


O SENSORIAMENTO REMOTO E OS RISCOS NATURAIS E AMBIENTAIS



Iran Carlos Stalliviere Corrêa
CECO/DGEOD/IGEO/UFRGS

Imagem da capa: Web Mapa de Movimentos de Solo da região do rio Taquari, município de Cotiporã-RS, para equipes de apoio na situação de calamidade - RS - maio de 2024. (Imagens cedidas pela National Geospatial-Intelligence Agency – NGA / Diretoria de Serviço Geográfico–DSG / Maxar Technologies 2024, Força Aérea do Chile e Força Aérea Brasileira. Fonte: EROS C e BlackSky).
Realização: Laboratório Latitude - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM) / Programa de Pós-graduação em Sensoriamento Remoto (PPGSR) / Departamento de Geodésia (DEGEO) / Instituto de Geociências (IGEO) / Universidade Federal do Rio Grande do Sul (UFRGS).

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

INSTITUTO DE GEOCIÊNCIAS

CENTRO DE ESTUDOS DE GEOLOGIA COSTEIRA E OCEÂNICA

DEPARTAMENTO DE GEODÉSIA




Imagem de terremoto em South Napa, Califórnia ocorrido em agosto de 2014. A foto mostra um interferograma obtido pela combinação de registros feitos por satélites, mostrando as alterações que aconteceram no solo durante o terremoto. Um único ciclo de cor representa cerca de meia polegada de deslocamento da superfície.

(fonte: https://media.wired.com/photos/59372ab6a88f414d9a8cc4f3/master/w_2560%2Cc_limit/Napa_Valley_quake.jpeg)

***O SENSORIAMENTO REMOTO E OS
RISCOS NATURAIS E AMBIENTAIS***

Iran Carlos Stalliviere Corrêa

2025

Prof. Iran Carlos Stalliviere Corrêa
Centro de Estudos de Geologia Costeira e Oceânica
Departamento de Geodésia
Instituto de Geociências
Universidade Federal do Rio Grande do Sul

C824o Corrêa, Iran Carlos Stalliviere
O sensoriamento remoto e os riscos naturais e ambientais. /
Iran Carlos Stalliviere Corrêa - Porto Alegre:
CECO/DPGEO/IGEO/UFRGS, 2025.
[179 f.] il.

ISBN: 978-65-01-28979-3

1. Erupção vulcânica. 2. Deslizamento de terra. 3. Avalanche.
4. Terremoto. 5. Prevenção de desastre. I. Título.

CDU 528

Catálogo na Publicação

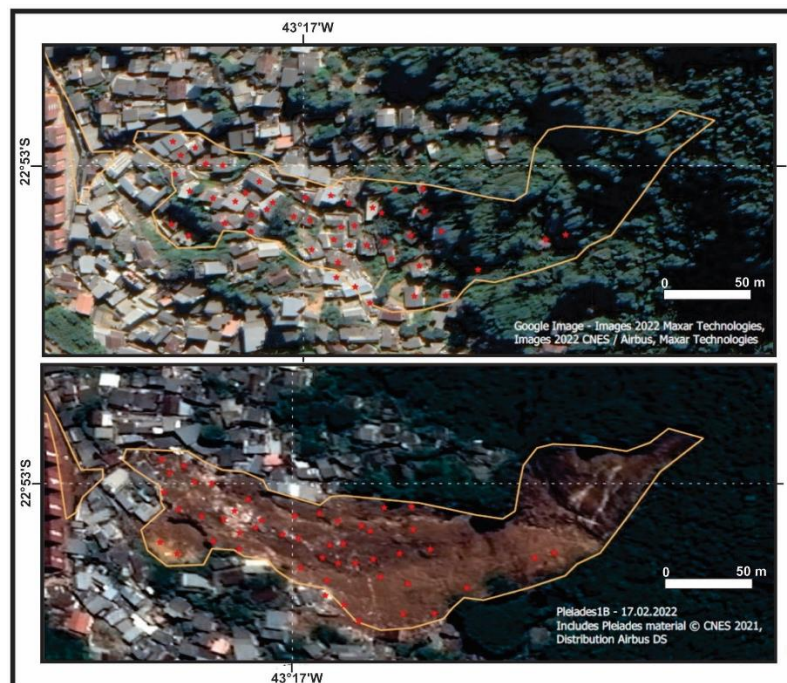
Biblioteca Instituto de Geociências - UFRGS
Renata Cristina Grun CRB 10/1113



INSTITUTO DE GEOCIÊNCIAS

Centro de Estudos de Geologia Costeira e Oceânica

Departamento de Geodésia



Imagens de satélite mostrando antes e depois dos deslizamentos em Petrópolis-RJ em 2022.
(fonte: <https://soupetropolis.com/wp-content/uploads/2022/03/WhatsApp-Image-2022-03-02-at-11.30.58.jpeg>)

O SENSORIAMENTO REMOTO E OS RISCOS NATURAIS E AMBIENTAIS

2025

Iran Carlos Stalliviere Corrêa



Reitora
Márcia Cristina Bernardes Barbosa

Vice-Reitor
Pedro de Almeida Costa

Diretor do Instituto de Geociências
Nelson Luiz Sambaqui Gruber

Vice-Diretora do Instituto de Geociências
Cassiana Roberta Lizzoni Michelin

Projeto Livro Didático

**Projetado e elaborado pelo Centro de Estudos de Geologia Costeira e Oceânica e
Departamento de Geodésia do Instituto de Geociências da UFRGS**

Diretora CECO: María Alejandra Gomez Pivel
Vice-Diretora CECO: Maria Luiza Correa da Camara Rosa

Chefe do Departamento de Geodésia: Clódis de Oliveira Andrades Filho
Chefe Substituto: Flavia Cristiane Farina

2025

**Segundo a lei nº 9610/98 e o Código Penal no Artigo 184, é vedada a
reprodução, por qualquer meio, desta apostila didática, sendo somente
permitida com autorização do professor-autor.
A cópia não autorizada é punível com sanções administrativas e penais.**

SUMÁRIO

Apresentação	8
I. INTRODUÇÃO	10
II. DADOS DO SENSORIAMENTO REMOTO	14
2.1 Dados obtidos a partir do Sensoriamento Remoto	14
2.2 Dados de fonte aberta	21
2.3 Qual o método usado em cada aplicação	24
2.3.1 Mudanças de direção	27
2.3.2 Variações da topografia	27
2.3.3 Métodos de medida de deslocamento	28
2.4 Informações sobre detecção de alterações	30
2.4.1 Mapeamento de fenômenos usando satélites e métodos de detecção de Alterações	30
III. OS PRINCÍPIOS DA CORRELAÇÃO DE IMAGENS	37
3.1 Que vem a ser correlação de imagens?	37
3.2 Correlação de imagens na prática: pré-processamento de imagens	39
3.3 Correlação de imagens na prática: metodologia de correlação	40
3.4 Correlação de imagens na prática: pós-processamento de correlação	44
IV. MEDIDA DA TOPOGRAFIA POR FOTOGRAMETRIA	45
4.1 Princípios gerais	45
4.2 Metodologia em detalhe	48
4.2.1 Aplicação para medir deformação	51
V. InSAR E AS SÉRIES TEMPORAIS	54
5.1 Princípios do InSAR	54
5.2 Séries temporais	63
5.2.1. Como fazer séries temporais a partir de séries de imagens?	65
5.2.2. Quais são os limites do método?	67
VI. TERREMOTOS E VULCÕES	70
6.1 Terremotos: um problema social	70
6.2 A que se deve estes terremotos?	72
6.3 Como são estudados os terremotos?	74
6.3.1 Técnicas de medida de deslocamento da superfície do solo: geodésia terrestre	76
6.3.2 Contribuição do sensoriamento remoto no estudo de terremotos	76
6.3.3 Mapeamento de falhas por análise de imagens ópticas e MDT	78
6.3.4 Monitoramento espaço-temporal da deformação pelo InSAR	83
6.3.5 Observação por satélite da deformação cossísmica	84
6.4 Vulcões e o sensoriamento remoto	87
6.4.1 Previsão de erupções vulcânicas: uma questão social	87
6.4.2 Como monitorar os vulcões?	90
6.4.3 Monitoramento de deformações	92

6.4.3.1 Monitoramento de deformação dos vulcões Lastarria e Cordón del Azufre	92
6.4.3.2 Rastreamento de mudanças de superfície	96
6.4.3.3 Avaliação dos volumes estimados e do fluxo de emissões	99
VII. MOVIMENTO DE MASSAS E GELEIRAS	101
7.1 Tipologia dos movimentos de massa	101
7.2 Movimentos terrestres perigosos	104
7.3 Contribuições do sensoriamento remoto e interesses de diferentes tipos de dados/sensores	108
7.3.1 Inventário de movimento rápido	110
7.3.2 Caracterização dos movimentos de massa	113
7.3.3 Movimento temporal de deslizamento lento	114
7.4 O sensoriamento remoto e as geleiras	116
7.4.1 Problemas na evolução das geleiras	118
7.4.2 Benefícios do sensoriamento remoto e os interesses dos diferentes tipos de dados de sensores	120
7.4.3 Inventário das geleiras e caracterização de seu estado superficial	121
7.4.4 Velocidade do fluxo superficial dos glaciares	126
VIII. INUNDAÇÕES, QUEIMADAS, INCÊNDIOS E DERRAMAMENTO DE ÓLEO	128
8.1 Mapeamento de áreas inundáveis através de sensoriamento remoto	128
8.1.1 Introdução	128
8.1.2 Topografia e modelo digital do terreno	129
8.1.3 Sensoriamento remoto e inundações	129
8.2 Mapeamento de áreas de queimada e incêndios	131
8.3 Sensoriamento remoto em ambiente urbano: área permeável e impermeável	134
8.4 Sensoriamento remoto com aplicação de imagens na banda do infravermelho	135
8.5 Sensoriamento remoto no derramamento de óleo	136
IX. INTELIGÊNCIA ARTIFICIAL E MONITORAMENTO	138
9.1 Inteligência artificial	138
9.2 Aprendizagem de máquina e imagens	140
9.3 Vigilância para alerta precoce	144
9.3.1 As vantagens do sensoriamento remoto	147
X. QUESTÕES DE CONHECIMENTO	151
XI. REFERÊNCIA BIBLIOGRÁFICA	163
XII. LEITURAS RECOMENDADAS	170
XIII. ABREVIATURAS	171
XIV – ALGUNS SITES PARA VISUALIZAÇÃO DE IMAGENS	172
XV. GLOSSÁRIO	173
XVI. RESPOSTAS DAS QUESTÕES DE CONHECIMENTO	177

APRESENTAÇÃO

Com a finalidade de contribuir para o conhecimento da aplicação do Sensoriamento Remoto na análise, interpretação e prevenção de desastres naturais e ambientais é que foi organizada esta coletânea de informações obtidas através de notas de aulas, de artigos científicos, de relatórios de Instituições, de cursos realizados de palestras assistidas durante quase cinquenta anos de magistério.

A elaboração deste trabalho não tem o intuito de compará-lo a um livro didático e científico e sim apenas um complemento para os alunos, no acompanhamento das aulas e para a comunidade em geral saber os benefícios que o sensoriamento remoto pode fornecer em relação aos desastres naturais e ambientais.

Este manuscrito pretende fornecer ideias básicas sobre a importância do sensoriamento remoto no estudo e prevenção dos desastres naturais e ambientais.


Neste alfarrábio se pretende apresentar as causas e os impactos ao meio ambiente e a vida humana que os desastres naturais, como erupções vulcânicas, deslizamentos de terra, terremotos e outros podem ocasionar e possibilitar, através do sensoriamento remoto, a prevenção destes desastres contra a vida humana, bem como os desastres ambientais ocasionados, em sua maioria, pela ação predatória dos seres humanos na natureza e pelas falhas e negligências em processos industriais e de transporte

Expresso meus agradecimentos a Profa. Maria Luiza Correa da Camara Rosa pela leitura e sugestões apresentadas para a melhoria deste trabalho.

Quero deixar registrado os meus mais profundos agradecimentos ao **Prof. Dr. Clóvis Carlos Carraro** (*in memoriam*) que foi quem me apoiou, durante toda minha vida universitária, e me ensinou os primeiros passos na aplicação do Sensoriamento Remoto na interpretação e análise de riscos.

Ao Prof. Dr. Clóvis Carlos Carraro o meu respeito e gratidão.

O Autor.



I. INTRODUÇÃO

Iniciaremos esta narrativa a partir do Vale do Colca, localizado na região sul do Peru, especificamente no povoado de Maca, aos pés do vulcão Sabancaya (Fig.1).



Figura 1. Vulcão Sabancaya em erupção – Peru

(fonte: [https://elcomercio.pe/resizer/lBwzN4KentVizCJXrv0rJ9InGVk=/1200x800/smart/filters:format\(jpeg\):quality\(75\)/cloudfront-us-east-1.images.arcpublishing.com/elcomercio/ITYJ3PG4UNB7RMSPWZUZRDW2K4.jpg](https://elcomercio.pe/resizer/lBwzN4KentVizCJXrv0rJ9InGVk=/1200x800/smart/filters:format(jpeg):quality(75)/cloudfront-us-east-1.images.arcpublishing.com/elcomercio/ITYJ3PG4UNB7RMSPWZUZRDW2K4.jpg))

A aldeia de Maca se encontra localizada sobre um deslizamento de terra que se move lentamente e é regularmente afetada por terremotos, causados por falhas tectônicas próximas, localizadas a menos de 10 km de distância. No povoado de Maca, em março de 2022, um terremoto de magnitude 5,5 na Escala Richter, causou a destruição de parte da aldeia. Os deslizamentos que ocorrem no vale, impedem a irrigação da terra e o desenvolvimento de infraestruturas, ameaçando assim toda uma economia baseada no turismo e na agricultura, enquanto o vulcão, em atividade quase constante desde 2015, ameaça a vida dos habitantes.

Como podem os satélites, localizados a uma altitude de quase 800 km, permitir compreender estes fenômenos naturais, acompanhar a sua evolução ao longo do tempo e, por que não, prever a sua ocorrência!

Em 1957, a URSS lançou o Sputnik (Fig.2), o primeiro satélite da história cuja órbita, ao redor da Terra, estava a uma altitude de aproximadamente 250 km e cuja única função era emitir bipes. Seguiram-se séries de satélites equipados com câmeras fotográficas como o Corona e o Hexagon, desenvolvidos pelos Estados Unidos a partir de 1959, ou o Zenit ou Lantar, desenvolvido pela União Soviética a partir de 1961. O objetivo desses satélites era a detecção de instalações militares dos outros países.



Figura 2. Satélite Sputnik – URSS.

(fonte: <https://img.odcdn.com.br/wp-content/uploads/2022/10/sputnik.png>)

A transmissão dos dados foi assegurada pela ejeção dos filmes recolhidos no solo ou em voo, por aviões. Ao mesmo tempo, satélites geoestacionários foram lançados para observar a cobertura de nuvens. Esses satélites que acompanham a rotação da Terra, observam sempre o mesmo ponto do solo. Essas órbitas muito altas, 36.000 km, não proporcionam uma resolução espacial precisa e, portanto, não têm aplicação para riscos geológicos naturais.

O primeiro satélite de observação da Terra, para fins civis, criado em 1972, foi o Landsat-1 com uma órbita de cerca de 900 km (Fig.3), que funcionou até 1978. Este permitia uma resolução de imagem de aproximadamente 80 m no solo, em diversas bandas espectrais, indo do visível até o infravermelho próximo.



Figura 3. Satélite Landsat-1 – USA.

(fonte: https://lh6.googleusercontent.com/proxy/u_RShBpLdtXLba0b0bu5ILAIFwVn91EGjYA4NxujhI TdHxgc1iL6y5sWu7t1YnwSNGn_ifscuRUCeafDAmODbKwvR1Ggf6m7F3-61dHz49XGpbOUqwulZ2Wzs)

Posteriormente surgiram novas gerações de satélites Landsat e atualmente temos mais de 50 anos de observação da Terra à nossa disposição. As várias imagens, até então obtidas pelos satélites, permitem observar, por exemplo o vulcão Ampato, no Peru, onde se pode observar as variações na calota polar do cume e de sua cobertura de cinzas, ligadas às erupções do vizinho vulcão Sabancaya, em 1995 e 2015.

Posteriormente ao Landsat, várias constelações de satélites ópticos foram construídos, tais como Spot em 1986, Aster em 1999, Quickbird em 2001, Worldview em 2009, com sensores ópticos com resolução espacial cada vez mais precisa até valores submétricos. Esses dados, originalmente para fins comerciais, são agora fornecidos gratuitamente e são de interesse histórico primordial para o estudo das mudanças globais e dos riscos naturais.

Alguns satélites possuem radares que têm a vantagem de observar através da cobertura de nuvens, durante o dia e a noite. Eles seguem a mesma evolução dos satélites ópticos, primeiro com finalidades militares, depois, com o surgimento dos radares, para observação da Terra, em meados da década de 1990. Após 2010, se observa uma multiplicação dos dados disponíveis, como pode ser visto na linha do tempo que mostra o lançamento dos principais satélites ópticos desde 1972 (Fig.4).




Figura 4. Linha de tempo na evolução do sistema Landsat.

(modificado: https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcT5R8sVIMc5K9Kv9B6Ro-3nHM7lg-B_pUhKoEohOeo8Qg&s)

A evolução dos satélites tem dois objetivos: o primeiro social, através de dados gratuitos e, segundo uma frequência de aquisição cada vez maior para observar

fenômenos transitórios. Assim, o programa europeu Copernicus fornece dados de satélites Sentinel, incluindo uma constelação de dois satélites radar denominada Sentinel-1, com uma frequência de revisita de seis dias no equador e uma resolução espacial de cerca de 10 m, bem como uma constelação de dois satélites ópticos denominados Sentinel-2, com frequência de revisita de cinco dias no equador e resolução espacial de 10 m nas quatro bandas espectrais do azul, verde, vermelho e infravermelho. Pode-se destacar também os satélites Landsat 7/8 que fornecem dados a cada dezesseis dias com resolução de 15 m e que oferecem, quase continuamente, dados de aquisição desde 2001. Ao mesmo tempo, o setor espacial vê sua estratégia evoluir para cobrir a Terra sempre com maior frequência e com melhor resolução espacial. Chega de grandes satélites pesando várias toneladas e integrando vários sensores. A indústria espacial está a recorrer a constelações de microssatélites pesando alguns quilos que permitem uma revisitação temporal muito elevada.

Assim, mais de 130 satélites formam a constelação PlanetScop e oferecem imagem de cada ponto do globo, diversas vezes ao dia, com resolução de 3 m em quatro faixas visíveis. Muitos países estão se voltando para o espaço. Esta corrida ao espaço levanta a questão do custo ambiental dos dados de satélite, a partir de um cálculo complexo que inclui fases de desenvolvimento do satélite, entrega de material, construção, lançamento, armazenamento e reprocessamento de dados. Cálculos iniciais tendem a mostrar que o uso de imagens de satélite está muito longe de ser neutro em carbono. Isto está sobretudo ligado às fases de desenvolvimento dos satélites e é, portanto, necessário racionalizar o lançamento de futuros satélites. Esta oferta de espaço também abre oportunidades cada vez maiores para o estudo dos riscos naturais ou ambientais, principalmente porque é acompanhado do fornecimento de dados.

Esta massa de dados também representa um desafio para o seu processamento. Assim, métodos de processamento automático surgiram nos últimos quinze anos, alguns dos quais são utilizados para detectar sinais ou objetos de interesse, como deslizamentos de terra, alagamento, medir movimentos de massa de alguns milímetros a vários metros e detectar mudanças de estado que podem ser precursoras de um perigo natural.

Voltando aos riscos naturais e ambientais, os dados de sensoriamento remoto apresentam vantagens únicas para o seu gerenciamento. A sua principal vantagem é a cobertura global que permite obter informações sobre todas as áreas do globo, incluindo aquelas que não são cobertas por instrumentos de medição terrestre. Isto permite estudar grandes regiões e, por vezes, ter acesso a informações muito localizadas, graças à alta

resolução espacial e temporal. Tem-se então a possibilidade de utilizar dados de arquivo para caracterizar o evento ou procurar a posteriori, potenciais sinais de alerta de eventos catastróficos, ou mesmo, detectar esses sinais antes do evento e assim poder dar o alarme.

II. DADOS DO SENSORIAMENTO REMOTO

2.1. Dados obtidos a partir do Sensoriamento Remoto

O princípio do sensoriamento remoto é registrar sinais vindos da superfície da Terra, através de sensores embutidos em uma plataforma distante da superfície. Nas aplicações a que temos interesse, esta plataforma pode ser um satélite, um avião ou um drone.

Os satélites de observação da Terra que nos interessam estão mais frequentemente localizados em órbitas quase polares, ou seja, estão quase orientados Norte-Sul, passam quase pelos polos. Como a órbita não é completamente polar, há uma pequena área em torno dos polos, Norte e Sul, que não é imageada por estes satélites (Fig.5).




Figura 5. Órbita Polar e varredura da superfície da terra.

(fonte: https://static.wixstatic.com/media/2cf7ad_80c3a97c45e747efb9c00da77da83409~mv2.jpg/v1/fill/w_400,h_264,al_c,q_80,enc_auto/2cf7ad_80c3a97c45e747efb9c00da77da83409~mv2.jpg)

Os satélites também são frequentemente colocados em órbita sincronizada com o Sol, ou seja, o satélite retorna verticalmente a um ponto da Terra sempre ao mesmo tempo, o que permite obter imagens com iluminação quase semelhante entre cada passagem. Estas restrições de órbita se combinam com restrições de resolução de imagem, bem

como com uma vida útil esperada do satélite, na maioria das vezes em torno de 5 a 10 anos, e com órbitas de satélite a cerca de 800 km de altitude.

Estas órbitas proporcionam, dependendo da faixa do satélite que corresponde à largura no solo da área imageada, tempos de revisita em um ponto que variam em torno de dez dias a um mês. Ao se combinar, não um satélite, mas uma constelação de vários satélites semelhantes, localizados em diferentes graus da órbita, é possível reduzir este tempo de revisita para menos de um dia.

Para outras plataformas (aéreas ou drones), as medições não são regulares ou sistemáticas, mas fixadas pela frequência das campanhas de voo. No entanto, as altitudes mais baixas utilizadas nestas campanhas, têm a vantagem de uma melhor resolução espacial dos dados obtidos, o que por vezes pode ser fundamental para a obtenção de imagens de pequenos objetos geológicos. Estes dados constituem, portanto, um complemento aos satélites, para que estes tenham uma visão extensa e de alta resolução de um objeto bem definido.

A bordo dessas plataformas estão diferentes tipos de sensores, os quais, convencionalmente se dissociam em sensores passivos, ou seja, aqueles que captam sinais provenientes de uma fonte externa refletida pela superfície da Terra, e sensores ativos que registram sinais refletidos por uma fonte de energia emitida pelo satélite (Fig.6).

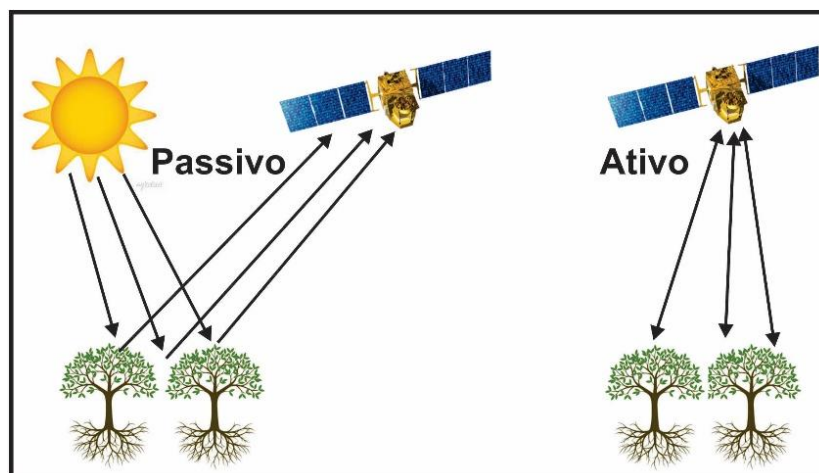


Figura 6. Sensores orbitais ópticos passivos e ativos.
(modificado: Marques da Silva, 2021)

Normalmente os sensores ópticos são sensores passivos, os quais registram a luz emitida pelo Sol e refletida pela superfície da Terra. Entretanto os radares são sensores ativos, eles registram a onda de radar que eles próprios emitem e que é refletida pela superfície terrestre. Morcegos ou golfinhos, por exemplo, utilizam esse mesmo princípio

ativo para se localizarem, emitindo ultrassom e registrando e analisando os ecos refletidos pelo ambiente.

Cada um destes sensores será sensível a uma banda de frequência limitada, ou seja, a uma pequena parte do espectro eletromagnético. Por exemplo, os sensores ópticos irão, na maioria das vezes, adquirir dados em comprimentos de onda visíveis ou próximos do visível, ou seja, comprimentos de onda em torno de 500 nm, aos quais o olho também é sensível (Fig.7).




Figura 7. Espectro eletromagnético da luz.

(fonte: <https://www.infoescola.com/wp-content/uploads/2007/12/espectro-visivel-da-luz.jpg>)

O olho humano também é um sensor passivo que opera no visível. Os olhos dos insetos também são sensores passivos, mas com sua sensibilidade alterada para o ultravioleta, eles são apenas ligeiramente sensíveis às cores vermelhas.

Os radares adquirem dados em comprimentos de onda do espectro eletromagnético maiores, em torno de alguns centímetros, chamados de micro-ondas. Outro exemplo de sensor ativo, o LIDAR (*Light Detection and Ranging* – Detecção e Alcance de Luz), que emite e registra ondas, não no domínio das micro-ondas, mas no infravermelho (Fig.7), graças a um laser, o que permite ter um feixe muito concentrado e, portanto, uma área imageada em solo muito pequena. A resolução espacial desses sensores varia muito. Se os LIDARs a bordo dos drones permitem pontos a cada cm, os LIDARs a bordo dos satélites têm um ponto muito maior no solo, por exemplo, 55 m para o satélite ICESAT.

A resolução das imagens ópticas de satélite varia de 30 cm para WorldView, 15 m para Landsat ou Aster e 250 m para MODIS, o que não permite a visualização dos mesmos

objetos. Por exemplo, na figura 8, se pode ver a mesma cena adquirida pelo MODIS, com 250 m de resolução, e pelo Sentinel, com 10 m de resolução, em uma área de cultivo e floresta.

Os radares também apresentam uma grande variabilidade na resolução espacial, de cerca de 1 m para satélites de alta resolução no modo Spotlight, como o TerraSAR-X, e à cerca de 10 m para o Sentinel-1.




Figura 8. Visualização da mesma cena adquirida por satélites com resoluções diferentes.
(fonte: <https://www.mp.br/arquivos/2020-05/sentinel.PNG?VersionId=.kruXVnpCYfPf5QqXQgjM47segKB6Xsg>)

Mas acima de tudo é uma questão de compreender que cada sensor será sensível a diferentes propriedades do solo, devido ao seu princípio e à sua geometria de aquisição, bem como ao seu comprimento de onda. Um sensor óptico geralmente gera imagens de áreas posicionadas verticalmente ao satélite, com a possibilidade de certos satélites desfocarem a imagem para observar áreas ligeiramente laterais, para frente ou para trás. Esta capacidade de apontar, permite aumentar a frequência de revisita, ou obter vistas estéreo próximas no tempo, da mesma área, o que permitirá gerar topografias também chamadas de Modelos Digitais de Terreno (MDT).

Os sensores ópticos irão gerar imagens da superfície da Terra, na maioria das vezes em bandas espectrais azuis, verdes, vermelhas, infravermelhas, às vezes infravermelhas térmicas ou ultravioletas. Esta diversidade espectral permitirá dissociar objetos da superfície terrestre cuja refletância, ou seja, a energia refletida, não é a mesma, dependendo do comprimento de onda utilizado. Assim, a refletância da vegetação é mais forte no infravermelho, enquanto a da água é mais forte no azul ou no verde (Fig.9). Olhar para a superfície da Terra em uma ou outra das bandas espectrais visíveis produzirá, portanto, imagens completamente diferentes (Fig.10).

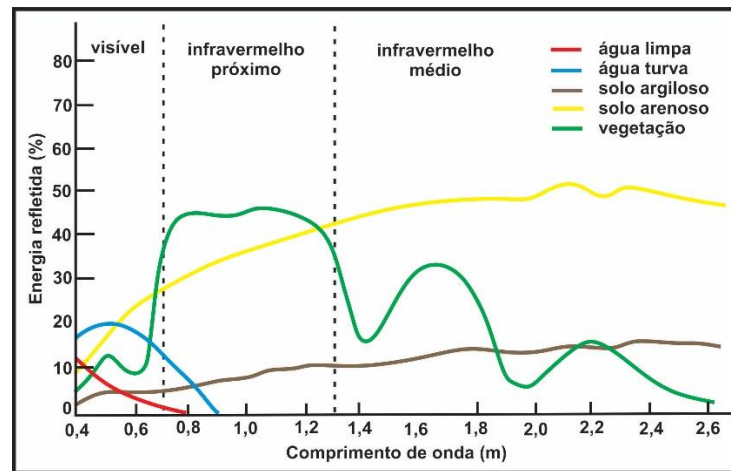


Figura 9. Espectro de reflectância de superfícies diferentes.

(modificado: <https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcQ6UpAj8Vz5TCLTUGHmIOv2NmL57Ct5Us75aIXWVELotQ&s>)




Figura10. Visualização da mesma imagem, a) Banda do vermelho, b) Banda do infravermelho próximo.

(modificado: <http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>)

Os sensores que possuem numerosas bandas de aquisição espectral possuem, portanto, maior capacidade de diferenciar vários objetos. Os sensores de radar, pelo menos os radares de imagem SAR, emitem uma onda lateral com um ângulo de incidência geralmente entre 20° e 45° e registram a onda refletida pela superfície terrestre. O sinal do radar é uma informação complexa que contém uma amplitude e uma fase, de modo que se tem duas imagens: uma imagem de amplitude que depende diretamente da quantidade de energia retroespalhada pelo alvo e uma imagem de fase que é um número entre π e $-\pi$.

Uma imagem de radar é caracterizada por duas direções: a direção do azimute que é paralela à trajetória seguida pelo satélite e a direção da distância (ou alcance) que está na direção da visão. Enquanto a direção do azimute está no plano horizontal, a direção

da distância contém uma componente vertical e uma componente horizontal cujo peso relativo depende do ângulo de incidência do radar. A projeção da direção da distância ao longo da linha de visão (ou alcance inclinado) no plano horizontal, é chamada de alcance no terreno (Fig.11).

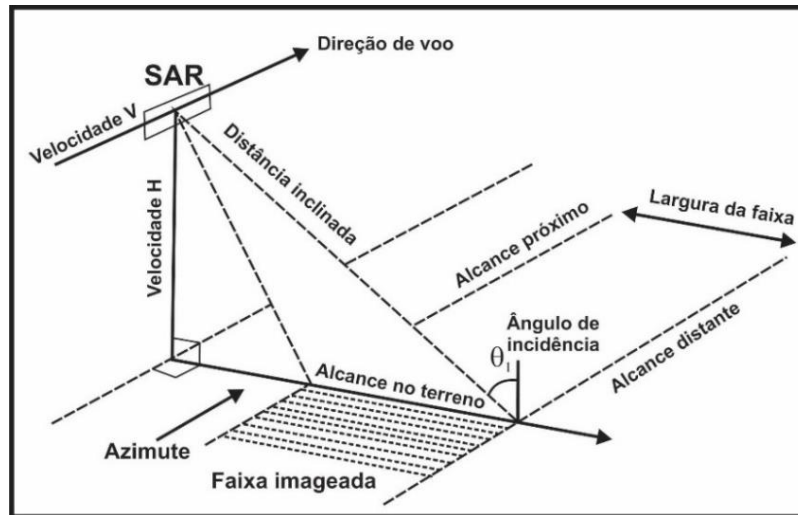


Figura 11. Principais direções de uma imagem de Radar.
(modificado: Moreira, 2011 e INPE, 2016)

A informação de amplitude fornece a quantidade de retro energia espalhada pelo alvo, que dependerá da sua orientação em relação ao radar, da sua rugosidade, do seu teor de água e do tipo de solo. À primeira vista, a orientação oblíqua do sensor tornará a informação de amplitude difícil de interpretar para os não iniciados, porque a geometria do radar é diferente da geometria óptica a que o olho humano está habituado (Fig.12).

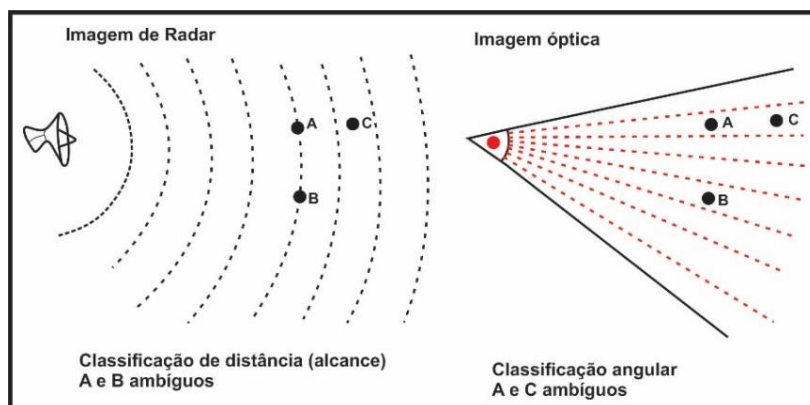


Figura 12. Geometria de imagem Radar e imagem Óptica.
(modificado: Marambio et al., 2009)

Na geometria do radar, dois pontos serão separados se estiverem localizados a distâncias diferentes do sensor (A e C), enquanto, na imagem óptica, eles serão separados se forem vistos em ângulos diferentes (A e B ou B e C) (Fig.12). Como resultado, as

encostas voltadas para o satélite são encurtadas. Esta é a zona de encurtamento que se pode ver em azul na figura 13 e apresenta energias retro difundidas muito fortes.




Figura 13. Zona de encurtamento em uma imagem de radar.
(modificado: Pinel & Albino, 2022)

Quando a inclinação é maior que o ângulo de incidência, ocorre um fenômeno de dobramento com inversão dos objetos na imagem do radar e superposição de áreas do solo localizadas em diferentes altitudes. Estas são as zonas de dobramento (*layover*) em verde e laranja na figura 14. As inclinações orientadas na direção oposta ao sensor terão tamanhos alongados e amplitudes muito menores, como mostra a área de alongamento em vermelho na figura 14. Algumas áreas podem estar em uma área cinza e não serem reproduzidas, isto é o que chamamos de zona de sombra que é mostrada em cinza na figura 14.




Figura 14. Zonas de uma imagem de Radar.
(modificado: Pinel & Albino, 2022)

Desta maneira, por exemplo, o monte Fuji no Japão, que parece simétrico nas imagens (Fig.15a), aparecerá assimétrico na imagem do radar (Fig.15b). A figura 15b, mostra uma imagem de radar adquirida em órbita ascendente com um satélite apontado para a esquerda da imagem.

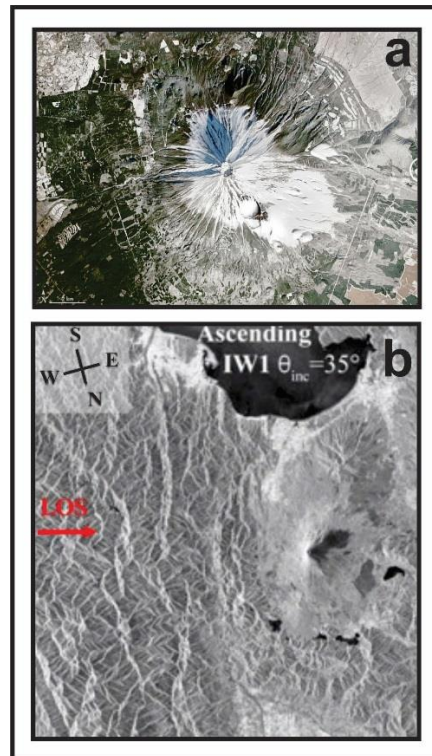


Figura 15. Imagem do monte Fuji em sua forma simétrica (a) e imagem de Radar do monte Fuji (b) – Japão.

