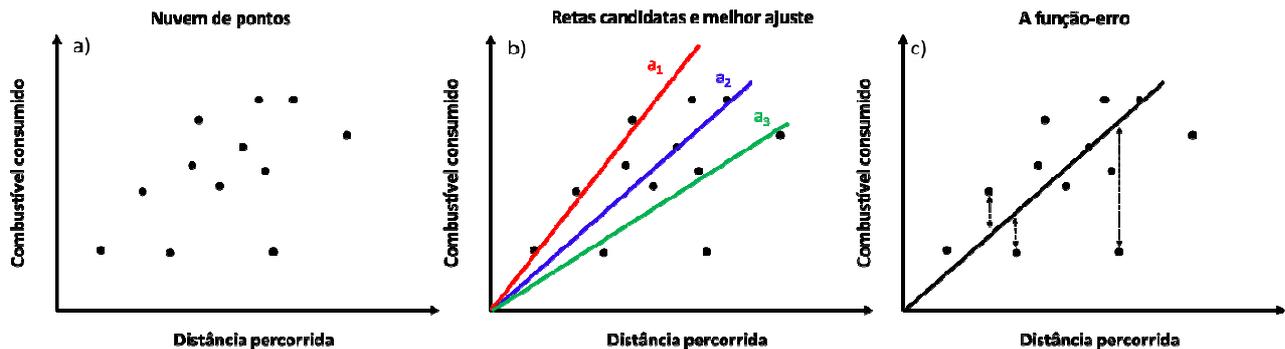
Tomemos como exemplo um caso simples, em que um modelo precisa de um único parâmetro para realizar previsões. Vamos supor que se pretende estimar a quantidade de combustível que um veículo consome ao percorrer uma determinada distância. Para isso tomou-se nota do consumo de combustível do veículo em “ n ” viagens. Os resultados são apresentados esquematicamente na figura 11a.

Assumiremos que o modelo que melhor se ajusta ao nosso problema é uma simples reta que passa pela origem, do tipo $y = ax$. Onde “ y ” é o consumo de combustível, “ x ” é a distância percorrida e “ a ” é o coeficiente angular da reta que é o parâmetro a ser otimizado. Note que apesar de apresentar uma tendência linear, os pontos se distribuem como uma nuvem, pois o consumo de combustível varia com fatores como a inclinação do terreno, peso do veículo, regulagem do motor etc.

Para cada “ a ” que testamos mede-se a distância vertical entre a reta modelo e os dados anotados. Essa diferença é elevada ao quadrado, para que tenhamos apenas valores positivos e

todos os erros são somados (equação 2). Agora podemos comparar os valores da função custo para cada coeficiente angular “a” e determinar qual deles é o menor, o mínimo local. Esse é o parâmetro ótimo para esse modelo (figura 12).

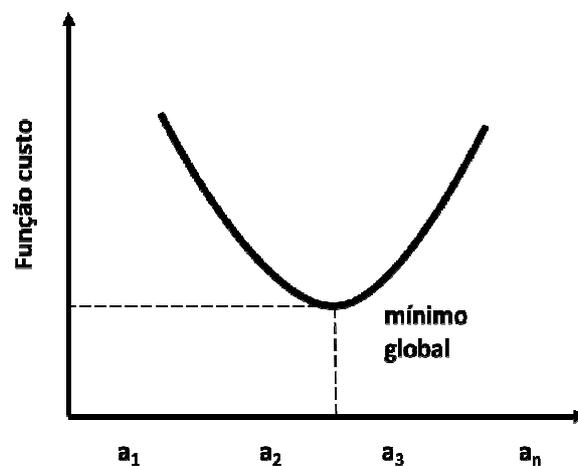
Figura 11 - Exemplo de regressão linear a) dados observados; b) retas que podem ser ajustadas aos pontos; c) o cálculo da função custo



.Fonte: O autor, 2023.

Agora tomemos um modelo um pouco mais complexo, em que seja necessário determinar dois parâmetros. Temos agora uma função custo que descreve uma superfície no espaço (figura 15b).

Figura 12: o mínimo global da função custo



Fonte: O autor, 2023.

7.5.2 A função custo na fase de treinamento

As redes neurais também são modelos que, durante a fase de treinamento, procuram se ajustar aos dados disponíveis da mesma maneira que nos exemplos anteriores, encontrando parâmetros que minimizam a função custo. A diferença é que no caso de redes mais complexas, destinadas a classificação de imagens, por exemplo, o número de parâmetros pode chegar a milhares, ou milhões. Esses parâmetros nada mais são do que os pesos e vieses atribuídos a cada conexão neural da rede.

7.5.3 Entropia cruzada

Entropia é um termo que foi apropriado da termodinâmica e se refere ao nível de desordem de um sistema fechado. Quanto maior a entropia, maior a desordem (<https://www.significados.com.br/entropia/>).

A entropia cruzada é geralmente usada como função custo em tarefas de classificação. O objetivo desses modelos é determinar a probabilidade de cada amostra analisada, neste caso cada pixel da imagem, pertencer a uma determinada classe. O comportamento esperado de uma rede neural bem treinada é atribuir uma alta probabilidade de uma amostra pertencer à classe correta e uma baixa probabilidade de pertencer a qualquer outra classe. Se durante a fase de treinamento a amostra recebe uma baixa probabilidade de pertencer à classe correta (figura 13- b), recairá na região de altas entropias e de altos gradientes da função custo. A rede deve então atualizar seus parâmetros, guiada pelo método gradiente, até que seja atribuída uma maior probabilidade de pertencer à classe correta, na região de baixos gradientes da função custo. Note que é preciso determinar um valor de corte acima do qual uma amostra é dita pertencente à uma determinada classe, sem dúvidas.

A entropia cruzada é definida como a soma das entropias de todas as estimativas de probabilidades de uma amostra pertencer a uma classe em um modelo (equação 3), ou seja, ela mede o erro global do modelo. Quando classificação de imagens é feita em apenas duas classes, como por exemplo 1 para lineamento e 0 para não lineamento, a função custo é chamada de entropia cruzada binária.

Figura.13 a) expressão matemática para a entropia cruzada binária. B) representação gráfica da entropia cruzada.

a)

$$H(x) = - \sum_{i=1}^n Y_i \log(p_i)$$

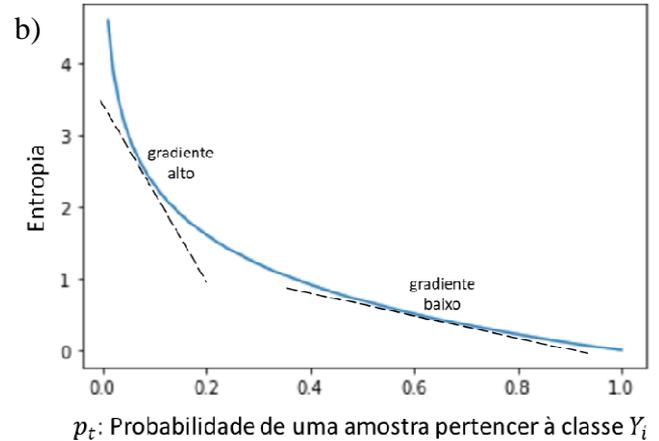
$H(x)$ = Entropia cruzada

Y_i = Rótulo da classe (0 ou 1)

p_i = probabilidade de pertencer à classe

Equação 3: Entropia cruzada

Fonte: o autor, 2023.



Amostras mal classificadas

Amostras bem classificadas

De forma geral a entropia cruzada funciona bem para problemas de classificação, pois converge mais rápido do que mínimos quadrados e tem melhor generalização (Pattern Recognition and Machine Learning, 2006 apud <https://machinelearningmastery.com/cross-entropy-for-machine-learning/>), mas não em todos.

7.5.3.1 Limitações da Entropia Cruzada

Existem casos em que a entropia cruzada não retorna resultados satisfatórios.

Exemplo: imagine que uma rede neural foi concebida para determinar a abundância relativa de isótopos de urânio em uma amostra. Segundo Mancini et al. (2021) os isótopos de urânio mais abundantes na crosta terrestre são ^{238}U (~99,3%) e ^{235}U (~0,7%).

Note que o isótopo ^{238}U é duas ordens de grandeza maior que ^{235}U . Uma rede neural que indique que 100% dos isótopos são ^{238}U vai apresentar uma função custo bem baixa, além de boas métricas de desempenho e não fará mais ajustes nos parâmetros. Essa rede neural é,

no entanto, inútil. Esse é o caso de um problema de classes desbalanceadas. (<https://medium.com/swlh/focal-loss-what-why-and-how-df6735f26616>):

Uma rede neural pode rapidamente aprender a classificar as amostras fáceis, aquelas que recebem altas probabilidades e que são maioria e negligenciar as amostras difíceis que recebem baixas probabilidades e são minoritárias. O aprendizado do modelo estabiliza, pois, as métricas, como valor da função custo e IoU, indicam que o resultado está bom. No entanto o modelo está tendencioso, enviesado, focado apenas nos exemplos majoritários, de fácil classificação.

Para contornar esse problema duas alterações na função custo podem ser aplicadas para que ela desloque seu foco para exemplos difíceis e classes minoritárias. Agora chamaremos a função custo de Entropia Focal.

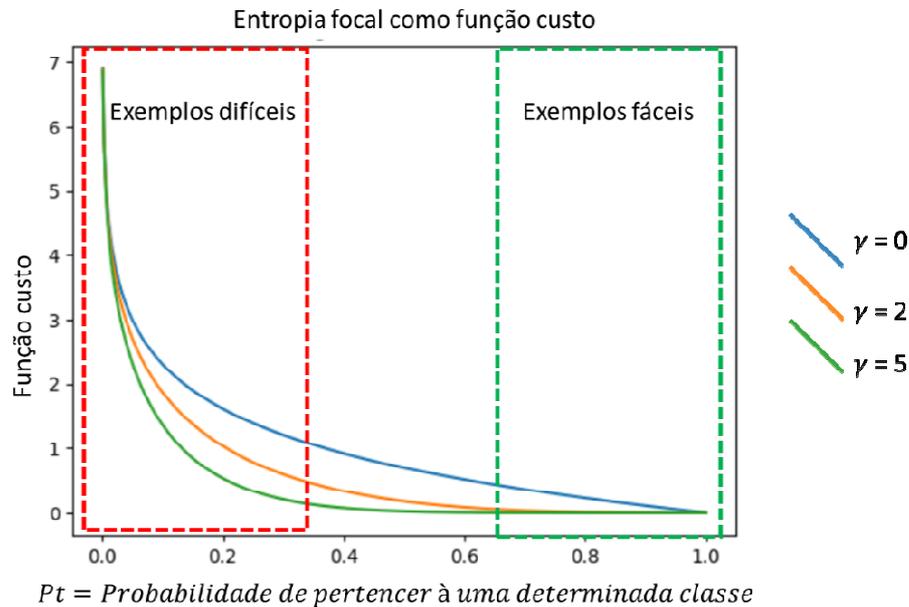
I) Fator modulador: O que controla a taxa de aprendizado dos parâmetros de um modelo é o gradiente da função custo. Para desviar o foco para os exemplos mais fáceis é preciso aumentar o gradiente na região das amostras na região de alta entropia, onde estão os exemplos difíceis, e diminuir o gradiente nas regiões onde amostras já estão bem classificadas. O fator modulador faz exatamente isso, aplicando uma transformação morfológica na função custo (figura 14) (equação 4) de acordo com a variável gamma (γ).

Equação 4) O fator modulador muda a forma da função custo, conferindo maiores gradientes à região dos exemplos difíceis, e menor gradiente à região exemplos fáceis

$$H(x) = - \overset{\text{Fator modulador}}{\boxed{(1 - p_t)^\gamma}} \log(p_t)$$

II) Parâmetro de ponderação alfa (α): A ocorrência de uma classe muito mais abundante que outras também pode criar um modelo enviesado que negligencia classes minoritárias. Por isso introduz-se o parâmetro de ponderação alfa que é geralmente definido como o inverso da frequência de uma classe (equação 5).

Figura 14 - Entropia focal modulada. Um artifício para acelerar a convergência da rede



Onde $\alpha = \text{Inverso da frequência da classe}$

Fonte: O autor, 2023.

Reunindo as duas alterações podemos definir a Entropia Focal como:

Equação 5) Entropia focal

$$H(x) = -\alpha(1 - P_t)^\gamma \log(p_t)$$

7.5.4 Função de custo Dice

A função Dice é baseada na interseção de conjuntos e apresenta resultados robustos para segmentação de imagens quando aplicada em conjuntos de dados com grande desbalanceamento e existem dados de treinamento bem classificados (Sudre et al. 2017).

Esta é a função custo utilizada na RNCP desenvolvida neste trabalho. Para problemas com 2 classes pode ser definida como:

$$DL_2 = 1 - \frac{\sum_{n=1}^N p_n r_n + \epsilon}{\sum_{n=1}^N p_n + r_n + \epsilon} - \frac{\sum_{n=1}^N (1-p_n)(1-r_n) + \epsilon}{\sum_{n=1}^N 2 - p_n - r_n + \epsilon}$$

Onde:

r = Valores de referência, dado de treinamento

p = Probabilidade prevista pela rede neural

ϵ = termo de estabilização que evita problemas de divisões por zero

Equação 6) Função Dice para duas classes

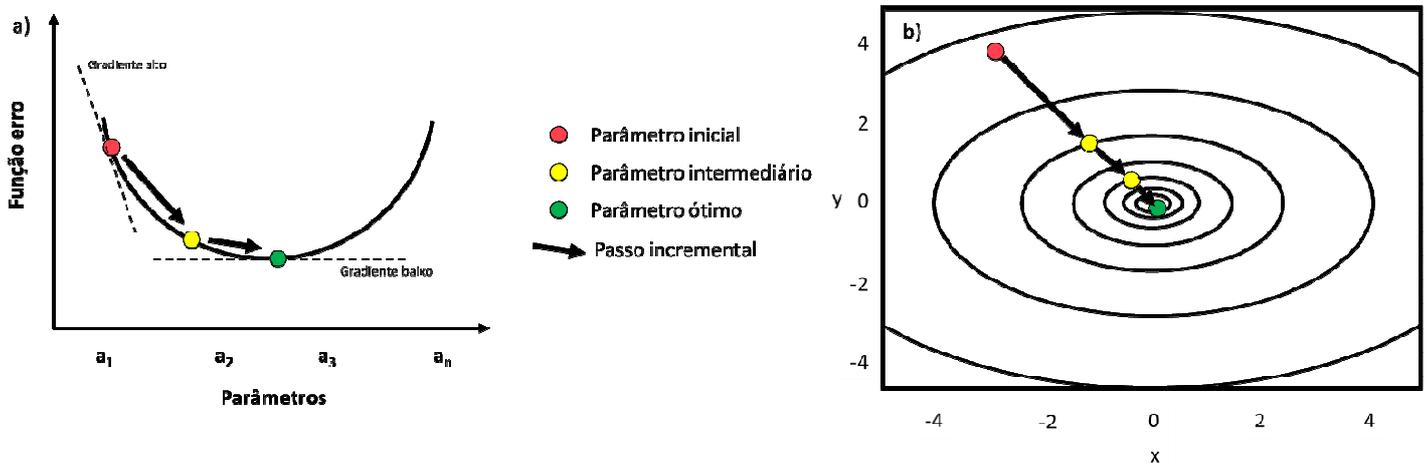
É interessante notar que a função Dice é semelhante ao índice de similaridade Jaccard,

$$\frac{A \cap B}{A \cup B}$$

7.6 Método do Gradiente

O método do gradiente, *Gradient Descent* em inglês, é uma estratégia de otimização amplamente utilizada no treinamento de modelos em aprendizado de máquina e aprendizado profundo nos anos de 2020 (<https://builtin.com/data-science/gradient-descent>). Esse método computacional age de forma iterativa, ou seja, repete um conjunto de comandos várias vezes, e a cada repetição muda o valor dos parâmetros no sentido contrário de maior inclinação da função custo, de maneira que ela diminua. Nesse método os parâmetros sofrem grandes alterações quando as amostras recaem numa região de altos gradientes, mas tendem a variar pouco quando recaem numa região de pequenos gradientes, pois estão próximas de um mínimo local. O processo é interrompido quando a diminuição da função custo se torna menor que um valor pré-determinado e os parâmetros encontrados são ditos ótimos.