(fonte: <https://veja.abril.com.br/wp-content/uploads/2016/05/japao-monte-fuji-patrimonio-20121213-02-original.jpeg?crop=1&resize=1212,909>)

O flanco ocidental do vulcão, voltado para o satélite, parece muito brilhante e encurtado. Este efeito será tanto mais significativo quanto mais baixo for o ângulo de incidência. Observe que para uma órbita ascendente, a primeira linha adquirida está localizada ao sul da área imageada, estando no topo da imagem do radar. A informação de fase permitirá, comparando-a com a fase da onda emitida, obter informações sobre as variações de distância entre o satélite e o solo, na escala de comprimento de onda, ou seja, muitas vezes da ordem de alguns centímetros, ou ainda o conteúdo de vapor d'água da atmosfera atravessada.

2.2. Dados de fonte aberta

Vejamos alguns dos satélites e sensores associados que serão citados com mais frequência nesta obra. Observe que será apresentado apenas dados de código aberto, ou

seja, dados que qualquer pessoa pode recuperar gratuitamente na web. Para dados de satélites ópticos, os satélites Sentinel-2, lançados pela Agência Espacial Europeia (ESA), permitem obter imagens a cada cinco dias no equador (Fig.16). Mas este período pode ser maior quando se vai mais para o norte, com 10 m de resolução, em quatro bandas espectrais; azul, verde, vermelho e infravermelho. A sua faixa de quase 300 km, permite cobrir grandes áreas em cada passagem e, portanto, obter essa elevada repetibilidade, apesar de ser uma constelação de apenas dois satélites. O par de satélites Sentinel-2 foi direcionado ao monitoramento da vegetação, solos e áreas costeiras e é dotado com sensor óptico de alta resolução espacial.



Figura 16. Satélite Sentinel-2 lançado pela ESA.
(fonte: <https://www.engesat.com.br/wp-content/uploads/Sentinel2.jpeg>)

Os dados dos satélites SPOT permitem obter um arquivo de dados, desde 1986 com resolução de 10 m, até 2002, depois 2,50 m e finalmente 1,5 m, desde 2012 (Fig.17). O SPOT possui faculdades estereoscópicas que permitem gerar modelos digitais de terreno.



Figura 17. Evolução e resolução do satélite SPOT desde 1986.
(modificado: https://decryptageo.fr/wp-content/uploads/2016/02/spot_constellation.jpg https://decryptageo.fr/wp-content/uploads/2016/02/spot_constellation.jpg)

O satélite Landsat, operado pela NASA e pelo USGS, tinha originalmente, em 1972, uma resolução de 70 m, sendo atualmente de 15 m com o Landsat-8. O Landsat combina profundidade temporal desde 1972, uma frequência de revisita bastante alta de 16 dias e grande diversidade espectral, com 11 bandas cobrindo a faixa do azul ao infravermelho térmico, para o Landsat-8 (Fig.4).

Os satélites PlanetScope lançados desde 2016, têm tamanho e peso tão pequenos que permitiram gerar uma constelação de mais de 130 satélites que cobrem a Terra, e que fotografam todos os pontos da superfície terrestre com uma frequência maior do que diária e com resolução espacial de cerca de 3 m (Fig.18).



Figura 18. Satélite espacial PlanetScope.
(fonte: <https://www.engesat.com.br/wp-content/uploads/Planet-Dove-Satellite.jpg>)

Existem outros satélites ópticos com melhor resolução, cujos dados podem ser adquiridos gratuitamente graças a acordos, através de parcerias acadêmicas. É o caso, por exemplo, dos dados de Plêiades, cuja resolução espacial de 70 cm, tem demonstrado interesse na detecção de pequenos objetos, como movimentos de massa (Fig.19).



Figura 19. Satélite espacial Plêiades de alta resolução.
(fonte: <https://earth.esa.int/eogateway/documents/20142/1390381/Pleiades-Satellite.jpg>)

No que diz respeito aos dados de radar de satélite, se tem atualmente aquisições sistemáticas dos satélites Sentinel-1 que adquirem, no modo Faixa Interferométrica Larga (*Interferometric wide swath*), imagens de 250 km de largura com resolução de 3 m de alcance e 15 m na direção do azimute (Fig.20). Quando os dois satélites Sentinel-1A e Sentinel-1B operaram juntos entre 2016 e 2021, o tempo de revisita foi de 6 dias em certas áreas, quando o tempo de revisita é geralmente de 12 dias.



Figura 20. Satélite espacial Sentinel-1.
(fonte: https://img.odcdn.com.br/wp-content/uploads/2022/01/Satelite_Sentinel_1B.jpg)

2.3. Qual o método usado em cada aplicação

Dependendo do fenômeno natural que se deseja estudar e de suas características espaciais e temporais, é necessário escolher, criteriosamente, o tipo de dados e o método utilizado para aproveitar ao máximo os dados satelitais disponíveis.

Do ponto de vista temporal, as principais características de um satélite são: o período total durante o qual ele adquire dados ou tempo de vida (*life time*) e o tempo entre duas aquisições sucessivas ou tempo de revisita (*revisit time*) (Fig.21).




Figura 21. Características temporais de um satélite.

Um evento transitório com duração inferior ao tempo de revisita não será detectável. Observar-se-á um evento tão curto causando uma mudança permanente de estado, mas não teremos informações sobre o momento exato em que ocorreu ou sobre sua evolução temporal (Fig.21).

Por outro lado, um fenômeno muito lento que tenha ocorrido durante um período superior ao tempo de vida do satélite será imageado, mas não na sua totalidade (Fig.21). Será necessário, portanto, questionar a duração do fenômeno estudado e sua velocidade.

Do ponto de vista da resolução espacial, uma imagem de satélite é caracterizada pela sua extensão espacial total e pela sua resolução espacial em X e Y (Fig.22).

A resolução espacial geralmente corresponde ao tamanho do pixel, mas esta será de pior qualidade se for necessária à média de várias observações para aumentar a qualidade dos dados. Observe que dados de alta resolução espacial que atingem resolução métrica, geralmente têm uma extensão espacial menor, da ordem de algumas centenas de quilômetros quadrados.

Para que um fenômeno seja detectável, ele geralmente deve afetar uma área maior que o tamanho de um pixel. Pelo contrário, se este evento afetar uma área maior que a imagem total, não será analisado na sua totalidade (Fig.22).




Figura 22. Características espaciais de uma imagem satelitária.

Os diferentes sinais detectáveis por satélites são alterações no estado da superfície, alterações na topografia, que podem ser induzidas, quer por deslocamentos verticais significativos, quer por fornecimento ou perda de material e deslocamentos da superfície do solo, que podem ser laterais ou verticais.

Cada técnica de estudo de dados de satélite é caracterizada por um limiar de detecção que corresponde ao sinal mínimo que pode ser detectado. Este limite depende potencialmente das condições de aquisição e do nível de ruído presente nos dados. O fenômeno estudado deve, portanto, ter induzido um sinal maior que esse limite de detecção, para ser visualizado e estudado (Fig.23).




Figura 23. Conceito de limite de detecção.

Dependendo do tamanho do objeto estudado, da amplitude do movimento esperado e da sua velocidade de movimento, recorre-se a um ou outro dos métodos disponíveis: detecção de alterações, medições de variação topográfica, medição de deslocamento de superfície por correlação de imagem ou InSAR.

Os dados ópticos serão preferidos para movimentos de grande amplitude, localizados espacialmente, de preferência horizontais, enquanto os dados de radar serão preferidos para movimentos menores que afetem uma área maior ou com uma componente vertical significativa. Caso o fenômeno estudado seja muito rápido para se caracterizar seu movimento, sempre será possível obter informações quantitativas sobre a área impactada, utilizando métodos de detecção de alterações.

A figura 24 ilustra, por exemplo, essa escolha de método no caso de deslizamentos.

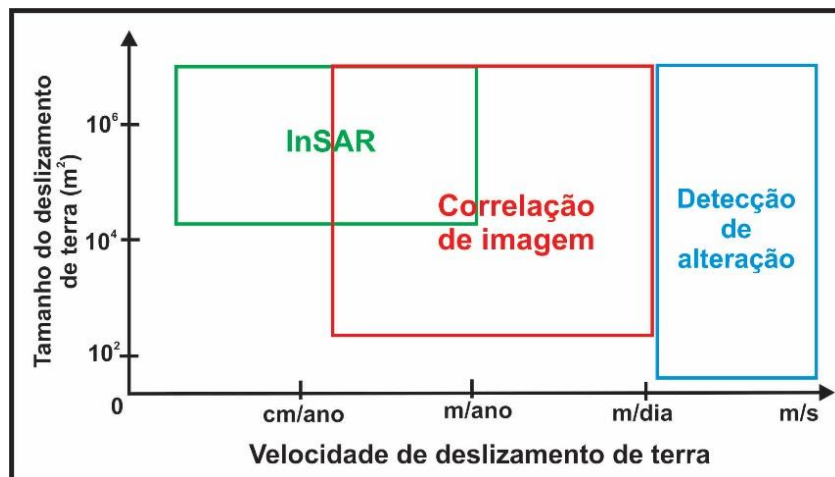


Figura 24. Escolha do tipo de método segundo o tamanho da zona afetada e a velocidade de deslizamento.

2.3.1. Mudança de direção

A detecção de alterações permite detectar mudanças na reflectância em dados ópticos, enquanto nos dados de radar, torna possível detectar alterações na retrodifusão do radar, induzidas por variações na rugosidade do solo, no seu teor de água ou na sua inclinação local, ou detectar alterações na coerência interferométrica. Assim, por exemplo, movimentos de massa, que são demasiado rápidos, resultam numa modificação excessiva da retrodifusão do solo dentro de um pixel e na perda do sinal interferométrico.

Na figura 25 se pode ver as mudanças na imagem óptica, induzidas pelo estabelecimento de um fluxo de lava do vulcão Cumbre Vieja, na ilha de La Palma, nas Canárias. O fluxo também é visto na imagem de amplitude do radar.




Figura 25. Mudanças na imagem óptica e de radar induzidas pelo estabelecimento de um fluxo de lava do vulcão Cumbre Vieja, na ilha de La Palma, nas Canárias.

(modificado: <https://cdn.knightlad.com/libs/juxtapose/latest/embed/index.html?uid=b7671450-ac87-11ec-b5bb-6595d9b17862>)

2.3.2. Variações da topografia

Existem vários métodos para quantificar variações na topografia, ou seja, variações na altitude da superfície do solo. Na maioria das vezes, essa variação é obtida se efetuando a diferença entre duas superfícies topográficas ou modelos digitais de terreno (MDT), adquiridos em dois momentos diferentes. Para calcular um MDT, é possível utilizar dados ópticos adquiridos na mesma área com vários ângulos de visão, sendo este o princípio da estereofotogrametria. Para a estereofotogrametria de drones, as incertezas serão da ordem de 1 cm, enquanto para satélites estéreos de altíssima resolução do tipo Pléiades, elas serão da ordem de 1 m. Também é possível usar dados de radar. Os dados de fase clássicos contêm informações sobre a topografia, mas o método mais simples é, quando disponível, usar dados biestáticos. Um satélite emite uma onda que é registrada ao

mesmo tempo por este satélite e por um satélite gêmeo localizado a uma curta distância. Este é o caso do satélite TanDEM-X voando em paralelo com o TerraSAR-X que pode ser visto na figura 26.




Figura 26. Uso de dados biestáticos obtidas pelos satélites TanDEM-X e TerraSAR-X.
(fonte: <https://www.inovacaotecnologica.com.br/noticias/imagens/010175100622-tandem-x.jpg>)

2.3.3. Métodos de medida de deslocamento

As técnicas de medir o deslocamento do solo, ou seja, métodos que permitem acompanhar o movimento dos objetos na superfície, podem ser obtidas através da correlação de imagens, as quais permitem obter o deslocamento nas duas direções da imagem, com uma precisão de cerca de 1/10 de pixel.

Esta técnica pode ser realizada em imagens ópticas ou em imagens de amplitude de radar. Aplicada a imagens ópticas de satélite que observam a Terra verticalmente, a correlação de imagens permite a medição no plano horizontal. Aplicada às imagens de radar, a correlação de imagens permite medir o deslocamento na direção de visão do satélite e na direção horizontal paralela à trajetória do satélite.

A interferometria de radar de satélite (InSAR), permite medir o movimento de massa em uma única direção, a da linha de visão do satélite, com uma precisão de uma fração do comprimento de onda do radar, normalmente 1 cm. Esta medição é relativa e limitada à medição de pequenos deslocamentos. Além disso, exige que a variação de fase entre dois pixels adjacentes não seja maior que π , o que limita o gradiente de deslocamento mensurável a valores inferiores a 1 m/km. Quando o fenômeno é de baixa amplitude, mas é observado durante um longo período, se pode passar de uma precisão de 1 cm, para um par de imagens de radar, a 1 mm por ano, para uma série temporal de várias imagens.

A figura 27 mostra a gama de fenômenos cuja extensão espacial e amplitude de movimento permitem o estudo pelo InSAR convencional, representada pela área branca. A área em laranja corresponde à gama de fenômenos que podem ser estudados com dados de radar, usando dados de séries temporais de alta resolução ou correlação de imagens de amplitude ou rastreamento de deslocamento de pixel. A área verde não pode ser estudada, enquanto a área em vermelho pode ser estudada por correlação óptica de imagens.

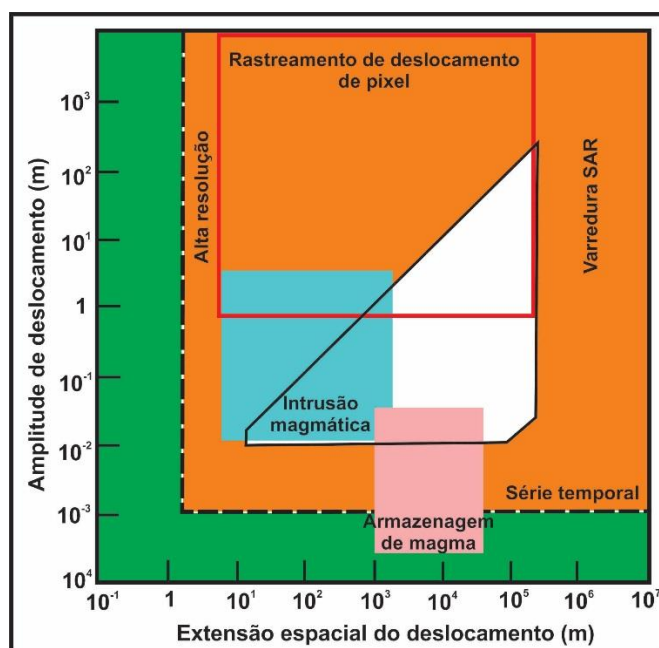


Figura 27. Visualização da relação entre a amplitude de deslocamento versus a extensão espacial do deslocamento.

Estão representados dois fenômenos de origem vulcânica (Fig.27): em rosa, o acúmulo de magma em um reservatório profundo e em azul, a propagação de uma intrusão ou dique magmático deste reservatório, em direção à superfície. Em teoria, estes dois fenômenos podem ser estudados com dados de radar. Mas quando olhamos para a resolução temporal, parece que a progressão do magma em direção à superfície é geralmente um fenômeno demasiado rápido para podermos estudar a sua evolução com dados de radar.

Concluindo, se deve primeiro tentar caracterizar, em primeira ordem, o fenômeno que se deseja estudar, avaliando sua extensão espacial, sua duração, sua velocidade e o tipo de sinal esperado. Isto permitirá a utilização dos dados e técnicas mais apropriados. Infelizmente, isso nem sempre é possível porque não temos necessariamente uma ideia a priori do que se procura, sendo então necessário testar diferentes conjuntos de dados e

diferentes métodos, o que levará mais tempo, mas permitirá caracterizar com precisão o fenômeno estudado com base na boa cobertura e boa resolução espacial dos dados de satélite. Mas devemos lembrar que a principal limitação dos dados de satélite continua a ser a sua baixa resolução temporal em comparação com os dados dos instrumentos terrestres registrados continuamente a cada segundo.

2.4. Informações sobre a detecção de alterações

Os riscos naturais podem causar alterações súbitas na superfície da Terra, sejam elas permanentes, por exemplo, no caso de depósitos vulcânicos, ou temporárias, como no caso de uma inundação. Para melhor gerir o impacto social destas mudanças, por exemplo, organizando socorro ou evacuações, é importante mapear rapidamente as áreas impactadas. Para antecipar perigos futuros e compreender a evolução do fenômeno, é necessário obter informação quantitativa como a estimativa dos volumes de magma emitidos durante as erupções ou de água acumulada nas inundações.

Vejamos como a análise das imagens adquiridas pelos satélites que orbitam a Terra, permite estudar as alterações na superfície terrestre e assim contribuir para a avaliação dos riscos naturais, a priori ou a posteriori. Vejamos alguns exemplos concretos para ilustrar os muitos fenômenos que ocorrem na superfície da Terra, que as imagens de satélite e os métodos de detecção de alterações podem mapear.

2.4.1. Mapeamento de fenômenos usando satélites e métodos de detecção de alterações

Um primeiro exemplo na detecção de mudanças é o desmatamento, o qual envolve avaliar os impactos das atividades antrópicas na floresta e identificar áreas de desmatamento antrópico ou após incêndios. O exemplo da figura 28, mostra a chamada imagem de variação total, calculada a partir de séries de imagens do satélite Sentinel-1. Trata-se da acumulação de variações temporais observáveis entre imagens ordenadas de acordo com a cronologia da sua aquisição, integrando também uma vertente multiescala, no sentido de que as variações podem se referir a duas imagens consecutivas ou a várias datas consecutivas, além de indicar o fato de às vezes pular determinadas datas específicas. Esses cálculos de variação multiescala são obtidos através da chamada transformada *wavelet*.

A detecção de alterações também nos permite estudar o recuo glacial, o qual envolve medir o comportamento dinâmico das geleiras ou identificar as linhas de ancoragem terrestre das barreiras de gelo da Antártica.

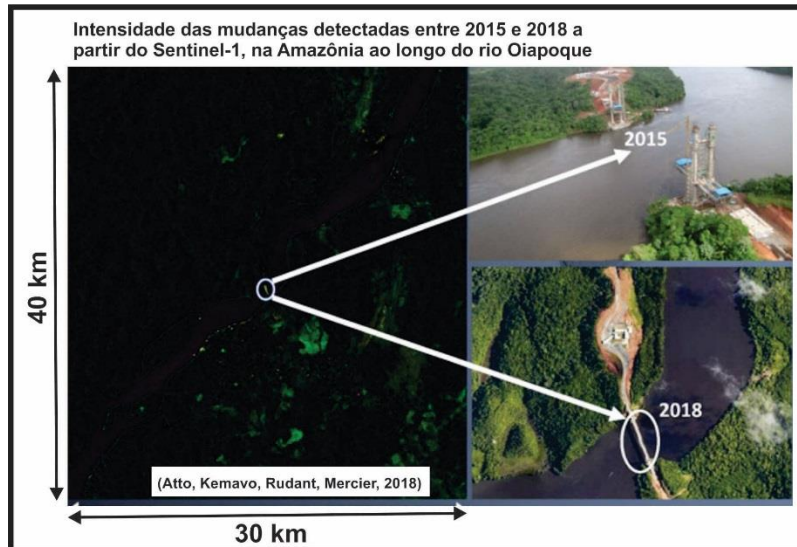


Figura 28. Intensidade das mudanças observadas em imagens em um determinado intervalo de tempo.
(modificado: Atto et al. 2018)

O exemplo mostrado na figura 29, ilustra um mapa de dinamismo da geleira Argentière, localizada no maciço do Monte Branco nos Alpes, calculado a partir de uma série de imagens SAR do satélite canadense RADARSAT-2. A medida de dinamismo utilizada, se refere à probabilidade de se observar uma mudança espacial, em função da evolução do coeficiente de variação, ao longo do tempo.

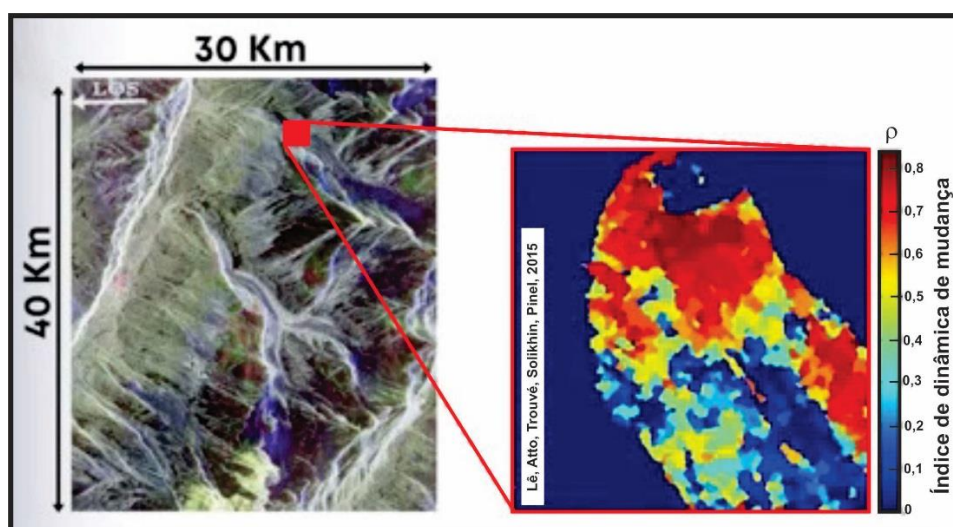


Figura 29. Mapa de dinamicidade da geleira Argentière – Monte Branco - Alpes.
(modificado: Lê et al, 2015)

Observa-se na figura 29 que na área glaciária, os índices de dinâmica de mudança são elevados ($\rho \approx 0,7$), em particular, nas zonas de queda dos séracs e nas zonas de fendas de movimento rápido ($\rho \approx 0,8$). Pelo contrário, em áreas estáveis (como rochas) onde quase não ocorre mudança, os índices de dinâmica de mudança são muito baixos ($\rho \approx 0,1$).

A detecção de alterações também é útil para rastrear atividades vulcânicas. O problema aqui consiste em avaliar o impacto das erupções vulcânicas no solo, mapeando os depósitos criados durante uma erupção. A ilustração da figura 30, refere-se à atividade do vulcão Merapi, na Indonésia, entre 2007 e 2011. O mapa de alterações à direita foi calculado a partir de uma série de imagens SAR do satélite japonês ALOS-PALSAR, utilizando classificação supervisionada e o conhecimento fornecido por estudos de campo e imagens ópticas dos satélites SPOT franceses.

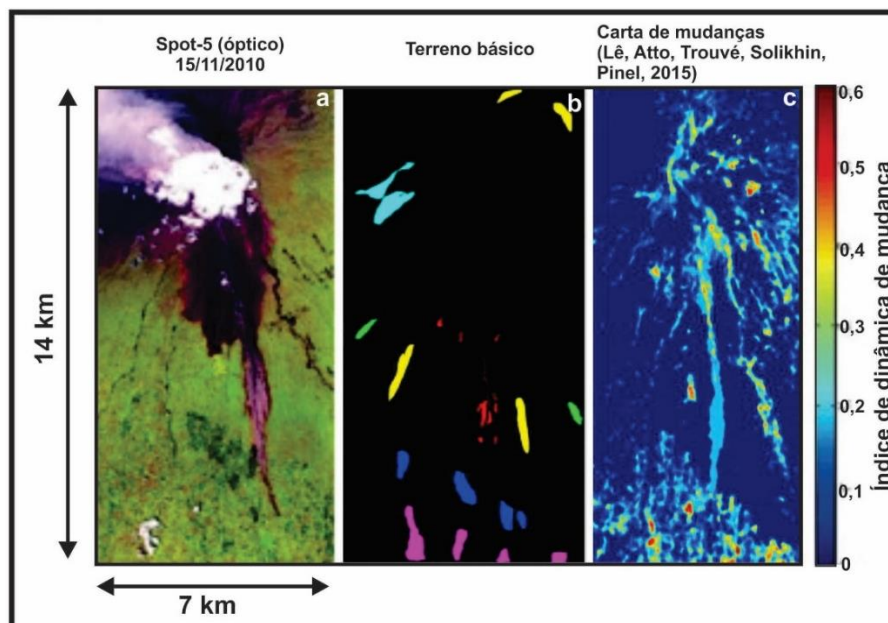


Figura 30. Atividade vulcânica no Merapi, Indonésia, mostrando a carta de mudanças.
(modificado: Lê et al, 2015)

Na figura 30 pode-se observar em (a) uma imagem do SPOT-5 do vulcão Merapi; em (b) se tem as amostras selecionadas: (1) Amostras de treinamento para o limite de testes de similaridade (azul escuro: área cultivada, amarelo: vegetação, ciano: depósitos do Merapi anteriores a 2010, magenta: aldeias) e (2) amostras reais para a avaliação quantitativa do mapa de detecção de alterações (vermelho: classe alterada, verde: classe inalterada); (c) mapa da dinâmica de mudança.

Para outros perigos naturais, como terremotos, inundações e tsunamis, as imagens de satélite são muito úteis durante a gestão de crises. A ativação de uma carta

internacional permite mobilizar os principais satélites de observações da Terra para avaliar os danos, comparando imagens antes e depois do evento.

A figura 31, ilustra a detecção de edifícios desabados em imagens de radar COSMOSky-Med após o terremoto de Áquila, na Itália, em 2009.

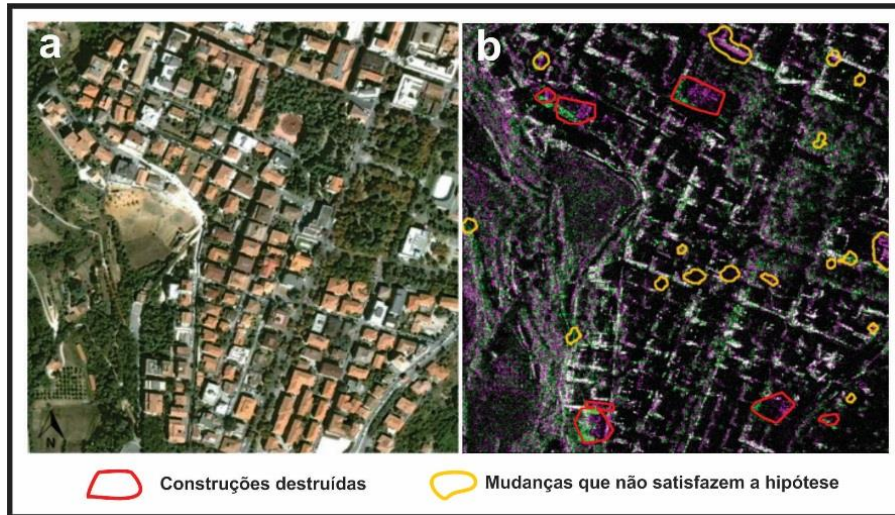


Figura 31. a) imagem óptica de Áquila – Itália em 09/2006. b) Mapa de construção alterado sobreposto à composição multitemporal RGB, ocasionada pelo terremoto em Áquila, Itália em 2009. (modificado: Martin et al. 2015.)

Uma mudança resulta na transição de um determinado estado para outro estado diferente do anterior. No caso de sensoriamento remoto por imagem e revisitação de locais de interesse, esses estados são diferenciados temporalmente considerando pares de imagens ou uma série temporal de imagens (Fig.32).

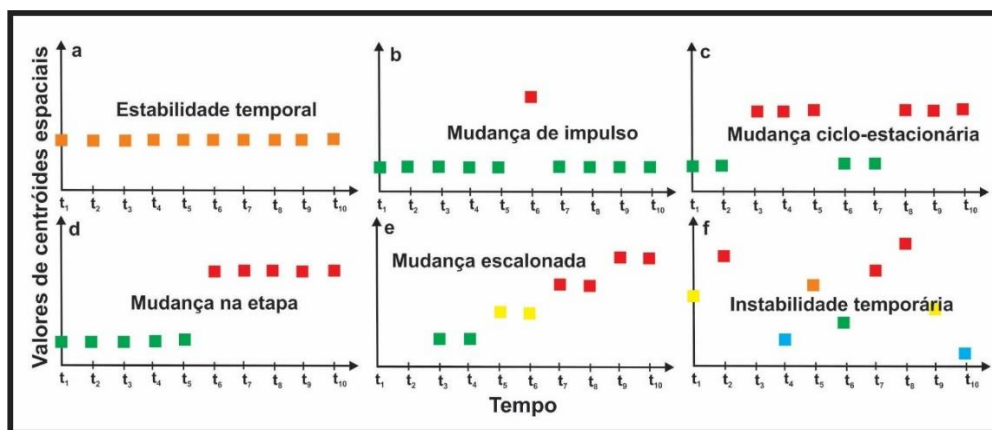


Figura 32. Casos padrões de mudanças.

Procura-se a presença de um ou mais eventos entre as datas de início e término da aquisição. O desafio do método de detecção de alterações é identificar automaticamente alterações potenciais. Os estados são lugares de regularidade, enquanto

as mudanças são singularidades características das transições entre estados. Em muitos casos, estas alterações afetam estatísticas como a média ou a variância, mas em muitos outros casos ocorrem na presença de incômodos, ou seja, informações que não são necessariamente úteis, induzidas pela variabilidade intrínseca ao ambiente natural. Assim, métodos ou estatísticas mais complexos devem ser desenvolvidos para alcançar um bom desempenho na detecção de alterações. Não se pode listar todos os métodos de detecção de alterações, nem todos os tipos de alterações, mas se pode, no entanto, identificar alguns casos padrões, conforme mostrado na figura 32. No caso da estabilidade temporal, as estatísticas espaciais locais, como a média ou as variâncias, não mudam ao longo do tempo (Fig.32a). Depois pode ocorrer uma breve mudança, com retorno ao estado inicial, chamada de mudança de impulso (Fig.32b) ou mudança ciclo-estacionária (Fig.32c). Neste último caso, estas mesmas estatísticas são apenas invariantes em ambos os lados da data em que a mudança ocorreu. Outro padrão de mudança é a de mudança de etapa, a qual apresentará um diferencial padrão ou *wavelet* mostrando apenas uma singularidade importante nesta data (Fig.32d). Nas áreas altamente dinâmicas, ou seja, onde a superfície muda frequentemente, e que se pode contar as mudanças, teremos as mudanças escalonadas (Fig.32e) ou instabilidade temporária (Fig.32f).

O que queremos dizer com dinamicidade ou simplesmente identificar classes de mudança? Iniciamos primeiro por definir dois termos relativos à aplicação de métodos. Fala-se do carácter inferencial de um método quando todos os parâmetros do método são fixados antecipadamente e o resultado da detecção é devolvido sem pôr em causa os seus parâmetros. Muitas estatísticas básicas, como distâncias médias, podem ser usadas para tomar decisões com base inferencial. Fala-se então de um formalismo de aprendizagem quando esses parâmetros estão sendo reavaliados e atualizados. Esta aprendizagem pode ser orientada por ajustes especializados ou ocorrer de forma autônoma dentro do significado do sistema, isso é então aprendizado de máquina. Após o treinamento, geralmente se muda para um protocolo de teste inferencial para avaliar a qualidade do aprendizado em dados que o sistema não conhece, ou seja, dados que não foram usados durante a fase de treinamento.

Para os métodos que envolvem aprendizado de máquina, esses podem ser classificados entre métodos supervisionados e métodos não supervisionados. Os métodos não supervisionados requerem pouca ou nenhuma informação especializada para se autocalibrarem, ou seja, ajustarem seus parâmetros. Quanto aos métodos

supervisionados, estes necessitam do fornecimento de uma grande quantidade de dados rotulados aos sistemas de aprendizagem, ou seja, os chamados dados de treino.

Existe uma vasta gama de métodos que envolvem diferentes níveis de supervisão dependendo do tipo de imagem utilizada, do tipo de análise à escala local ou global, do tipo de atributo e do tipo de aplicação. Assim, se pode utilizar imagens bitemporais ou séries temporais densas, imagens de um único tipo ou multivariadas, por exemplo, multiespectrais em óptica, polarimétricas em SAR ou ainda imagens resultantes de uma fusão de dados multissensor, multirresolução ou multitemporal. Pode-se usar análises locais ao nível de pixel ou globais no sentido do objeto, com base em informações semânticas, causais ou bidirecionais, binárias ou multiclases multitemporais. Também se pode usar vários atributos como, parâmetros estatísticos, diferenças e proporções entre bandas, elementos extraídos de aprendizagem profunda ou mesmo métricas sensíveis à variação de textura.

Um primeiro exemplo de abordagem não supervisionada é a detecção de um fluxo de lava após uma erupção, no caso, do vulcão Nyiragongo, na República Democrática do Congo (Fig.33).

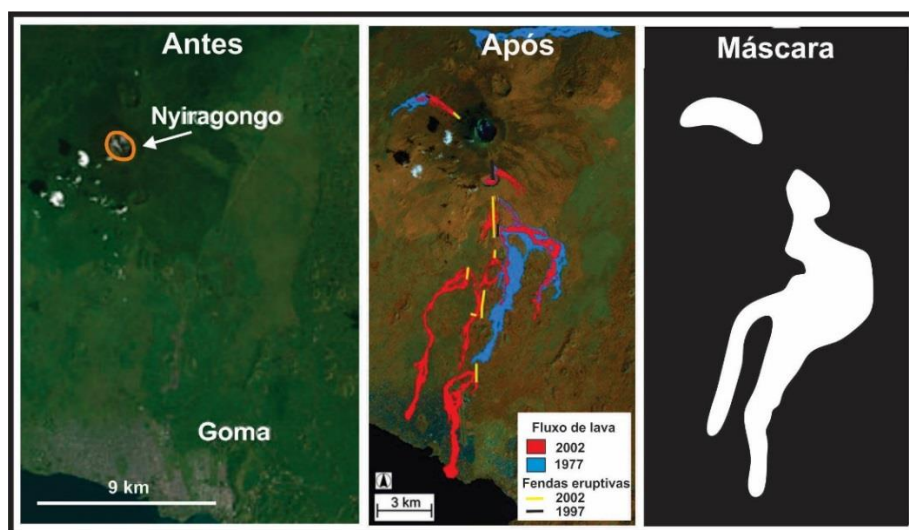


Figura 33. Abordagem não supervisionada da detecção de fluxo de lava da erupção do vulcão Nyiragongo em maio de 2002.

(modificado: <https://reliefweb.int/sites/default/files/styles/large/public/previews/d6/88/d688e10f-1d64-34c5-895a-ce2a12d52997.png>)

As imagens SAR são muitas vezes úteis para detectar áreas afetadas por um desastre natural, pois podem ser adquiridas imediatamente a seguir ao evento, independentemente das condições meteorológicas. Na figura 33 temos duas imagens de radar adquiridas pelos satélites europeus ERS, antes e depois da erupção de maio de 2002, onde um fluxo de lava atingiu o aeroporto da cidade de Goma (República

Democrática do Congo). A imagem à direita é uma máscara das áreas afetadas desenhada manualmente e utilizada para avaliação de métodos de detecção de alterações.