Figura 15: Representação do método gradiente para a) modelos com um parâmetro e b) modelos com dois parâmetros. O Método Gradiente procura valores para os parâmetros ao longo da maior inclinação da superfície, de maneira a otimizar a busca de um valor mínimo



Fonte: O autor, 2023.

A cada iteração do modelo o valor dos parâmetros muda, na direção de maior gradiente, de maneira que a função custo assuma menores valores. Essa mudança pode ser maior ou menor, dependendo do passo incremental (*learning rate*). Esse hiperparâmetro condiciona a velocidade de convergência do modelo. Um alto valor de passo incremental economiza tempo durante o treinamento, mas se for demasiadamente grande, o valor dos parâmetros pode saltar de uma borda para outra da função custo e nunca atingir o mínimo local desejável.

7.7 Métricas de desempenho

As métricas de desempenho visam avaliar a eficácia das RNCPs. O valor da função-custo é o mais direto, quanto menor, melhor. Ele norteia todo o processo de treinamento e validação da rede e pode ser usado para definir um número ótimo de iterações necessárias. Quando a função-custo se estabiliza, as iterações seguintes se tornam desnecessárias. Uma das métricas mais simples e amplamente utilizadas em aprendizado profundo é o Índice de Jaccard, ou Coeficiente de Similaridade de Jaccard. Trata-se de uma razão que mede a

similaridade entre dois conjuntos de dados, referidos também como intercessão sobre união IoU (figura 6).

7.8 Sobre ajuste (*overfit*)

Figura 16 - Exemplo esquemático de um modelo sobreajustado (*overfit*), quando uma função que honra perfeitamente todos os dados deixa de capturar sua tendência e se torna inútil



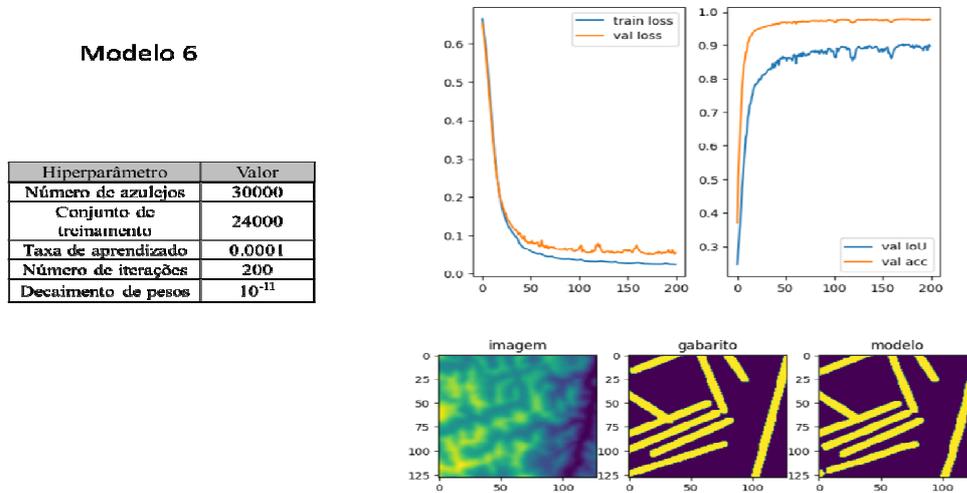
A complexidade de um modelo pode ser expressa pela ordem do polinômio que procura se ajustar aos dados de treinamento. O polinômio mais simples, de primeira ordem é uma reta. Esse tipo de problema é chamado “regressão linear”. No entanto, a maioria dos problemas em que RNCP são empregados, são mais complexos, e exigem polinômios de maior ordem para gerar boas previsões. Quanto maior a ordem, melhor o modelo se ajusta aos dados, e menor é o seu erro global. O aumento demasiado da ordem polinomial de uma RNCP pode causar o fenômeno conhecido como “sobre ajuste” (*overfit*). Nesse caso teremos regressão de um polinômio de ordem muito alta que se ajusta muito bem aos dados disponíveis, e cujo erro tende a zero, mas perde a capacidade de representar uma tendência e como consequência, de ser preditivo, tornando-se inútil (figura 16). Diz-se de um modelo sobreajustado que ele é complexo demais para os dados disponíveis.

O caso apresentado a seguir é um exemplo de sobreajuste que apareceu durante este trabalho. É difícil ter certeza o que causou o sobreajuste neste caso. Pode ser que número de épocas tenha sido demasiado, ou a forma como os azulejos (*tiles*) foram carregados. Nessas

primeiras tentativas os azulejos eram sorteados aleatoriamente para treinar o modelo, e quando mudamos para um carregamento regular, o problema desapareceu.

A figura 17 mostra o modelo 6 treinado com sorteamento aleatório de azulejos, onde 0,56% dos azulejos disponíveis foram usados. As quatro métricas mostram excelente convergência, com função custo de treinamento e validação (*train loss* e *val loss*) estabilizadas abaixo de 0.1, e acurácia e IoU (interseção sobre união) em torno de 0.9. A inspeção visual também sugere que o que foi predito pelo modelo é quase idêntico ao gabarito, ou seja, lineamentos interpretados por um humano. A figura 18-b mostra como usando pouco mais de 0,5% dos dados a rede é capaz de reproduzir perfeitamente os lineamentos em toda a área (os dados de treinamento estão em uma área a cerca de 50km a leste da área de estudo). A figura 18-a mostra o resultado da aplicação desse modelo na área de estudo. Vê-se que esse modelo falhou absolutamente em prever qualquer lineamento nesse teste-cego. Em modelos sobre ajustados como esse a rede aprende a honrar os dados de treinamento, e mais nada.

Figura 17 - No modelo 6 usamos 3 vezes mais dados de treinamento e validação, com 200 iterações. As funções de custo estabilizaram com valores próximos, assim como IoU e acurácia. Os resultados visuais são excelentes.



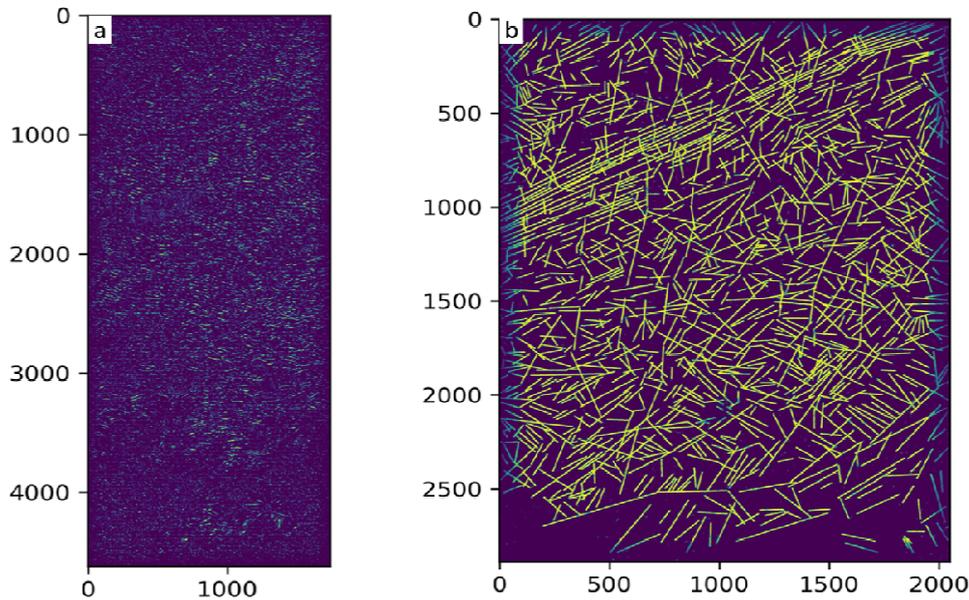
. Fonte: O autor, 2023.

Na seção 8 vemos os resultados previstos pela rede depois de alterada a forma de carregamento de azulejos, de aleatório para regular.

7.9 Redes neurais convolucionais

A convolução é uma operação matemática assim como a multiplicação, soma ou divisão, mas com uma diferença: a convolução traz consigo a ideia de movimento. A cada operação dá-se um “passo” e se realiza a operação novamente. Esse processo é especialmente eficaz no tratamento de imagens, e na otimização de redes neurais.

Figura 18 - a) Previsão de lineamentos na área estudada; b) lineamentos previstos na área onde a rede foi treinada. A RNCP está sobreajustada e não foi capaz de entregar qualquer resultado



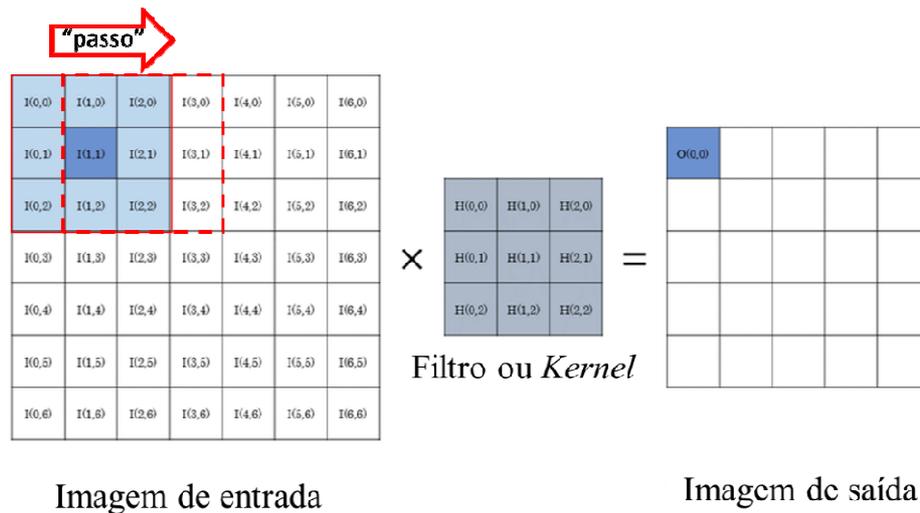
.Fonte: O autor, 2023.

Sabendo que uma imagem digital é uma matriz em que cada componente guarda informações sobre os pixels da imagem, como cor (RGB) e contraste, a aplicação de filtros se dá por meio de uma convolução com outra matriz chamada filtro ou *kernel*. O filtro começa atuando em uma extremidade da imagem e depois se desloca, repete sua operação e em seguida se desloca novamente. Ao chegar ao final da linha ele pula para a linha debaixo, realizando uma varredura em toda a imagem. Os resultados são gravados em uma terceira matriz, formando a imagem filtrada (figura 19). Os filtros possuem as mais diversas finalidades, mas entre os mais simples estão os filtros de média que visam atenuar valores anômalos tornando a imagem menos ruidosa, e os filtros de derivada que realçam mudanças ou quebras na tendência dos dados. Em redes neurais criadas para tratar imagens, cada camada oculta é uma matriz bidimensional que interage com a próxima camada através de convolução. Isso gera grandes volumes de dados, e muitas vezes redundantes. Para tornar o processo viável é necessária a redução do volume de dados. Isso se faz com camadas intermediárias chamadas camadas de *pooling*

Essas camadas atuam usando um processo muito semelhante à convolução, varrendo a camada anterior com uma janela que, ou seleciona um valor, ou faz uma média de alguns

valores e cria uma matriz significativamente menor como saída, pronta para a convolução com a próxima camada.

Figura 19: Ilustração de uma convolução entre uma imagem digital e um filtro (*kernel*). Depois de realizar uma operação com os nove pixels do canto superior esquerdo o filtro dá um “passo” para o lado e repete a operação. Dessa forma o filtro fará uma varredura em toda a imagem.



Fonte: O autor, 2024. Modificado de Baskin, *et al.* (2017).

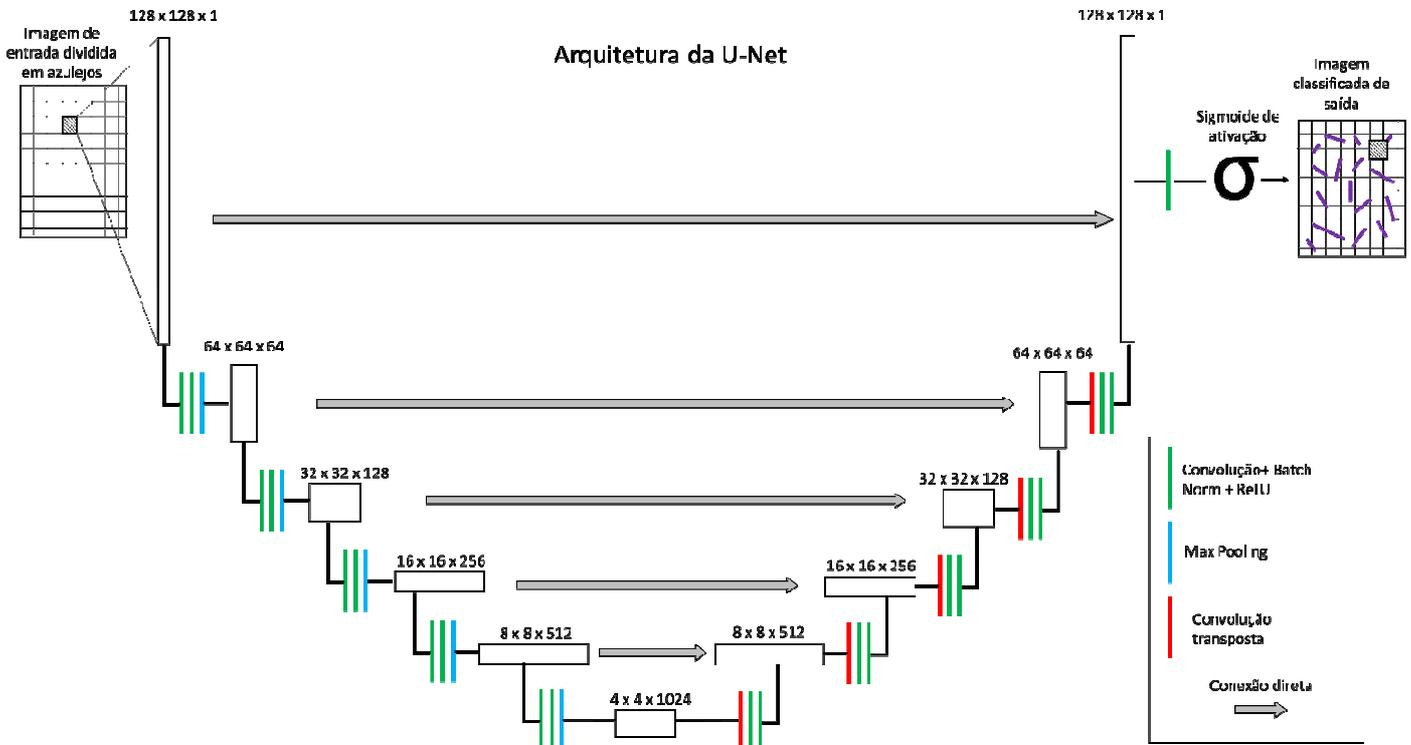
7.10 U-Nets

A arquitetura U-Net foi desenvolvida e é amplamente utilizada na análise e classificação de imagens em ciências médicas (Du et al. 2020), mas recentemente tem sido aplicada em diversos campos da ciência, incluindo geociências. Seu nome se refere à sua forma em “u” característica e consiste basicamente em dois caminhos. O primeiro é chamado de *encoder*, ou caminho de contração, e é aqui que a imagem de entrada é desconstruída à medida que ganha mais “profundidade” ao custo de sua resolução. Em outras palavras, através de uma série de operações de convolução e *pooling*, a representação da imagem diminui em altura e largura, mas ganha mais canais. A cada operação de convolução realizada os valores obtidos se tornam argumentos da função de ativação ReLU que estabelece um limite acima do qual (geralmente zero) a conexão é ativada com seu próprio valor, do contrário a conexão permanece inativa. Na figura 20 é possível notar que o azulejo de entrada tem as dimensões

em pixels: $128 \times 128 \times 1$ e ao final do caminho *encoder* a representação tem dimensões $16 \times 16 \times 256$. Após atingir a parte mais basal da rede, ou gargalo, os dados entram no *decoder*, ou caminho expansivo. Aqui a representação da imagem readquire resolução através de operações de convolução e convolução transposta que gradualmente restauram a imagem ao seu tamanho original. É possível aumentar o caminho *decoder* de modo a obter imagens com mais resolução que as de entrada, como exemplificado na figura 7. Ademais, o caminho *decoder*, recebe informação direta do caminho *encoder* numa operação chamada “conexão direta” (*skip connection*). Essa informação é concatenada a representação para que RNCP possa melhor aprender a classificar e localizar objetos (Siddique et al. 2021).

A arquitetura final da rede, como por exemplo: número de camadas, profundidade e função de ativação, à época da escrita desta dissertação, é escolhida basicamente com o método de tentativa e erro. Busca-se um arranjo que entregue resultados satisfatórios, evitando o sobreajuste, a custo razoável em termos de tempo e recurso de máquina.

Figura 20: Arquitetura da U-net utilizada



Fonte: O autor, 2023.

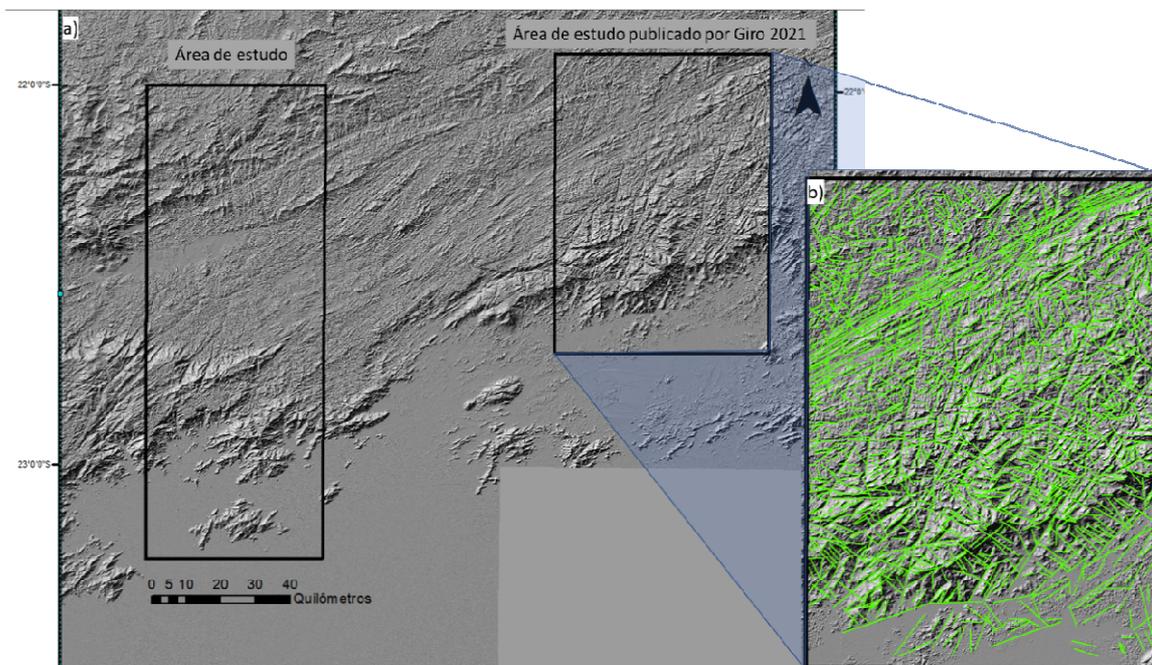
8 APLICAÇÃO DE RNCP NA ÁREA DE ESTUDO

O fluxo de trabalho escolhido para extração de lineamentos na área de estudo usa uma RNCP com arquitetura U-Net em linguagem Python disponível no anexo I. Foi treinada com dados anotados em uma região a cerca de 60 quilômetros de distância. Isso evita o sobreajuste da rede e garante uma classificação tipo “teste cego”, em que a classificação não é influenciada pelo treinamento da rede.

Para o treinamento da rede neural usaremos exemplos publicados por Giro et al. (2021) e gentilmente cedidos. Giro interpretou manualmente 1437 lineamentos (figura 21) em uma localidade situada no mesmo contexto da faixa e dobramentos Ribeira, dominada por um *trend* NE que evidenciam a foliação das rochas e corredores de lineamentos representativos de zonas de cisalhamento regionais.

Para realizar as análises e executar o código utilizamos o *cluster* de computadores da Petrobras chamado CDI – Ciência de Dados Interativa, com 12 CPUs (*Central Processing Unit*) e 125 GB de memória RAM (*Random-Access memory*) com GPUs (*Graphic Processing Unit*).

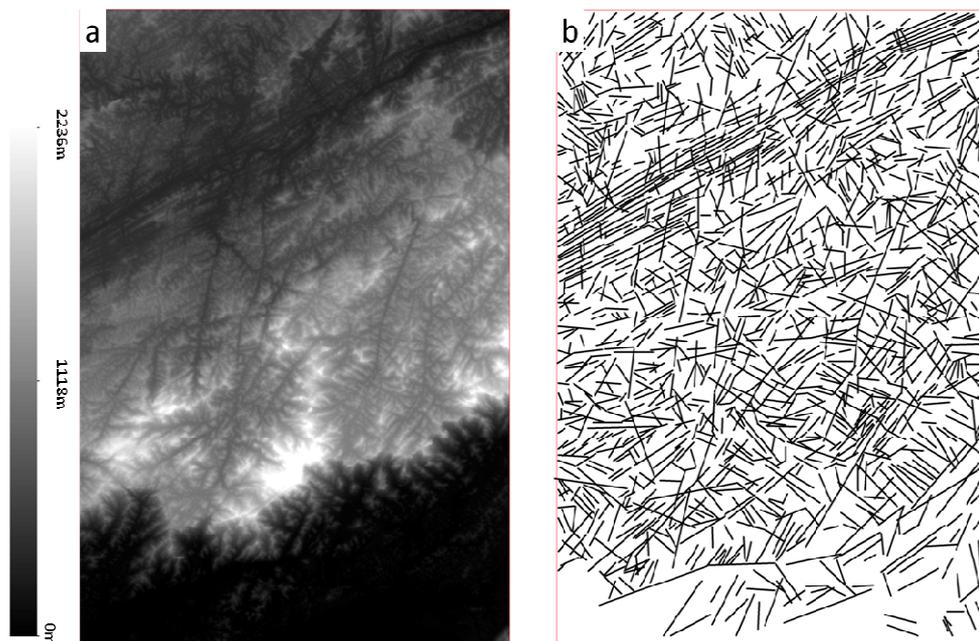
Figura 21: a) Área de estudo deste trabalho e área controle publicado por Giro 2021, b) lineamentos interpretados por Giro e cedidos para fins de treinamento da rede neural



8.1 Pré-tratamento

A primeira etapa realizada foi a adaptação dos dados aos requerimentos de entrada da RNCP. Os dados SRTM e a máscara (imagem contendo os lineamentos anotados) foram convertidas para SIRGAS 2000 UTM zona 23S, meridiano central -45, normalizados entre 0 e 1, recortados com tamanhos idênticos e exportados em 300 DPI (*dots per inch* ou pontos por polegada). Os dados pré-processados são mostrados na figura 22.

Figura 22: a) Modelo digital de elevação SRTM; b) lineamentos anotados por Giro et al. 2021



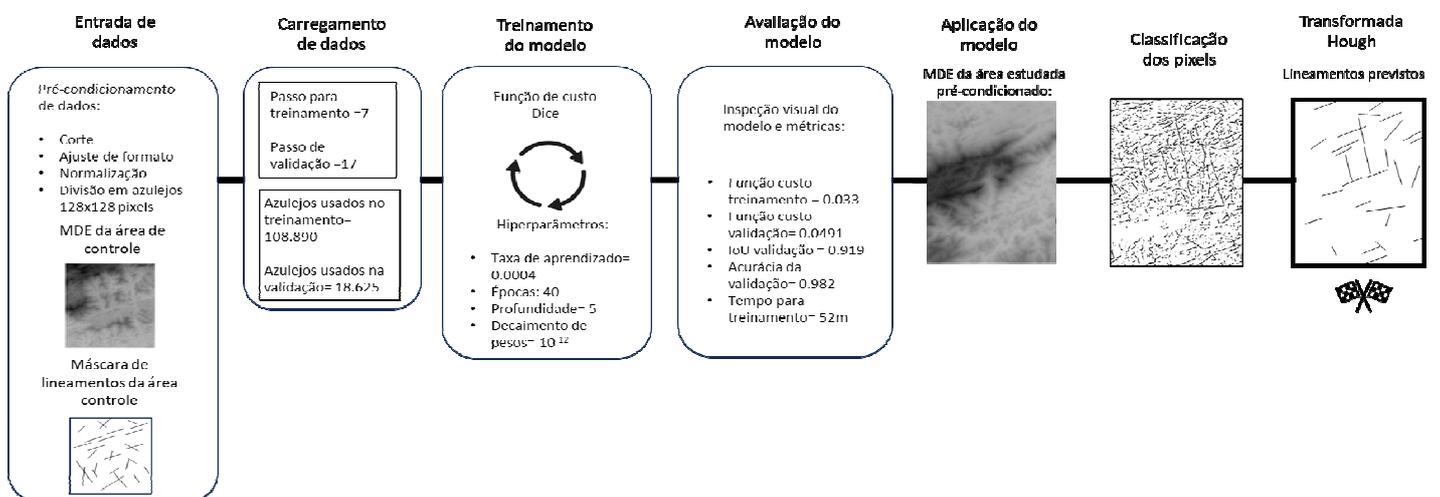
Fonte: O autor, 2023.

8.2 Hiperparâmetros

Depois de carregar os dados, foi preciso determinar quais hiperparâmetros seriam usados. Trata-se dos parâmetros que controlam o processo de treinamento da rede e que não são otimizados durante o treinamento. Alguns permanecerão fixos, como a função custo (Dice), função de ativação (ReLU), batch size (32), mas testamos variações dos seguintes hiperparâmetros:

- a) Número de azulejos (*tiles*): Quantidade de dados utilizados no treinamento e validação da rede que é função do *stride*, ou deslocamento realizado pelo *kernel* a cada convolução;
- b) Conjunto de validação: Quantidade de azulejos usados na validação, também definido por um *stride*;
- c) Taxa de aprendizado: É o deslocamento, ou “passo” dado na função custo na busca do mínimo global, ou seja, os melhores pesos das sinapses. Uma taxa muito pequena pode causar demora excessiva na busca e uma taxa muito alta pode nunca encontrar o mínimo, causando fortes oscilações no valor da função custo;
- d) Número de iterações (*epochs*): É o número de vezes que os dados vão percorrer toda a rede, retropropagar os erros e atualizar os pesos. Nas primeiras iterações o valor da função custo tende a cair muito, mas após um certo número de iterações o valor se estabiliza, tornando as demais iterações um desperdício de processamento, podendo até causar sobreajuste (Haslebacher et al. 2023);
- e) Decaimento de pesos (*weight decay*): Trata-se de uma regularização que evita o sobreajuste. Soma-se à função custo um valor proporcional ao quadrado dos pesos das sinapses, de modo que se forem muito altos a função custo cresce muito e se afasta da estabilização. Isso impede que pesos muito altos monopolizem o processo de aprendizado.