A figura 34, ilustra o resultado de três operadores de distância que podem ser aplicados para detectar mudanças. O primeiro operador é o valor absoluto de uma diferença simples que pode ser vista à esquerda (Fig.34a). Apresenta alto ruído devido ao fenômeno *speckle*, que afeta as imagens SAR. Os outros dois operadores medem a divergência entre as distribuições observadas em uma vizinhança de tamanho 11x11 pixels de duas maneiras. Na imagem que aparece ao centro (Fig.34b), a divergência é calculada a partir das médias e variâncias locais sob a hipótese gaussiana. À direita (Fig.34c), a divergência é calculada diretamente a partir dos histogramas locais. Uma abordagem não supervisionada buscará limitar automaticamente esse tipo de distância para colocar pixels, cujo valor seja maior que o limite na classe “mudança”. Se tivermos informações básicas, poderemos avaliar o desempenho dessas abordagens, variando o limite de detecção.




Figura 34. Resultado obtidos a partir de três operadores de distância, em uma mesma área, aplicados para detectar mudanças.

O segundo exemplo diz respeito à aprendizagem supervisionada. O algoritmo de detecção será guiado por informações especializadas fornecidas na forma de pares dados e classes de membros associados, o conjunto de tais pares constitui a chamada base de aprendizagem. Em ambiente de altas montanhas, geralmente é difícil obter dados concretos em grandes áreas. Para construir essa base, conta-se com uma infinidade de satélites que fornecem informações espectrais variadas. Assim, combinando, por exemplo,

as observações ópticas e SAR, obtidas num pequeno intervalo de tempo, e considerando a informação temporal, se pode construir uma base de aprendizagem muito fiável. Uma vez construída esta base, se necessita escolher um modelo paramétrico e identificar os parâmetros, que maximizam a sua capacidade de reconhecimento, das classes incluídas na base de aprendizagem. Na detecção de alterações, as classes de interesse são “mudança” ou “mesmo estado anterior”. Uma rede neural em evolução é, por exemplo, um modelo relevante para resolver este problema de identificação, quando é adequadamente construída e cuidadosamente treinada.

O exemplo apresentado na figura 35, ilustra a detecção de uma mudança de estado, ou seja, a transição do estado de “neve seca” para o estado de “neve molhada” ou “sem neve”. A neve molhada é mostrada em vermelho no mapa de detecção. Este exemplo é o resultado obtido após o treinamento de uma rede neural convolucional em informações conjuntas de especialistas ópticos e SAR. A óptica detecta a neve na sua totalidade e o radar só consegue distinguir a neve molhada. A combinação dos dois permite monitorar a mudança no estado da cobertura de neve. A detecção de alterações por meio de imagens de satélite é um meio de analisar e extrair informações úteis sobre as mudanças que ocorrem na superfície da Terra. Essas informações permitem avaliar melhor as áreas impactadas por desastres naturais. De um modo mais geral, a detecção de alterações permite monitorizar as variáveis ambientais e, neste sentido, constitui uma ferramenta importante para monitorizar as consequências das alterações climáticas.



Figura 35. Carta de neve do maciço de Monte Branco, França
(modificado: Lê et al., 2023)

III. OS PRINCÍPIOS DA CORRELAÇÃO DE IMAGENS

3.1. O que vem a ser correlação de imagens?

A correlação de imagens é uma técnica que permite medir o deslocamento ocorrido de um determinado ponto, entre duas imagens. É comumente usada para detectar

movimentos de massa a partir de duas imagens ópticas de satélite, adquiridas na mesma área em momentos diferentes.

A figura 36, mostra uma área da superfície terrestre que sofreu um terremoto, enquanto a figura 37 mostra um exemplo de mapa de correlação com a representação do movimento de massa resultante do terremoto. O mapa de correlação foi gerado a partir de uma imagem de satélite tirada antes e depois do terremoto. As cores indicam a magnitude do movimento de massa, enquanto as setas indicam a direção do movimento.




Figura 36. Imagem de uma área da superfície terrestre que sofreu um terremoto.




Figura 37. Mapa de correlação com a representação do movimento de massa resultante do terremoto.

Então, qual é o objetivo da correlação de imagens?

A correlação de imagens permite medir, remotamente, a deformação do solo em grandes áreas com alta densidade espacial, exatidão e precisão. Nas ciências da terra, a correlação de imagens é uma ferramenta poderosa para medir deformações do solo,

associadas a desastres naturais, como terremotos, vulcões, deslizamentos de terra e até mesmo o movimento de geleiras ou dunas de areia.

Esta técnica permite ainda medir movimentos de massa com precisão subpixel. Assim, se tivermos duas imagens com resolução de 1 m, podemos esperar recuperar movimentos de massa com uma precisão de cerca de 10 cm (ou seja 1/10 do tamanho do pixel). No entanto é importante notar que esta precisão ainda é muito inferior à de outras técnicas geodésicas espaciais, como InSAR ou GPS.

No entanto, a correlação de imagens é particularmente eficaz na resolução de descontinuidades acentuadas, como rupturas superficiais de terremotos e deslizamentos de terra. Isto pode ser muito útil, uma vez que outras técnicas mais precisas, como o InSAR, muitas vezes falham perto de descontinuidades acentuadas, enquanto as medições GPS são geralmente muito esparsas. A correlação de imagens é, portanto, uma técnica complementar a essas outras técnicas.

Outra vantagem da correlação de imagens é que se pode correlacionar imagens ópticas separadas por períodos muito longos, ... podendo-se correlacionar imagens adquiridas com diferentes sensores, e ... podendo-se produzir mapas de deslocamento do solo para períodos mais antigos que InSAR ou GPS, remontando ao início do século XX, ou seja, ao início da fotografia aérea na década de 1920.

3.2. Correlação de imagens na prática: pré-processamento de imagens

O COSI-Corr, Ames Stereo Pipeline e MicMac são três aplicativos gratuitos que podem ser usados para correlacionar imagens de satélite.

Antes de correlacionar duas imagens, elas devem ser recalibradas e ortorretificadas. A recalibração envolve o alinhamento de duas imagens de satélite entre si, muitas vezes usando pontos de correspondência, para que os pixels localizados, em locais estáveis, tenham as mesmas coordenadas projetadas no solo.

A ortorretificação envolve a reamostragem de uma imagem de satélite para remover os efeitos da distorção topográfica da imagem, produzindo assim uma imagem com geometria de visão vertical em cada localização de pixel, ou seja, imagem que pode ser sobreposta a um mapa (Fig.38).

Algumas imagens de satélite, como dados Landsat, Sentinel-2 e Planet, são entregues na forma de produto recalibrado e ortorretificado. Neste caso é possível passar diretamente para a etapa de correlação. Caso contrário, se deve recalibrar as imagens por

meio de pontos de ancoragem ou de correspondência, e ortorretificá-las por meio de um modelo digital de terreno (MDT). Assim que se tenha duas imagens ortorretificadas, se pode correlacioná-las e produzir um mapa de deslocamento.

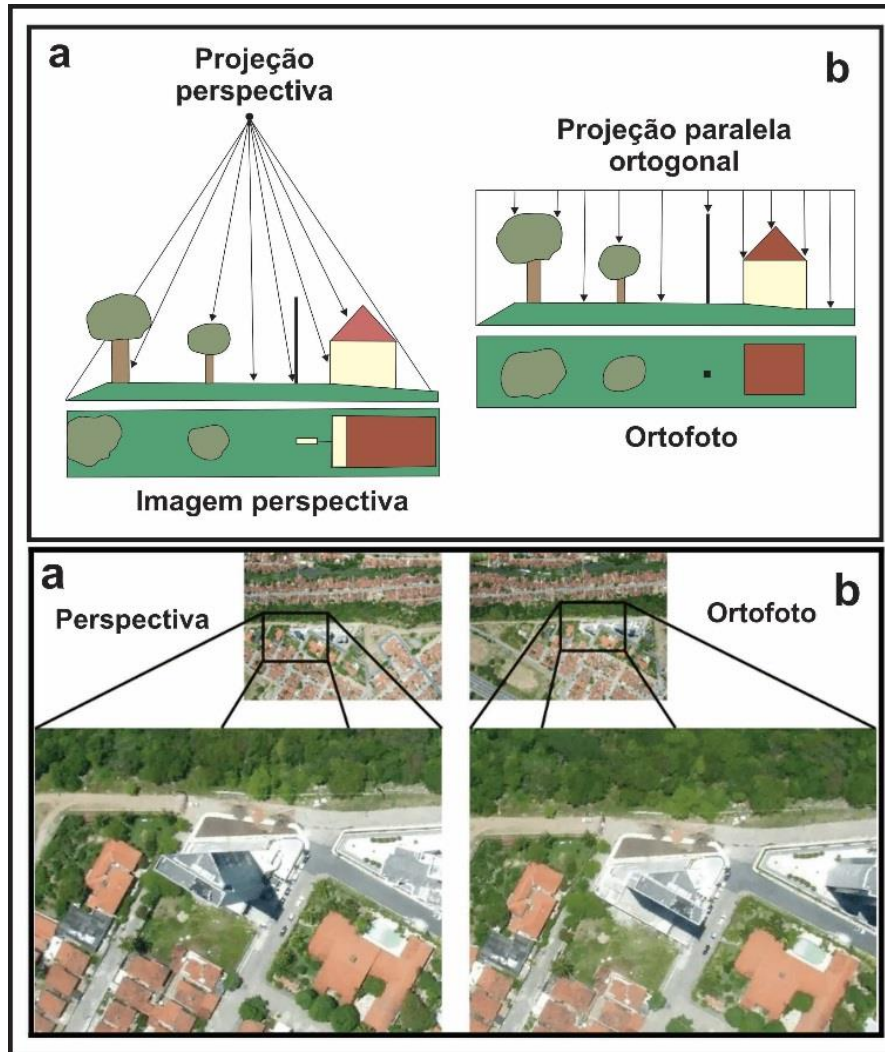


Figura 38. Processo de ortorretificação de uma imagem a partir da imagem de perspectiva.
(modificado: <https://adenilsonjovanini.com.br/blog/ortorretificacao/>)

3.3. Correlação de imagens na prática: metodologia de correlação

Existem duas abordagens comuns para correlacionar imagens: correlação espacial e correlação no domínio da frequência, ambas dão resultados semelhantes.

A correlação espacial é geralmente mais intuitiva de entender, para pessoas sem formação matemática. Normalmente se aborda o problema de correlação especificando uma imagem primária (referência) e uma imagem secundária (em movimento) (Fig.39).

Quer-se ver quão bem a imagem secundária está referenciada à imagem primária, em outras palavras, a imagem secundária está deslocada da imagem primária?

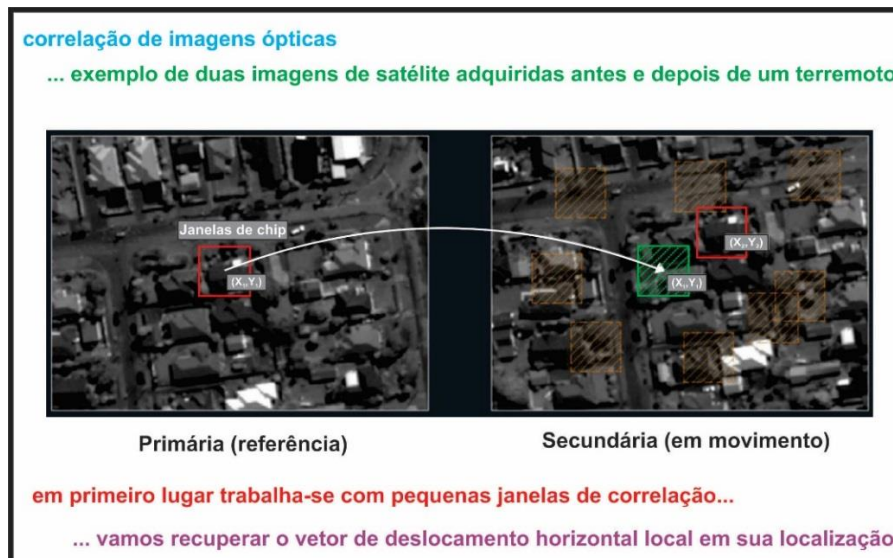


Figura 39. Correlação de duas imagens ópticas antes e depois de um terremoto.
(modificado: Martin & Rathje, 2014)

Frequentemente os deslocamentos entre imagens apresentam grande variabilidade espacial em uma imagem grande, portanto, se necessita resolvê-los em uma escala espacial menor, usando, para isso, uma janela deslizante.

A correlação óptica da imagem mede a deformação que ocorreu entre a aquisição de duas imagens separadas, uma imagem pré-evento (primária), e uma imagem pós-evento (secundária). O processo de correlação trata de encontrar manchas de pixels correspondentes nas duas imagens e obter o deslocamento da localização relativa das duas manchas. A figura 39 ilustra o processo de correlação. A imagem primária é dividida em fragmentos de pixels, chamados de janelas de chip. Para cada janela de chip da imagem primária, é realizada uma busca na imagem secundária com a finalidade de encontrar a localização deste mesmo chip. Por exemplo, o quadrado vermelho na imagem primária descreve uma janela de chip centrada na localização (X_1, Y_1) . Na imagem secundária, a janela do chip é primeiro comparada com os pixels na mesma posição (X_1, Y_1) , assinalado em verde na figura 39. A comparação é medida quantitativamente através de um coeficiente de correlação entre os valores de pixel correspondentes nos dois chips. O chip também é comparado com locais vizinhos, assinalados pelos quadrados laranja e um coeficiente de correlação é calculado para cada local. O chip com a maior correlação, assinalado pelo quadrado vermelho na imagem secundária, é considerada a melhor correspondência e essa localização é considerada como a localização do chip primário na imagem secundária. Uma relação sinal-ruído (SNR) é atribuída à correspondência, refletindo a qualidade da correlação (1 = correlação perfeita; 0 = sem correlação). A posição do chip de melhor correspondência na imagem secundária (X_2, Y_2)

é comparada com a posição na imagem primária (X_1, Y_1) para obter deslocamentos relativos Leste-Oeste e Norte-Sul.

Quando se correlaciona a imagem primária e secundária (Fig.40), se realiza a comparação (ou correlação) em várias regiões pequenas, usando uma medida de similaridade entre essas duas regiões. Essas regiões correspondem a conjuntos de pixels localizados dentro de uma janela deslizante, cujo tamanho normalmente gira em torno de 32 x 32 pixels, podendo ser menor ou maior (Fig.41).

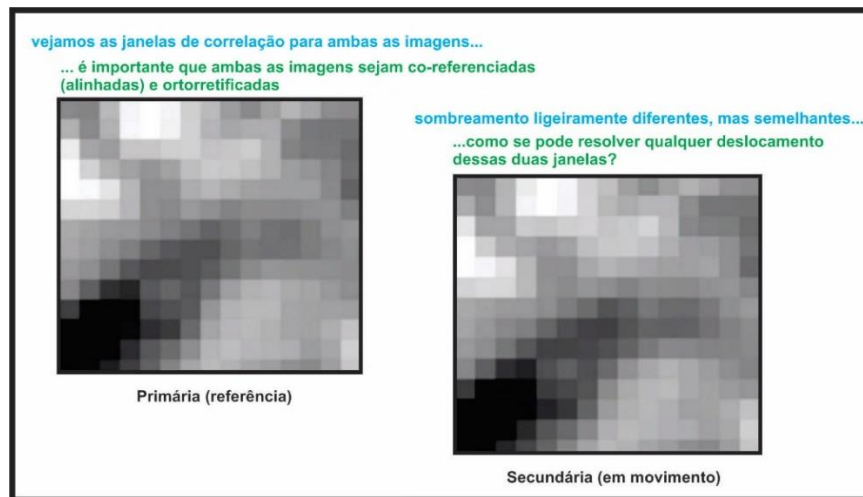


Figura 40. Janelas de correlação entre duas imagens.
(modificado: Stumpf et al.,2017)

Uma das medidas de similaridade mais popular é a correlação cruzada normalizada (Fig.41). A qualidade da correlação é dada pelo coeficiente de correlação, onde 0 corresponde a correlação fraca ou sem correlação e 1 a correlação boa.

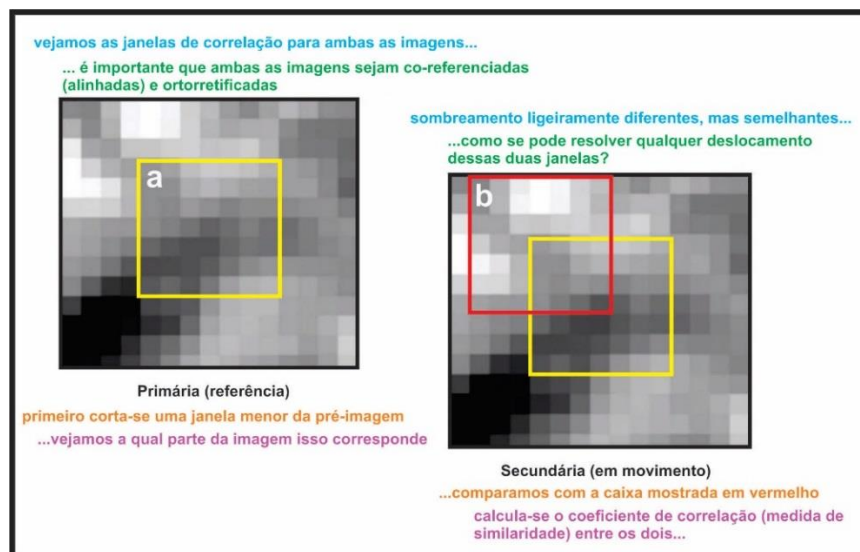


Figura 41. Correlação de duas imagens para a determinação do coeficiente de correlação (r).
(modificado: Stumpf et al.,2017)

Efetua-se uma pesquisa em uma pequena grade, usando numerosas posições diferentes de janelas secundárias em torno da posição fixa da janela primária (Fig.42).

O cálculo do coeficiente de correlação (r) para todas as posições da janela secundária, fornecerá um mapa de como a qualidade da correlação varia no espaço, dependendo da posição da linha e da coluna da janela secundária (Fig.43).

$$r = \frac{\sum_m \sum_n (a_{mn}-A)(b_{mn}-B)}{\sqrt{[\sum_m \sum_n (a_{mn}-A)^2][\sum_m \sum_n (b_{mn}-B)^2]}} \quad (\text{equação de correlação – matlab})$$

onde: A=média (a) B=média (b)

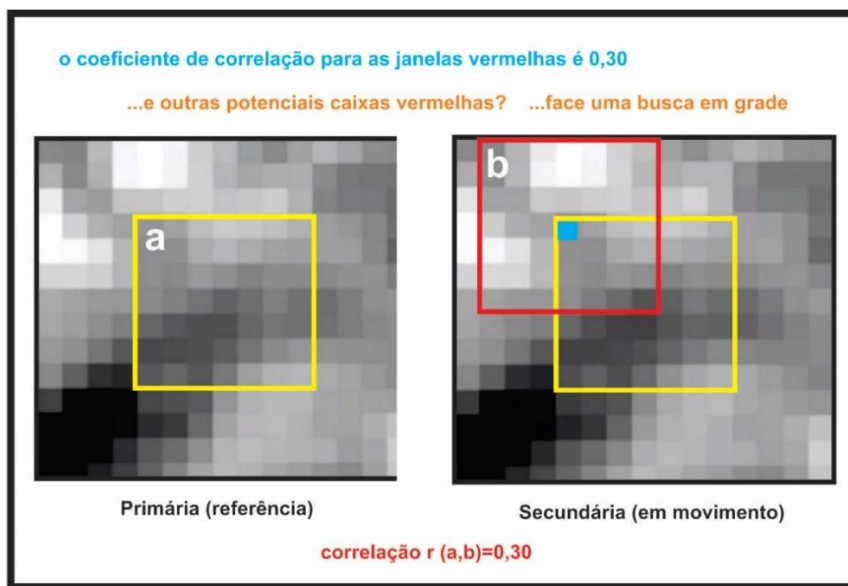


Figura 42. Determinação do coeficiente de correlação.
 (modificado: Stumpf et al.,2017)

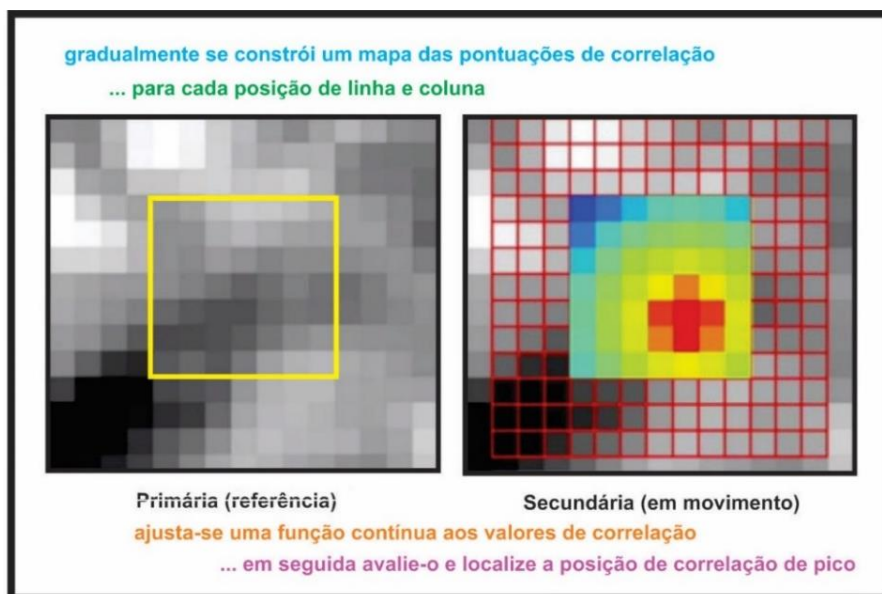


Figura 43. Mapa dos deslocamentos locais ao longo de toda a imagem.
 (modificado: Stumpf et al.,2017)

Em seguida, se ajusta uma função contínua a esses valores e se avalia essa em uma grade mais fina (dando precisão de subpixel), para encontrar a melhor posição de linha e coluna da janela secundária e, portanto, a melhor pontuação de correlação (Fig.44). Obtém-se assim o movimento preciso entre as duas janelas.

À medida que se calcula o deslocamento sobre uma pequena área, em vários locais ao longo de toda a imagem, se pode produzir um mapa de como os deslocamentos locais variam no espaço da imagem.

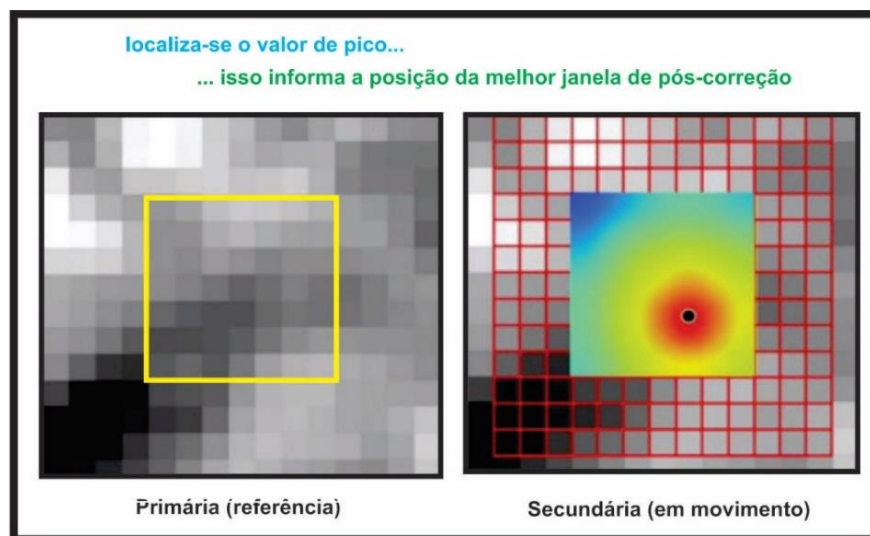


Figura 44. Melhor janela de pós-correção.
(modificado: Stumpf et al.,2017)

Também se pode acompanhar a pontuação máxima de correlação para cada posição, o que pode ser útil para eliminar valores não confiáveis durante o pós-processamento.

Além disso, também é possível correlacionar duas imagens no domínio da frequência, onde, em vez de mover a janela de correlação secundária no espaço (ou seja, entre diferentes posições de linha e coluna), basta olhar para a diferença de fase das transformadas de Fourier da imagem primária e da imagem secundária.

3.4. Correlação de imagens na prática: pós-processamento de correlação

Os mapas de deslocamento bruto, geralmente contêm muito ruído e é por isso que o pós-processamento é essencial para poder interpretar corretamente os mapas de deslocamento.

As fontes típicas de ruído são: valores irreais, rampas globais (devido ao desalinhamento das imagens de satélite), ruído estereoscópico, sulcos, ondulações (produzidas pelas vibrações do satélite), artefatos dobrados, ruído de alta frequência, ruído correlacionado com a topografia (devido às condições de iluminação diferente das imagens de satélite de entrada), etc.

A precisão da correlação da imagem com fotos aéreas ou de satélite é geralmente da ordem de 1/10 de pixel. No entanto, a magnitude do ruído de correlação pode facilmente atingir vários pixels, especialmente para ruído estereoscópico residual que não foi removido durante a ortorretificação.

Estas fontes de ruído podem ser significativamente reduzidas pelo pós-processamento, o que é essencial para poder interpretar corretamente o seu mapa de deslocamento. Esta etapa requer um pouco mais de reflexão do que a etapa de correlação.

A partir do momento que se tem os mapas de deslocamento pós-processados, se pode usá-los para realizar análises científicas, por exemplo, se pode medir o deslocamento de uma falha.

A correlação de imagens se tornará ainda mais interessante no futuro, à medida que se tenha acesso a imagens estereoscópicas de maior resolução, adquiridas em escalas de tempo cada vez mais curtas. Isto permitirá processar séries temporais densas, o que ajudará a caracterizar melhor, em 3D, a natureza dinâmica dos processos que deformam a superfície terrestre.

IV. MEDIDA DA TOPOGRAFIA POR FOTOGRAMETRIA

4.1. Princípios gerais

Para observar a deformação de objetos geofísicos que podem representar riscos naturais, como vulcões, deslizamentos de terra ou geleiras, é muito útil poder reconstruir a topografia da superfície desses objetos. Uma abordagem para calcular a topografia da superfície terrestre é a fotogrametria: literalmente, o uso de fotografias para registrar medições. A fotogrametria se baseia na chamada aquisição estereoscópica de duas ou mais imagens, tiradas com ângulos de visão diferentes e semelhantes à percepção humana do relevo, através dos nossos dois olhos.

Para ilustrar isso se tem a figura 45, onde o princípio básico consiste em medir o movimento aparente de um objeto entre essas duas imagens, denominado paralaxe. Na verdade, o objeto mais próximo, representado na figura em vermelho, terá maior paralaxe

do que o objeto mais distante, representado na figura em azul. Assim, é possível calcular a distância do objeto à câmera, por triangulação. Conhecendo-se com precisão a posição da câmera ou a posição de um determinado ponto nas imagens, é possível calcular a posição tridimensional de cada ponto da imagem e reconstruir o que se chama de nuvem de pontos.

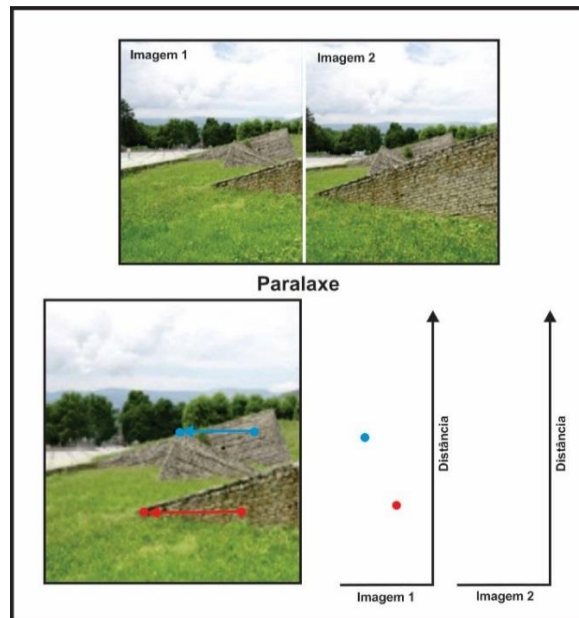


Figura 45. Medida do movimento aparente entre duas imagens consecutivas.

No sensoriamento remoto, as imagens estereoscópicas são tradicionalmente adquiridas por aeronaves ou satélites que adquirem imagens ao longo de uma linha de voo ou órbita com sobreposição significativa entre elas (Fig.46). Mais recentemente, os chamados satélites ágeis permitem rastrear um objeto direcionando a câmera ao longo da órbita.




Figura 46. Processo de obtenção de imagens com superposição.
(fonte: <https://wingtra.com/wp-content/uploads/photogrammetry-1.png>)

Na fotogrametria é necessário o uso de aparelhos fotográficos ou câmeras. Vários parâmetros da câmera devem ser levados em consideração para reconstruir a topografia. Distingue-se entre parâmetros externos e parâmetros internos. Os parâmetros externos são a posição e orientação da câmera. Os parâmetros internos estão ligados ao sistema óptico: centro óptico da lente, distância focal e possíveis distorções da lente, que levam à deformação geométrica, por exemplo, as distorções em forma de almofada e distorções em forma de barril (Fig.47).



Figura 47. Representação esquemática das distorções em forma de almofada e de barril.
(modificado: <https://lesdeuxpiedsdehors.com/wp-content/uploads/2022/06/les-distorsions-en-photographie.png>)

Os parâmetros internos são geralmente estimados antes da aquisição das fotos por calibração ou podem ser estimados a posteriori (Fig.48).

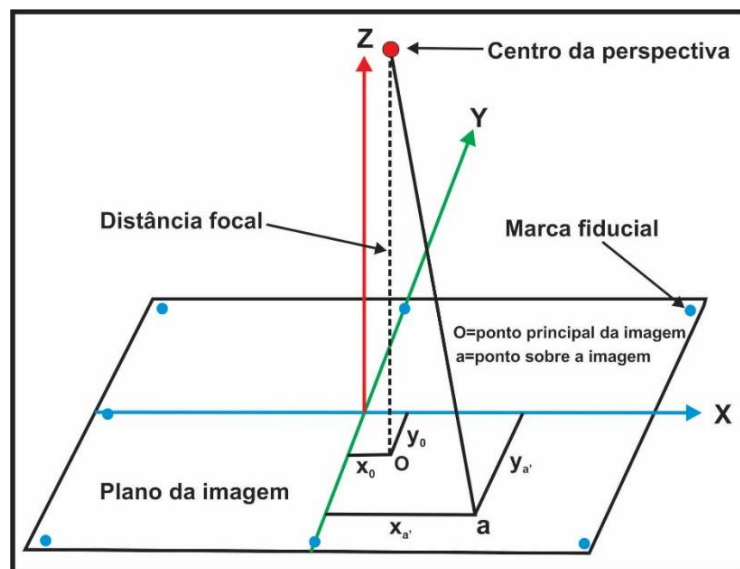


Figura 48. Geometria interna e variáveis associadas a uma imagem capturada por uma câmera aérea.
(modificada: ERDAS,2010)

Parâmetros externos às vezes são conhecidos através de GPS integrado ou sistemas inerciais, mas geralmente são refinados após o fato (Fig.49).

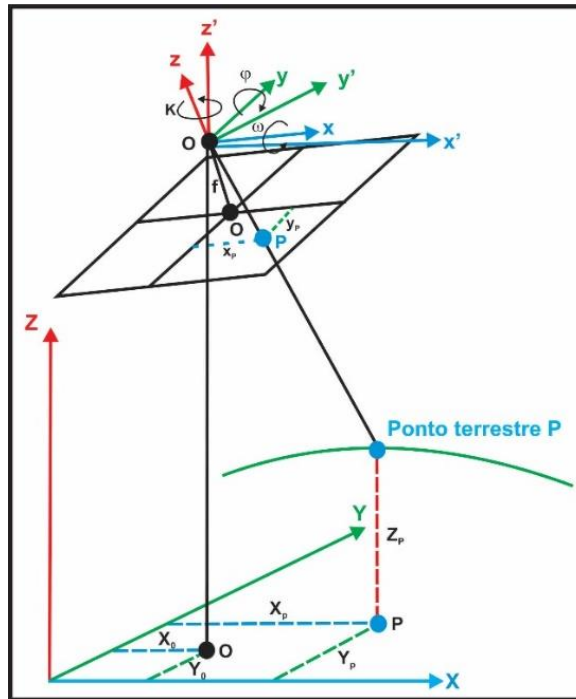


Figura 49. Parâmetros externos de orientação e posição da câmera.
(modificado: ERDAS, 2010)

4.2. Metodologia em detalhe

Vejamos os detalhes do método fotogramétrico, que é dividido em cinco etapas principais. O primeiro passo consiste em encontrar pontos homólogos entre pares de imagens estereoscópicas. Atualmente essa identificação é feita, sobretudo, através de ferramentas de visão computacional, como o método Transformação de Recursos Invariáveis em Escala (SIFT), ou muito recentemente, recorrendo à Inteligência Artificial (IA), denominada Aprendizagem Automática (AA) (Fig.50). A posição desses pontos permite estimar a orientação relativa das câmeras entre si, durante a filmagem.




Figura50. Conjunto de pontos homólogos documentados na fotografia com coordenadas X,Y,Z.
(fonte: Imagens de satélite e observatório do glaciar MNTS Pléiades/ Pléiades @CNES 2017-2022)

A segunda etapa, opcional, consiste em identificar pontos na imagem cuja posição no solo é conhecida com precisão, chamados de Pontos de Controle no Solo (PCS)(Fig.51). A posição destes pontos pode ser conhecida com muita precisão, a partir de medições de campo feitas por GPS, ou a partir de imagens georreferenciadas e de uma topografia já existente, por exemplo, de uma campanha de fotogrametria anterior. Estes pontos permitem restringir a posição e orientação absoluta das câmeras no espaço. Esta etapa não é necessária se os parâmetros externos das câmeras forem bem conhecidos, como é o caso das missões de satélite modernas.




Figura 51. Pontos de controle na imagem cujas posições no solo são conhecidas.
(fonte: Imagens de satélite e observatório do glaciar MNTS Pléiades/ Pléiades @CNES 2017-2022)

A terceira etapa consiste em garantir a consistência entre as posições das câmeras, a qual é denominada de ajuste de feixe. A posição de um ponto homólogo é limitada pela equação de colinearidade ou coplanaridade. Estas refletem o fato de que os raios de luz provenientes do mesmo objeto e atingindo as duas câmeras, estão no mesmo plano do espaço. A partir de uma posição inicial aproximada das câmeras, é possível traçar esses raios de luz que deveriam cruzar na posição do objeto. Em caso de erro na posição das câmeras, esta intersecção não acontece (Fig.52). É possível, utilizando métodos de otimização, estimar a posição e orientação das câmeras de forma que a distância de intersecção seja a mais próxima possível de zero.




Figura 52. Compensação ou ajuste de feixe.

A quarta etapa consiste em calcular a paralaxe para cada pixel da imagem 1 na imagem 2 (Fig.53). Atualmente esta etapa é obtida se utilizando as abordagens de correlação de imagens apresentadas anteriormente. Geralmente é possível encontrar um ponto homólogo para cada pixel, exceto nos seguintes casos:

1º caso: se o pixel não for fotografado durante as duas aquisições.

2º caso: se o pixel estiver mascarado por outro objeto, neste caso se fala de oclusão.

3º caso: se a textura for insuficiente na imagem, como no caso de superfícies perfeitamente lisas ou saturadas, por exemplo uma superfície coberta de neve fresca ou a superfície de um lago.




Figura 53. Abordagem de correlação de imagens para a determinação da paralaxe.

(fonte: openMVG.readthedocs.io)

Por fim, na quinta etapa, é possível reconstruir a posição 3D de cada pixel por triangulação, que é chamada de nuvem de pontos (NP) (Fig.54). Esta etapa requer o

conhecimento da paralaxe calculada na etapa 4, bem como dos parâmetros internos e externos das câmeras, calculados na etapa 3.