Figura 23: Fluxo esquemático do modelo 22 que obteve melhores resultados, com suas especificidades

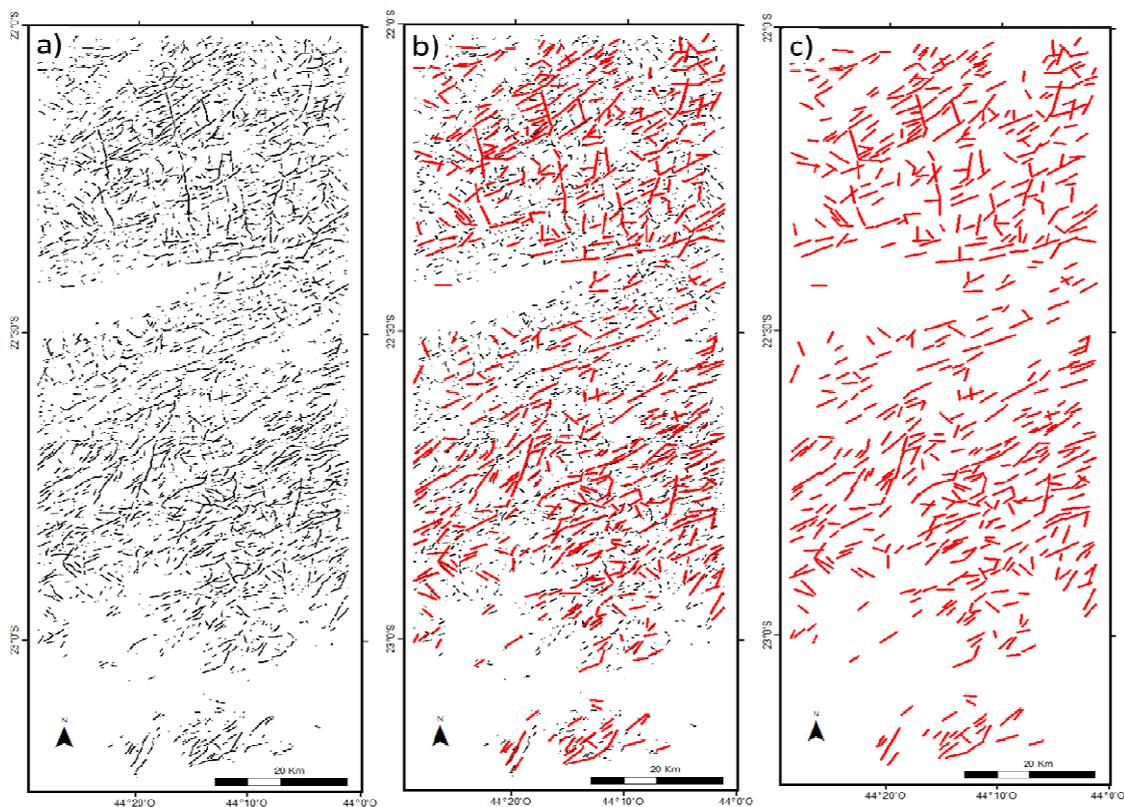


8.3 Transformada Hough:

As imagens geradas pela RNCP são o resultado da classificação dos pixels em branco – não lineamento e preto – lineamento. O resultado, no entanto, é significativamente ruidoso como pode-se ver na figura 24a que mostra o caso do modelo 30. As imagens possuem pixels classificados como lineamento agrupados em pequenos aglomerados que não tem equivalência com os lineamentos interpretados manualmente.

A transformada de Hough é uma técnica matemática capaz de detectar formas geométricas em imagens digitais nesse caso, retas. Ela funciona transformando padrões espacialmente estendidos para produzir objetos em um espaço paramétrico (Hassanein et al. 2015). Na prática a transformada converte os aglomerados de pixels classificados como lineamentos pela RNCP em segmentos de reta, adequados para a comparação com os lineamentos interpretados manualmente.

Figura 24: a) Resultado da classificação feita pelo modelo 30; b) transformada de Hough sobre a imagem classificada; c) segmentos de reta, o resultado final



Fonte: O autor, 2023.

9 RESULTADOS

Nesta seção vamos discutir e confrontar os resultados obtidos em quatro versões de lineamentos feitos pelo autor (V1 a V4), uma feita por uma estudante do primeiro ano em geociências (STD) e duas versões obtidas como saída de RNCPs (M22 e M30).

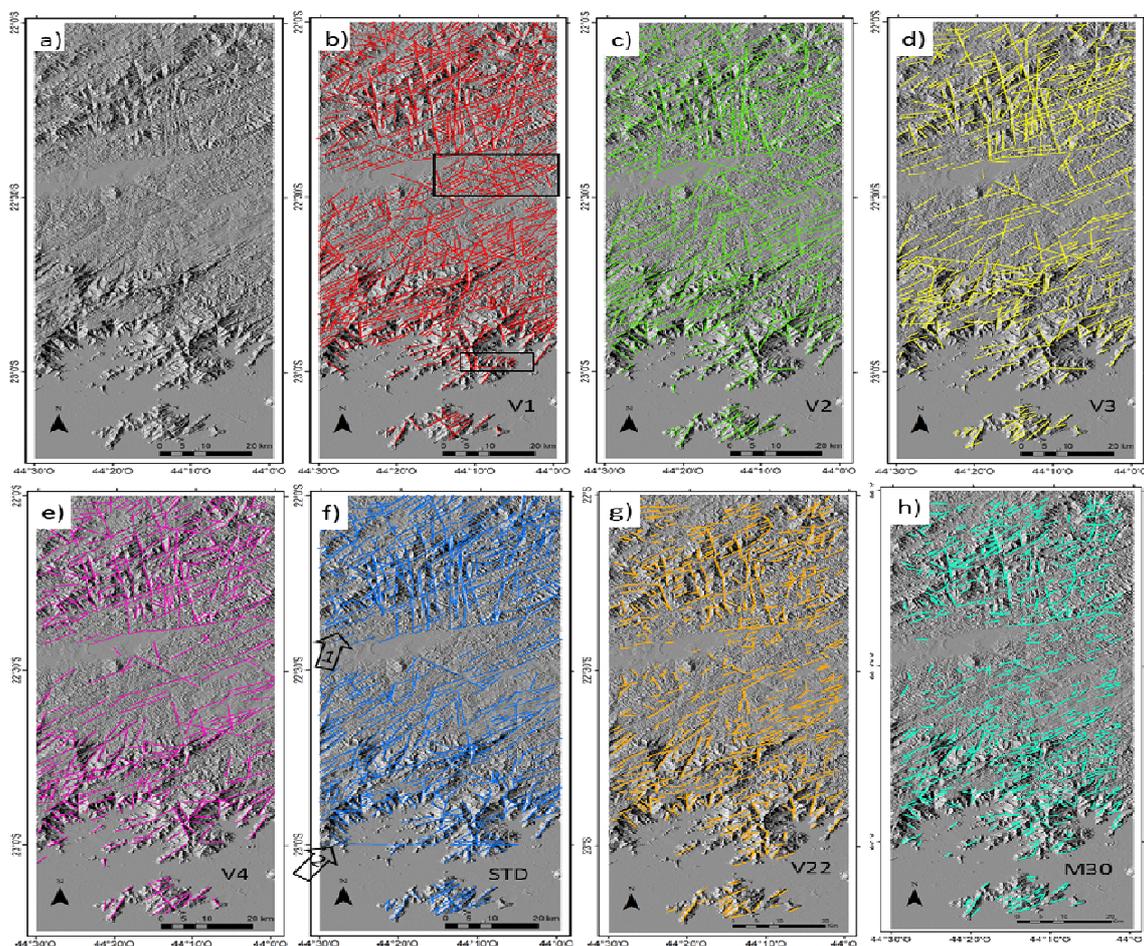
Analisando as versões interpretados manualmente (V1 a V4), é possível notar que o número de lineamentos interpretados diminui sistematicamente ao longo das sessões de mapeamento (figura 25). O autor relata que no início do projeto sua motivação para trabalhar estava muito alta e depois de representar os lineamentos mais importantes continuou desenhando e isso pode ter causado a interpretação de lineamentos de segunda ordem, ou menos importantes, indicados por retângulos pretos na figura 25-b. Esses lineamentos de segunda ordem contrastam com os de primeira ordem, formados pelo bandamento das rochas, grandes zonas de cisalhamento, empurrões e pelo corredor de lineamentos na parte norte da área. Os lineamentos de segunda ordem, existem, mas apresentam espaçamento menor que 1mm na escala de 1:250.000 (1250 m) e por isso não deveriam ser representados. Durante as sessões de mapeamento seguintes, revisitando a área, o autor decidiu que que esses lineamentos compõe o pano de fundo e não se diferenciam de feições adjacentes, como definido por O'Leary et al. (1976).

Ao longo das repetidas sessões de mapeamento o autor, inconscientemente, focou cada vez mais nas feições mais importantes, aquelas melhor representam os lineamentos da área. Isso fica claro ao se analisar a figura 26, onde pode-se ver como o índice de Jaccard das diversas sessões de mapeamento, agrupadas de dois em dois, tende a aumentar nas últimas versões (o maior índice encontrado foi entre as versões V3 e V4) e é baixo entre as primeiras interpretações. Além disso o número de lineamentos que não se repetem é maior nas primeiras versões e menos nas últimas. V1 possui 153 lineamentos que lhe são exclusivos e que tem baixa consistência, ou que compõe o pano de fundo e não devem ser representadas na escala escolhida. Com a repetição das interpretações os lineamentos se tornaram menos numerosos e mais robustos, com a consolidação dos critérios de mapeamento.

Analisando os resultados STD é possível perceber que mesmo sem possuir conhecimento avançado da geologia regional, a aluna foi inquestionavelmente capaz que capturar as grandes estruturas e tendências gerais. Contudo, um expressivo corredor de lineamentos de direção NE ao norte da área, as zonas de cisalhamento Fumaça-Rio preto e Quatis-Serra das Coroas, foi subrepresentado. Essas são estruturas retiníneas com centenas de

quilômetros de extensão, e mas foram representadas com segmentos de reta de no máximo dez quilometr desconectados (seta 1 na fig 25-f). Outro ponto foi a anotação de um grande lineamento leste-oeste na parte sul da área. Trata-se de um ruído provocado pela junção de duas imagens raster e não tem significado geológico (seta 2 na fig 25-f). A anotação de lineamentos não-geológicos pode ocorrer com ruídos coerentes e retilíneos, ou ainda com estradas, barragens, canais e outras estruturas antrópicas e pode afetar extrações feitas por computadores da mesma forma. A anotação de lineamentos não-geológicos pode ser evitada com o acúmulo de experiência por intérpretes humanos e pela inclusão de exemplos enganosos e anotados como tal, no conjunto de dados de treinamento de uma RNCP, de modo a ensinar a rede a diferenciar e evitar lineamentos não-geológicos.

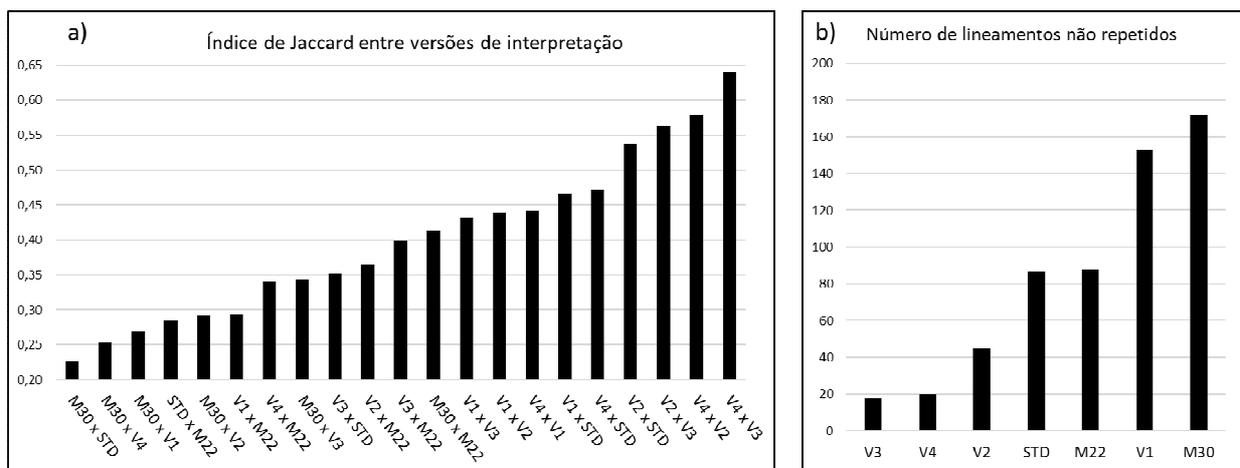
Figura 25 - Extração de lineamentos a) SRTM, pseudo iluminação azimuth 315, elevação 45; 393 lineamentos; f) STD– 744 lineamentos; g) Modelo 22 – 638 lineamentos; h) Modelo 30 – 654 lineamentos b) V1 – 729 lineamentos; c) V2 – 493 lineamentos; d) V3 – 410 lineamentos; e) V4 –



As distribuições dos comprimentos de diferentes versões dos lineamentos estão representadas em diagramas de caixa (*boxplots*) na figura 27 que apresenta também as suas direções nos diagramas de roseta. A base da caixa mostra o valor do primeiro quartil, o topo mostra o terceiro quartil, a linha do meio a mediana e o “x” indica a média. Os fios de bigode (*whiskers*) são as duas linhas para fora das caixas e representam os mínimos e máximos da distribuição.

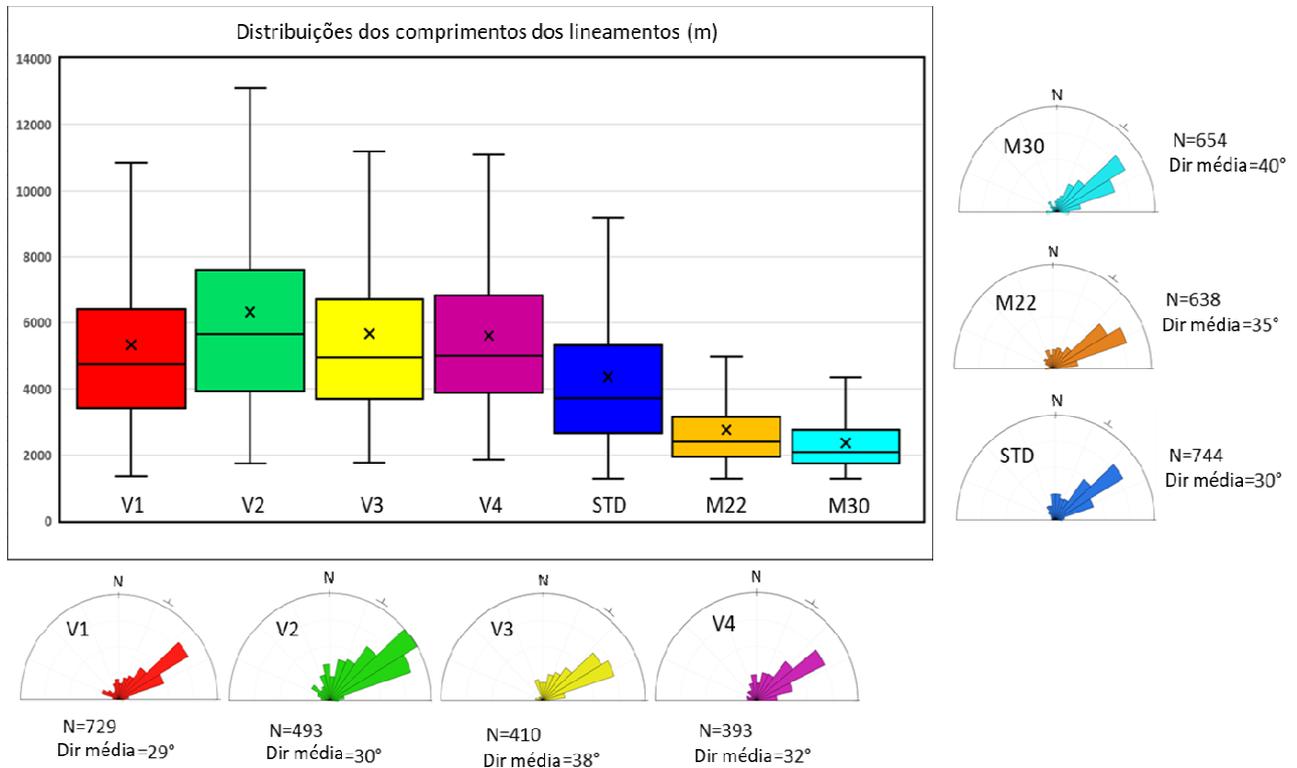
Lineamentos interpretados manualmente são V1 até V4 (feitos pelo autor) e STD (feito por uma aluna do primeiro ano). Eles são ligeiramente positivamente assimétricos, o que significa que existem mais lineamentos longos do que curtos. Os valores mínimos das distribuições tendem a ser similares, uma vez que os comprimentos foram limitados a 1250m ou 0,5cm na escala de mapeamento. É possível notar que os lineamentos feitos manualmente são mais longos que os produzidos pelo computador. Esse fato está relacionado à capacidade que os humanos tem de perceber a tarefa a frente de maneira abstrata. Nós somos capazes de dar um passo atrás, ver a imagem como um todo e conectar cristas de montanhas e vales que estão alinhados em um único lineamento. Computadores, por outro lado, até agora, não são capazes disso. Eles trabalham localmente, desenhando lineamentos mais curtos. Os diagramas de roseta mostram que as direções não variam significativamente pelas diferentes versões, mantendo uma direção média em torno de 32°.

Figura 26: V1 a V4 são versões produzidas pelo autor, STD foi produzida por uma estudante e M22 e M30 são o resultado obtido pelo computador. a) Índice de Jaccard mostrando a similaridade entre as versões; b) número de lineamentos que não se repetem em outras versões, um indicativo de baixa consistência.



Fonte: O autor, 2023.

Figura 27 - Diagramas de caixa mostrando as distribuições dos comprimentos dos lineamentos e diagramas de roseta mostrando suas direções.

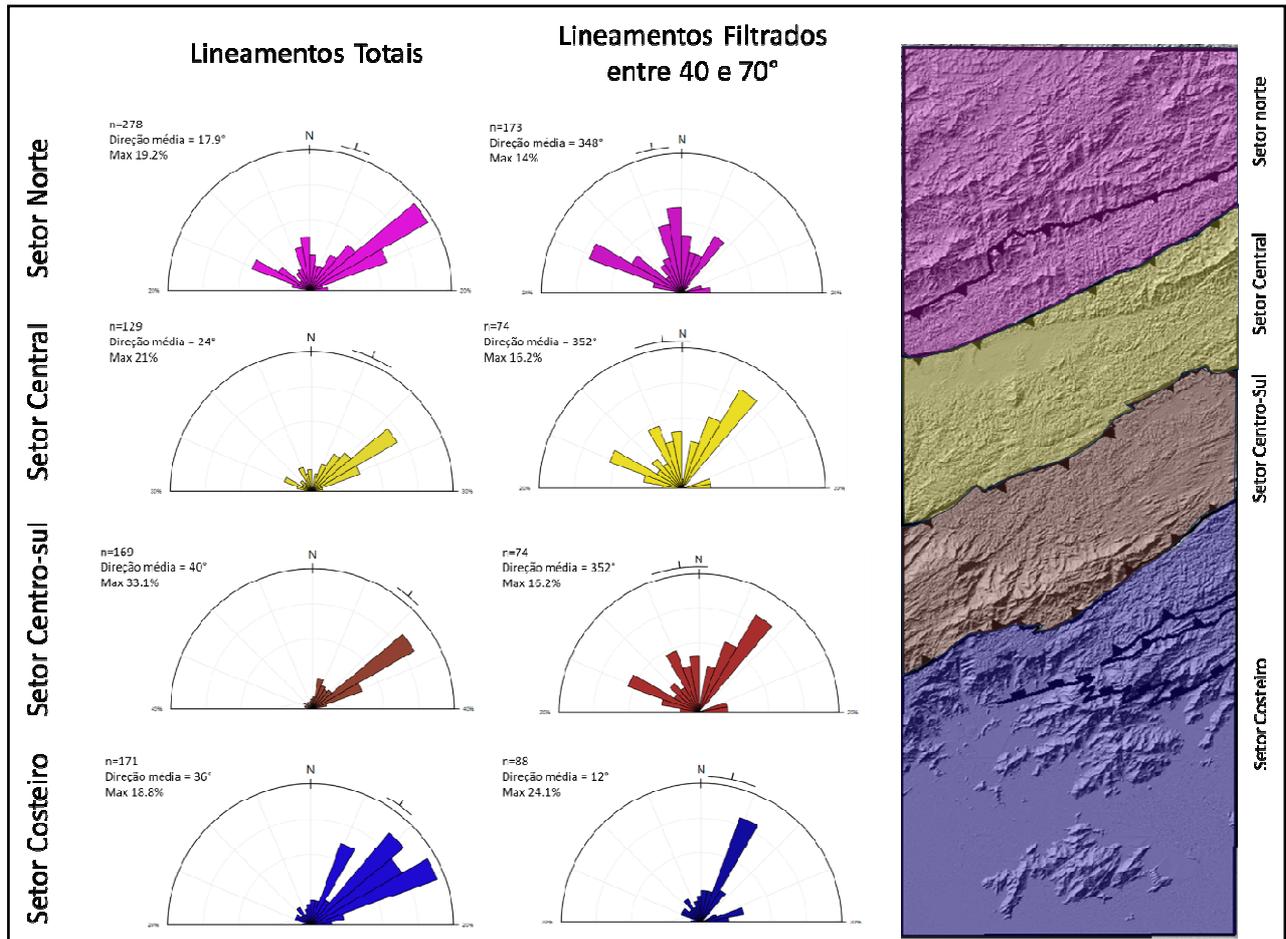


Fonte: O autor, 2023.

9.1 Manipulação dos dados obtidos manualmente

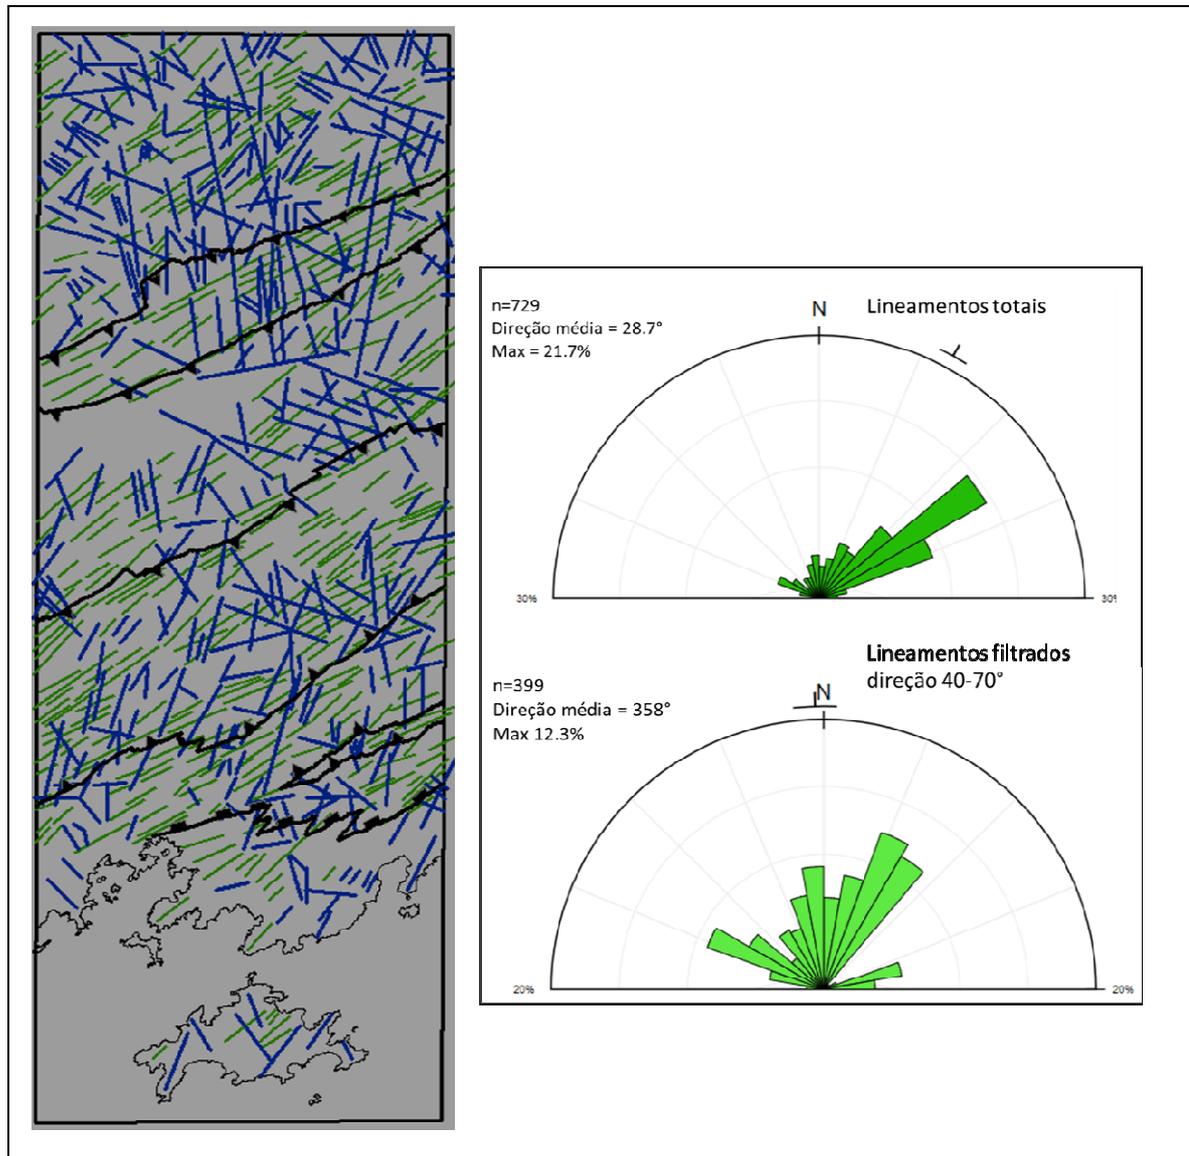
A porção setentrional da área estudada contém um corredor de lineamentos de direção NNW denominado Feixe de Lineamentos Andrelândia Barra Mansa (FLAMB). Com o intuito de tornar mais evidente as direções do FLAMB, fez-se uma filtragem dos lineamentos obtidos na primeira rodada de interpretações (V1), retirando aqueles com direção entre N40 e N70 que constituem a tendência geral da Faixa Ribeira central. Os resultados são mostrados na figura 29, onde os lineamentos são agrupados de acordo com os mesmos critérios de setorização dos diques. Nota-se a influência do FLAMB de direção N-S no setor norte e subordinadamente nos setores central e centro-sul. O setor costeiro ainda apresenta uma forte influência do *trend* NE da Faixa Ribeira. Na figura 29 observa-se os lineamentos que foram retirados, pondo em evidência o conjunto de lineamentos N-S que compõe o FLAMB e da direção WNW.

Figura 28 - Lineamentos V1 divididos por setores e filtrados entre 40° e 70°. As rosetas filtradas mostram a influência do FLAMB no setor norte, e uma influência menor nos setores central e centro-sul



Fonte: O autor, 2023.

Figura 29 - Lineamentos V1. Em verde os lineamentos que foram retirados da análise por comporem o *trend* geral da Faixa Ribeira



Fonte: O autor, 2023.

9.1.2 Hipótese sobre controle da direção dos lineamentos:

Na área de estudo ocorrem 40 tipos litológicos catalogados em campanhas de mapeamento, o que reflete o avançado nível de detalhamento. No entanto, se faz necessário o agrupamento dessas unidades para que seja possível formular hipóteses.

As mudanças de reologia associadas ao conteúdo e conectividade de minerais micáceos foram investigadas por Shea et al. (1993) que observou tendências de diminuição de resistência, aumento de anisotropia e aumento de ductibilidade com o aumento de conteúdo de micas em corpos de prova.

Assim formulamos a seguinte hipótese: Unidades litológicas com um maior conteúdo de minerais micáceos devem acomodar a deformação de maneira distinta daquelas unidades com menor teor de minerais micáceos. Esses minerais apresentam um plano de clivagem bem definido que, quando alinhados de forma planar, formam zonas de descontinuidade que oferece menor resistência aos esforços cisalhantes. Além disso, filossilicatos têm H₂O em sua estrutura cristalina que, quando mobilizada, contribui para um aumento dos fluidos percolantes, o que favorece a acomodação da deformação de forma plástica, dúctil.

Enquanto as rochas com baixo teor de mica e matriz predominantemente quartzo-feldspática, deveriam responder aos esforços de maneira mais rúptil. Assim, é esperado diferentes estilos deformacionais, diferentes respostas ao *emplacement* de diques e diferentes orientações de lineamentos.