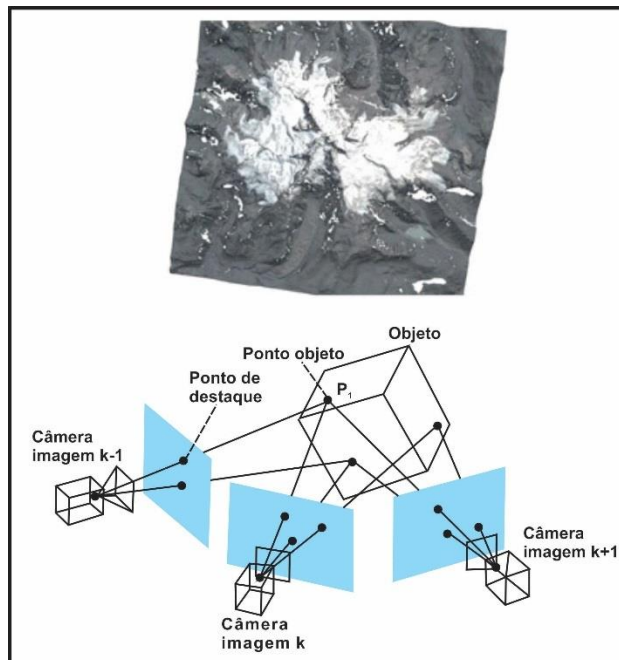


Figura 54. Reconstrução da posição 3D de cada pixel por triangulação.
(fonte: openMVG.readthedocs.io)

4.2.1. Aplicação para a medida de deformação.

Para um objeto essencialmente plano, como uma porção da superfície terrestre, pode ser mais simples representar uma nuvem de pontos (NP) na forma de um Modelo Digital de Terreno (MDT). Um MDT é uma representação em uma grade regular ou matricial da topografia (Fig.55a). Na verdade, é uma imagem 2D onde o valor de cada pixel representa a altitude da superfície considerada.

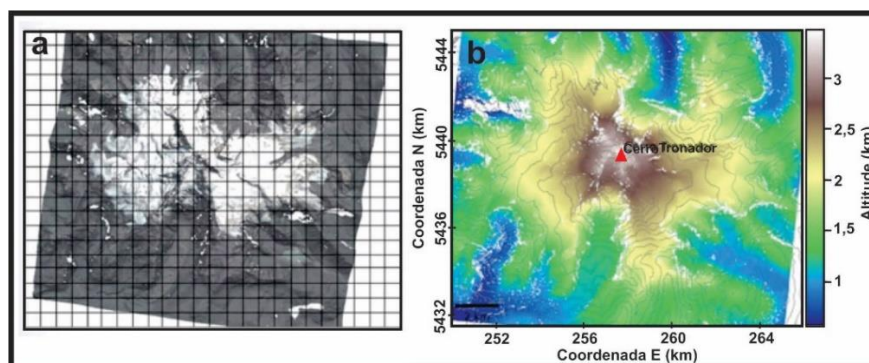


Figura 55. a) Representação de uma grade regular. b) Modelo digital do terreno
(fonte: openMVG.readthedocs.io)

O MDT pode ser obtido a partir de nuvens de pontos, por exemplo, tomando a altitude média de todos os pontos presentes no pixel (Fig.55b).

Quando se tem diversas observações em datas diferentes, é possível subtrair dois MDTs para calcular o deslocamento vertical ou a variação de altitude da superfície, em cada ponto. Isto permite quantificar certos processos naturais, como o afinamento dos glaciares, o impacto da erosão ou deslizamentos de terra.

Na figura 56, se pode ver, em vermelho, as áreas de afinamento ou subsidência da superfície, e em azul, as áreas de espessamento ou emergência da superfície. Ao subtrair MDT, muitas vezes é necessário corrigir certas falhas de georreferenciamento que podem ter persistido durante a geração do MDT. O defeito mais comum é um deslocamento horizontal, o qual resulta em variações opostas de altitude para objetos com orientações opostas, por exemplo, Norte-Sul ou Leste-Oeste. Para defeitos de deslocamento maiores, o chamado método Ponto Interativo Mais Próximo (PIMP), pode ser usado para registrar duas nuvens de pontos.

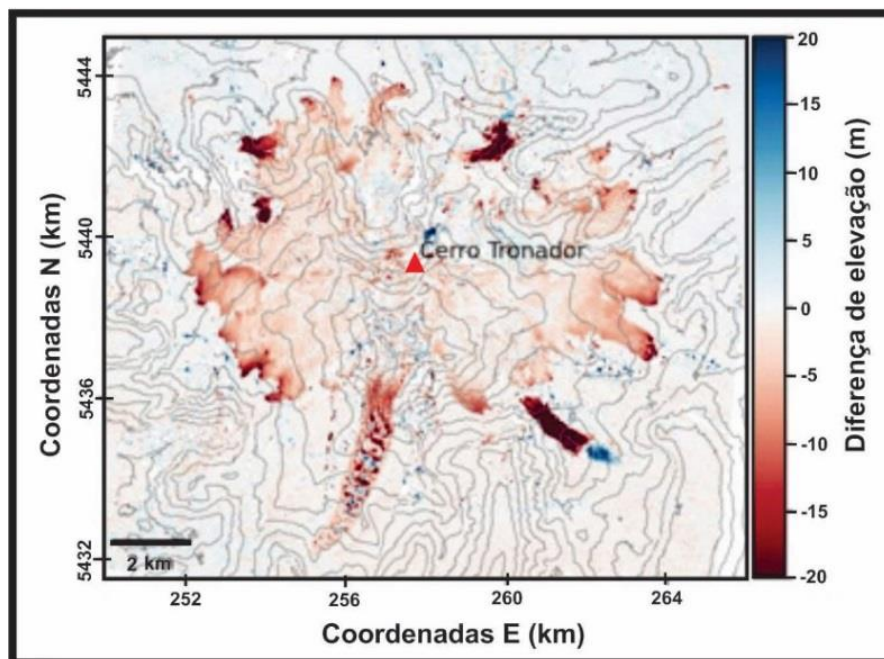


Figura 56. Modelo Digital do Terreno mostrando as áreas de subsidência e as de elevação na região do Cerro Tronador - Chile.
(fonte: openMVG.readthedocs.io)

Muitas vezes é interessante projetar as imagens originais num plano, para observar a condição da superfície dos objetos estudados. Para sobrepor essas imagens em um mapa, é necessário corrigi-las, para que cada pixel seja visto como se fosse observado verticalmente, em um terreno plano. Este processo é chamado de ortorretificação. Esta correção é particularmente visível para objetos verticais (Fig.57).

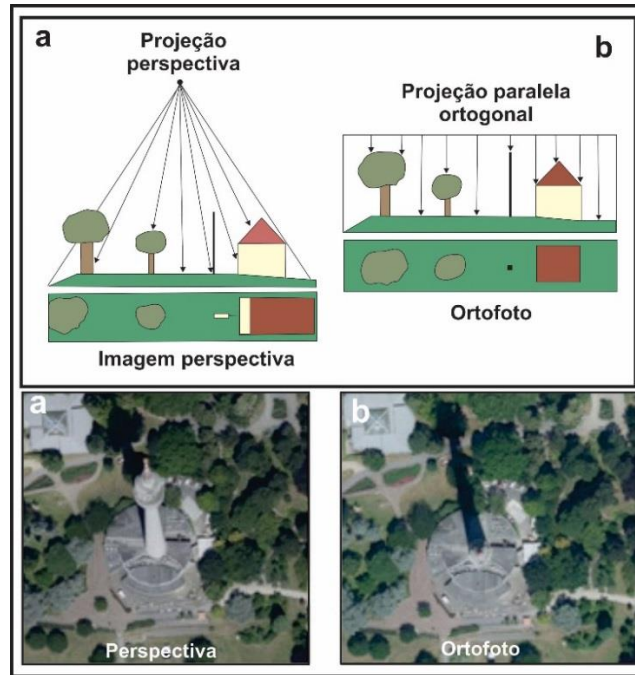


Figura 57. a) Imagem original. b) Imagem ortorretificada.
(fonte: copyright geavis – fotos: district de Colongne-Allemagne)

Um penhasco visto obliquamente ocupa, na verdade, uma área extremamente pequena no mapa. Para certos objetos de estudo que estão longe da horizontal, como a erosão de uma falésia, a abordagem MDT e ortofoto não é adequada. Nestes casos, é habitual observar as mudanças numa direção normal à superfície em questão. É o caso, por exemplo, do método denominado M3C2 como a altitude da superfície, a partir de imagens estereoscópicas (Fig.58). Tais imagens são acessíveis a partir de campanhas de medição terrestre, campanhas aéreas ou missões de satélite, como o sensor ASTER a bordo do satélite Terra ou a missão CNES Pléiades. Mais recentemente, a grande acessibilidade dos drones, permite medir a topografia de pequenas áreas de estudo com baixo custo e alta resolução espacial.




Figura 58. Observação de mudanças de uma direção normal a superfície em questão, denominado método M3C2: distância média entre as duas nuvens medidas ao longo de N entre pontos médios i_1 e i_2 , derivado em uma escala d.
(fonte: James et al, 2017)

V. InSAR E AS SÉRIES TEMPORAIS

5.1. Princípios do InSAR

A Interferometria de Imagens Obtidas por Satélites (InSAR) é uma técnica que permite a exploração de imagens de radar, as quais contêm a amplitude e a fase da onda retroespalhada (Fig.59).

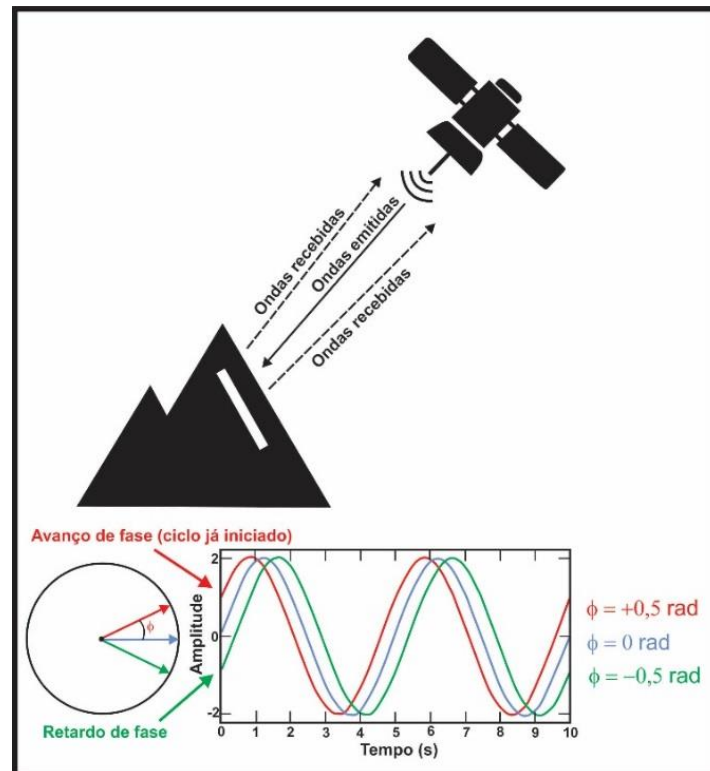


Figura 59. Imagem Radar: amplitude e fase da onda retroespalhada.
(modificado: <https://www.researchgate.net/publication/258806551/figure/fig4/AS:297374686695427@1447911058229/DInSAR-basic-concept.png>)

Os valores da imagem são codificados como números complexos. Os pixels da imagem são classificados de acordo com a distância ao satélite, e o radar é o instrumento para medir a distância do satélite à terra, dentro do ângulo de visão do radar (Fig.59). Quando se observa a fase de uma imagem de radar cujo valor está localizado entre $-\pi$ e π , ela aparece como um sinal aleatório. A interação entre a onda e o solo é complicada porque depende da posição relativa dos objetos no pixel. Esta é a fase adequada da imagem (Fig.60).

Tomemos o caso idealizado em que o satélite passa exatamente no mesmo local uma segunda vez e a superfície do solo não mudou, e a desaceleração da onda devido à atmosfera é idêntica. A fase da segunda imagem (Fase 2) será então idêntica à primeira (Fase 1) (Fig.61).




Figura 60. Imagem de fase do Radar
(modificado: a. Angier,2020. b. Moreira et al.2013).

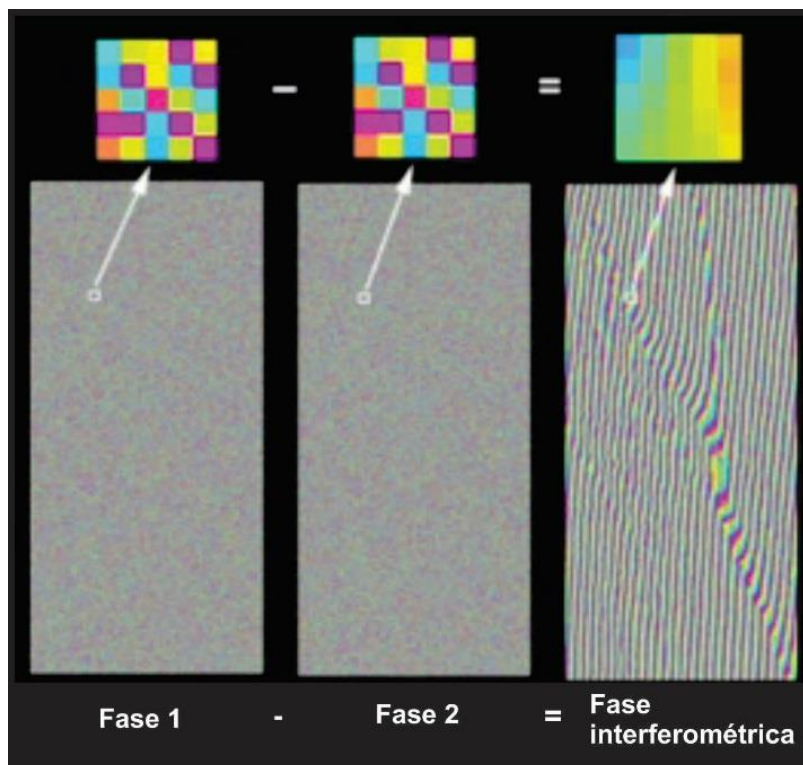


Figura 61. Diferença de fase entre a fase 2 e fase 1 e obtenção da fase interferométrica.
(modificado: Grandin, 2015)

$$\varphi_1 = \varphi_{\text{tempo trajeto 1}} + \varphi_{\text{próprio 1}}$$

$$\varphi_2 = \varphi_{\text{tempo trajeto 2}} + \varphi_{\text{próprio 2}}$$

$$\Delta\varphi = \varphi_2 - \varphi_1$$

se

$$\varphi_{\text{próprio 1}} = \varphi_{\text{próprio 2}}$$

$$\Delta\varphi = \varphi_{\text{tempo trajeto 2}} - \varphi_{\text{tempo trajeto 1}}$$

O interferograma será zero em todos os lugares, entretanto isso nunca acontece. Por quê? Em primeiro lugar, durante a sua segunda passagem, o satélite não retorna exatamente ao mesmo lugar. A distância entre as duas passagens é chamada de linha de base. Assim, o tempo de ida e volta, a distância entre o mesmo ponto e o satélite no tempo 1 e no tempo 2, não será a mesma. Isto induzirá uma diferença de fase que dependerá da topografia e da posição dos satélites (Fig.62).




Figura 62. Diferença de fase entre duas passagens do satélite pelo mesmo lugar.
 (modificado: Augier, 2020)

Como se sabe exatamente a posição dos satélites, ou seja, a sua órbita, e uma superfície de referência, o elipsoide terrestre, se pode encontrar, a partir da diferença de fase, a altitude em relação a este elipsoide e assim obter os Modelos Digitais do Terreno (MDT) (Fig.63).

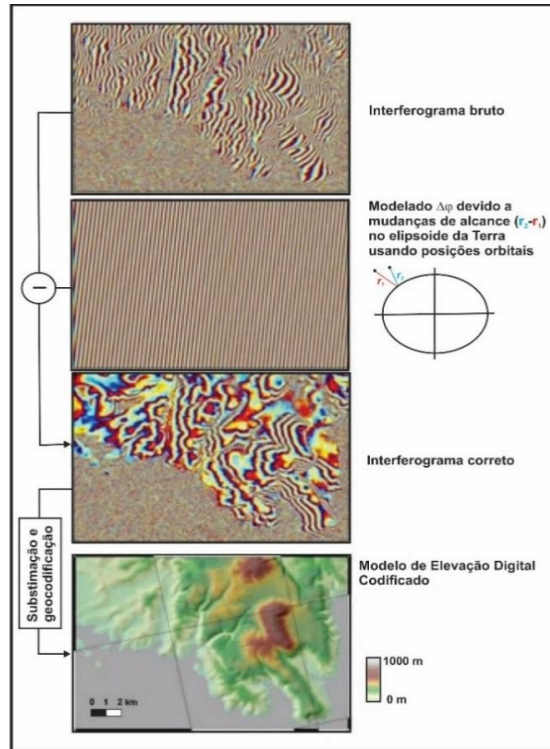


Figura 63. Fase para a obtenção do Modelo Digital do Terreno.

No interferograma corrigido se observam franjas que acompanham a topografia como curvas de contorno (Fig.64). É como se estivéssemos andando pela topografia em uma bicicleta cujas rodas foram pintadas com diversas cores, representando a fase que varia entre $-\pi$ e π . A cada volta da roda, a impressão cria uma franja. Isto envolve contar as rotações das rodas e as franjas, para encontrar a altitude. Este é o chamado estágio de desenrolamento das franjas interferométricas.




Figura 64. Fase de processamento com o desenvolvimento de franjas que acompanham a topografia como curvas de contorno.
(modificado: Augier, 2020)

Se entre as duas passagens do satélite o solo se mover, por exemplo, devido a intumescência de um vulcão, isso modificará a distância Terra-satélite e a diferença de fase também conterà o efeito desse deslocamento (Fig.65).




Figura 65. A mudança de alcance causada pelo deslocamento do solo medida ao longo da linha de visão do radar (LOS)

(modificado: <https://site.tre-altamira.com/wp-content/uploads/InSAR-Interferometric-synthetic-aperture-radar.jpg>)

Para extraí-lo, se inicia removendo o efeito da topografia, usando um Modelo Digital Externo do Terreno (MDET) (Fig.66).

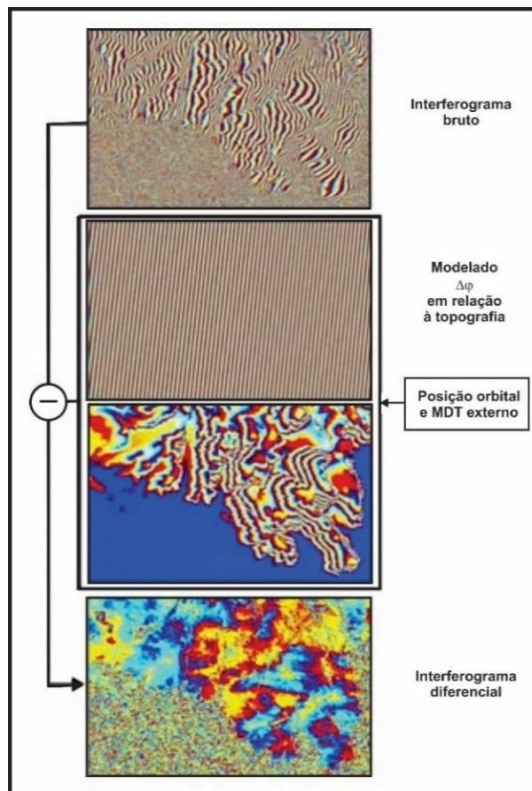


Figura 66. Interferograma com a remoção do efeito da topografia

O interferograma apresenta então franjas associadas à aproximação ou distância do solo em relação aos satélites. Deve-se contar o número dessas franjas para desenrolar a fase e obter o deslocamento do solo.

Na figura 67, se tem um interferograma que captura uma deformação do vulcão Piton de la Fournaise, um vulcão ativo da Ilha da Reunião.

Ao se ampliar a área do vulcão, se observa que à medida que nos aproximamos da cratera, há uma sucessão de franjas que vão da coloração do amarelo ao vermelho. Olhando para a escala, se vê que nesse sentido a fase diminui, o que significa que a distância terra-satélite diminui à medida que nos aproximamos da cratera. Os vulcanologistas interpretam este sinal como uma elevação da superfície do solo, induzida pelo estabelecimento de uma intrusão magmática, em profundidades rasas. Tem-se o deslocamento, mas em ângulo com unidade em radianos. Então, como se converte a fase de radianos em unidades de movimento do solo até o satélite? Isso dependerá do comprimento de onda usado.

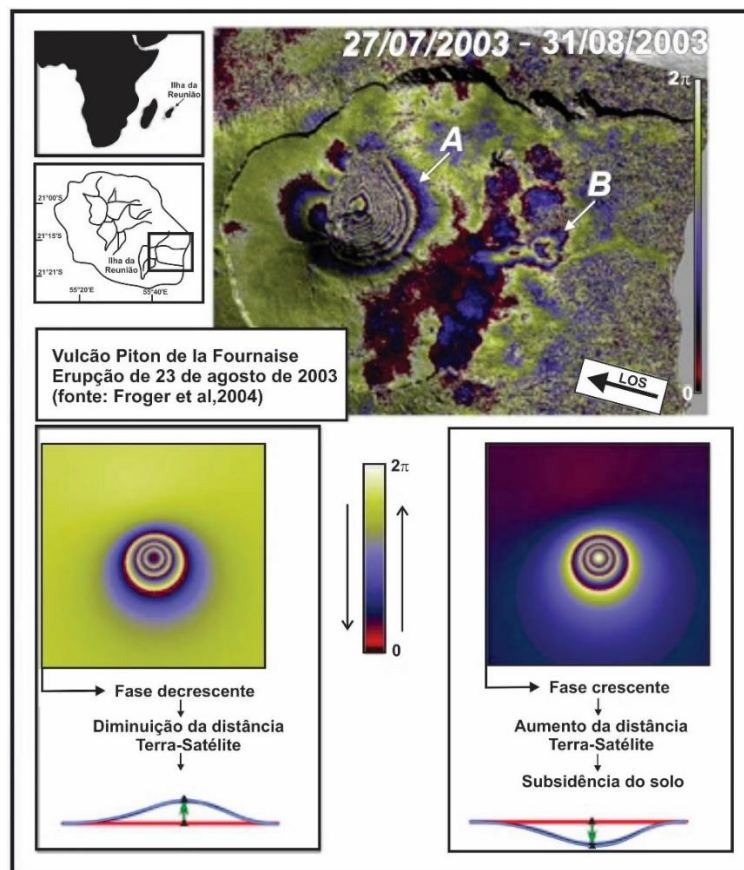


Figura 67. Exemplo de um interferograma do vulcão Piton de la Fournaise, na ilha da Reunião. Interferograma abrangendo 35 dias, de 27 de julho a 31 de agosto de 2003. As fases foram desenhadas no DEM sombreado. Um ciclo completo de fase (vermelho-azul-amarelo) representa um aumento no alcance de 2,8 cm entre a superfície terrestre e o satélite. A) padrão de franjas relacionado à erupção de agosto de 2003; B) padrão de franjas relacionado com a compactação de fluxos lávicos recentes.

(modificado: Froger et al, 2004)

No caso do satélite Sentinel-1, o comprimento de onda tem o valor de 5,6 cm e, portanto, uma franja corresponderá a 2,8 cm de movimento na direção de visão do satélite (Fig.68).

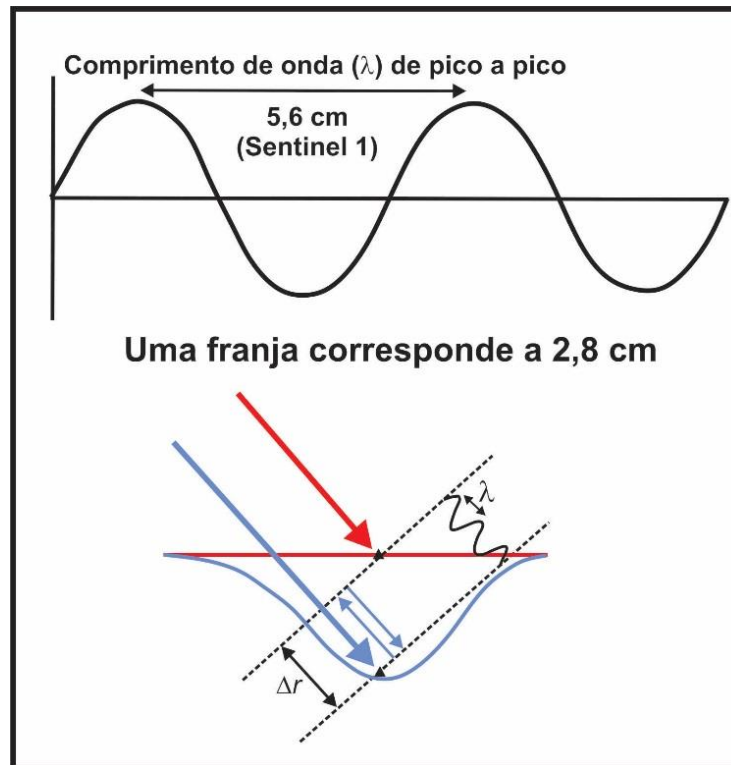


Figura 68. Comprimento da franja na direção de visão do satélite.

(modificado: <https://site.tre-altamira.com/wp-content/uploads/InSAR-Interferometric-synthetic-aperture-radar.jpg>)

Parte extra $2 \times \Delta r = \varphi \lambda_{\mu} \frac{\lambda}{2\pi}$ Para uma franja (1 ciclo) $\Delta r = \varphi \lambda_{\mu} \frac{\lambda}{4\pi}$

Na verdade, o comprimento de onda deve ser dividido por dois porque a deformação observada é duplicada pelo percurso de ida e volta da onda. Movimentos terrestres da ordem de centímetros, podem ser medidos em um interferograma, com satélites localizados a várias centenas de quilômetros acima do nível do mar.

Até agora, para compreender plenamente o princípio, se levantou a hipótese de que o tempo de propagação está ligado apenas à distância terra-satélite e que a própria fase entre as duas datas se anula. Mas como podemos explicar os padrões *wavelet* ou frontais nos interferogramas, bem como as áreas onde a fase parece ruidosa? (Fig.69).

Muitos padrões nos interferogramas são devidos a heterogeneidades espaciais da atmosfera atravessada pela onda. Na verdade, a atmosfera, contendo vapor de água,

introduz atrasos na propagação das ondas (Fig.70). Esses atrasos são da ordem de 1 a 6 cm nos interferogramas. Eles são perturbadores porque se misturam ao sinal de movimento, entretanto podem ser parcialmente corrigidos por métodos empíricos, modelos atmosféricos ou mesmo medições externas como GPS.




Figura 69. Padrões diferenciais nos interferogramas.
(modificado: Augier, 2020)




Figura 70. Perturbações ocasionadas pela presença de nuvens.
(modificado: Augier, 2020)

O ruído é causado por uma linha de base muito grande entre as duas aquisições ou, por uma mudança na organização dos alvos presentes dentro de um pixel, os quais causarão uma decorrelação temporal do sinal (Fig.71), por exemplo, devido à vegetação muito variável ou à deformação excessiva entre as duas datas. Quanto mais tempo passar entre essas duas aquisições, mais áreas de decorrelação haverá, principalmente em áreas com vegetação.

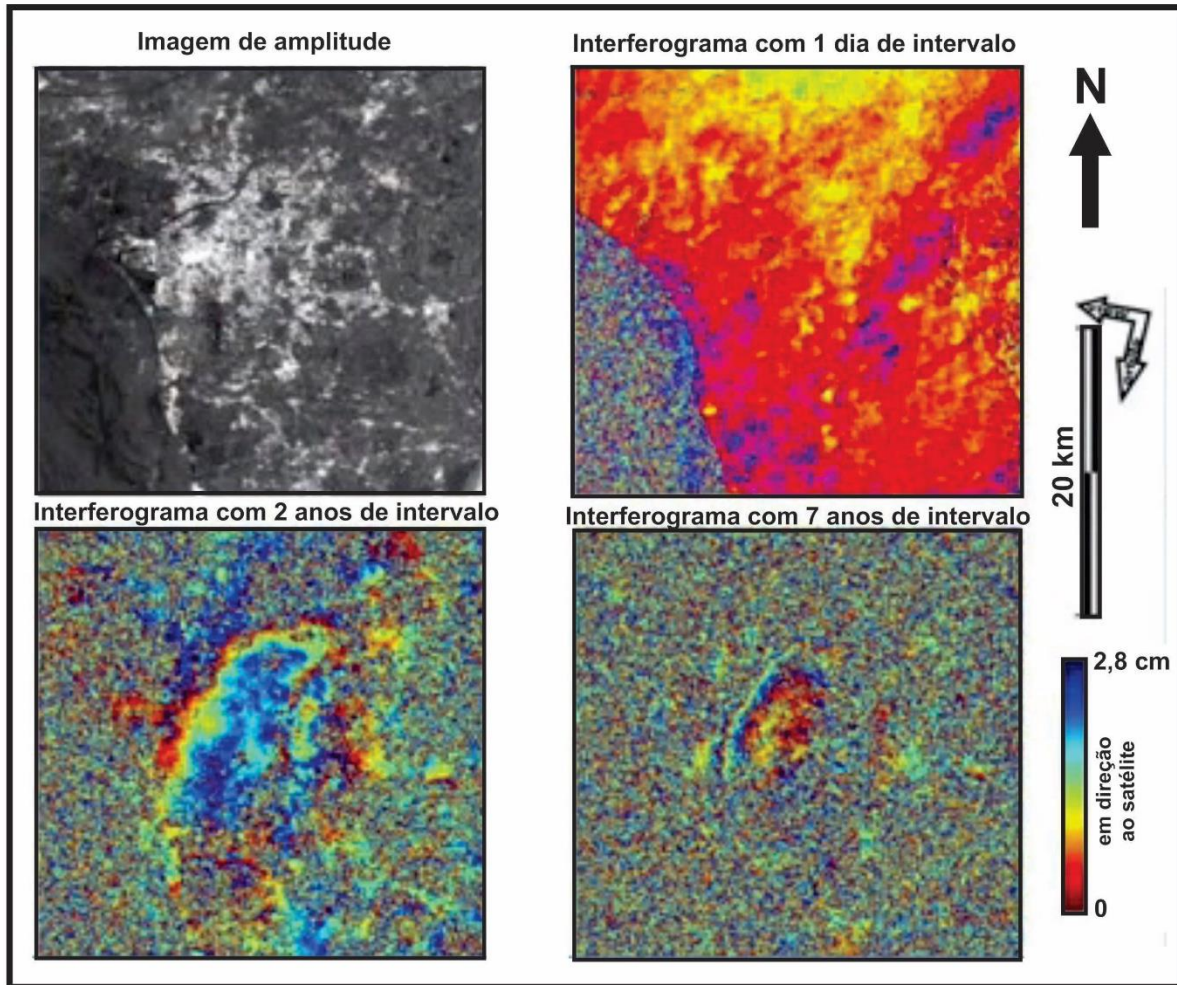


Figura 71. Decorrelação temporal de uma imagem com o passar do tempo.

Para evitar ao máximo esses efeitos, se usam filtros que consistem em calcular a média de diferentes pixels ou em selecionar os pixels mais estáveis. A filtragem leva à perda de resolução espacial, mas permite ganhos na qualidade do sinal (Fig.72). Em geral, para um interferograma filtrado do tipo Sentinel-1, temos resoluções espaciais de 100 a 200 m. Devemos lembrar que um interferograma contém a diferença de fase e permite obter a altitude ou o deslocamento do solo.




Figura 72. Um interferograma antes e após a filtragem.
(fonte: Agência Espacial Europeia-ESA)

Viu-se que o deslocamento é medido apenas no ângulo de visão do satélite. A precisão da medição do deslocamento é de alguns centímetros, para um interferograma obtido pelos atuais satélites radar do tipo Sentinel-1, com resolução espacial em torno de 10 m. Se buscarmos reduzir ruídos como o ruído atmosférico, por exemplo, teremos uma resolução espacial de 100 a 200 m. Os principais limites da interferometria serão o atraso atmosférico, a decorrelação temporal e a resolução da ambiguidade que não permite medir deslocamentos excessivamente grandes.

5.2. Séries temporais

Neste item veremos como combinar múltiplas imagens para gerar séries temporais de deslocamentos de solos. Os satélites adquirem imagens com grande regularidade e, portanto, em grande número, mesmo quando as condições de aquisição são específicas. Por exemplo, os satélites radar utilizam ondas que podem passar pelas nuvens e mesmo ser transmitidas à noite. Assim temos que com apenas dois satélites, a constelação Sentinel-1 imageia completamente a superfície do globo em seis dias, em órbita ascendente (Fig.73).

Em uma mesma área geográfica se pode obter assim até 350 imagens, todas com a mesma geometria.



Figura 73. Aquisição de imagem pelo satélite Sentinel 1.
(fonte: <https://adenilsongiovani.com.br/blog/wp-content/uploads/2021/11/sentinel-1-780x437.jpg>)

Mas como se pode usar todas essas imagens? Pode-se fazer o que chamamos de séries temporais, as quais são sequências de medições apresentadas em ordem cronológica (Fig.74). Graças a elas, se pode acompanhar as mudanças, ao longo do tempo, que falam sobre os processos naturais.




Figura 74. Sequência de medidas apresentadas em ordem cronológica.
(modificado: <https://www.cesbio.cnrs.fr/wp-content/uploads/2022/07/patches-1-1-400x235.png>)

Estas alterações, ao longo do tempo, podem ser mudanças no estado da superfície, ou movimentos do solo como na figura 75, que mostra uma protuberância do solo ligada a uma intrusão de magma, ou mesmo variações de altitude.




Figura 75. Mudança no estado da superfície do solo.
 (modificado: Augier, 2020)

As vantagens de construir séries temporais são inúmeras. Essas permitem uma melhoria muito forte na precisão da medição e possibilitam visualizar fenômenos transitórios, como o mostrado na figura 75, de uma aceleração da protuberância de um vulcão antes de uma erupção.

5.2.1. Como fazer séries temporais a partir de séries de imagens

Um método simples, consiste em obter as imagens em ordem cronológica e comparar sucessivamente cada imagem com a adquirida imediatamente a seguir. Desta forma se pode obter diretamente os pequenos incrementos de deslocamento, os quais chamamos de δD_1 , δD_2 etc. (Fig.76).




Figura 76. Comparação sucessiva de cada imagem com sua posterior.

Este método é útil para observar grandes mudanças que ocorrem em tempos muito curtos, mas não permite observar mudanças lentas que ocorrem em escalas de tempo muito maiores, isso devido que o ruído de medição aumenta gradualmente quando se adicionam os deslocamentos incrementais para obter o deslocamento cumulativo entre o início e o fim da série temporal. Pode-se melhorar criando-se pares, por exemplo, interferogramas, a partir de imagens com separações de tempo muito variadas, como na figura 76, entre as imagens D_1 e D_6 ou D_1 e D_4 . O que nos dá medições de deslocamento D_{1-6} ou D_{1-4} ... ocorre assim redundância da medição e, portanto, a possibilidade de tornar as observações mais robustas. Por exemplo, uma erupção vulcânica será observada por vários pares de imagens, ao se combinarem esses pares, que formam uma rede, obter-se-á séries temporais do deslocamento cumulativo do solo D_k , em cada intervalo de tempo k . Esta rede define um sistema de equações lineares cujas incógnitas são os incrementos de D , o δD . A inversão de mínimos quadrados do sistema permite encontrar o deslocamento a cada aquisição ao longo do tempo, mas também isolar ruídos e quantificar resíduos.