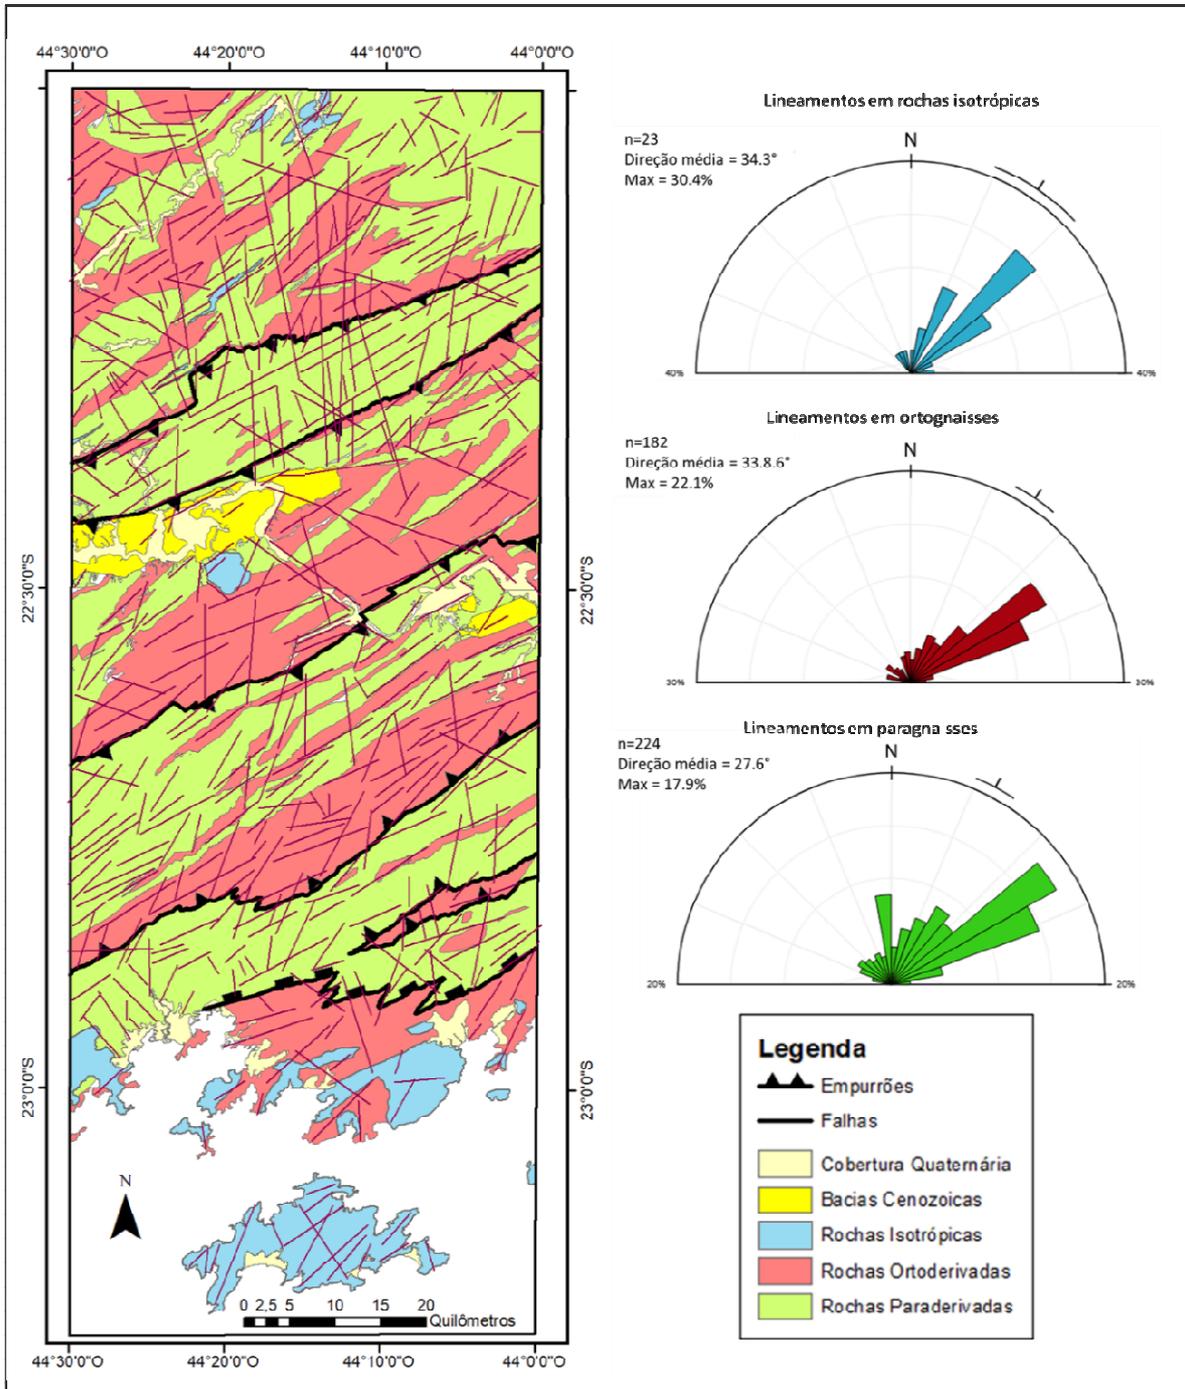
Desta maneira decidimos agrupar as unidades litológicas em quatro associações:

- a) Paraderivadas: Gnaisses metassedimentares tipicamente bandados com um conteúdo de micas relativamente alto. Podem conter também silimanita e granada;
- b) Ortoderivadas: Gnaisses cujo protólito são rochas ígneas, são bandadas e contém tipicamente um conteúdo de micas menor que as paraderivadas;
- c) Rochas isotrópicas: São rochas de formação tardia, tardi ou pós-colisionais. Não são necessariamente isentas de estruturas internas penetrativas, mas não apresentam bandamento, ou xistosidade marcante;
- d) Bacias cenozoicas: Bacias de Resende e Volta Redonda.

Para testar a hipótese de que a composição e textura das rochas deveria controlar as direções dos lineamentos, agrupou-se os lineamentos por associação litológica, da segunda rodada de extração manual (v2) (figuras 30).

A análise visual e dos diagramas de roseta mostra que não há mudança significativa entre as diferentes associações e, portanto, a hipótese é falsa. Isso sugere que os lineamentos anotados nos dados SRTM são representativos não de falhas e juntas, como definido por Hobbs (1904), mas sim das foliações e contatos entre litologias que por vezes ocorre em zonas de sutura ou cisalhamento.

Figura 30 - lineamentos da segunda rodada (V2), e as direções dos lineamentos por associação litológica. A composição geral das rochas não parece controlar as direções dos lineamentos



.Fonte: O autor, 2023.

9.2 Resultados obtidos pela RNCP:

A seguir apresentamos os resultados obtidos em 7 dos 30 modelos testados em que a sensibilidade de cada hiperparâmetro foi testada à base de tentativa e erro. As tabelas contêm os valores testados, os gráficos mostram os valores da função custo nos dados de treinamento e validação e a direita as métricas IoU (índice de similaridade de Jaccard ou interseção/união) e acurácia. A porcentagem de *tiles* (azulejos) se refere ao número total de tiles possíveis, quando o paço é igual a 1. Note que o número de tiles (n) decresce com o quadrado do paço (s).

Equação 7: Número de tiles (n) carregados dado o paço da convolução.

Descreve o número de tiles de tamanho (T) que podem ser extraídos de uma imagem com (C) colunas e (R) linhas de pixels e carregadas para treino validação dado o paço (s).

$$n = \left[\text{floor} \left(\frac{C - T}{s} \right) + 1 \right] \times \left[\text{floor} \left(\frac{R - T}{s} \right) + 1 \right]$$

Figura 31 - O modelo 1 apresentou uma boa convergência da função custo nos dados de treinamento, mas apresentou oscilação de alta amplitude das outras métricas. O resultado é ruim

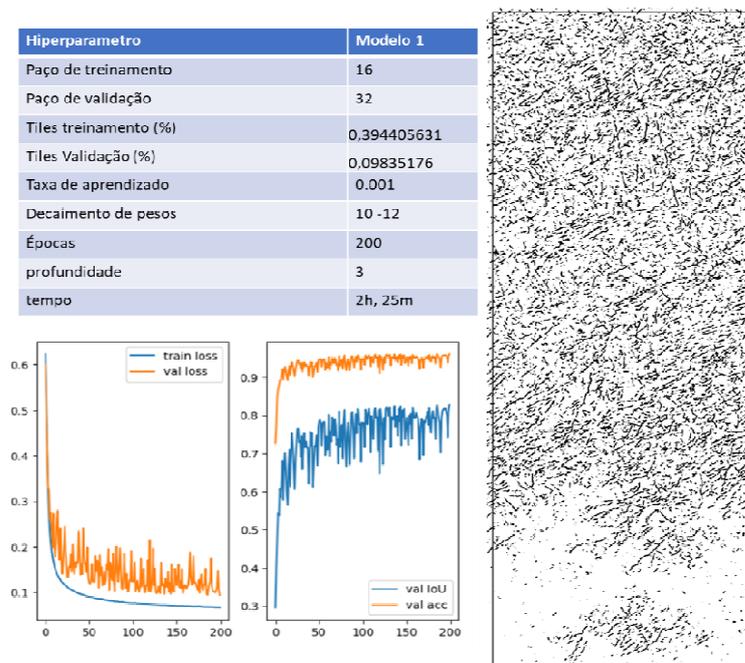
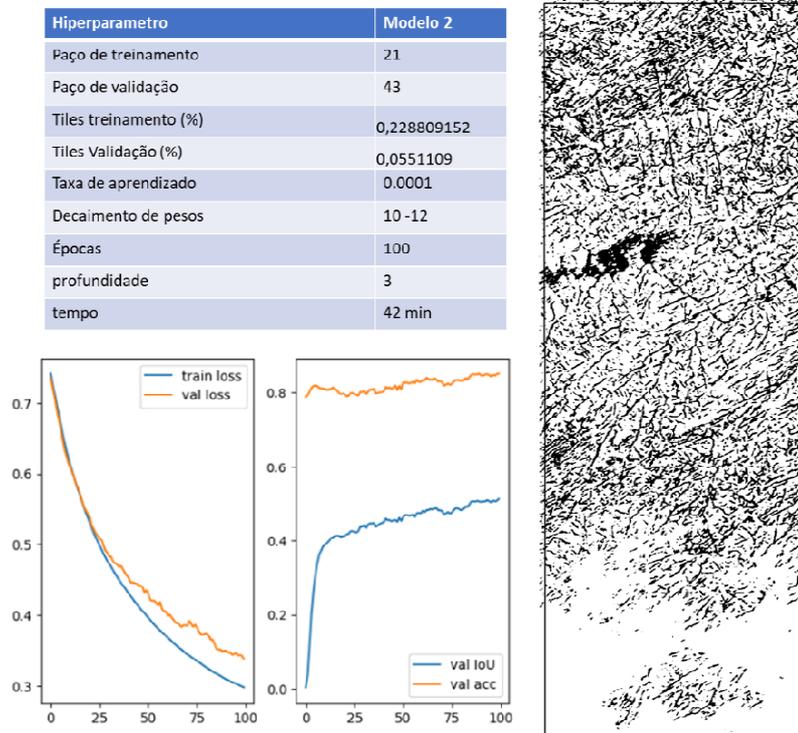
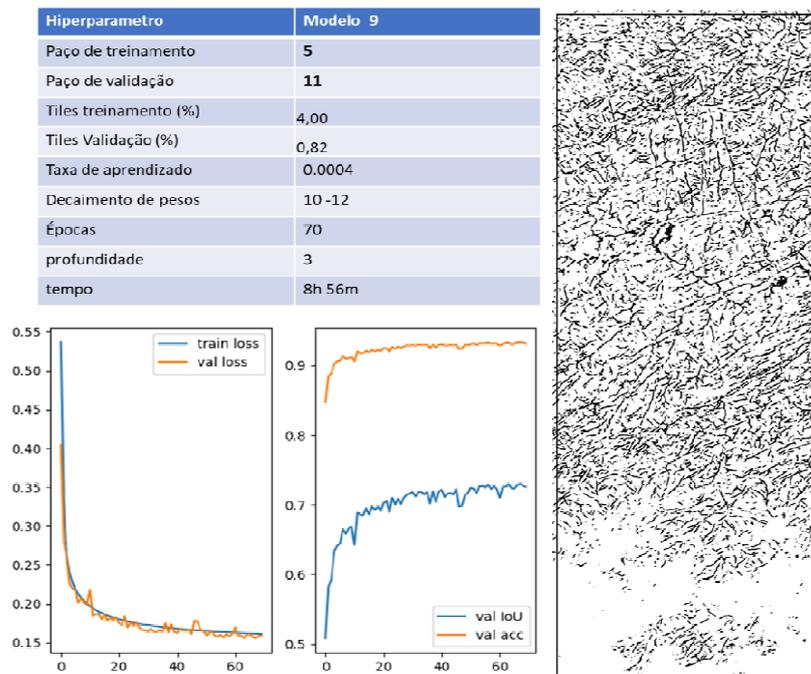


Figura 32 - No modelo 2 diminuiu-se a taxa de aprendizado em 10 vezes, o que resolveu a oscilação, mas não estabilizou a função custo. Mais épocas são necessárias. O resultado é mediano.



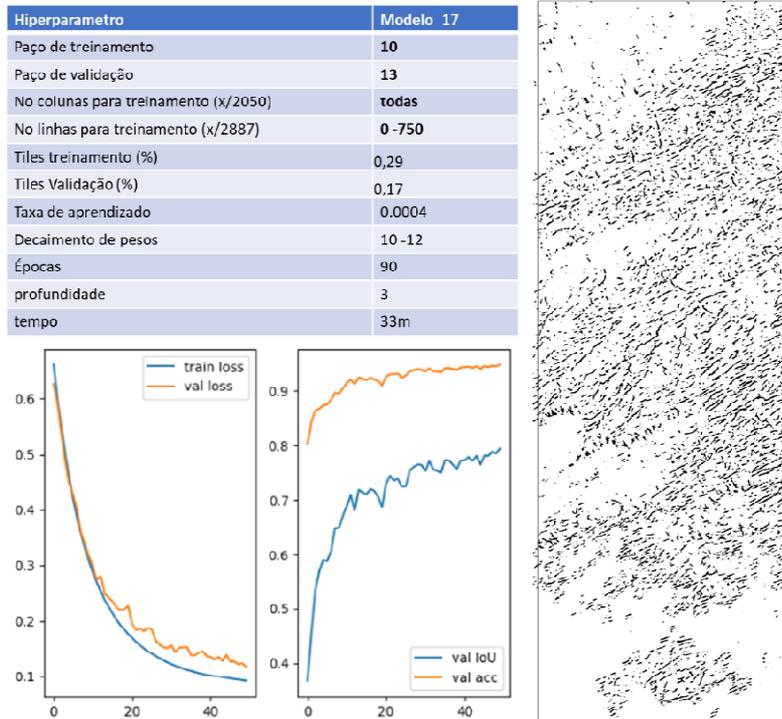
Fonte: O autor, 2023.