Desta maneira se obtém séries temporais de deslocamento do solo, como neste exemplo do vulcão Cayambe, no Equador, entre o final de 2014 e o final de 2018 (Fig.77).

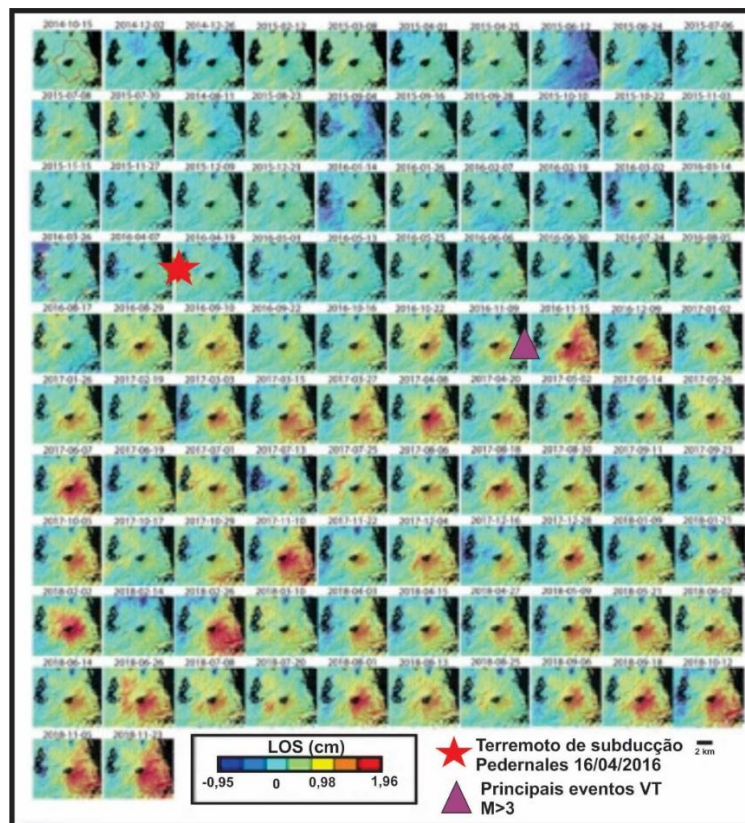


Figura 77. Série temporal de deslocamento de solo, observada no vulcão Cayambe no Equador.
(fonte: Espín Bedón et al. 2022)

A protuberância formada é muito tênue e só pode ser medido através da produção de uma série temporal por interferometria de radar. O mesmo princípio se aplica à construção de séries temporais por correlação de imagens ópticas ou de radar. Por outro lado, as séries temporais de mudança no estado da superfície são mais complicadas porque uma mudança pode ser reversível ou irreversível, progressiva ou descontínua e não é representada por uma única variável em função do tempo.

5.2.2 Quais são os limites do método?

Os limites do método de correlação óptica de imagens são: a decorrelação devido à mudança no estado da superfície, às nuvens que mascaram o solo e às variações na orientação do sol no momento das aquisições dos satélites.

Vemos que se a orientação do Sol mudar entre duas aquisições, isto criará um movimento aparente do ponto vermelho em direção ao ponto azul (Fig.78.). Se todas as aquisições ocorrerem ao mesmo tempo, haverá um efeito sazonal com sombras mais longas no inverno do que no verão (Fig.79), se tendo, portanto, um artefato sazonal na série temporal que se pode estimar e remover.




Figura 78. Variação da posição do sol na hora da obtenção da imagem.

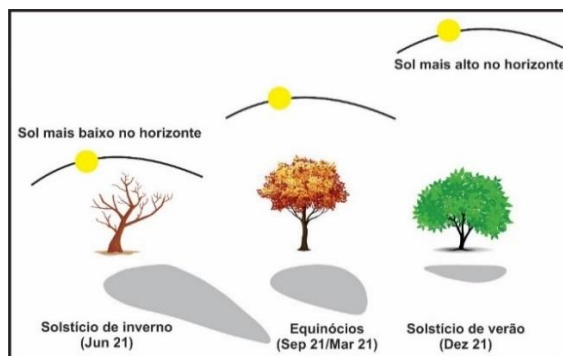


Figura 79. Efeito sazonal da sombra de um objeto com as estações do ano.

No registro do terremoto de Baluchistão (Paquistão) em 2013 (Fig.80), vê-se que a série temporal apresenta um salto associado aos terremotos e um sinal sazonal associado à altura do sol. A sua correção permite refinar a medição do sinal cossísmico, ou seja, associado ao sismo cujo deslocamento é apresentado em verde. No caso da interferometria radar, as principais limitações são: a decorrelação temporal e o atraso atmosférico.




Figura 80. Registro do terremoto de Baluchistão, no Paquistão em 2013.
(modificado: Hollingsworth et al., 2017)

A figura 81, mostra uma imagem de uma série temporal de movimentos na linha de visão entre o final de 2014 e 2021, no Peru.

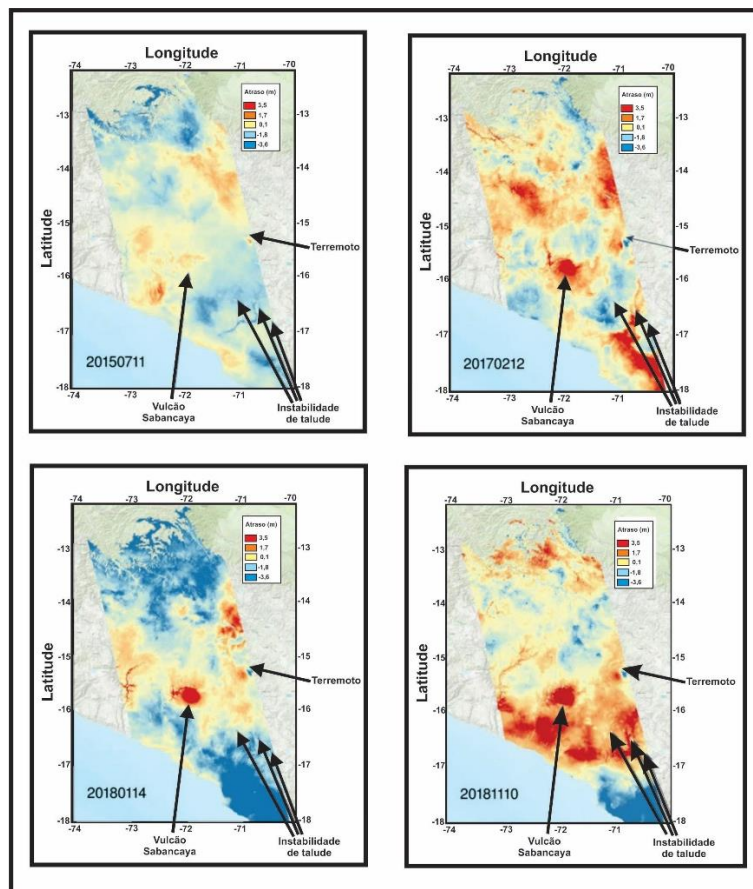


Figura 81. Imagens de uma série temporal da região do vulcão Sabancaya no Peru.
(modificado: Thollard et al., 2021)

Pode-se observar um forte sinal de elevação no vulcão Sabancaya que está em vermelho na figura 81, o efeito de um terremoto, sinais localizados mostrando instabilidades gravitacionais, mas também vemos uma forte variabilidade temporal que se deve a atrasos atmosféricos nas imagens. Este sinal atmosférico mascara o deslocamento cumulativo associado ao lento carregamento intersísmico das falhas, que só é encontrado no mapa de velocidades. Observe que a medição realizada é relativa no espaço e no tempo.

Como há muitas aquisições, o cálculo das séries de dados temporais requer grande capacidade de computação e armazenamento. Por exemplo, para o satélite Sentinel-1, foi efetuado mais de 1.500 interferogramas e foram necessários vários terabytes para processar as poucas centenas de imagens disponíveis desde 2014.

Viu-se as interpretações de sinais tectônicos, gravitacionais e vulcânicos, mas também existem muitos outros sinais, tais como, os de derretimento de permafrost e os hidrológicos que são, frequentemente, os principais sinais visíveis em mapas verticais de velocidade, como no exemplo do Tibete (Fig.82). A interpretação destes sinais requer, portanto, grande conhecimento da área e processamento estatístico para separar as diferentes fontes dos sinais.

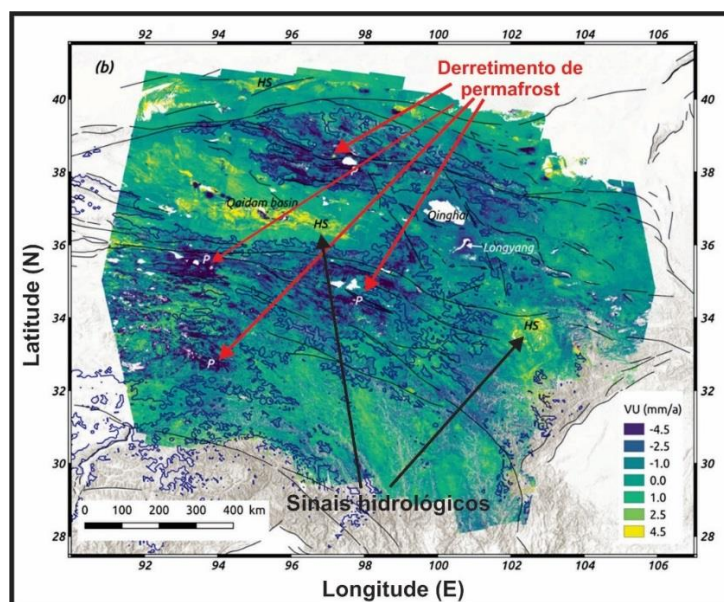


Figura 82. Imagem de uma série temporal com a identificação de sinais hidrológicos e de derretimento de permafrost, no Tibete. P representa os locais em depressão e HS os locais em elevação. (modificado: Lemrabet et al.,2023)

A realização de séries temporais permite obter medições mais robustas e muito mais precisas e monitorar deformações transitórias. No entanto, construí-los requer tempo de computação e espaço de armazenamento muito significativos.

6. TERREMOTOS E VULCÕES

6.1 Terremotos: um problema social

Vejamos os terremotos e, mais particularmente, a forma como se pode utilizar as imagens de satélite para monitorizar e estudar estes perigosos fenômenos telúricos, que são frequentemente a causa de danos em cascata.

O grande terremoto de Tohoku que atingiu o Japão em 2011, é um triste exemplo (Fig.83). Todos se lembram das terríveis imagens do tsunami que gerou e dos impactos duradouros ligados aos danos na central nuclear de Fukushima.



Figura 83. Localização do epicentro do terremoto de Tohoku, ocorrido no Japão em 2011.
(modificado: <https://www.researchgate.net/publication/280132845/figure/fig4/AS:391608060137476@1470378045737/Figura-4-Ubicacion-geografica-del-sismo-de-Tohoku-Japon-2011.png>)

Foi um terremoto de magnitude 9,1 que rompeu e deslizou a interface da zona de subducção em mais de 30 m (Fig.84). É a interface entre a placa de Honshu e a placa do Pacífico, que mergulha sob o Japão. Cerca de 20 mil pessoas morreram e quase 10 mil ficaram feridas ou desaparecidas.




Figura 84. Visualização da Placa Pacífica mergulhando sobre a Placa de Honshu, no Japão.

Outros sismos, infelizmente famosos pelo seu impacto, foram o do Haiti em 2010, o de Palau em 2018 ou, muito recentemente, os terríveis terremotos da Turquia e da Síria em 2023, que destruíram mais de 6.000 edifícios e causaram mais de 57.000 mortes. Este último foi uma sequência sísmica com a nucleação de um terremoto de magnitude 7,8, seguido, 9 horas depois, por um terremoto de magnitude 7,6 e mais de 10.000 “tremores secundários” ou réplicas (Fig.85). Estes exemplos dramáticos mostram que os sismos são questões importantes para as sociedades e que é melhor compreendê-los para antecipar os danos que podem causar.

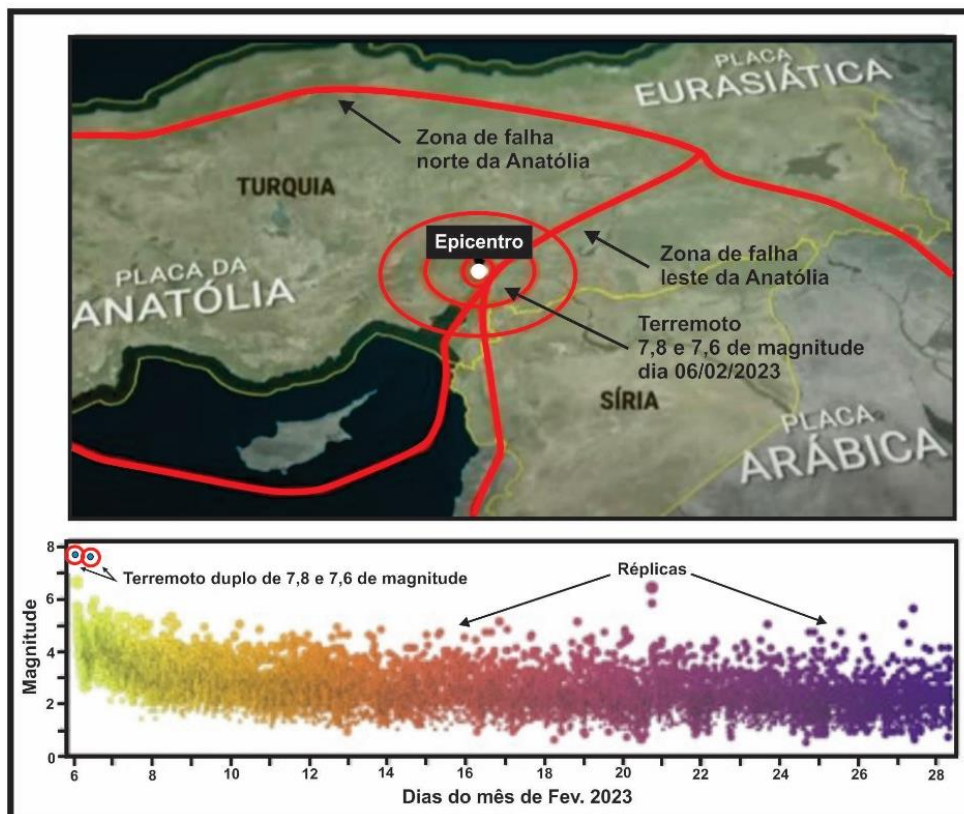


Figura 85. Evolução do terremoto da Anatólia -Turquia, ocorrido em 06 de fevereiro de 2023.
(modificado: Dal Zilio & Ampuero,2023)

Atualmente é impossível prever a data dos sismos, mas se pode localizar as suas prováveis áreas de ocorrência e compreender os seus mecanismos através da observação e, assim, preparar-nos melhor para os mesmos.

Quando se observa a sismicidade tectônica no mapa da figura 86, se nota que os terremotos, representados por estrelas, se distribuem principalmente nos limites das placas tectônicas. Mas há também uma sismicidade mais difusa dentro dos próprios continentes.

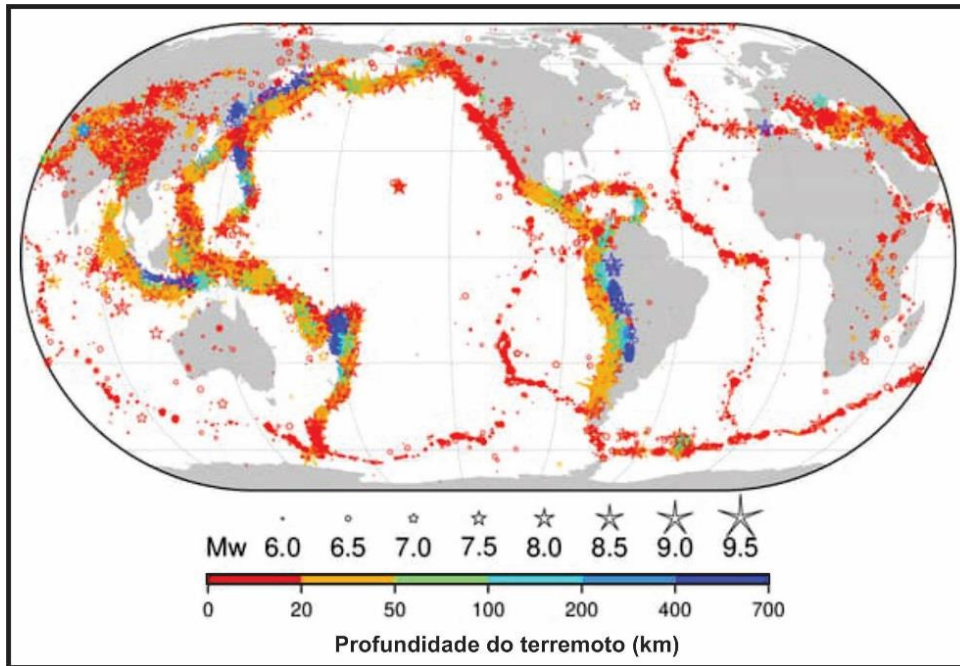


Figura 86. Carta de sismicidade mundial entre 1976 e 2018 de terremotos com magnitude maior que 5,5.
(fonte: Vincendon, 2023)

6.2. A que se deve estes terremotos?

A crosta terrestre se move lentamente, no máximo alguns centímetros por ano, sob o efeito de forças tectônicas, o que é chamado de placas tectônicas (Fig.87).

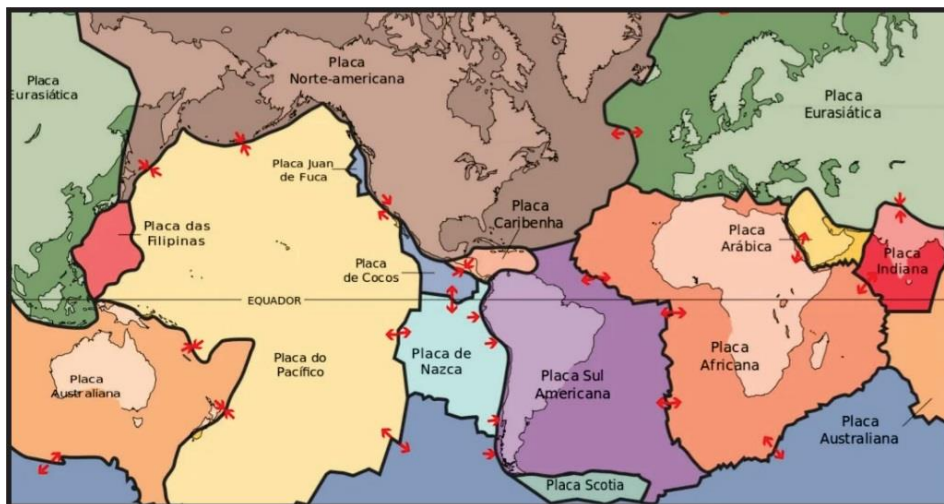


Figura 87. Placas tectônicas do globo terrestre.
(fonte: <https://static.todamateria.com.br/upload/pl/ac/placas-tectonicas-og.jpg>)

As falhas acomodam esses movimentos de superfície. Existem falhas normais que acomodam extensão, falhas inversas que acomodam compressão e falhas de deslizamento que acomodam deslizamento horizontal entre dois blocos, como a falha de San Andreas, na Califórnia (Fig.88).




Figura 88. Tipos de falhas

(modificado: <http://claramartinsfefe.blogspot.com/2010/05/tipos-de-falhas.html>)

As falhas geralmente são bloqueadas durante o período intersísmico, ou seja, não deslizam livremente entre grandes terremotos. Durante esse período, que pode durar milhares de anos, as falhas acumulam energia transmitida por esses lentos movimentos tectônicos, mas quando a energia acumulada excede um limite ou se as condições mecânicas mudam, a falha é desbloqueada e libera repentinamente a energia elástica acumulada, ocorrendo então um movimento rápido ao longo da falha que acompanha o movimento das placas tectônicas (Fig.89).




Figura 89. Período intersísmico e cossísmico de uma falha.

Este movimento repentino está associado a uma ruptura da falha, que se propaga a uma velocidade de alguns quilômetros por segundo, e cria ondas sísmicas que também se propagam a alguns quilômetros por segundo. Essa rápida ruptura da falha é o terremoto. Este período é denominado período cossísmico e dura apenas alguns segundos a alguns minutos. A duração depende da magnitude do terremoto. Quanto maior o terremoto, mais tempo leva.

Por exemplo, o terremoto de Sumatra, em 2004, de magnitude 9,3, durou dez minutos. Após o terremoto, a falha entra em um período de relaxamento pós-sísmico,

durante o qual ocorre um reajuste mecânico do ambiente que pode durar de vários meses a vários anos. Em algumas falhas também pode haver períodos de deslizamento lento e transitório, durante os quais a falha desliza vários centímetros a decímetros por ano sem criar ondas sísmicas. As falhas, portanto, passam por vários períodos de atividade e mudam o seu comportamento, o que é chamado de ciclo sísmico (Fig.90).




Figura 90. Perfil de um terremoto seguido de períodos de relaxamento sísmico.

Cada período deste ciclo sísmico é acompanhado por uma deformação da superfície do solo em torno da zona de falha.

6.3. Como são estudados os terremotos?

Como se estudam esse ciclo sísmico?

Classicamente se estudam as ondas liberadas durante os terremotos por meio de sismógrafos que as registram e que estão localizados mais ou menos longe da falha (Fig.91).




Figura 91. Sismógrafo

(fonte: <https://www.infoescola.com/wp-content/uploads/2018/01/sismografo.jpg>)

Mas a geodésia e o sensoriamento remota também fornecem informações valiosas, medindo o movimento da superfície do solo em ambos os lados da falha. Na verdade, em cada período do ciclo sísmico, a superfície do solo se move, dependendo das restrições tectônicas exercidas sobre a falha e do estado mecânico do ambiente. Esses movimentos do solo refletem, portanto, o deslizamento que ocorre em profundidade ao longo da falha (Fig.92).




Figura 92. Magnitude e deslizamento médio ao longo da falha.

Quando um terremoto de grande magnitude, ou seja, maior que seis, ocorre em uma profundidade rasa, por exemplo, a uma profundidade de 10 km, a superfície do solo, em ambos os lados da falha, se move vários centímetros ou mesmo vários metros, e pode criar rupturas visíveis na superfície do solo (Fig.93).



Figura 93. Estrada com trecho deslocado para a esquerda na região da Turquia.

(fonte: <https://img.r7.com/images/falha-ao-longo-da-linha-golbasi-turkogl-na-turquia-com-deslocamento-da-estrada-a-esquerda-21022023021252939?dimensions=442x241>)

Medir todos esses movimentos próximos e distantes da falha permite encontrar o deslizamento que ocorreu ao longo do plano da falha. Quanto maior for esse deslizamento e mais extensa for a zona rompida da falha, maior será a magnitude do terremoto(Fig.92).

6.3.1. Técnicas de medida de deslocamento da superfície do solo: Geodésia terrestre

Para medir os deslocamentos da superfície do solo, existem diversas técnicas. A geodésia permite obter um posicionamento preciso. A geodésia terrestre, por exemplo, a distancimetria ou a geodésia espacial, por exemplo, o GPS, permitem medir redes de marcadores ancorados no solo em diferentes momentos e assim saber quais os movimentos que ocorrem ao longo do tempo (Fig.94).




Figura 94. Determinação do deslocamento do solo por GPS.
(fonte: Incorporated Research Institutions for Seismology-IRIS)

Na figura 95, se pode ver os movimentos do solo medidos por GPS, representados por setas. A velocidade do movimento é caracterizada pelo tamanho da seta. A seguir veremos como fazer medições geodésicas a partir de imagens adquiridas por satélite, avião ou drone, e assim obter uma visão ampliada desses movimentos ao longo do tempo.

6.3.2. Contribuição do sensoriamento remoto no estudo de terremotos

Na figura 95 se pode ver o mesmo movimento de deslizamento calculado por interferometria, a partir de imagens de radar adquiridas por satélite.

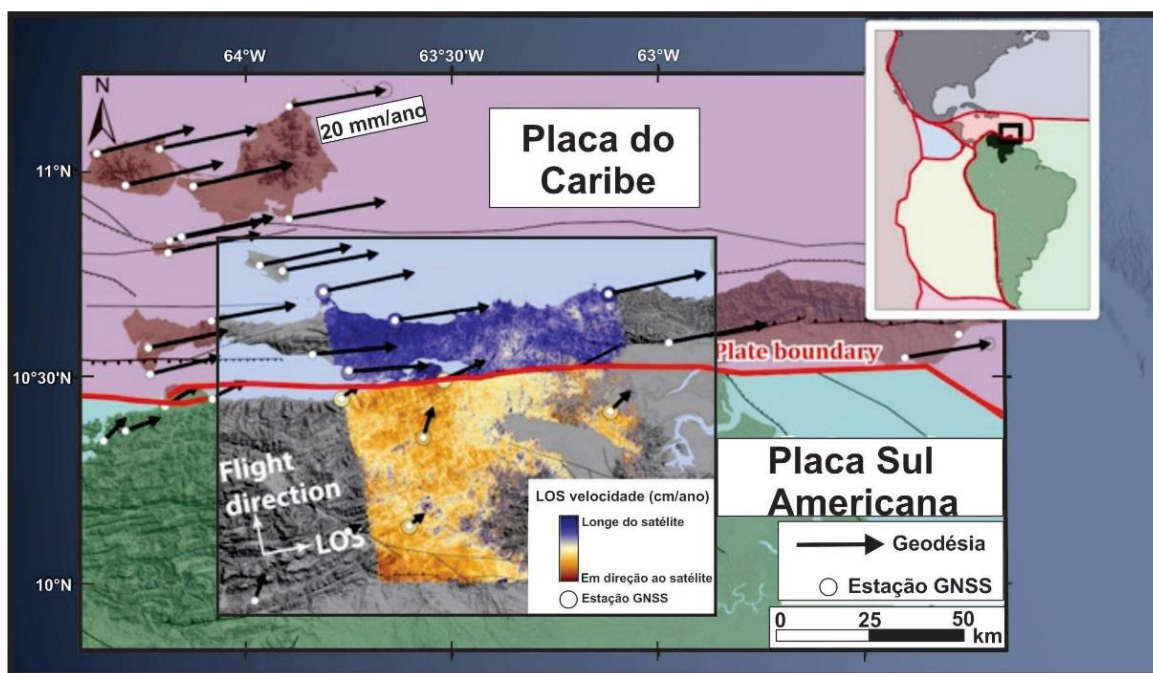


Figura 95. Deslocamento ao longo do limite de placa entre as placas Sul-Americana e Caribenha.
(modificado: Reinoza et al, 2005)

Em azul, a área está se afastando do satélite e em amarelo a área está se aproximando do satélite. As técnicas de sensoriamento remoto permitem assim, mapear falhas, terremotos e deslocamentos associados, em alta resolução espacial. O sensoriamento remoto, mais particularmente as imagens de satélite, tem agora o potencial de fornecer uma visão global e regional das falhas. Essas imagens podem atingir uma alta resolução espacial que pode ser centimétrica, e uma resolução temporal com tempos de revisita de alguns dias. Estes dados, por vezes adquiridos a mais de 700 km do solo, permitem observar deslocamentos criados por falhas e registados na paisagem há milhares de anos, mas também captar deslocamentos atuais de falhas. Todos estes movimentos da superfície terrestre, ligados à atividade das falhas, fornecem informações valiosas sobre o ciclo sísmico das falhas.

Por último, do ponto de vista social, as imagens de satélite, após um terremoto, são também essenciais porque permitem detectar danos ou mesmo organizar a ajuda humanitária. Por exemplo a figura 96 nos mostra um mapa de danos causados por um terremoto na Turquia.

Este mapa (Fig.96) é calculado se comparando as alterações na imagem do radar entre um período pré-sísmico, aqui quatro meses antes do terremoto, e a primeira imagem obtida após o terremoto. Para o aspecto científico e social, existem cartas internacionais que permitem solicitar às agências espaciais que programem aquisições de satélites em zonas sísmicas e os distribuam gratuitamente.

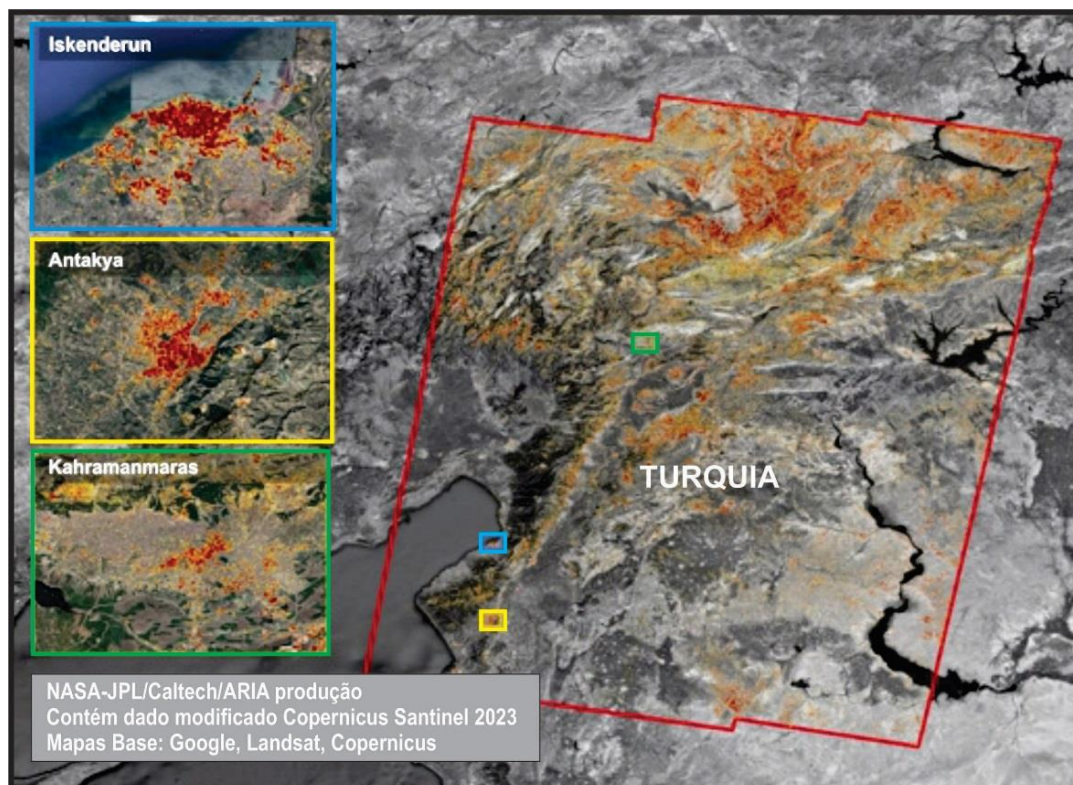


Figura 96. Mapa de danos causados por terremotos na Turquia. Os pixels vermelhos escuros representam áreas com probabilidade de danos graves em edifícios, casas e infraestruturas ou alterações na paisagem, enquanto as áreas laranja e amarelas estão moderadas ou parcialmente danificadas.
(modificado: NASA-JPL/Caltech/ARIA produção)

Os terremotos tectônicos afetam as sociedades humanas e ocorrem ao longo de falhas, sendo, portanto, necessário estudar os movimentos do solo ligados às falhas para compreender as suas atividades.

6.3.3. Mapeamento de falhas por análise de imagens ópticas e MDT

As imagens da Terra permitiram grandes avanços no conhecimento das falhas. Historicamente isso começou em meados do século XIX com imagens aéreas tiradas por aviões que permitiram mapear os danos e possíveis rupturas causadas pelos terremotos.

Um exemplo é o terremoto de magnitude 7,3, ocorrido no lago Hegben em 1959, nos Estados Unidos, onde se pode ver na figura 97, danos impressionantes, como o deslizamento de terra que foi desencadeado pelo terremoto.

No entanto, deve-se ter em mente que um terremoto nem sempre produz deformações visíveis na superfície, principalmente quando o epicentro é profundo ou de baixa magnitude (Fig.98). Entretanto para sismos grandes ou muito superficiais, os geólogos, com o apoio de imagens de satélite, podem encontrar vestígios de rupturas sísmicas antigas, que remontam a 100 mil anos, mas que podem ter marcado a paisagem.




Figura 97. Barragem do lago Hebgen, vista aérea. Observe a erosão da face a jusante da barragem causada por seiches. Novas escarpas de falhas aparecem como linhas brancas na encosta esquerda.
(foto do Serviço Florestal dos EUA) (Fischer, 1960).

Estes vestígios são ainda mais marcados se tiver havido uma sucessão destas rupturas ao longo de milênios que geraram deslocamentos que se acumulam ao longo do tempo. Os movimentos cumulativos de terremotos passados podem, portanto, ser mapeados utilizando marcadores específicos na paisagem.

Por exemplo, podemos citar uma escarpa reconhecível por mudanças localizadas na encosta criadas por falhas reversas ou normais ou leitos de rios compensados por falhas transcorrentes (Fig.99).




Figura 98. Mapeamento de ruptura sísmica a partir de uma fotografia aérea.
(fonte: USGS)




Figura 99. Escarpa criada pela atividade da falha de Chichimene, Colômbia.
(modificado: @Ortiz-SGC)

Na figura 100, se pode ver um rio deslocado pela falha de San Andrés na Califórnia. Além disso, você consegue encontrar a direção e direção da deformação nesta imagem? Graças a imagens aéreas e de satélite, os geólogos conseguiram mapear inúmeras falhas ativas.



Figura 100. Esquema do movimento lateral da falha de San Andrés interpretado a partir do deslocamento dos vales de drenagem.
(modificado: https://cdn.serc.carleton.edu/images/vignettes/collection/figure_2_wallace_creek.webp)

Este trabalho é de grande importância porque permite compreender melhor as áreas com elevado risco sísmico, devido que os sismos geralmente ocorrem em falhas pré-existentes, podendo também detectar complexidades geométricas ao longo das falhas. Na natureza as falhas não são planos perfeitos com arestas retas, estas podem ser compostas por vários segmentos, que podem se dividir e mudar de orientação, isto pode influenciar a propagação de futuras rupturas sísmicas.

Na figura 101, se pode ver os deslocamentos causadas pela ruptura do solo de um dos terremotos da Turquia em 2023.



Figura 101. Imagem mostrando a ruptura e o deslocamento da superfície associada ao terremoto de magnitude 7,8 que atingiu a Turquia em fevereiro de 2023.

(fotos: Sinan Akçiz) (modificado: <https://news.fullerton.edu/app/uploads/2023/04/turkeys-destructive-earthquakes.jpg>)

O Sensoriamento Remoto, devido à sua cobertura muito ampla, é uma ferramenta muito importante para o estudo de falhas; e a cada desenvolvimento tecnológico em sensoriamento remoto, resulta em avanços científicos no conhecimento de falhas.

O lançamento dos satélites LandSat, o primeiro satélite civil de observação da Terra, permitiu, na década de 1970, mapear as falhas do Tibete, uma das regiões mais ativas e perigosas da Terra, e assim propor um modelo de deformação do Tibete (Fig.102).




Figura 102. Mapa simplificado das falhas ativas do Tibete.

(modificado: Molnar & Tapponnier, 1978)

Atualmente, para fazer esse mapeamento, se utilizam dados ópticos ou de radar de alta resolução, como imagens do satélite Plêiades, cujos pixels têm 50 cm ou Modelos Digitais de Terreno (MDT), calculados a partir de pares estereópticos, imagens de radar, ou LiDAR, que permite observar o solo mesmo através de vegetação densa (Fig.103).

Estes dados de altíssima resolução prometem-nos muitas novas descobertas na compreensão de falhas e outras estruturas ativas na superfície do planeta.