Figura 33 - No modelo 9 testou-se aumentar o conjunto de dados de treinamento para 4%, a um alto custo computacional (quase 9 horas) e um resultado mediano. Um grande conjunto de dados de treinamento não necessariamente retorna bons resultados.



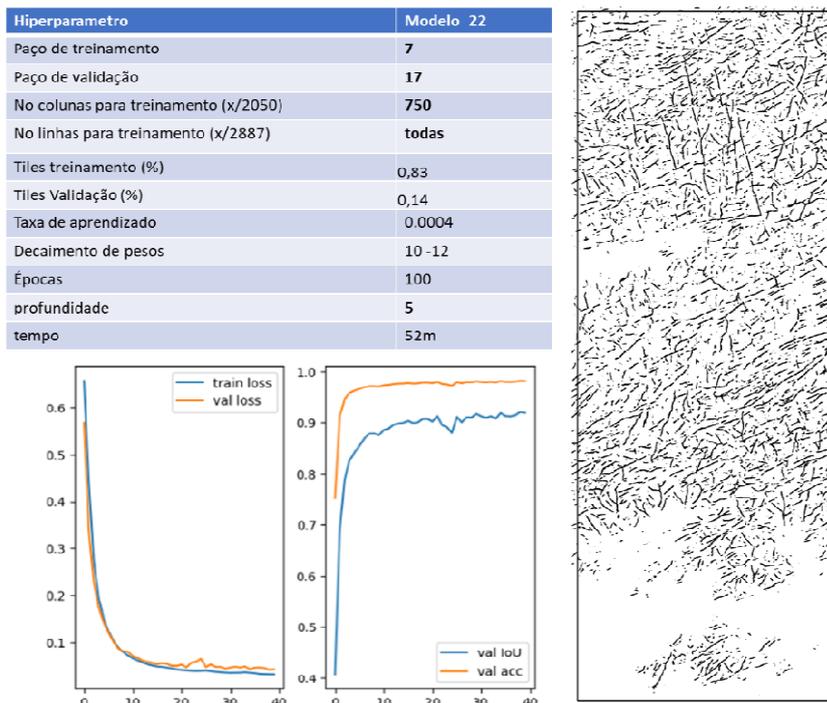
Fonte: O autor, 2023.

Figura 34 - No modelo 17 testou-se restringir a área da imagem de treinamento. Das 2887 linhas de pixels fornecemos 750. Resultado foi ruim



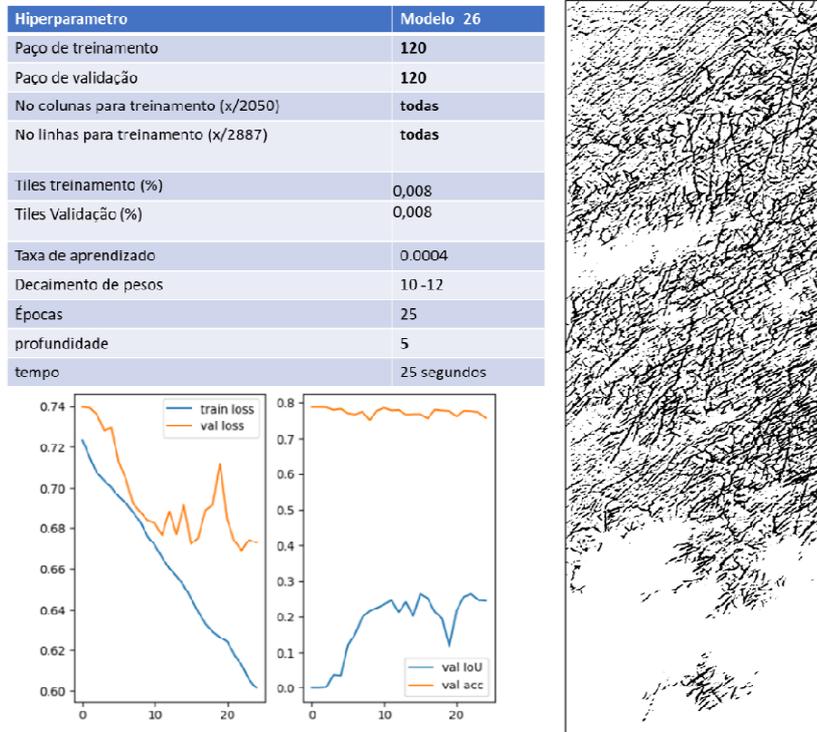
. Fonte: O autor, 2023.

Figura 35 - No modelo 22 aumentou-se o conjunto de dados diminuindo o paço para 7, e aumentou-se a profundidade da U-net para 5, o que resultou em uma imagem menos ruidosa. Resultado bom.



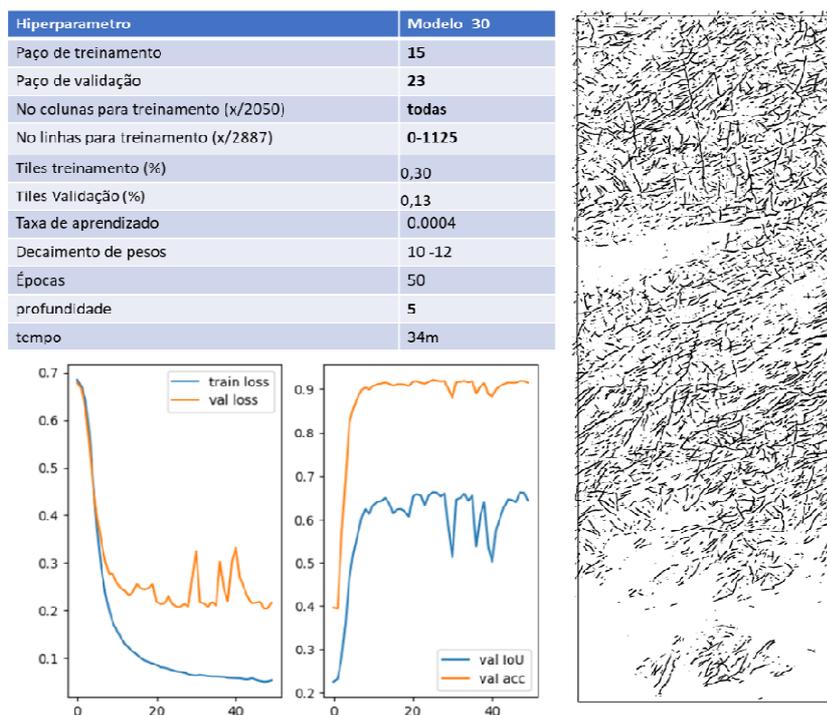
Fonte: O autor, 2023.

Figura 36: No modelo 26 testou-se hiperparâmetros para um treinamento expedito, em 25 segundos. Mesmo com poucos dados de treinamento o resultado mostra que as principais feições foram capturadas.



Fonte: O autor, 2023.

Figura 37: No modelo 30 excluiu-se um corredor de lineamentos ao norte da área de treinamento, visando eliminar esse viés. Apesar de algumas métricas apresentarem valores intermediários, o resultado pode ser considerado bom.



Fonte: O autor, 2023.

No total 30 modelos foram testados, nos quais os hiperparâmetros da RNCP foram variados e sistematicamente testados, em um processo de tentativa e erro que moldaram as imagens de saída para os resultados desejados.

O modelo 1 mostrou variações de alta amplitude nas métricas de treinamento e validação, o que foi resolvido baixando-se a taxa de aprendizado (modelo 2), de tal modo que os valores de validação pudessem convergir suavemente para as regiões mais baixas da função custo. O ponto negativo é que o modelo demorou mais para completar seu treinamento, já que mais épocas foram necessárias para estabilização. Em seguida a quantidade de dados usados no treinamento foi aumentada para 4% do total de azulejos disponíveis, em um modelo que levou cerca de 9 horas para ser treinado (modelo 9). A inspeção visual mostrou que não houve ganhos significativos em relação a outros modelos treinados com menos dados. No modelo 17 testou-se restringir a área de treinamento no dado controle e apesar de ter sido treinado em um tempo adequado, 33 minutos, o resultado ainda foi pobre. No modelo 22 aumentou-se a profundidade da RNCP de 3 para 5 e isso resultou em imagens menos ruidosas e melhores lineamentos, por razões não totalmente conhecidas.

Esse é, de fato, um processo de tentativa e erro. Profundidades maiores foram tentadas, sem êxito. O modelo 22 foi considerado o melhor em termos de inspeção visual. A figura 23 mostra o fluxo de trabalho esquemático do modelo 22 com seus hiperparâmetros e métricas. O modelo 26 testou um treinamento expedito, em apenas 25 segundos. O resultado é surpreendente, pois apesar de ruidoso, o modelo capturou muito bem as tendências gerais do dado. Por último, o modelo 30 foi treinado em uma área restrita da área controle, excluindo o corredor de lineamentos de direção NEE na porção norte (ver figura 22b). O resultado foi bom, indicando que os lineamentos pouco espaçados podem estar introduzindo uma tendência, ou viés, indesejados.

10 CONTEXTUALIZAÇÃO DO TRABALHO E DISCUSSÕES

10.1 Trabalhos anteriores

O uso de RNCPs tem crescido em soluções para problemas de classificação de imagens. Trabalhos anteriores mostram que, no campo das geociências, RNCPs têm o potencial de reduzir drasticamente o tempo empregado na interpretação de dados que podem ser dispostos como imagens, como por exemplo: dados sísmicos, gravimétricos, magnetométricos, multiespectrais, fotografias de afloramentos, seções delgadas e modelos digitais de elevação.

Yu et al. (2021) empregou RNCPs para extrair planos de falhas de dados sísmicos 3D e atingiu performances comparáveis à interpretação de experts humanos, além de reduzir o tempo envolvido, de meses, para horas. Haslebacher et al. (2023) as utilizou para identificar e classificar feições lineares na superfície congelada do satélite natural de Júpiter, Europa. Em seu trabalho afirma-se que um intérprete treinado e focado levou 4 horas para mapear 260 feições em um conjunto de dados que cobre menos de 0.1% da superfície de Europa. A esse passo, seriam necessários cerca de 500 dias, trabalhando 8 horas por dia sem perder o foco para mapear toda a superfície. Uma rede neural composta de camadas convolucionais e outras totalmente conectadas, treinada em 5.2 horas devolveu resultados satisfatórios em minutos, embora seja difícil avaliar o tempo envolvido na construção, teste e controle de qualidade. Essa tecnologia também pode ser usada para classificar estruturas geológicas. Zhang et al. (2018) testou modelos de aprendizado profundo para classificar fotografias de campo em estruturas como: anticlinal, dobras ptigmáticas, ripples, falhas, *boudins* entre outros, treinados com um conjunto de 2206 imagens anotadas e seu modelo atingiu 90% de acurácia.

10.2 Viabilidade de aplicação das RNCPs

A aplicação dessa tecnologia, sem dúvida, representa um divisor de águas na maneira como geocientistas processam e extraem informações de imagens, principalmente em termos da escala em que isso se tornou possível. Há, contudo, limitações associadas a esse método.

Para que a máquina possa “aprender” a realizar tarefas, como a de classificação de imagens, é preciso fornecer um número adequado de exemplos já classificados e a máquina se encarregará de estabelecer relações entre o conjunto de entrada e o de saída e por fim, será capaz de generalizar o problema.

A qualidade dos resultados obtidos está diretamente relacionada ao conjunto de dados de treinamento que deve conter a essência do problema, assim como exceções e não conter exemplos errôneos que podem ser perpetuados. O conjunto de dados de treinamento deve ser um repositório do conhecimento acumulado sobre a tarefa a ser realizada e nesse contexto, dados os limites razoáveis, a qualidade é mais importante que a quantidade. Essa afirmação pode ser exemplificada pelos modelos 9 e 26: O modelo 9 usou 5000 vezes mais dados para seu treinamento que demorou mais de 1000 vezes mais tempo. Os resultados, no entanto, não são muito diferentes (figuras 33 e 36). Feng et al. (2019) mostra que apesar da aplicação de grandes conjuntos de dados de boa qualidade, o que raramente está disponível, ser a solução ótima, o uso de RNCPs pré-treinadas e refinadas com um pequeno conjunto de treinamento é uma escolha razoável.

Ademais, a tarefa de criar (ou adaptar) uma RNCP, criar o conjunto de dados de treinamento, determinar bons hiperparâmetros e treinar a rede, pode ser extremamente demorado. Por isso é importante dimensionar corretamente a tarefa a ser executada antes de se optar por essa tecnologia. Para casos em que não há dados anotados disponíveis, outros métodos são mais adequados. Farahbakhsh et al. (2018) propõem um fluxo de trabalho que utiliza métodos como análise da componente principal (PCA em inglês), filtros adaptativos e convolucionais e atributos de detecção de borda para extrair lineamentos sem a aplicação de redes neurais. E no caso em que não há tecnologia disponível e o tamanho do conjunto de imagens permitir, a extração manual de lineamentos com bons critérios de interpretação com algumas repetições é, sem dúvida, o método mais indicado.

CONSIDERAÇÕES FINAIS

Neste trabalho nós comparamos os resultados de lineamentos topográficos extraídos repetidamente de modelos digitais de elevação feitos por pessoas e por computadores que utilizam redes neurais convolucionais profundas com arquitetura U-Net.

O processo de interpretação, embora essencial para a incorporação de dados, é subjetivo e não há uma resposta certa com que nossos resultados possam ser comparados, então foram criadas cinco versões de interpretação realizadas na área de estudo (quatro feitas pelo autor, V1 a V4 e uma feita por uma estudante do primeiro ano em geociências, STD), de modo a quantificar a repetibilidade dos resultados e, por consequência, sua robustez (Mabee et al. 1994). Para isso, agrupamos os resultados obtidos por interpretação manual e por RNCPs dois a dois e calculamos o índice de similaridade de Jaccard, além de contar lineamentos que não se repetem em outras versões e têm, portanto, baixa consistência.

A interpretação manual está sujeita a vieses intrínsecos, como a mudança de critérios durante a interpretação, motivação variável ao longo do trabalho, fatores ligados à qualidade da visão individual, lesões provocadas por esforço repetitivo, modelo evolutivo adotado e quando parar. Para mitigar esses fatores é importante que os critérios de mapeamento estejam bem definidos antes do início da interpretação. Para melhores resultados a interpretação deve ser repetida algum tempo depois, mesmo que em uma pequena parte dos dados e idealmente por outras pessoas. Isso induz uma maior repetibilidade e confiabilidade, mesmo que não torne o resultado livre de vieses humanos.