Figura 103. Meios de alta resolução espacial que permitem imagear falhas ativas.

O mapeamento de falhas também é útil para avaliar o risco sísmico probabilístico num local. Isto consiste, em particular, em estimar, num raio em torno do local, quais os sismos que provavelmente ocorrerão no futuro, por exemplo nos próximos 50 ou 100 anos, com que probabilidades de ocorrência e os efeitos no movimento do solo. Assim, o mapeamento de falhas ativas que podem causar terremotos é uma informação importante, assim como o dos movimentos do solo (Fig.104).

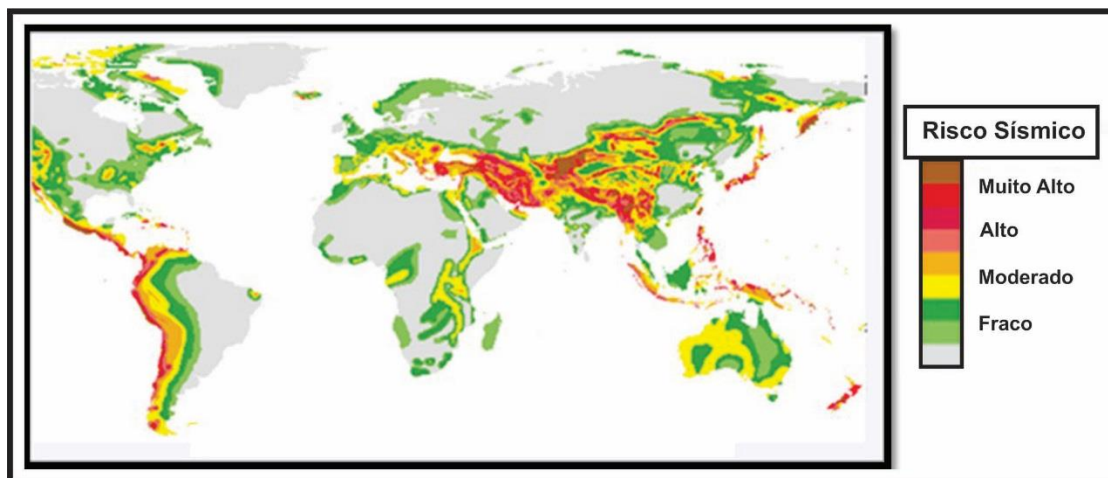


Figura 104. Mapa de Risco Sísmico do globo terrestre.
(fonte: <https://rusoares65.pbworks.com/f/1321486242/maparisicosismico.jpg>)

A estimativa do risco sísmico probabilístico também requer o conhecimento de eventos sísmicos passados, bem como das propriedades do solo. Infelizmente, os sismos também ocorrem regularmente em falhas não mapeadas, por exemplo, devido à erosão natural que pode ter apagado os marcadores da atividade de deformação nas falhas. Essa dificuldade de mapeamento é um dos muitos problemas da pesquisa atual.

6.3.4. Monitoramento espaço-temporal da deformação pelo InSAR

Além de saber onde estão as falhas ativas, o sensoriamento remoto também nos permite medir como o solo se deforma em torno dessas falhas, ao longo do ciclo sísmico, inclusive durante os períodos de aquiescência entre os terremotos, quando a falha carrega lentamente e se prepara para um futuro terremoto. Isto é possível, graças aos dados de radares de satélite que permitem observar movimentos da ordem de alguns milímetros por ano.

É, portanto, possível observar movimentos tectônicos em ambos os lados das falhas e medir os gradientes de deformação em torno dessas falhas. A quantificação destes gradientes, permitem saber a que velocidade e a que profundidades a falha ocorreu durante o período intersísmico e, assim, estimar quanta energia foi acumulada pela falha e que será potencialmente libertada durante o próximo sismo.

O sensoriamento remoto permite uma alta resolução espacial de cerca de 100 m de tamanho de pixel. Na figura 105, se pode ver mudanças tectônicas na região do Tibete, a partir do mapa de velocidade média, calculado entre 2014 e 2020, com cerca de 130 imagens de radar Sentinel-1, usadas para calcular quase 630 interferogramas de radar por órbita, cuja extensão da aquisição terrestre é visível, no mapa, em tons de cinza claro, com um total de 14 órbitas.

Sobre o mapa da figura 105, se pode observar o movimento através das falhas transcorrentes de Altyn Tagh, Haiyuan, Kunlun, Yushu, Ganzi e Xianshuihe que se reflete na imagem por um contraste de cores.

Também é possível observar deslizamentos transitórios lentos, graças às séries temporais de deslocamento do solo e, portanto, ver variações temporais na deformação. A compreensão da física e, em particular, das leis de fricção que regem a mecânica destas falhas, está no centro da investigação atual, questões para as quais o sensoriamento remoto é uma fonte essencial de informação.

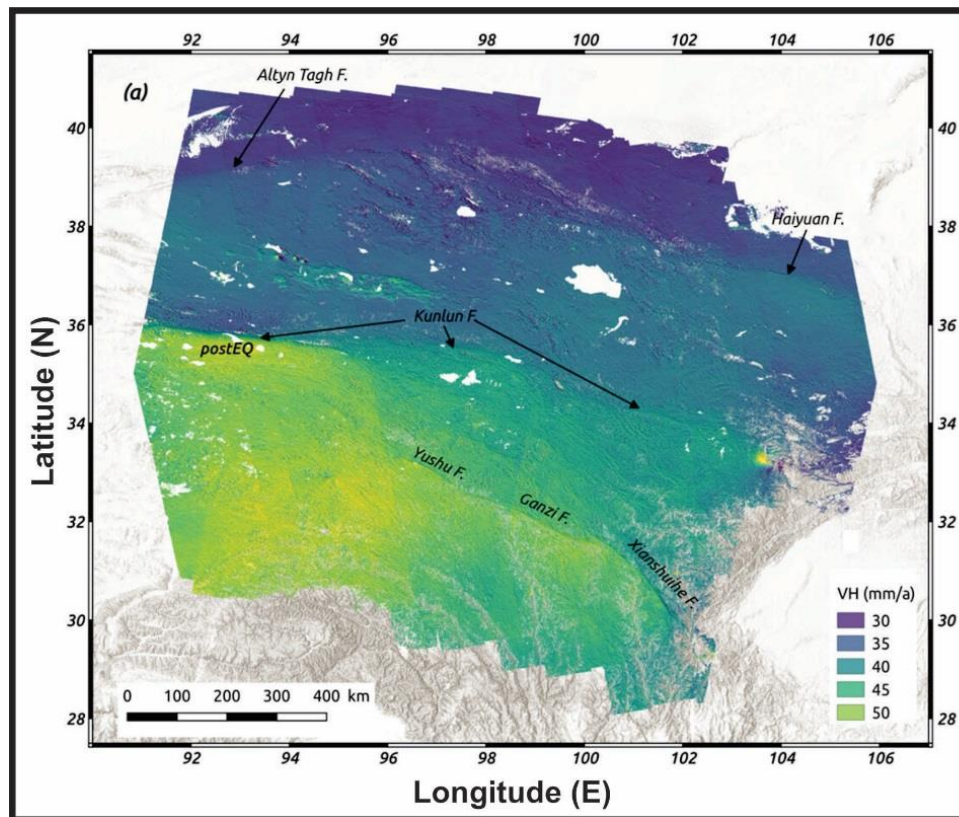


Figura 105. Mapa de velocidade média de deslocamento horizontal do solo, na região do Tibete, calculada pelo InSAR. (fonte: Lemrabet, et al., 2023)

6.3.5. Observação por satélite da deformação cossísmica

Certamente o período mais impressionante do ciclo sísmico, que é possível estudar com sensoriamento remoto, é o período cossísmico: isto é, o próprio terremoto.

Para ilustrar este período cossísmico, se tem o exemplo do terremoto de magnitude 7,5 em Palu, na Indonésia, que ocorreu em 2018 e que pode ser estudado com radar e imagens ópticas adquiridas antes e depois do terremoto. As imagens de radar permitem calcular um interferograma que mede os movimentos da superfície terrestre.

Na figura 106, se pode ver, em particular, franjas coloridas, onde cada uma destas corresponde a uma mudança na distância de 13 cm, entre o satélite e o solo. Estas franjas formam lóbulos, cada um dos quais corresponde a um pico de deslizamento na falha, durante o terremoto. Quanto mais estreitas são as franjas, maior é a deformação sofrida pelo solo. O sismo ocorre numa falha, mas gera deformação em grande escala, este é o campo de deformação elástica que é medido através da geodésia e, portanto, do InSAR.

Este campo de deformação permite saber que o sismo rompeu uma porção da falha, de aproximadamente 150 km de extensão, sendo uma parte terrestre a Sul e outra parte marítima a Norte.

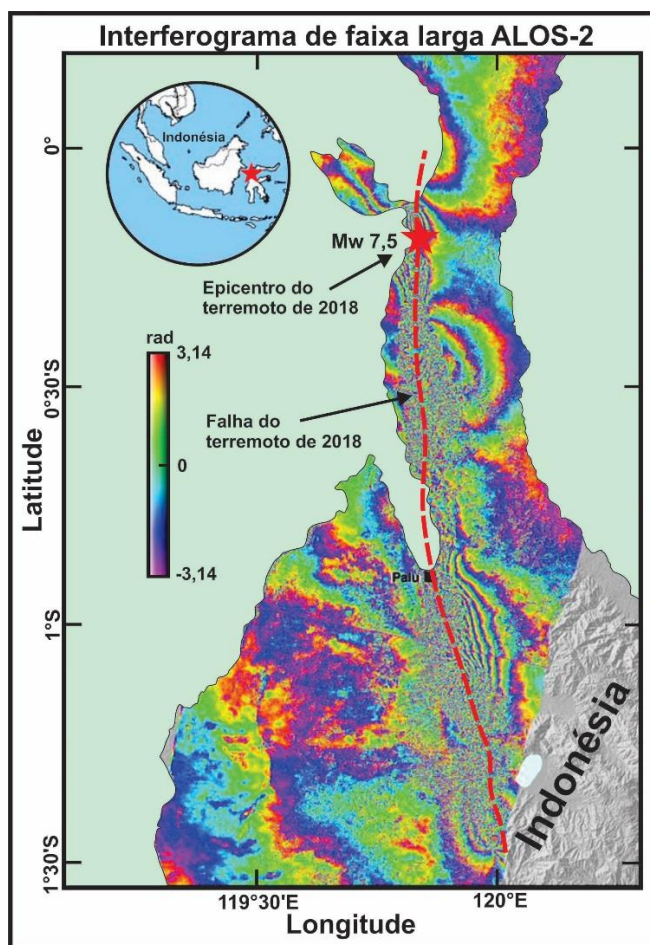


Figura 106. Interferograma ALOS-2 do terremoto de magnitude 7,5 ocorrido em 2018 em Palu, Indonésia.
(modificado: He et al. 2018)

No interferograma da figura 106 se pode facilmente distinguir 3 lóbulos principais nas franjas. É este padrão de deformação superficial que permite modelar o deslizamento que ocorreu em profundidade, ao longo da falha.

Quando as franjas são muito estreitas para serem discerníveis, não se pode mais medir a deformação por interferometria, é o que acontece perto da zona de ruptura, na parte onde está o solo, se necessitando utilizar outro método se quisermos medir o deslocamento.

A correlação das imagens ópticas adquiridas antes e depois do terremoto também permite observar o movimento do solo. Com este método se obtém menor precisão nas áreas mais distantes da falha, mas se consegue medir movimentos próximos à falha, o que o InSAR não consegue fazer porque satura.

No caso da figura 107, por exemplo, a correlação óptica permite mostrar que o deslocamento está claramente localizado ao longo da falha. O terremoto cortou, portanto, a crosta terrestre muito claramente até a superfície, como se fosse um corte de faca.




Figura 107. Deslocamento Norte-Sul da falha de Palu obtido a partir da correlação de imagens ópticas.
(modificado: https://earthjay.com/earthquakes/20180928_indonesia/displacement_sentinel_2B_01_johann_champenois.jpg)

Até 5 m de deslocamento relativo podem ser medidos ao longo da falha, o que nos permite saber que esta falha é uma falha sinistral. Isso quer dizer que se ficarmos sobre um bloco da falha e olharmos para o bloco oposto, do outro lado do traço da falha, ele se moverá para a esquerda. Com este exemplo, se pode perceber como a complementaridade de ferramentas de sensoriamento remoto, combinando tanto MDT, radar e imagens ópticas, nos permite aprender que a ruptura foi iniciada em uma área de complexidade geométrica pouco conhecida e que se propagou por mais de 180 km, atingindo uma velocidade de ruptura supercisaalhante, ou seja, com uma velocidade de ruptura superior à das ondas sísmicas S.

O sensoriamento remoto permite observar a atividade passada das falhas, sendo esta registada na paisagem, mas também permite observar a sua atividade atual com monitorização dos movimentos do solo. Isto nos permite compreender o ciclo sísmico de falhas que ultrapassa a memória da humanidade, mas que continua a afetar as nossas sociedades atuais.

6.4. Vulcões e o Sensoriamento Remoto

6.4.1. Previsão de erupções vulcânicas: uma questão social

Vejamos as erupções vulcânicas e, mais especificamente, como os pesquisadores usam satélites para monitorar e estudar essas montanhas fascinantes, mas às vezes muito perigosas. O objetivo dos pesquisadores é reduzir o impacto dos perigos vulcânicos na população. Na verdade, existem quase 1.500 vulcões ativos, o que significa que esses vulcões experimentaram pelo menos uma erupção durante os últimos 11.000 anos (Fig.108).



Figura 108. O vulcão Popocatepetl é um dos vulcões mais ativos do México.
(fonte: https://c.files.bbci.co.uk/2541/production/_101873590_tv018041925.jpg)

Devido ao crescimento contínuo da população mundial, hoje, mais de 800 milhões de pessoas, ou 10% da população mundial, vivem a menos de 100 km de um vulcão ativo (Fig.109). Além disso, se pode prever que os impactos das erupções vulcânicas, provavelmente, aumentarão no futuro.




Figura 109. Mapa de localização dos vulcões ativos no globo terrestre.
(fonte: https://www.esa.int/images/GVP_L.jpg)

Recentemente, a erupção do vulcão Cumbre Vieja nas Ilhas Canárias, em dezembro de 2021, destruiu nada menos que 3.000 edificações em seis meses (Fig.110).



Figura 110. Erupção do vulcão Cumbre Vieja em La Palma nas Ilhas Canárias.
(fonte: <https://imagens.brasil.elpais.com/resizer/0i0eHDMF2kOvAsjnKV22T4qtrdg=/1200x675/cloudfront-eu-central-1.images.arcpublishing.com/prisa/ICOPZVUR54L2IR6VBJ2UULCHPA.jpg>)

Outro exemplo, em junho de 2018, a erupção do vulcão Fuego, na Guatemala, soterrou uma aldeia em apenas alguns minutos, causando a morte de várias centenas de pessoas (Fig.111).



Figura 111. Vulcão Fuego localizado na Guatemala. Aos pés do vulcão a cidade de La Antigua.
(fonte: https://media.istockphoto.com/id/1251221528/pt/foto/volcano-of-fire.jpg?s=612x612&w=0&k=20&c=fgfHCTtHUOF67h4_wqK8a5RxtUPKxoTHC5_07b-a_1Q=))

Para entender como os cientistas usam imagens de satélite de vulcões, primeiro explicaremos algumas noções simples de vulcanologia.

O magma, que é um líquido produzido pela fusão de rochas, geralmente é armazenado nas profundezas do vulcão, em reservatórios de magma (Fig.112). O aumento da pressão no reservatório, provocado, por exemplo, por um novo fornecimento

de magma, fará com que o reservatório se rompa e o magma suba em direção à superfície, através de uma rede de fraturas, denominadas intrusões magmáticas. Durante esta subida, se o gás permanecer preso no magma, a erupção será explosiva, com emissão de fluxos piroclásticos e plumas de cinzas. É o caso das erupções do vulcão Merapi, na Indonésia. Por outro lado, se o gás escapar antes de chegar à superfície, então a erupção será considerada efusiva, com a emissão de fluxos de lava, como por exemplo no vulcão Kilauea no Havaí ou em Piton de la Fournaise na ilha da Reunião (Fig.113).




Figura 112. Partes de um vulcão

(fonte: https://static.mundoeducacao.uol.com.br/mundoeducacao/conteudo/partes_vulcao.jpg)

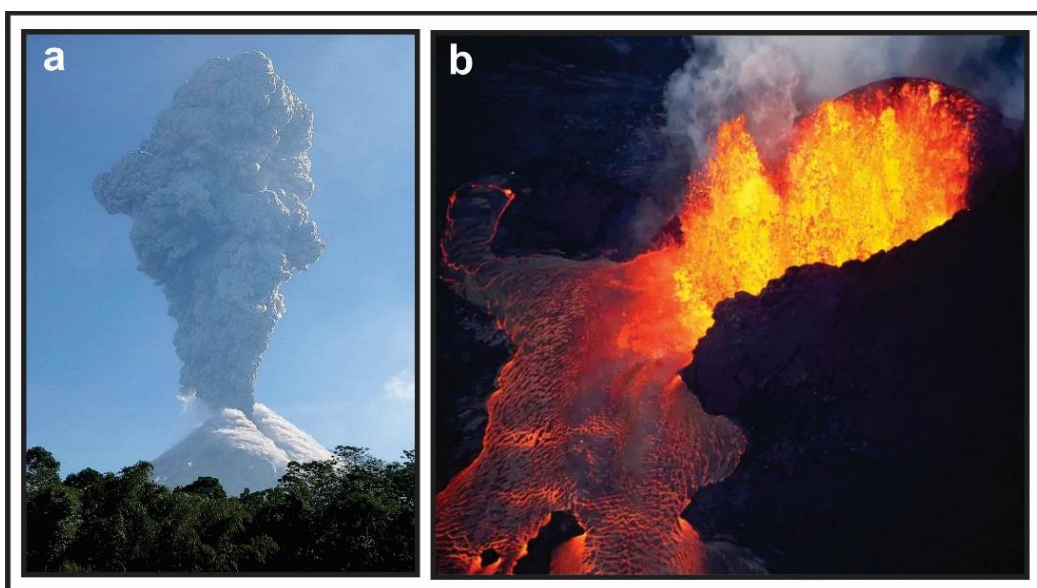


Figura 113. Erupção vulcânica. a) vulcão Merapi com erupção explosiva. b) vulcão Kilauea com emissão de fluxo de lava.

(fonte: a) <https://i.pinimg.com/736x/51/dd/51dd51f2a99ce366960da5bb250bbd13.jpg>
b) https://p2.trrsf.com/image/tget/cf/940/0/images.terra.com/2018/06/06/2018-06-06T114440Z_1_LYNXPPEE550U6_RTROPTP_4_HAWAII-VOLCANO.JPG)

6.4.2. Como monitorar os vulcões?

Para antecipar as erupções, os vulcanólogos contam com a detecção de sinais de alerta da pressurização do sistema magmático e da propagação do magma em direção à superfície. Os principais sinais são: em primeiro lugar, a alteração da composição dos gases ao nível das fumarolas ou lagos vulcânicos; em segundo lugar, o aumento da sismicidade sob o edifício vulcânico e, finalmente, em terceiro lugar, a deformação da superfície do vulcão.

Todos estes sinais físicos são mensuráveis, graças à instalação de diferentes sensores localizados na superfície do vulcão, tais como: espectrômetros para gases, sismógrafos para terremotos e GPS para deformações. No entanto, a instrumentação terrestre tem várias desvantagens, uma delas é o custo de instalação e manutenção dos equipamentos e sua calibração, o que muitas vezes as instituições não dispõem dos meios financeiros necessários para esta monitorização. Além disso, esses sensores podem ser destruídos durante uma erupção e devem, portanto, ser substituídos, o que tem um custo adicional. A outra desvantagem é que algumas áreas vulcânicas são completamente inacessíveis devido ao terreno acidentado ou ao perigo durante atividades eruptivas. Devido a estas limitações, apenas 10% dos vulcões ativos estão bem instrumentados. Mas então como podemos monitorar os 1.350 vulcões ativos e não instrumentados? Usando satélites.

Os satélites de observação têm sido uma revolução na forma como se percebe o planeta Terra (Fig.114). Com satélites em órbita polar, todos os pontos da superfície podem ser fotografados diariamente, tornando possível obter imagens de todos os vulcões subaéreos.




Figura 114. Alguns dos principais satélites que orbitam a Terra.
(crédito: ESA/Rosetta/NavCam – CC BY-SA IGO 3.0, ESA/DLR/FU Berlin, CC BY-SA IGO 3.0, ESA/Photographer's nome, CC BY-SA IGO 3.0)

Os vulcanologistas usam diferentes satélites e métodos para monitorar a atividade vulcânica. Os satélites radar e o método de interferometria radar, denominado InSAR, permitem detectar movimentos do solo antes, durante e depois de uma erupção (Fig.115).




Figura 115. Interferogramma Cosmo-SkyMed 2012-2014 mostrando deformação da área do cume do Kilauea e da zona do Rift do Alto/Médio Oriente. As áreas isoladas de subsidência nas crateras Alae e Makaopuhi são devidas ao resfriamento da lava que encheu essas crateras durante a erupção Mauna Ulu de 1969-1974.
(modificado: Dzurisin et al., 2019)

As imagens ópticas ou de radar permitem detectar alterações no tipo de superfície causadas pela instalação de produtos eruptivos durante uma erupção, sejam fluxos de lava ou fluxos piroclásticos (Fig.116).




Figura 116. Imagem óptica e radar com medida de mudança no tipo de superfície na área dos vulcões Nyiragongo e Nyamulagira na República Democrática do Congo.
(modificado: Sentinel-1Copernicus, tratado por ESA, CC BY-AS 3.0 IGO)

Os dados de satélite também nos permitem calcular Modelos Digitais de Terreno (MDT), representação 3D verdadeira da topografia. Isto permite extrair variações da topografia ligadas à atividade vulcânica e assim calcular as espessuras dos fluxos ou o volume e fluxo do magma emitido (Fig.117).




Figura 117. Modelo digital do terreno obtidos através da variação topográfica da região dos vulcões Nyiragongo e Nyamulagira na RDC.

6.4.3. Monitoramento de deformação

Vejamos como os cientistas usam dados de satélite para estudar a atividade vulcânica. Para isso, vamos pesquisar sobre três vulcões localizados em continentes diferentes.

Veremos um complexo vulcânico no Chile, incluindo Lastarria e Cordón del Azufre, um vulcão na Indonésia, Merapi, e finalmente um vulcão na República Democrática do Congo, Nyamulagira.

6.4.3.1. Monitoramento de deformação dos vulcões Lastarria e Cordón del Azufre

Partindo do Altiplano, uma área desértica a mais de 4.000 m acima do nível do mar, que fica na Cordilheira dos Andes, na fronteira entre o Chile e a Argentina, região totalmente isolada, estando a localidade mais próxima a mais de 250 km, é onde se situa o complexo vulcânico constituído pelos vulcões Cordón del Azufre e Lastarria (Fig.118).

Nesta região é muito difícil a instalação de estações de monitorização terrestre destes vulcões, porém, com imagens de satélite, é possível ter rapidamente uma visão global da área vulcânica.




Figura 118. Altiplano na Cordilheira dos Andes onde se situa o complexo vulcânico constituído pelos vulcões Cordón del Azufre e Lastarria.
(modificado: Google Earth, imagem 2024)

Na figura 119, na imagem de amplitude de radar adquirida pelo satélite Sentinel-1 em 2022, se pode identificar claramente a infinidade de domos vulcânicos presentes na região. A última erupção ocorreu há vários milhares de anos, e os vulcanólogos pensavam que este vulcão estava extinto, porém, qual não foi a surpresa quando analisaram as imagens de satélite adquiridas pela missão ENVISAT em 2003.




Figura 119. Imagem de amplitude do satélite Sentinel-1 da região dos vulcões Lastarria e Cordón del Azufre – Chile.
(modificado: Froger et al., 2007)

Na figura 120, se tem um interferograma, uma imagem de diferença de fase, obtidas entre 9 de março de 2003 e 26 de junho de 2005. Observa-se um grande sinal

concêntrico de 30 km de diâmetro centrado no vulcão, o qual está se deformando. Cada franja interferométrica representa aproximadamente 2,8 cm de deslocamento na linha de visão do satélite. Com aproximadamente duas franjas da periferia para o centro do sinal, se obtém um deslocamento máximo de 5,6 cm, em dois anos e quatro meses.

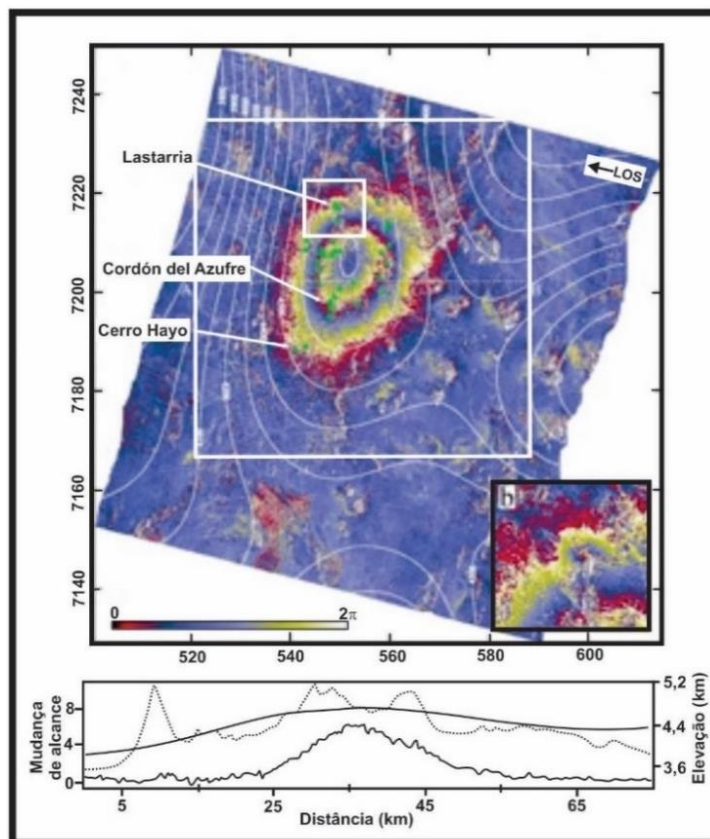


Figura 120. Interferograma calculado entre 09 e 26/06/2005 da região dos vulcões Lastarria e Cordón del Azufre. (modificado: Froger et al., 2007)

A sucessão de franjas, amarela, azul e vermelha, nos informa sobre a direção do movimento. Na imagem se observa um movimento do solo em direção ao satélite, indicando que o vulcão está inchando.

Estes resultados confirmam que este vulcão não está extinto, mas sim muito ativo e as conclusões são ainda mais preocupantes. Os modelos indicam que este sinal é induzido pela pressurização de um reservatório de magma com cerca de 10 km de profundidade, o que pode sugerir uma erupção no futuro.

Para monitorizar este vulcão, é crucial utilizar dados de satélite para acompanhar a evolução dos movimentos do solo ao longo do tempo. Isso é feito produzindo séries temporais de mapas de deslocamento, se calculando séries temporais de interferogramas como os mostrados na figura 121.

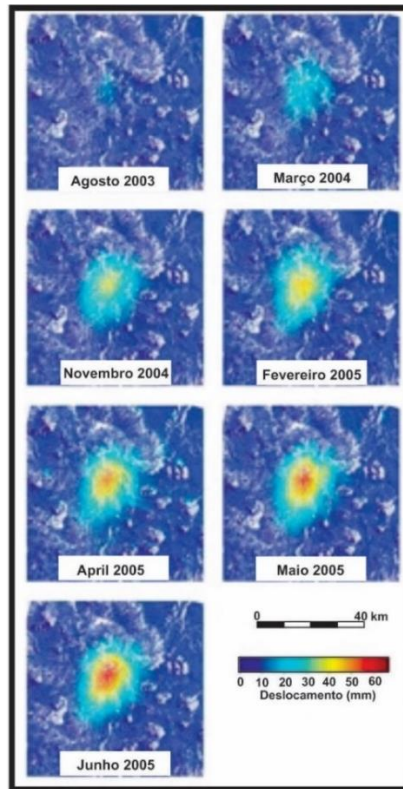


Figura 121. Série temporal de cartas de deslocamento entre 2003 e 2005.
(modificado: Forger et al., 2007)

A partir de séries temporais (Fig.122), se pode observar uma taxa de quase de 3 cm ao ano entre 2003 e 2010. Desde 2011, as taxas de movimento diminuíram, sugerindo uma redução no fornecimento de magma, nas profundezas do reservatório magmático. O Cordón del Azufre é um vulcão explosivo e uma única erupção pode ter um impacto regional ao longo de cem quilômetros. A linha azul representa o ajuste do modelo usando um modelo exponencial duplo no qual a sobrepressão do reservatório aumenta desde o início até 2006 (linha pontilhada), após o qual a sobrepressão permanece constante.




Figura 122. Séries temporais INSAR mostrando uma desaceleração da taxa de deformação com o passar do tempo. LOS – deslocamento da linha de visão do satélite; ΔP - reservatório sobrepressão. (modificado: Henderson et al. 2017)

6.4.3.2. Rastreamento de mudanças de superfície

O vulcão Merapi, localizado na ilha de Java, é um dos vulcões mais ativos da Indonésia, com erupção média a cada cinco/seis anos (Fig.123). Mas em 4 de novembro de 2010, este vulcão sofreu uma erupção excepcional, a qual acontece uma vez por século, com depósitos que foram transportados até uma distância de 16 km do cume.



Figura 123. Vulcão Merapi um dos mais ativos da ilha de Java.
(fonte: Gooel Earth)

Vejamos como os dados de satélite permitem mapear rapidamente esses depósitos que são muito extensos e difíceis de serem mapeados em campo. O mais óbvio é utilizar dados ópticos, como a imagem WorldView-2 (Fig.124), adquirida em 2010, poucos dias após a erupção, a qual permite ver os detalhes dos depósitos.



Figura 124. Imagem óptica do satélite WorldView-2. PDC=corrente de deposição piroclástica.
(modificado: Charbonnier et al., 2013)

Porém, nem sempre é possível obter rapidamente uma imagem óptica livre de nuvens, principalmente na estação chuvosa. Uma alternativa é usar imagens de radar. Em

particular, a formação de depósitos, ao modificar a rugosidade do solo e destruir a vegetação, provoca uma modificação da amplitude do sinal do radar, conforme mostrado na figura 125, que representa a relação entre uma imagem de amplitude adquirida após a instalação dos depósitos e uma imagem adquirida previamente.




Figura 125. Imagem de amplitude do vulcão Merapi antes e após a erupção de 2010.
(modificado: Solikhin et al., 2015)

Na imagem as áreas caracterizadas por uma diminuição na amplitude aparecem escuras, enquanto as áreas caracterizadas por um aumento na amplitude aparecem em branco. É, portanto, possível utilizar esta evolução da amplitude para produzir composições coloridas que realcem esta evolução (Fig. 126).




Figura 126. Imagem de composição colorida do vulcão Merapi obtida através da evolução da amplitude.
PDC=corrente de deposição piroclástica, BAF=fluxo de blocos e cinzas.
(modificado: Solikhin et al., 2015)

Outra característica de um par de imagens de radar que pode ser utilizada é a coerência (Fig.127). Geralmente é baixa em áreas com vegetação, mas se torna quase nula se a superfície do solo tiver sido modificada pela instalação de um fluxo. Ao fazer uma classificação supervisionada de todas as informações de amplitude e agregar coerência, se consegue mapear os depósitos colocados de forma muito satisfatória, e isso contando apenas com as imagens de radar disponíveis, independentemente da cobertura de nuvens (Fig.128).




Figura 127. Imagem de coerência mostrando área escura de baixa coerência onde o fluxo ocorreu. (modificado: Solikhin et al., 2015)

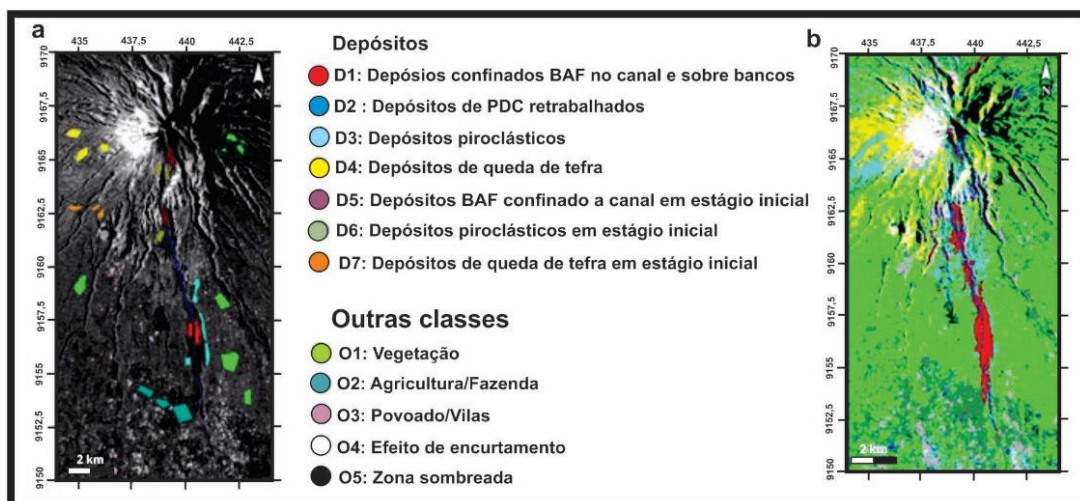


Figura 128. a) Área de treinamento usada para classificação supervisionada, b) resultado de uma classificação supervisionada. (modificado: Solikhin et al., 2015)

6.4.3.3. Avaliação dos volumes emitidos e do fluxo de emissões

Por fim, vamos à África, para um dos vulcões mais ativos do continente, o Nyamulagira, localizado na República Democrática do Congo, perto da fronteira com Ruanda. Este vulcão sofreu 7 erupções desde a década de 2000 (Fig.129).



Figura 129. Vulcão Nyamulagira na República Democrática do Congo.
(fonte: https://upload.wikimedia.org/wikipedia/commons/thumb/1/13/An_aerial_view_of_the_towering_volcanic_peak_of_Mt._Nyiragongo.jpg/1200px-An_aerial_view_of_the_towering_volcanic_peak_of_Mt._Nyiragongo.jpg)

Este vulcão é do tipo efusivo com fontes de lava produzindo cones e fluxos de lava de vários quilômetros que podem ser vistas do espaço (Fig.130). Estes fluxos de lava são uma ameaça para os 2 milhões de habitantes que vivem na cidade de Goma, localizada a apenas 25 km do vulcão.




Figura 130. Imagem de amplitude Sentinel-1 do vulcão Nyamulagira com a visualização do fluxo de lavas em cor cinza escuro.

Para reduzir o impacto de futuras erupções, uma informação importante para os vulcanologistas é saber com precisão as espessuras, bem como o volume dos fluxos de lava emitidos anteriormente. Isto permite realizar um estudo estatístico dos volumes eruptivos e melhorar os mapas de áreas que podem ser potencialmente afetadas por fluxos futuros. As observações de campo permitem medir, de tempos em tempos, a espessura dos fluxos de lava. Mas como saber as espessuras dentro do fluxo, onde é impossível caminhar? A solução é usar dados de satélite para produzir modelos 3D da topografia chamados Modelos Digitais de Terreno (MDT) (Fig.131).




Figura 131. Modelo Digital do Terreno da área do vulcão Santa Helena, antes e após a erupção de 18/05/1980.
(modificado: <https://pubs.usgs.gov/circ/c1050/fig49.jpg>)

O princípio é calcular um MDT antes e depois da erupção. A diferença entre os dois MDTs dará as variações na topografia, associadas ao estabelecimento do fluxo. Desta maneira cada pixel da imagem carrega informações sobre a espessura do material.

Na figura 132, temos o mapa de espessura obtido a partir de dados do radar TanDEM-X, cada pixel tem apenas 5 x 5 m. Seriam necessários 1 milhão de pontos de medição no campo para obter o mesmo resultado. Ao integrar a soma de todos esses pixels de espessura, é possível derivar o volume total do fluxo de lava. Se a erupção for suficientemente longa, é possível fazer o mesmo trabalho durante a erupção para caracterizar a evolução temporal dos volumes eruptivos e assim derivar um fluxo eruptivo.

Espera-se que estes três exemplos tenham ajudado você a entender como os dados de satélite podem ser usados para compreender e monitorar melhor o funcionamento dos vulcões.

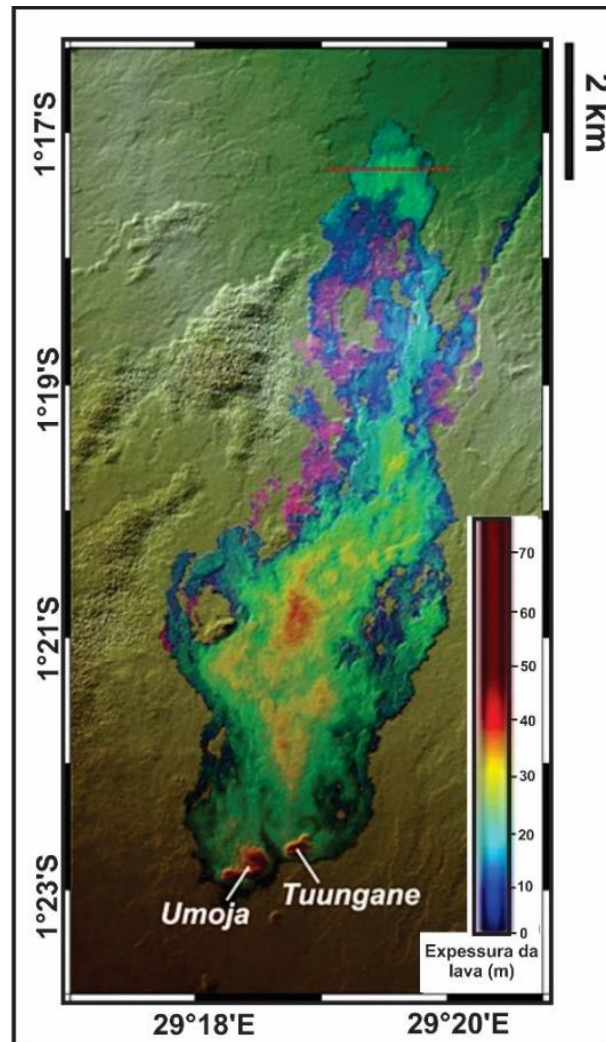


Figura 132. Mapa de espessura do fluxo de lava ocorrido durante a erupção de 2011-2012, através dos cones secundários do vulcão Nyamulagira. (modificado: Albino, et al., 2015)

7. MOVIMENTOS DE MASSA E GELEIRAS

7.1. Tipologia dos movimentos de massa

Neste capítulo vamos falar sobre movimentos de massa. Mas o que é isso exatamente?

A figura 133 nos mostra um exemplo de movimento de massa, chamado de queda de rocha e que apresenta uma velocidade de deslocamento de vários metros por segundo.



Figura 133. Queda de rochas no corredor de Goûter, no Monte Branco nos Alpes.
(fonte: <https://i.ytimg.com/vi/UWOTHOPLKgQ/hqdefault.jpg>)

Na figura 134, temos outro movimento de massa denominado de fluxo de detritos que pode variar em tamanho e apresenta uma velocidade de deslocamento de alguns centímetros por segundo.



Figura 134. Vista do fluxo de detritos ocorrido em 4 de julho de 2023, em Brienz-Brinzauls na Suíça.
(fonte: KEYSTONE/Gian Ehrenzeller)

Outro tipo de movimento de massa é o movimento denominado deslizamento de terra, o qual apresenta uma velocidade de deslocamento de alguns milímetros a alguns metros por ano ou mesmo metros por segundo (Fig.135).

Existe, portanto, uma grande variedade de tipos de movimentos, velocidades e tamanhos. Assim, os métodos de monitoramento e estudo destes movimentos irão variar de acordo com estas três propriedades.



Figura 135. Deslizamento de terra em Nova Friburgo 2011
(fonte: <https://www.nucleodoconhecimento.com.br/wp-content/uploads/2019/04/4.jpg>)

Há cerca de 4.000 vítimas de movimentos de massa todos os anos em todo o mundo, número que pode aumentar significativamente durante fortes sismos em regiões montanhosas ou em períodos de grandes precipitações pluviais. Os tremores sísmicos causam uma grande concentração de movimentos do solo de todos os tipos nas regiões ao redor da zona de falha e até várias centenas de quilômetros de distância (Fig.136).



Figura 136. Deslizamento de terra causado pelo terremoto de Hokkaido em 2018 no Japão
(fonte: crédito foto: JIJI PRESS. AFP)

Esta distribuição evidencia uma grande variabilidade espacial dos movimentos de massa, o que levanta a questão dos fatores, particularmente a geologia, a morfologia da superfície e a hidrologia, que controlam o seu desencadeamento numa escala muito pequena.

Essa complexidade torna a previsão de localização extremamente difícil. Além disso, os movimentos de massa apresentam variações muito fortes na sua velocidade ao longo do tempo. Por exemplo, o deslizamento de terra de Maca, localizado no Peru, mostra movimentos sazonais (círculo laranja), períodos de estabilidade (círculo azul) e velocidades excepcionais (círculos verdes) em anos de fortes chuvas ou durante terremotos próximos (Fig. 137).

A velocidade do movimento da massa é, portanto, uma função de forçantes naturais, chuvas fortes ou derretimento de neve, terremotos, erosão fluvial, atividades humanas como irrigação, desmatamento ou instalação de edifícios ou estradas.

É importante detectar movimentos de massa e acompanhar a sua velocidade ao longo do tempo, porque a sua ruptura catastrófica é muitas vezes precedida por uma fase de aceleração de algumas horas a alguns meses.




Figura 137. Deslocamento acumulado de deslizamento de terra em Maca no Peru entre 1986-2022.

7.2. Movimentos terrestres perigosos

Denomina-se de “movimento terrestre perigoso” a previsão que deverá permitir definir onde, quando e qual a dimensão do evento.

Para a questão “Onde”, podemos mapear todos os movimentos de massa ocorridos numa determinada região, de forma a determinar a importância dos fatores morfológicos e geológicos na probabilidade de instabilidade. Com este método pode-se chegar aos mapas de suscetibilidade aos movimentos do solo (Fig.138).

Uma alternativa é detectar áreas de declive afetadas por movimentos lentos, ativos ou passados, podendo assim se identificar áreas específicas a serem monitorizadas ao longo do tempo.

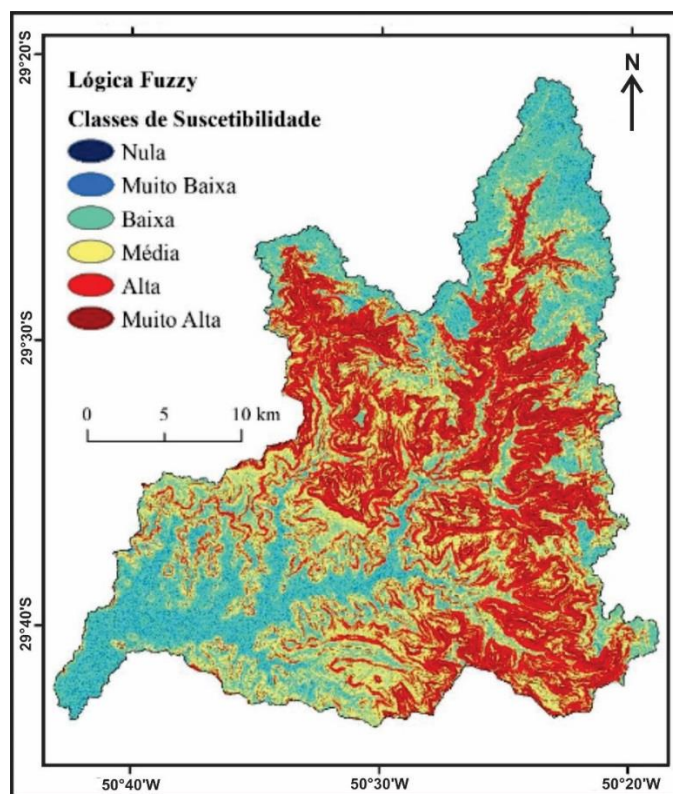


Figura 138. Mapa de suscetibilidade a movimentos de massa da Bacia Hidrográfica do rio Rolante – RS.
(fonte: Quevedo, 2019)

A resposta à pergunta “Quando?” também pode ser abordada de forma semelhante à pergunta “Onde?”. Assim, a análise de bases de dados de movimentos do solo desencadeados por uma determinada força (chuva forte ou sismo), permite definir limiares de chuva ou choque sísmico necessários para ativar determinados tipos de movimentos do solo.

Na Noruega, por exemplo, existe um sistema de alerta de movimentação de massa em todo o país, cujos níveis de alerta são definidos com base em previsões de precipitação e grau de saturação de água no solo, atualizadas duas vezes por dia (Fig.139).

O monitoramento dos movimentos lentos do solo, ao longo do tempo, permite detectar comportamentos anormais, ou seja, acelerações ou velocidades nunca antes observadas neste movimento do solo, ou acelerações mais fortes neste objeto em comparação com o que é observado ao mesmo tempo em movimentos lentos do solo circundante.

Infelizmente, nem todas as rupturas são precedidas de movimentos lentos, e mesmo quando preexistem movimentos lentos, a sua aceleração não é necessariamente constante, ou é medida com demasiadas incertezas para se obter uma previsão fiável, ou,

finalmente, a aceleração pode ser demasiado rápida para ser medida antes da ruptura. A previsão de perigos não deve, portanto, se basear apenas na procura de precursores.

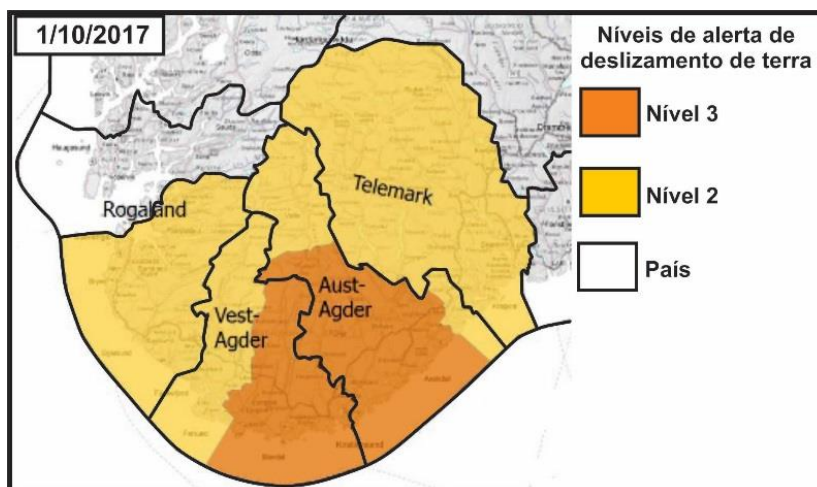


Figura 139. Mapa de emissão de alertas de deslizamento de terra para o sul da Noruega no período de 30/9 a 3/10 de 2017. (fonte: Krøgli et al., 2017)

A questão da dimensão do evento se refere sobretudo a uma superfície afetada pela deformação e num volume mobilizável, o que irá impactar sua propagação a jusante e portanto, na sua ameaça.

Assim, o catastrófico deslizamento de terra de Chamoli, em fevereiro de 2021, na Índia, mobilizou cerca de 30 milhões de m³ de rocha e devastou o vale a jusante ao longo de várias dezenas de quilômetros, soterrando uma central hidroelétrica, 25 km abaixo, e matando 300 pessoas (Fig.140).



Figura 140. Deslizamento de água, lama e escombros, em rompimento de geleira na Índia, em 7 de fevereiro de 2021 (foto: Reprodução KK Productions/Via AP)

Em 2024, durante períodos de fortes chuvas no Rio Grande do Sul, ocorreram vários deslizamentos de terra, destruindo casas, interditando rodovias e ocasionando

mortes (Fig.141). Grande parte destes deslizamentos já se encontram delimitados em suas áreas de ocorrência graças aos esforços das equipes de pesquisa da UFRGS conforme mostrado na figura 142.



Figura 141. Deslizamento de terra no Rio Grande do Sul em 29/04/2024 durante período de chuvas prolongadas.

(fonte: <https://horacampinas.com.br/wp-content/uploads/2024/05/chuvassul1.webp>)




Figura 142. Delimitação dos deslizamentos de solos ocorridos em parte do vale do Taquari-RS em maio de 2024.

(fonte: EROS C e BlackSky. Realização: Laboratório Latitude - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM) / Programa de Pós-graduação em Sensoriamento Remoto (PPGSR) / Departamento de Geodésia (DEGEO), Instituto de Geociências (IGeo) | Universidade Federal do Rio Grande do Sul (UFRGS).

Felizmente, a grande maioria dos deslizamentos de terra são bastante pequenos (geralmente menos de 100 a 1.000 m³), e os grandes deslizamentos de terra superiores a um milhão de m³ geralmente representam menos de 1 em 1.000 a 10.000 deslizamentos de terra.

Segundo trabalhos de Uber *et al.* (2012) foi elaborado um mapa de suscetibilidade à ocorrência de movimentos de massa para a Bacia do Marumbi, na região de Morretes-PR (Fig.143).

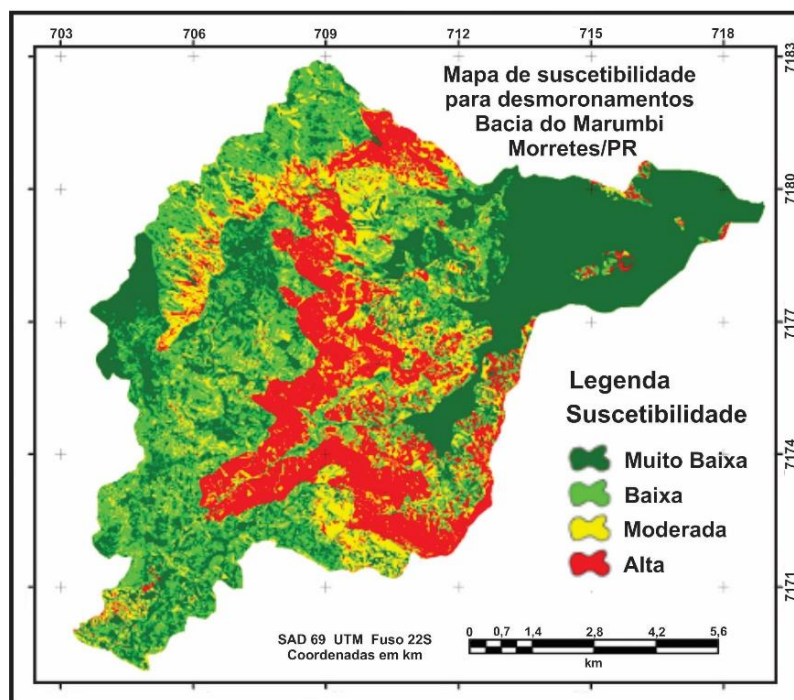


Figura 143. Mapa de suscetibilidade para movimentos de massa da Bacia do Marumbi, região de Morretes-PR.
(fonte: Uber *et al.*, 2012)

Com base no critério área por movimentos de vertente acumulados, o mapa foi classificado em quatro principais divisões de suscetibilidade: alta, moderada, baixa e muito baixa. Os limites das classes de suscetibilidade foram estabelecidos tendo em conta a capacidade preditiva do modelo utilizado. Assim, a classe de suscetibilidade alta abrange 20% da área total da bacia, a classe de suscetibilidade moderada abrange 21% da área total enquanto as classes de suscetibilidade baixa e muito baixa ocupa mais da metade (60%) da superfície total da bacia.

7.3. Contribuições do sensoriamento remoto e interesses de diferentes tipos de dados/sensores

A localização dos movimentos de massa em áreas muitas vezes inacessíveis, bem como as suas velocidades muito variáveis ao longo do tempo, fazem com que o sensoriamento remoto por satélite se tenha tornado rapidamente na principal ferramenta para detectar, seguir e caracterizar a grande maioria dos movimentos de massa. No entanto, os movimentos massa também têm especificidades que dificultam a utilização de

satélites para estes tipos de situações: encostas íngremes não visíveis para todos os satélites, tamanhos de alvos muito pequenos, não detectáveis com dados de fonte aberta, e velocidades que variam muito ao longo do tempo. Essas características envolvem a utilização de diversos métodos e dados de satélite que dependerão do tamanho e da velocidade dos objetos procurados.

Por exemplo, o InSAR permite detectar e rastrear movimentos de massa muito lentos, cuja velocidade varia de alguns mm/ano a 1 m/ano. Para movimentos de massa um pouco mais rápidos ou para dados separados por um longo período, se pode usar a correlação de imagens, seja aplicada a dados ópticos ou dados de radar.

Imagens ópticas que possuem um pixel menor, mais textura que as imagens de radar e visão vertical, permitem a detecção de movimentos menores, em tamanho e velocidade, que o radar, porém quando a área está muito nublada, o radar é a única alternativa.

Na figura 143 temos a imagem do mesmo deslizamento de terra visto tanto por correlação de imagem óptica, usando 2 imagens separadas por 4 anos, que mostram um deslocamento base de quase 10 m (Fig.144a,b), e depois visto por um InSAR, a partir de 2 aquisições separadas por 18 dias, que imageia, principalmente, o movimento mais fraco da parte a montante (Fig.144c,d).

Além disso, não seríamos mais capazes de distinguir as franjas, pois seriam muito estreitas. A correlação óptica da imagem mede movimentos no plano horizontal e tem uma incerteza de aproximadamente um décimo de pixel, ou seja, para imagens Landsat 8, com resolução de 15 m, a incerteza será de aproximadamente 1,5 m.

O InSAR mede movimentos na direção de visão do satélite com uma incerteza de um décimo do comprimento de onda do radar. A dificuldade do InSAR, na determinação de movimentos de deslizamentos, reside no seu pequeno tamanho e na sua velocidade que nem sempre permite o desdobramento da fase, ou seja, passar de uma fase de radar para um movimento real.

Quando a velocidade do movimento do solo é muito grande, especialmente durante a ruptura, as condições da superfície mudam, o que significa que os deslizamentos de terra perturbam o solo e destroem a vegetação, como pode ser visto na figura 141 Os métodos de correlação de imagens não funcionam mais. Métodos de detecção de alterações precisarão ser usados para detectar movimentos no solo.

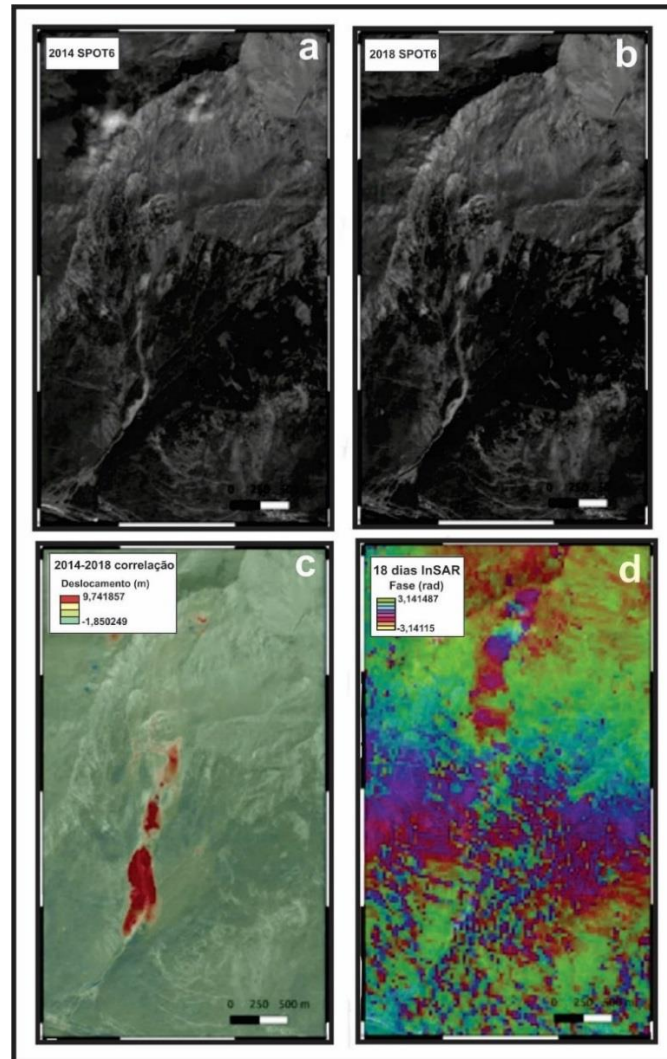


Figura 144. Imagem SPOT 6/7 de um deslizamento em Vanoise, nos Alpes Franceses, e deslocamentos de solo obtidos por correlação de imagens separadas por 4 anos (a;b), e pelo InSAR separadas por 18 dias (c;d). (fonte: SPOT)

7.3.1. Inventário de movimento rápido

Desde a generalização de dados de satélite com resolução suficiente (>30 m), as imagens multiespectrais permitem o mapeamento regular de centenas ou mesmo milhares de deslizamentos de terra, na escala de regiões ou de países inteiros.

Com uma única imagem se pode mapear todos os deslizamentos ainda visíveis e obter um catálogo “histórico” representando de uma a várias décadas. Com duas imagens se pode mapear apenas os “novos deslizamentos de terra” que ocorreram durante um evento desencadeador específico, como um terremoto ou um tufão (Fig.145).

O método clássico consiste em detectar alterações no brilho e na textura das imagens ópticas, considerando o contexto geomorfológico e evitando mapear perturbações antrópicas, ou seja, ligadas às atividades humanas.



Figura 154. Interpretação de deslizamento de terra ocasionado pelo terremoto de Gorkha, Nepal em 2015.
(modificado: Marc et al., 2019; imagem: Robert Behling GFZ)

Métodos que também agregam dados de radares estão sendo desenvolvidos com a vantagem de restringir melhor a data de ocorrência de movimentos de solo em áreas nubladas.

A vantagem do mapeamento por satélite é ser capaz de obter informações quantitativas sobre a superfície dos movimentos de massa e suas posições na paisagem para um grande número deles, muitas vezes vários milhares, e relacioná-los com as propriedades locais da paisagem e do evento desencadeador (Fig.146).




Figura 146. Gráfico mostrando a comparação da densidade de deslizamentos de terra entre os deslizamentos de terra induzidos por terremotos e chuvas fortes.
(modificado: Yamagishi & Iwahashi, 2007)

As conclusões deste tipo de estudo permitem formar cenários úteis em termos de perigos, por exemplo, relacionando a quantidade de movimentos do solo com a distância à falha sísmica que causou o sismo (Fig.147).




Figura 147. Quantidade de movimento do solo em função da distância até a falha sísmica.
(modificado: Gorum et al., 2011)

7.3.2. Caracterização dos movimentos de massa

Se a localização dos movimentos de massa for a primeira questão para um estudo de perigos, outras características específicas são importantes, tais como o seu tamanho, o seu volume ou a sua velocidade, os quais permitirão estudos de propagação de fluxo e portanto, de impacto.

O volume é obtido de forma diferente para deslizamentos rápidos ou lentos. Para deslizamentos rápidos, o volume é estimado após sua ocorrência, fazendo a diferença entre dois Modelos Digitais de Terreno (MDTs), um adquirido antes e outro depois do evento.

A figura 148 mostra o resultado obtido pela diferença de dois MDTs de uma área da Nova Zelândia afetada pelo terremoto de Kaikoura em 2016.




Figura 148. Mapa mostrando a diferença entre dois MDT adquiridos antes e depois do terremoto de Kaikoura na Nova Zelândia em 2016.
(modificado: Bernard et al., 2020)

As partes azuis mostram áreas de erosão ou perda de espessura, enquanto as áreas vermelhas mostram áreas de depósitos ou ganho de espessura. Estas diferenças servem de base para o cálculo do volume, cuja precisão final dependerá da precisão dos registros dos MDTs entre eles e da qualidade individual de cada um dos MDTs. A qualidade do MDT é melhor em áreas planas do que em encostas, o que tem forte efeito na estimativa dos volumes de movimentos de solo localizados em encostas íngremes. Para estimativas em áreas de falésias, se recorre, portanto, à obtenção de MDTs, por fotogrametria ou Lidar, do solo em frente à falésia.

Estimar os volumes de movimentos lentos de terras é mais complicado. Ou se tem medições no solo, provenientes de perfurações ou perfis geofísicos, que nos dão a espessura da massa instável em diferentes locais, ou o sensoriamento remoto pode ser usado fazendo hipóteses sobre a reologia da massa instável, ou seja, a maneira como o material se deforma.

Utilizando os campos de deslocamento horizontal, medidos pela correlação de imagens, bem como as variações topográficas por diferença nos MDTs, se pode obter a profundidade da superfície de deslizamento em qualquer ponto do movimento do solo (Fig.149).

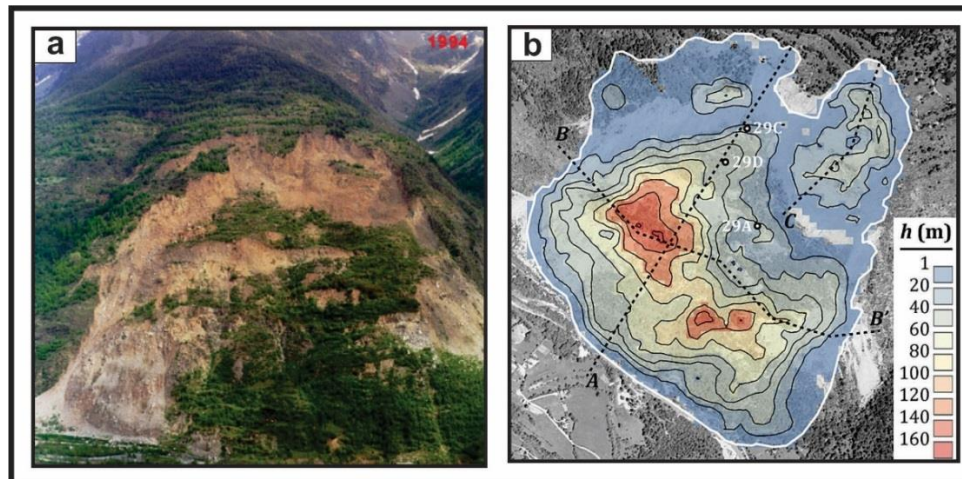


Figura 149. a) Foto do deslizamento lento de terra de La Clapière, Alpes Franceses.
b) Mapa de espessura da massa instável do deslizamento.
(modificado: Booth et al., 2013)

7.3.3. Monitoramento temporal de deslizamento lento

O advento dos satélites com aquisição sistemática, ou seja, que adquirem todas as imagens ao longo da sua órbita, tornou possível obter séries temporais de imagens de satélite com uma elevada frequência de revisita, podendo ser obtida até uma ou mais imagens por dia e um grande período temporal. Estas séries temporais podem, portanto, ser utilizadas para estudar tanto os efeitos de longo prazo como os efeitos transitórios no mesmo movimento lento do solo, e assim estudar os diferentes fatores que modulam a sua velocidade: terremotos, chuva, erosão fluvial e forçante antropogênico.

Para isso, estes estudos se baseiam na medição de séries temporais de deslocamento, na maioria das vezes por correlação óptica de imagens ou por InSAR.

Assim, a série temporal de deslocamentos realizada, utilizando satélites de alta frequência, como o Sentinel-2, no deslizamento de Punillo no Peru, permitiu ver a forte variabilidade temporal da velocidade, com a maior parte do deslocamento acomodado em dois meses, durante uma aceleração produzida pela adição de material à massa instável. Estas séries temporais de deslocamentos permitem, portanto, estudar a mecânica dos movimentos de massa, permitindo às vezes detectar acelerações pré-ruptura (Fig.150).

Graças à correlação de imagens ópticas, foi produzida uma série temporal de deslocamentos do solo ao longo dos meses anteriores a este deslizamento, se podendo

perceber claramente uma aceleração do movimento nos dois meses anteriores ao evento, que chegou a quase 7 m (Fig.150).




Figura 150. Deslocamento acumulado de movimento de massa na região do Peru com uma aceleração do movimento nos últimos dois meses anterior ao evento. (modificado: Lacroix et al.,2023)

A detecção desta aceleração é possibilitada pela alta frequência de aquisições de satélites. Esses movimentos são frequentemente tão pequenos que não podem ser detectados opticamente. A técnica InSAR, que permite acompanhar movimentos muito lentos, constitui uma excelente fonte de informação para detectar o início de uma aceleração pré-ruptura.

Na figura 151, o processamento do InSAR permitiu detectar uma aceleração de um deslizamento na China, com um deslocamento de apenas 6 cm nos dois meses anteriores à sua ruptura.

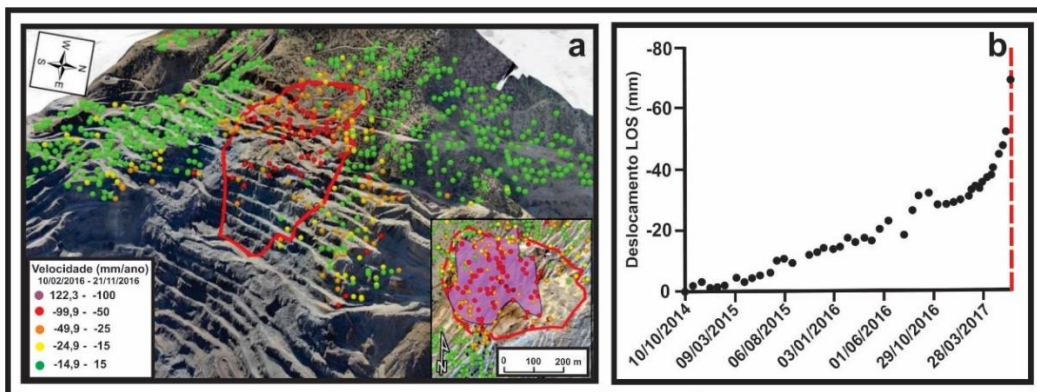


Figura 151. a) Imagem InSAR mostrando a deformação precursora que levou à falha do talude da mina a céu aberto em Xinmo na China em 17/11/2016. O polígono a direita delimita a área afetada por tendências aceleradas de deslocamento. b) Gráfico mostrando o deslocamento acumulado de movimento de massa em Xinmo na China. (modificado: Carlà et al.,2019)

Estes diferentes métodos para medir a velocidade e, assim, detectar movimentos lentos do solo de diferentes naturezas e cinemáticas, a partir de satélites de alta

frequência, estão agora mais fáceis. Eles permitem o monitoramento automatizado e em tempo real da instabilidade da gravidade e existem serviços de processamento automático. Portanto, é importante não tanto saber como processar os dados, mas sim interpretar os resultados, bem como compreender e quantificar as fontes de incerteza.

7.4. O Sensoriamento Remoto e as Geleiras

O que é uma geleira? Um glaciar é uma massa natural de gelo que provém da transformação progressiva da neve, sob o efeito da acumulação sucessiva ano após ano. Esta massa de gelo flui por gravidade, por deformação do material e por deslizamento na rocha subjacente, quando a temperatura do gelo está próxima do ponto de fusão.

Esquemáticamente, se pode caracterizar duas zonas principais de uma geleira (Fig.152): a montante, a zona de acumulação onde os ganhos de massa, ao longo de um ano, são maiores que as perdas ligadas à ablação, nesta o balanço de massa é considerado positivo; a jusante, a zona de ablação onde a neve acumulada, durante o inverno, derrete completamente e parte do gelo proveniente da zona de acumulação, também derrete, o que ocasiona, nesta zona, uma perda de massa ao longo do ano, maior que o ganho. O balanço de massa é considerado negativo, pois como a geleira flui continuamente, parte do gelo perdido na zona de ablação é compensado pelo fluxo de gelo da zona de acumulação. Assim, para que um glaciar exista e se mantenha ao longo do tempo, deve existir um contexto climático que conduza a acumulações significativas de neve que não derretam completamente durante a estação de ablação seguinte (Fig.152).




Figura 152. Seção esquemática de uma geleira com a zona superior de acumulação e a zona inferior de ablação.
(modificado: Six & Vincent, 2024)

Hoje, estas condições são encontradas em cadeias de montanhas de grandes altitudes, incluindo nos trópicos, ou em altas latitudes em regiões polares, onde as geleiras podem atingir o nível do mar. Processos de acumulação e ablação na superfície de uma geleira, ou seja, ganhos e perdas de massa, dependem diretamente das condições meteorológicas, particularmente da precipitação de neve, radiação solar, radiação atmosférica, temperatura e humidade do ar ou mesmo velocidade e direção do vento.

De um ano para o outro, dependendo das condições climáticas, o balanço de massa de toda a geleira pode ser positivo ou negativo (Fig.153a). A longo prazo, se as condições climáticas forem desfavoráveis para os glaciares, por exemplo, na sequência de um aumento das temperaturas, aumentando o degelo ou de uma redução na precipitação, limitando a acumulação, o volume do glaciar diminuirá e, com isso, a sua geometria mudará e sua área de superfície e comprimento diminuirão (Fig.153b,c). Por outro lado, se as condições forem favoráveis, o volume da geleira aumenta, a sua área de superfície e o seu comprimento aumentam (Fig.153d,e). As geleiras apresentam geometria variável e seu tamanho varia ao longo do tempo, dependendo das condições climáticas.




Figura 153. Esquema evolutivo de uma geleira com as variações de temperatura ou precipitação. (modificado: https://media.springernature.com/lw685/springer-static/image/chp%3A10.1007%2F978-1-4614-9213-9_472-1/MediaObjects/214584_0_En_472-1_Fig1_HTML.gif)

7.4.1. Problemas na evolução das geleiras

Como foi mencionado, as geleiras têm, estritamente falando, geometria variável. Seu tamanho varia ao longo do tempo, dependendo das condições climáticas. Ligado ao fluxo do gelo e à configuração das encostas das montanhas onde se situam os glaciares, podem ser a causa de vários tipos de perigos.

A história recente atesta acontecimentos catastróficos que ocasionaram milhares de vítimas. As questões relacionadas com os glaciares podem ter um impacto em diferentes escalas, tanto local como global.

Um exemplo de perigo glacial é a queda de *seracs*, avalanches de gelo ou o colapso total ou parcial de uma geleira. Estes fenômenos são difíceis de prever e antecipar, porque dependem de vários fatores como o regime térmico do glaciar, a quantidade de água no gelo ou mesmo a situação topográfica do glaciar.

Um exemplo recente, mostrado na figura 154, é o de um pequeno glaciar na encosta norte do cume da Marmolada, na Itália. Parte da língua glaciar desabou no início de julho de 2022, causando cerca de dez vítimas. Milhares de toneladas de gelo e rochas caíram a mais de 200 km/h formando um buraco de 200 m de comprimento e 80 m de altura.



Figura 154. Vista do glaciar de Marmolada na Itália após o desabamento de parte do glaciar.
(foto: <https://www.gedistatic.it/content/gnn/img/lastampa/2023/07/02/202250671-aff39366-0398-40fc-8080-a8cf5c78cb53.jpg>)

Outro exemplo são os lagos que se formam à medida que a frente da geleira recua. Dependendo da topografia da área glaciar, pode se formar um chamado lago proglacial, podendo ocorrer drenagem acidental. Um dos exemplos mais mortíferos da história é o lago Palcacocha, nos Andes do Peru (Fig.155). Após o colapso do gelo no lago em 1941,

uma onda atingiu a barragem, fazendo com que o lago fosse drenado repentinamente. Isso gerou um deslizamento de terra que soterrou parte da cidade de Huaraz, causando entre 6 e 7 mil vítimas.