Os resultados das extrações manuais mostram a mudança nos critérios de interpretação. As primeiras versões tenderam a capturar mais lineamentos que frequentemente não se repetiram nas versões subsequentes. Ao longo das interpretações o número de lineamentos diminuiu e a similaridade entre versões aumentou.

A experiência prévia não se apresentou como um viés significativo no problema abordado. Os lineamentos obtidos por uma estudante do primeiro ano (STD) capturaram satisfatoriamente os lineamentos na área estudada, apesar de ter anotado falsos positivos, como a marca de junção entre duas imagens.

A maior similaridade entre interpretações manuais e modelos gerados por computador foi entre M22 e V3. Isso sugere que a última versão manual (V4) pode ter ficado minimalista e deixado de fora lineamentos de 1ª ordem. O excesso de versões feitas por um humano

também pode atrapalhar, já que o trabalho repetitivo pode comprometer a motivação do operador.

A tecnologia de RNCP tem um enorme potencial de reduzir a subjetividade envolvida no processo. Mesmo realizado a extração de lineamentos de forma manual, o intérprete pode consultar a classificação realizada por RNCPs e tirar proveito dela para aprimorar seus próprios critérios. E no caso de um modelo já treinado e feito um controle de qualidade, a classificação de imagens se dá em poucos segundos. Os resultados obtidos nesse trabalho são, no entanto, ruidosos (contém falsos positivos) e inconsistentes (contém falsos negativos). É possível aperfeiçoar a RNCP com mais testes de tentativa e erro, fazendo ajustes finos dos hiperparâmetros e com pré e pós condicionamentos das imagens. Esse modelo especializado, no entanto, provavelmente responderia com maus resultados em um conjunto de dados de entrada diferentes, ou para um problema ligeiramente diferente. Por exemplo, a extração de lineamentos em uma área com outras texturas, ou se desejássemos obter apenas lineamentos de vales. Infelizmente o tempo necessário para a aprimoração da RNCP excederia o escopo desta dissertação.

O uso de RNCP exclui não a necessidade de interpretação manual em uma parte dos dados que serão usados para o treinamento da rede. Nessa etapa o intérprete deve depositar todo seu conhecimento sobre o modelo evolutivo formador de lineamentos e suas sutilezas. A qualidade dos dados de treinamento influencia diretamente o resultado das previsões feitas pelo computador.

As RNCPs podem reduzir drasticamente o tempo envolvido na interpretação de lineamentos em dados de MDE, no entanto, o tempo usado na escrita do código (ou adaptação de um já existente), pré-processamento dos dados, teste de hiperparâmetros e controle de qualidade pode anular o ganho de tempo com o emprego da tecnologia.

Sendo assim, conclui-se que o uso de RNCPs é adequado para a obtenção de lineamentos em grandes conjuntos de dados, em que a interpretação manual seja impraticável, ou exponha o intérprete ao risco de lesão por esforço repetitivo (LER). Para pequenos conjuntos de dados, a interpretação manual com rigorosos critérios estabelecidos e algumas repetições é a opção mais recomendada.

Quanto a hipótese de que o conteúdo de mica das rochas controlaria a ocorrência de lineamentos, as evidências mostram que não. As direções dos lineamentos não mudam significativamente nas rochas paraderivadas, ortoderivadas e isotrópicas. Não obtivemos informações sobre o conteúdo global de micas nas rochas da área de estudo. Como tanto rochas ortoderivadas e paraderivadas são gnaisses com mica, é possível que haja variações

desse mineral dentro das próprias associações litológicas, e o contraste entre elas não seja expressivo. Novos agrupamentos podem mostrar um eventual controle.

Humanos são imensamente versáteis. Podemos nos adaptar rapidamente para executar tarefas complexas cooperativamente. Os computadores, até agora, são capazes apenas de imitar nossas habilidades, ainda assim depois de muitas e muitas linhas de comando.

REFERÊNCIAS

- Almeida, F.F.M. 1967. Origem e evolução da plataforma brasileira. DNPM. Div. Geol. Min., bol. 241. 36 p.
- Almeida, F.F.M. 1976. The system of continental rifts bordering the Santos Basin, Brazil. *Anais da Academia Brasileira Ciências*, 48:15-26.
- Almeida F.F.M., Hasui Y., Brito Neves, B.B, Fuck, R.A. 1977. As províncias estruturais do Brasil. In: SBG, Simp. Geol. Nordeste, 8, Bol. Esp., 12p.
- Almeida F.F.M., Hasui Y., Brito Neves, B.B, Fuck, R.A. 1981. Brazilian Structural Provinces: an introduction. *Earth Sciences Rev.*, 7817: 1-29
- Almeida J.C.H, Dios F.B., Mohriak, W.U., Valeriano, C., Heilbron, M., Eirado, L.G., Tomazzoli, E. 2013. Pre-rift tectonic scenario of the Eo-Cretaceous Gondwana break-up along SE Brazil – SW Africa insights from Tholeiitic mafic dykes swarms. *Geological Society, London. Special Publications*, v.369, p.11-40.
- Almeida J., Dios, F., Mohriak, W.U., Valeriano, C.D.M., Heilbron, M., Eirado, L.G., Tomazzoli, E., 2013. Pre-rift tectonic scenario of the eo-cretaceous Gondwana break-up along SE Brazil-SW Africa: insights from tholeiitic mafic dyke swarms. *Geol. Soc. Spec. Publ.* 369, 11–40. <https://doi.org/10.1144/SP369.24>.
- Aghaee A., Shamsipour P., Hood S., Rasmus Haugaard, 2021. A convolutional neural network for semi-automated lineament detection and vectorisation of remote sensing data using probabilistic clustering: A method and a challenge, *Computers & Geosciences*, Volume 151, 2021, 104724, ISSN 0098-3004, <https://doi.org/10.1016/j.cageo.104724>.
- Baskin C., Liss N., Mendelson A., Zheltonozhskii E.2017. Streaming Architecture for Large-Scale Quantized Neural Networks on an FPGA-Based Dataflow Platform.
- Clark S.F., Jr., Moore, R.B., Ferguson, E.W., and Picard, M.Z., 1996, Criteria and Methods for Fracture-Trace Analysis of the New Hampshire Bedrock Aquifer: U.S. Geological Survey Open-File Report 96–479, 12 p.
- Cogné, N., Cobbold, P., Riccomini, C., Gallagher, K., 2013. Tectonic setting of the Taubaté Basin (Southeastern Brazil): Insights from regional seismic profiles and outcrop data, *Journal of South American Earth Sciences*, Volume 42, Pages 194-204, ISSN 0895-9811, <https://doi.org/10.1016/j.jsames.2012.09.011>.
- Du G., Cao X., Liang J., Chen X., Zhan Y., 2020. Medical Image Segmentation based on U-Net: A Review. *Journal of Imaging Science and Technology*. 64. 10.2352/J.Imaging Sci.Technol.2020.64.2.020508.

Farahbakhsh, E., Chandra, R., Olierook, H.K.H., Scalzo, R., Clark, C., Reddy, S.M., Müller, R. D., 2018. Computer vision-based framework for extracting geological lineaments from optical remote sensing data.

Feng S., Zhou H., Dong H., 2019. Using deep neural network with small dataset to predict material defects, *Materials & Design*, Volume 162, , Pages 300-310, ISSN 0264-1275, <https://doi.org/10.1016/j.matdes.2018.11.060>.

Freitas, N.C., Almeida, J., Heilbron, M., Cutts, K., Dussin, I., The Cabo Frio Thrust: a folded suture zone, Ribeira belt, SE Brazil, *Journal of Structural Geology*, <https://doi.org/10.1016/j.jsg.2021.104379>.

Fletcher S., Islam, M. Z. 2018. Comparing sets of patterns with the Jaccard index. *Australasian Journal of Information Systems*, 22. <https://doi.org/10.3127/ajis.v22i0.1538>

Goldstein A., Marshak S., 1988. Analysis of fracture array geometry. *Basic Methods of Structural Geology* 249–268.

Guedes E., Heilbron M., Morisson Valeriano, C., Almeida J.C.H., Szatmari P., 2016. Evidence of Gondwana early rifting process recorded by Resende-ilha Grande dike swarm, southern Rio de Janeiro, Brazil. *J. South Am. Earth Sci.* 67, 11–24. <https://doi.org/10.1016/j.jsames.2016.01.004>.

Guedes E., Heilbron M., Vasconcelos P. M., Valeriano C. M., Almeida J. C. H., Teixeira W. & Thomaz Filho A. 2005. K/Ar and 40Ar/39Ar ages of dikes emplaced in the onshore basement of the Santos Basin (Resende Area, SE-Brazil): implications for South Atlantic opening and tertiary reactivation. *South American Journal of Earth Sciences*, 18, 371–382.

Haslebacher C., Thomas N., Bickel V.T. 2023 LineMapper: A deep learning-powered tool for mapping linear surface features on Europa. *Icarus*, doi: <https://doi.org/10.1016/j.icarus.2023.115722>.

Hassanein, A., S., Mohammad, S., Sameer, M., Ragab, M. E. 2015. A Survey on Hough Transform, Theory, Techniques and Applications. <https://doi.org/10.48550/arXiv.1502.02160>

Heilbron M., do Eirado L.G., Almeida J., 2016. *Geologia e Recursos Minerais do Estado do Rio de Janeiro: texto explicativo do mapa geológico e de recursos minerais*. Belo Horizonte, CPRM, 2016. In: 01 mapa geológico, escala 1:400.000 e 01 mapa de recursos minerais, escala 1:400.000 (Série Programa de Geologia do Brasil, PGB, Coleção Mapas Geológicos Estaduais)

Heilbron M., Valeriano C.M. Valladares C.S., Machado, N. 1995. A Orogênese Brasileira no segmento central da Faixa Ribeira, Brasil, *Revista Brasileira de Geociências*, 25(4): 249-266.

Heilbron M., Mohriak, W., Valeriano C.M., Milani E., Almeida J.C.H., Tupinambá, M. 2000. From collision to extension: the roots of the southeastern continental margin of Brazil. In: Talwani and Mohriak (Eds) *Atlantic Rifts and Continental Margins*, *America Geophysical Union, Geophysical Monograph Series*, v. 115:1-34

Heilbron M., Valeriano C.M., Peixoto C., Tupinambá M., Neubauer F., Dussin I., Corrales F., Bruno H., Lobato M., Almeida J.C.H., Eirado-Silva L.G., 2020. Neoproterozoic magmatic arc systems of the central Ribeira belt, SE-Brazil, in the context of the West-Gondwana pre-collisional history: A review, *Journal of South American Earth Sciences*, Volume 103, 2020, 102710, ISSN 0895-9811, <https://doi.org/10.1016/j.jsames.2020.102710>.

Heilbron M., Silva L.G.E., Almeida J.C.H., Tupinambá M., Peixoto C., Valeriano C.M., Lobato M., Rodrigues S.W.O., Ragatky C.D., Silva M.A., Monteiro T., Freitas N.C.D., Miguens D., Girão R., 2020. Proterozoic to Ordovician geology and tectonic evolution of Rio de Janeiro State, SE-Brazil: insights on the central Ribeira Orogen from the new 1:400,000 scale geologic map. *Brazilian Journal of Geology* 50, p. 1-25. <https://doi.org/10.1590/2317-4889202020190099>

Hobbs, Lineaments of the Atlantic Border region. *GSA Bulletin* 1904; 15 (1): 483–506. doi: <https://doi.org/10.1130/GSAB-15-483>

Jordan G. 2005. Extraction of morphotectonic features from DEMs: Development and applications for study areas in Hungary and NW Greece.

Kovács Z. L. 2006. *Redes neurais artificiais*. Editora Livraria da Física.

Mabee S.B., Kenneth C.H., Donald U. Wise, D.U., 1994. A method of collecting and analyzing lineaments for regional scale fractured bedrock aquifer studies. *Groundwater* 32 (6): 884-894. <https://doi.org/10.1111/j.1745-6584.1994.tb00928.x>.

McCulloch W.S., Pitts W. 1943. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, Vol 5, pp 115-133. Reprinted in Anderson & Rosenfeld, 1988, pp 18-28.

Mancini L. H., Bonotto D. M. 2021. Contribuição dos isótopos naturais de urânio no estudo da movimentação das águas subterrâneas. *Derbyana*, 42. <https://doi.org/10.14295/derb.v42.746>

Ramachandran P., Zoph B., Le Q. , 2017. Searching for Activation Functions, *Neural and Evolutionary Computing* , doi: doi.org/10.48550/arXiv.1710.05941

Ramli M.F., Yusof N., Yusoff M.K. et al. 2010. Lineament mapping and its application in landslide hazard assessment: a review. *Bull Eng Geol Environ* 69, 215–233. <https://doi.org/10.1007/s10064-009-0255-5>

Rasamoelina A. D., Adjailia F., Sinčák P. 2020. A review of activation function for artificial neural network. In *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)* (pp. 281-286). IEEE.

Riccomini C., L. G. Sant'Anna A. L., Ferrari. 2004. Evolução geológica do rift continental do sudeste do Brasil. Pp. 383-405. In: Mantesso-Neto, V., A. Bartorelli, C. D. R. Carneiro & B. B. Brito-Neves (Eds.). *Geologia do continente Sul-Americano: Evolução da obra de Fernando Flávio Marques de Almeida*. São Paulo, Editora Beca, 673p.

Sharma S., Sharma S., Athaiya, A. 2017. Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.

Shea W. T., Kronenberg A. K., 1993. Strength and anisotropy of foliated rocks with varied mica contents, *Journal of Structural Geology*, Volume 15, Issues 9–10, , Pages 1097-1121, ISSN 0191-8141, [https://doi.org/10.1016/0191-8141\(93\)90158-7](https://doi.org/10.1016/0191-8141(93)90158-7).

Siddique N., Paheding S., Elkin C. P., Devabhaktuni V., 2021. U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications, in *IEEE Access*, vol. 9, pp. 82031-82057, , doi: 10.1109/ACCESS.2021.3086020.

Sudre, C.H., Li, W., Vercauteren, T., Ourselin, S., Jorge Cardoso, M. 2017. Generalised Dice Overlap as a Deep Learning Loss Function for Highly Unbalanced Segmentations. In: Cardoso, M., et al. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support . DLMIA ML-CDS 2017 2017*. Lecture Notes in Computer Science, vol 10553. Springer, Cham. https://doi.org/10.1007/978-3-319-67558-9_28