Figura 155. Vista do lago Palcacocha no Peru.
(foto: Alexander Luna)

Um terceiro exemplo é o dos vulcões cobertos por uma calota polar. Um grande número deles é encontrado na Cordilheira dos Andes ou na Islândia e durante uma fase de erupção vulcânica, toda ou parte da calota polar pode derreter rapidamente e causar um fenômeno chamado *Lahar*, que corresponde à lava torrencial muito densa que devasta tudo em seu caminho. Um exemplo é a erupção do Nevado del Ruiz, na Colômbia, que ocorreu em 1985, onde parte da calota polar derreteu durante a erupção, e a cidade de Armero foi, em grande parte, coberta por *Lahars*, causando quase 24.000 vítimas.

A nível regional, uma das principais questões ligadas à evolução dos glaciares é agora a dos recursos hídricos de origem glacial. Com efeito, os glaciares constituem um reservatório importante nas bacias hidrográficas das montanhas, sendo que a cobertura de neve e as águas subterrâneas desempenham um papel essencial, especialmente no final do verão, quando a cobertura de neve do inverno derrete completamente. As questões relativas aos recursos hídricos incluem o abastecimento de água potável, a irrigação e até a produção hidroelétrica.

Finalmente, a nível global, a principal questão ligada à evolução atual dos glaciares é a da subida do nível do mar. Durante o século XX, a subida do nível médio do mar foi da ordem de 1,7 mm por ano e duplicou para 3,5 mm por ano, nas últimas duas décadas (Fig.156).

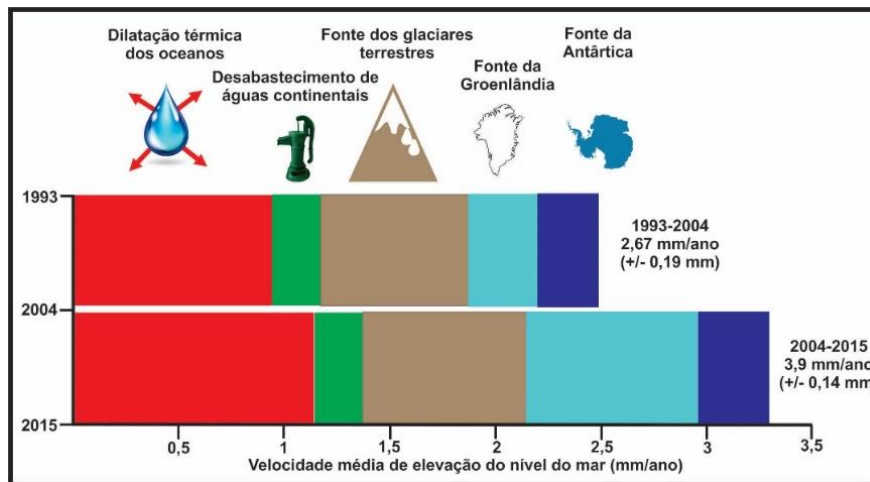


Figura 156. Gráfico da velocidade média da variação do nível do mar entre 1993 e 2015 com suas contribuições.
(modificado: Dieng et al. 2017)

A contribuição das geleiras de montanha é equivalente à das duas grandes calotas polares, a Antártica e a Groenlândia a qual, atualmente, gira em torno de 1 mm por ano. Até 2100, a subida do nível do mar poderá alcançar várias dezenas de centímetros e até ultrapassar 1 m, em caso de desestabilização de certos setores da Antártida. As consequências para todas as infraestruturas localizadas nas zonas costeiras, que acolhem quase um bilhão de pessoas na Terra, e para a sociedade como um todo, poderão ser desastrosas.

7.4.2. Benefícios do sensoriamento remoto e os interesses dos diferentes tipos de dados de sensores

O sensoriamento remoto fornece dados essenciais para monitorar a evolução das geleiras e antecipar os impactos ligados a esta evolução nas questões anteriormente mencionadas. Em primeiro lugar, os dados de satélite nos permitem ter uma visão global de todos os glaciares do planeta, ao contrário das medições de campo que só podem ser realizadas num número limitado de glaciares.

Por exemplo, os satélites Sentinel-2 da Agência Espacial Europeia, fornecem uma cobertura completa das superfícies continentais da Terra a cada cinco dias. Posteriormente, os dados do satélite permitem medir as principais variáveis de interesse para a monitorização dos glaciares: a sua superfície, o seu comprimento, o estado da sua superfície, ou seja, se o glaciar está coberto de neve ou se aparece gelo, se o lago se forma na frente ou sobre a geleira, as variações na altitude da superfície, o que permite quantificar se a geleira ganha ou perde volume, por fim, as velocidades de fluxo da geleira, cujas variações podem ser utilizadas como precursoras de desestabilização (Fig.157).



Figura 157. Dados fornecidos pelo sensoriamento remoto.

7.4.3. Inventário dos glaciares e caracterização de seu estado superficial

Já se abordou que as questões relacionadas com os glaciares podem ter impacto em diferentes escalas. Vejamos agora como os produtos de sensoriamento remoto podem ser úteis para solucionar problemas.

Para quantificar as questões relacionadas com os glaciares e identificar áreas de risco, a primeira coisa a fazer é saber onde estão localizados esses glaciares, ou seja, fazer os inventários. Além disso, como a área superficial dos glaciares muda com o passar

do tempo, esses inventários devem ser repetidos ao longo do tempo. Internacionalmente, este trabalho de inventário é coordenado como parte de uma iniciativa chamada *Global Land Ice Measurements from Space (GLIMS)*.

Nestes inventários, se pode mapear o estado da superfície do glaciário, ou seja, a parte onde o gelo é visível, o que é denominado de zona de ablação; a parte onde a geleira está coberta de neve, a zona de acumulação; também a presença de detritos rochosos na superfície da geleira ou a presença de lagos na própria geleira ou em sua frente (Fig.158).




Figura 158. Partes de um glaciário. ELA – Linha de Equilíbrio Altitudinal.
(fonte: Rivera et al. 2016)

Para estas diferentes tarefas, os dados de satélite, particularmente os dados ópticos multiespectrais, são muito interessantes. Isso ocorre porque a quantidade de radiação refletida pela superfície nos comprimentos de onda do espectro solar, depende das propriedades da superfície. Assim, combinando diferentes bandas espectrais, por exemplo, criando índices, se pode detectar e, portanto, mapear as superfícies de interesse.

Por exemplo, no trabalho de Shukla *et al.* (2018), os autores realizaram um inventário multitemporal de lagos glaciais na região de Sikkim, no leste do Himalaia, entre 1975 e 2017. Para isso, usaram imagens ópticas de resolução decamétrica adquiridas por diferentes sensores. Ao longo do período de estudo, puderam observar um aumento na superfície dos lagos de quase 25%, ligado ao recuo das línguas glaciais (Fig.159).




Figura 159. Mudança em lagos supraglaciais (SGL), lagos pró/periglaciais em contato com a geleira (PGLC), lagos pró/periglaciais distantes da geleira (PGLA) e outros lagos (OL) entre 1975 e 2017. (modificado: Shukla et al., 2018)

Este trabalho de mapeamento pode ser amplamente automatizado para processar massivamente dados de satélite à escala de todas as regiões, ou mesmo à escala global. Para isso, se utiliza métodos de classificação que são chamados de supervisionados ou não supervisionados dependendo do grau de expertise que queremos colocar no processo de detecção (Fig.160).

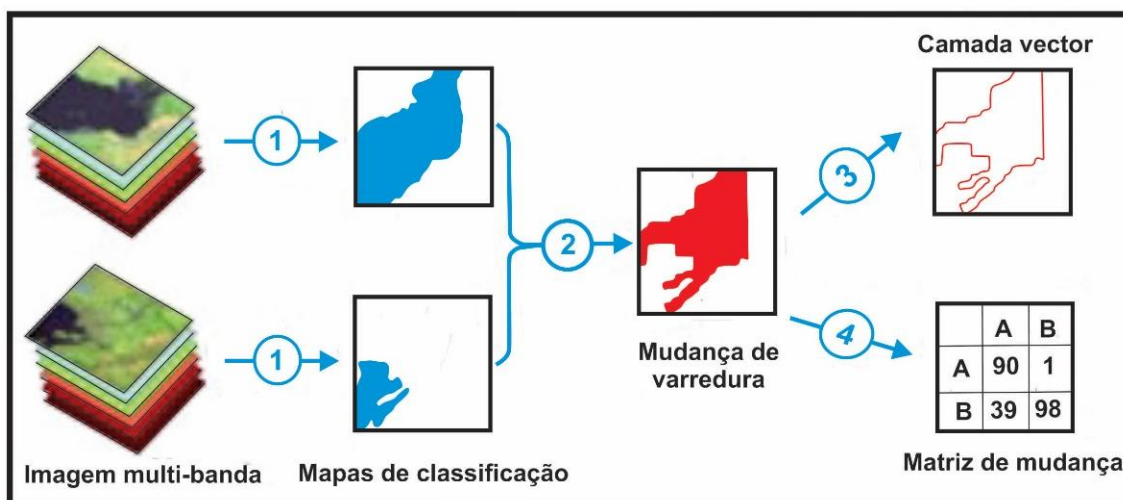


Figura 160. Métodos de classificação supervisionados e não supervisionados.

Nas contribuições da inteligência artificial (IA) para o processamento de dados de satélite, observa-se que foram implementadas um grande número de abordagens com nomes por vezes poéticos, como árvores de regressão, florestas aleatórias ou mesmo redes neurais.

Para caracterizar variações no volume das geleiras, pares de imagens estereoscópicas podem ser usados. Anteriormente vimos que a altitude da superfície pode ser medida por fotogrametria ou a partir de dados de radar ou mesmo a partir de medições a laser. Estes dados permitem obter um modelo digital da superfície do glaciar, ou seja, uma representação tridimensional (Fig.161).




Figura 161. Representação 3D de um glaciar do Everest.
(fonte: https://geomatyx.com/hero/Everest_3d_model.jpg)

Pela diferença entre dois modelos digitais de terreno adquiridos em datas diferentes, quantificamos as variações de espessura e, portanto, de volume das geleiras. Dependendo do tipo de dados, a precisão varia. Utilizando dados de alta resolução espacial, como dados de radar ou dados ópticos do tipo Plêiades, se pode quantificar os volumes de gelo mobilizados por um evento catastrófico, como foi o caso, por exemplo, durante o colapso da geleira Aru, no Tibete, ocorrido em julho e setembro. 2016.

Como pode ser visto na figura 162, nas imagens do Sentinel-2 obtidas com dias de intervalo entre antes e depois do desastre, duas línguas glaciais se romperam e a avalanche de gelo percorreu quase 10 km. Pela diferença nos modelos digitais de terreno, adquiridos com dados Tandem X e Plêiades, foi possível quantificar o volume colapsado em quase 150 milhões de metros cúbicos. (Kääb *et al.*, 2018) (Fig.163).




Figura 162. Colapso da geleira Aru 1 e 2 no Tibete, ocorrido em 17 de julho e 21 de setembro de 2016.
(modificado: https://eoimages.gsfc.nasa.gov/images/imagerecords/88000/88953/tibet_sar_2016268.jpg)

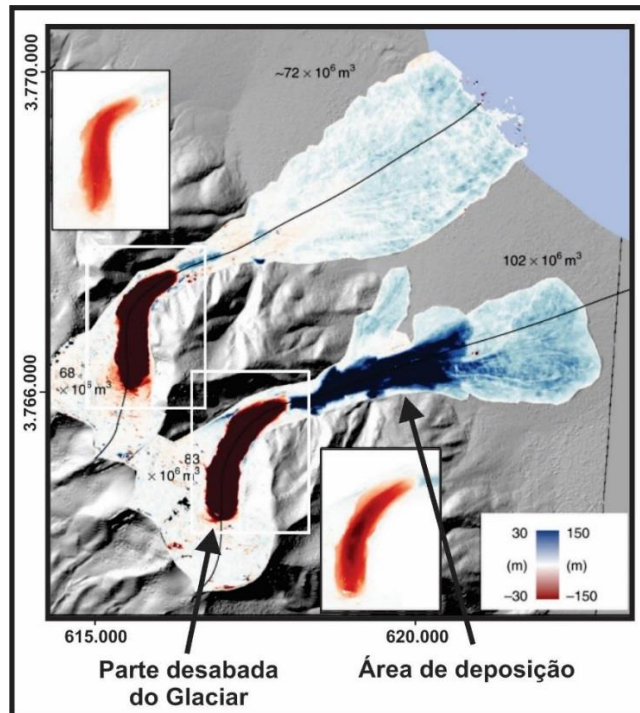


Figura 163. Mudanças de elevação entre 25/11/2015 e 1/10/2016. As zonas de origem do colapso são fornecidas em duas escalas de cores (± 30 m, figura principal; ± 150 m, inserções). Os valores observados na figura indicam os volumes de origem e de depósito.
(modificado: Kääb et al, 2018)

Outros tipos de dados estéreo-ópticos de sensores como o ASTER têm uma resolução espacial menor do que Plêiades ou TanDEM-X, mas são adquiridos para todas as superfícies da Terra cada vez que o satélite passa, ou seja, a cada dezesseis dias, desde o ano 2000.

Este tipo de dados permitiu documentar de forma global a perda de volume dos glaciares nas últimas duas décadas. Hugonnet *et al.* (2021), mostraram que todos os 220 mil glaciares do mundo perderam quase 270 bilhões de toneladas por ano, entre 2000 e

2020 (Fig.164). Esta perda de gelo, traduzida em volume de água, corresponde a mais de 20% da subida do nível do mar, documentada ao longo deste período.




Figura 164. Recuo do glaciar Upsala situado na Patagônia entre 2003 e 2018.
(modificado: Hugonnet et al. 2021)

7.4.4. Velocidade do fluxo superficial dos glaciares

Para caracterizar a velocidade com que as geleiras fluem, pode-se usar correlação de imagens ou interferometria de radar. Millan *et al.* (2022), para quantificar a velocidade do fluxo de todas as geleiras do mundo, usaram mais de 800.000 pares de imagens de satélite, adquiridas entre 2017 e 2018, pelos satélites Landsat-8 da NASA e Sentinel-1 e Sentinel-2 da Agência Espacial Europeia. Este atlas ilustra a grande variedade de comportamentos dos glaciares que fluem algumas dezenas de metros por ano, como nos Alpes, e outros cujas velocidades de fluxo atingem vários quilômetros num único ano, como na Patagônia (Fig.165).




Figura 165. Mapa de velocidade de fluxo do gelo dos campos de gelo do Sul da Patagônia.
(modificado: Millan et al., 2022)

Estes dados de velocidade são muito importantes para melhor restringir a representação dos glaciares em modelos de fluxo e assim estimar melhor os seus desenvolvimentos futuros. Além disso, as medições de velocidade permitem documentar eventos potencialmente catastróficos, como os "surges" glaciais, estes deslizamentos inesperados dos glaciares que podem fazer com que a sua frente avance vários quilômetros no espaço de um ano.

Além disso, dados de velocidade são usados para estimar espessuras de gelo que são, em grande parte, desconhecidas porque são complexas de medir. Conhecer os volumes de gelo é essencial em termos de recursos hídricos e particularmente à escala local. Por exemplo, nos Andes tropicais da América do Sul, o estudo mais recente para quantificar os volumes glaciais, mostrou que os estoques de água glacial seriam quase um quarto inferiores às estimativas anteriores. Tal resultado mostra que a pressão sobre os recursos hídricos nessas regiões e os riscos em termos de gestão para as décadas futuras é uma questão importante, seja para irrigação, consumo de água potável ou mesmo produção hidrelétrica.

VIII. INUNDAÇÕES, QUEIMADAS, INCÊNDIOS E DERRAMAMENTO DE ÓLEO.

8.1. Mapeamento de áreas inundáveis através de sensoriamento remoto

8.1.1. Introdução

Os eventos de inundação são responsáveis por quase 55% de todos os desastres registrados e por aproximadamente 72,5% do total de perdas econômicas ao redor do mundo. Anualmente, as inundações causam danos a cidades, rodovias, infraestrutura e agricultura, com altíssimos custos em vidas e para a economia, como um todo (Fig. 166).



Figura 166. Inundação da região central da cidade de Porto Alegre, no estado do Rio Grande do Sul, Brasil, em 5/5/2024.
(foto: REUTERS - Renan Mattos).

Vários fatores contribuem para a ocorrência desse tipo de desastre, entre os quais a intensidade e a duração das precipitações, o derretimento de neve, o desmatamento, práticas inadequadas de uso do solo, sedimentação de leitos e a obstrução de canais de rios, as quais ocorrem de forma natural ou por ações antrópicas.

Segundo Miola (2013), o mapeamento de áreas inundáveis é uma medida não estrutural e cujo objetivo é atuar como uma ferramenta de planejamento e prevenção, para áreas urbanas e para a bacia hidrográfica, elaborado a partir de uma análise dos fatores de maior influência para o problema, como chuva, relevo etc.

As inundações e enchentes são eventos naturais relacionados à água, que ocorrem nos cursos dos rios. Embora frequentemente confundidos, esses termos possuem significados diferentes. A inundação ocorre quando um corpo de água transborda, alcançando as áreas planas laterais, conhecidas como planície de inundação, enquanto a enchente, esta ocorre quando o nível da água no canal de drenagem aumenta devido ao

aumento do fluxo, sem transbordamento. Sendo a inundação o impacto mais significativo na sociedade (Costa, 2022).

O tamanho e a ocorrência das inundações dependem da intensidade e distribuição de precipitação na bacia hidrográfica, da taxa de infiltração de água e da saturação do solo, bem como das características morfométricas e morfológicas da bacia de drenagem.

Devido à ocorrência frequente de eventos hidrológicos extremos, especialmente nas áreas urbanas, com alta taxa de impermeabilização do solo e densidade populacional elevada, as inundações urbanas são fenômenos que não se limitam apenas aos grandes centros urbanos, mas também são observados em cidades de médio e até mesmo pequeno porte, como as que ocorreram em mais de 400 municípios do Rio Grande do Sul em 2024.

8.1.2. Topografia e modelos digitais de terreno.

A topografia de uma bacia exerce uma influência significativa nos fenômenos relacionados à água, à geologia e à biologia que ocorrem na paisagem. A disposição espacial das características geográficas, frequentemente, pode ser utilizada como uma maneira indireta de avaliar a variação espacial desses fenômenos, permitindo que sejam cartografados por meio de abordagens simples.

A topografia tem grande importância nas estimativas de vazão e do tempo de chegada da cheia através dos modelos chuva-vazão, por contribuir com informações da bacia. Uma análise da topografia, juntamente com outros fatores que contribuem para os eventos de cheia, como ações antrópicas e precipitações, podem indicar as áreas vulneráveis a enchentes, denominadas áreas inundáveis.

Os modelos digitais de terreno (MDT), podem ser utilizados como ferramentas que podem contribuir com dados como declividade, comprimento ao longo do escoamento, direção do escoamento, área acumulada de drenagem, rede de drenagem e delimitação da bacia, aprimorando os modelos chuva-vazão, visto que estes utilizam grades para armazenar dados topográficos, comumente definidos por imagens *raster*, onde cada pixel contém um valor correspondente à altitude local (Lima, 2021).

8.1.3. Sensoriamento remoto e inundações

Os resultados obtidos em vários trabalhos, mostram que o mapeamento de áreas de inundação, efetuados a partir de sensoriamento remoto, podem ser aplicados em locais

onde não há um mapeamento da área de inundação, de modo acessível, podendo ser realizado de qualquer localidade. A modelagem deve ser feita com os MDTs filtrados, ou sejam, os que obtiveram maiores índices de combinação com o mapeamento de referência e que seja acrescentada uma margem de erro no entorno da modelagem, principalmente em trechos onde o curso d'água possui curvas sinuosas, visto que a modelagem não delimita com precisão essas áreas.

Dessa forma, um dos principais problemas urbanos dos municípios brasileiros, as inundações, podem ter uma fonte de dados de embasamento, para que medidas de prevenção sejam tomadas, sem o desprendimento de excessivos recursos profissionais e financeiros.

Estudos podem ser desenvolvidos para mapear remotamente as bacias e disponibilizar publicamente os resultados obtidos, para que os comitês responsáveis pelas bacias hidrográficas ou agentes públicos, possam utilizar durante a gestão dos municípios, auxiliando em planejamento urbano que previna os impactos do processo de inundação.

Séries temporais de dados de sensoriamento remoto são muito úteis para a gestão de desastres como inundações, uma vez que possibilitam a identificação do local preferencial de ocorrência das inundações ao longo dos anos; das áreas potenciais de inundação; da magnitude das inundações em diferentes anos e se estas se encontram em modificação em função do uso e da cobertura do solo; da época do ano em que preferencialmente ocorrem as inundações em uma dada área; e de mudanças temporais (Fig.167).



Figura 167. Imagens do Sentinel-2 da região dos rios Jacuí, Taquari e Guaíba antes e depois da cheia de 2024, no Rio Grande do Sul.

(fonte: <https://ciram.epagri.sc.gov.br/wp-content/uploads/2024/05/Figura1-955x1024.jpg>)

Na figura 167 pode-se observar como as águas dos rios cobriram extensas áreas em municípios devastados pela enchente, em decorrência das chuvas intensas que atingiram o Estado.

Na figura 168 se observa o alcance da destruição provocada pelas enchentes no vale do Taquarí-RS, com o registro do antes e depois, onde é possível analisar o impacto ocasionado na região dos municípios atingidos.

Por meio das imagens obtidas num determinado período, é possível mapear os alagamentos ocorridos em áreas rurais e urbanas, o que auxilia os tomadores de decisões a estabelecerem as decisões estratégicas e emergenciais, e poder acompanhar a evolução da situação nessas áreas para, futuramente, direcionar os esforços de reconstrução.



Figura 168. Imagens de satélite da região do Vale do Taquarí-RS antes e depois da cheia de 2024.
(fonte: https://www.rbsdirect.com.br/filestore/0/0/0/4/2/8/4_076f47dfe0b941/4824000_9235c71d0515920.jpg?w=700)

8.2. Mapeamento de áreas de queimadas e incêndios

Segundo Betancurt & Santos (1981), o sensoriamento remoto pode ser considerado a tecnologia ideal para a identificação e o monitoramento de incêndios florestais, ou mesmo queimadas, por sua praticidade, rapidez e baixo custo.

Para a identificação de incêndios ou queimadas é preciso detectar focos de calor através da diferença de temperatura entre os alvos imageados na superfície terrestre. Pereira (1987), identificou três fontes de radiação infravermelha termal envolvidas nesse processo: emissão pelas substâncias em combustão; emissão e reflexão de outros elementos presentes na área em que ocorre o fogo, incluindo-se os resíduos de combustão; e emissão e reflexão do solo exposto na área queimada.

Uma aplicação do sensoriamento remoto é a delimitação de áreas de incêndios ou queimadas, como no caso do incêndio ocorrido no Peru, nas proximidades das ruínas de Machupicchu, entre 20 e 24 de julho de 2017, utilizando-se imagens do Landsat-8, incluindo visualização e cálculo da extensão da área queimada pelo incêndio florestal, assim como sobreposição de camadas de informação geográfica do recurso cultural (sítios arqueológicos e caminho Inca) do Parque Arqueológico Nacional de Machupicchu (PANM), (Fig.169).

A partir das imagens foi possível determinar e cálculo as áreas queimadas através da digitalização interativa do polígono das feições das áreas atingidas presentes nas imagens infravermelhas (RGB: B654) ortoretificadas do Landsat 8, de 2013 e 2017.

A área atingida pelo incêndio florestal que ocorreu de 20 a 24 de julho de 2017 foi de 347,31 ha, correspondente a 0,9% do Parque Arqueológico Nacional de Machupicchu (PANM).



Figura 169. Delimitação da área queimada, polígono em amarelo, pelo incêndio florestal de 21 a 24 de julho de 2017 na região próxima as ruínas de Machupicchu-Peru.
(fonte: <https://mundogeo.com/wp-content/uploads/2018/02/Imagem-104.jpg>)

Outro exemplo é a imagem observada na figura 170, obtida pelo satélite Aqua, da Nasa, que mostram claramente o impacto das queimadas nos estados do Amazonas, Rondônia, Mato Grosso e Pará.



Figura 170. Demarcação e acompanhamento das queimadas na região norte do Brasil a partir do satélite Aqua da Nasa em 21/08/2019.

(fonte: <https://img.odcdn.com.br/wp-content/uploads/2019/08/20190821044124.jpg>)

Na imagem é possível observar um “corredor de fumaça” se espalhando por longas distâncias sobre a região imageada, levada pelos ventos. As “plumas” acinzentadas são as nuvens de fumaça gerada pelas queimadas, enquanto os pontos brancos são as nuvens propriamente ditas.

Outro exemplo são os incêndios que atingiram as áreas florestais na divisa entre Mato Grosso e Mato Grosso do Sul, no centro-oeste brasileiro, em novembro de 2023. No dia 22 de novembro, o satélite Copernicus Sentinel-2, da Agência Espacial Europeia, flagrou as regiões afetadas pelo fogo (Fig. 171).




Figura 171. Imagem do satélite Copernicus Sentinel 2, da região Parque Nacional do Pantanal Matogrossense. As cores em vermelho representam as regiões de queimadas.

(fonte: https://www.rbsdirect.com.br/filestore/7/0/9/3/7/8/4_cd13298b9489025/4873907_a904042985f02db.jpg?w=1024&h=1024&a=c)

Os dados multitemporais de satélites como Landsat, Sentinel, Aqua e outros, demonstraram mais uma vez a sua capacidade e eficácia na detecção e avaliação de áreas queimadas por incêndios florestais.

8.3. Sensoriamento Remoto em ambiente urbano: área permeável e impermeável

A quantificação da relação entre superfícies infiltrantes e superfícies impermeabilizadas constitui um dos parâmetros mais importantes para avaliar as restrições ambientais impostas por uma área urbana ao seu ambiente natural. Imagens orbitais do Landsat ou do SPOT, não apresentam boa resolução para a visualização e delimitação dos principais objetos que constitui a rede urbana (edifícios, estacionamentos, calçadas, gramados, jardins etc.), devido ao tamanho de seus pixels (20 m no melhor dos casos). Entretanto a nova geração de sensores com alta resolução espacial, podem superar estas dificuldades.

Alguns satélites como o IKONOS apresentam um nível de precisão que permite distinguir claramente os automóveis, as estradas, os jardins, as ruas pavimentadas etc.



Figura 172. Imagem IKONOS da região de Lyon, França.
(fonte: Chevrel et al., 2002)

A figura 172, representa o perímetro sul da colina do Mont d'Or, localizado em Lyon, na França, onde o relevo é cortado pela última volta do rio Saône, antes da sua confluência com o curso do Ródano, onde pode ser visto as áreas com vegetação, áreas com permeabilidade do solo, as quais aparecem mapeadas em laranja, enquanto as áreas impermeabilizadas, tais como estacionamentos, rodovias, ruas, telhados, praças pavimentadas etc, aparecem em azul celeste. A zona inferior da figura 172 foi objeto de um estudo mais aprofundado que permitiu individualizar com precisão as zonas com capacidade de infiltração, das zonas de escoamento.

8.4. Sensoriamento Remoto com aplicação de imagens na banda do infravermelho

A figura 173 ilustra uma imagem Landsat TM 7 da região de Bordeaux, França, delimitando claramente a resposta das principais unidades constituintes da paisagem. A composição corresponde a uma representação nas cores vermelho-verde-azul onde o vermelho traduz a resposta no infravermelho médio, o verde a resposta no infravermelho próximo e o azul a resposta no visível (domínio verde).




Figura 173. Imagem Landsat na banda do infravermelho da região de Bordeaux, França.
(fonte: Rudant et al., 2002)

A distinção é clara entre a floresta de coníferas da região de Landes (em tons de verde mais escuro) e as outras unidades de vegetação, aqui representadas principalmente por prados, em tons verde claro, na região ao norte de Médoc e na região de Entre-deux-Mers.

As áreas de solo ou superfície mineralizadas são representadas em tons de vermelho: cidade de Bordeaux, vinhas da margem esquerda do estuário do Gironde (Médoc), região a leste de Libourne e a noroeste de Langon na margem esquerda do rio Garonne.

O azul é especialmente utilizado na distinção da turbidez das águas dos estuários e, em menor grau, das águas costeiras.

A foto da figura 173, foi obtida em 8 de março de 2000, ou seja, 70 dias após a terrível tempestade de 27 de dezembro de 1999, o que possibilita reconhecer e mapear muitas das áreas de devastação ocasionada pelo vento (áreas de árvores derrubadas), as quais aparecem em tons de rosa no meio da floresta de Landes.

8.5. Sensoriamento Remoto no derramamento de óleo

Apesar dos registros históricos mostrarem uma diminuição nos desastres com derramamento de óleo, os mesmos alertam para os riscos presentes nas atividades petrolíferas em áreas costeiras e oceânicas (Leifer *et al.*, 2012).

A busca por novas reservas e o crescimento da produção e do consumo mundial de petróleo, ocasionam o aumento de riscos potenciais de novos derramamentos de óleo, em especial na margem continental brasileira, devido as recentes descobertas na região do pré-sal, intensificando as atividades de exploração, produção e transporte de petróleo e derivados.

A identificação de derrames de óleo, em imagens de satélite, tem por base o contraste térmico existente entre áreas com presença de óleo e adjacências. A partir de certa quantidade de óleo derramado, a sua identificação é obtida através da alteração da emissividade, da capacidade calorífica e da condutividade térmica das superfícies (Leifer *et al.*, 2012).

A capacidade de detecção de óleo a partir da banda do infravermelho termal (IVT) depende de algumas variáveis, incluindo a espessura do derrame e o horário de observação.

A figura 174 mostra um derrame de óleo na costa da Síria, próximo a cidade de Baniyas se deslocando em direção NE para a Turquia e ilha de Creta.



Figura 174. Imagens de satélite mostram derramamento de óleo ao longo da costa da Síria, perto de Baniyas, em 24 de agosto de 2021.

(fonte: <https://www.cnnbrasil.com.br/wp-content/uploads/sites/12/2021/09/210831102656-syria-oil-spill-0824-exlarge-169.jpg>)

Películas de óleo podem ser detectados a partir de imagens de radar, as quais modificam a tensão superficial, provocando diferentes graus de atenuação das ondas capilares e gravitacionais curtas produzidas pela ação dos ventos (Alpers & Hühnerfuss, 1989). Nas áreas sem óleo, a reflexão é predominantemente difusa, ao passo que na região com presença de óleo, com menor rugosidade, a maior parte da energia é refletida especularmente, na direção oposta à do sensor. Esse fenômeno ocasiona a presença de áreas escuras nas imagens de radar, devido ao menor retroespalhamento do pulso incidente (Fig.175).

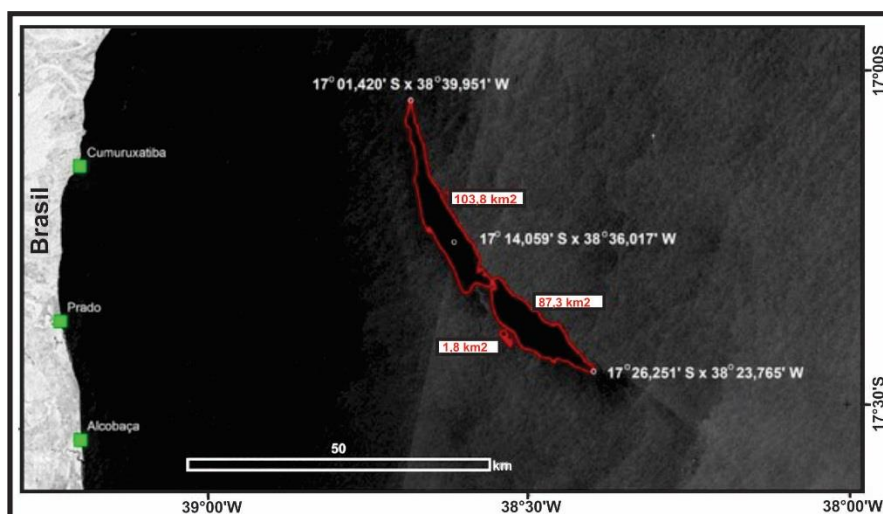


Figura 175. Imagem do satélite Sentinel mostra mancha com características de óleo a 50 km da costa da Bahia – Brasil.

(fonte: [https://s2-g1.glbimg.com/DnyChijG46AYkzNjg_k4GI3GUyiw=/0x0:1280x905/600x0/smart/filters:gifv\(\):strip_icc\(\)/i.s3.glbimg.com/v1/AUTH_59edd422c0c84a879bd37670ae4f538a/internal_photos/bs/2019/r/d/lxHAG7SfSqdmJ8TYipCw/manchadeoleo-sentinel2.jpeg](https://s2-g1.glbimg.com/DnyChijG46AYkzNjg_k4GI3GUyiw=/0x0:1280x905/600x0/smart/filters:gifv():strip_icc()/i.s3.glbimg.com/v1/AUTH_59edd422c0c84a879bd37670ae4f538a/internal_photos/bs/2019/r/d/lxHAG7SfSqdmJ8TYipCw/manchadeoleo-sentinel2.jpeg))

A crescente disponibilidade e diversidade de satélites têm consolidado o uso operacional do sensoriamento remoto orbital em ações de resposta, como fonte de informações para a detecção e a caracterização de derramamentos, bem como para modelos de deriva de óleo, contribuindo no planejamento de operações de recolhimento, aplicação de dispersantes e queima in situ (Fingas & Brown, 2014).

Os radares orbitais são amplamente utilizados por permitirem o imageamento durante o dia e a noite, com alta frequência temporal, amplas faixas de cobertura, sem a interferência de condições meteorológicas adversas. Os dados obtidos permitem localizar e estimar a área dos derrames de óleo e visualizar a fragmentação e o deslocamento das manchas em tempo próximo do real, fornecendo dados úteis para definir a rota das inspeções das áreas, bem como o posicionamento das embarcações durante as operações de resposta (Leifer *et al.*, 2012; Fingas & Brown, 2014).

IX. INTELIGÊNCIA ARTIFICIAL E MONITORAMENTO

9.1. Inteligência Artificial

A inteligência artificial (IA) e o aprendizado de máquina (AM) ou aprendizagem automática (AA) são um pouco sonhadores, mas também assustadores, como se fossem um pouco mágicos e, portanto, não confiáveis, embora seja exatamente o oposto. Simplificando, o aprendizado de máquina (AM) é um algoritmo que aprenderá, a partir dos dados existentes, a executar uma tarefa específica. Vejamos um exemplo simples: suponhamos que eu queira estimar automaticamente o consumo anual de eletricidade de uma casa com base em informações básicas, como metragem quadrada, número de habitantes, etc. Neste caso, os dados de entrada do meu modelo serão as características (área superficial, número de habitantes etc.) e o que procuro, portanto os meus dados de saída será o consumo da casa. Necessito então de informações conhecidas sobre outras casas das quais conheço os dados de entrada e saída, portanto o seu consumo real.

Na figura 176, cada ponto é uma casa e se assume aqui que tenhamos apenas um recurso de entrada, por exemplo, área superficial. A partir desses dados, posso ter um modelo e é por isso que falamos sobre dados de treinamento. Aqui se pode pensar na regressão linear, que é a forma mais simples de modelo de aprendizado de máquina (AM). No nosso caso, nosso modelo não é verdadeiramente linear.

Então, para uma casa nova, falamos sobre dados de teste. A partir dessas informações, área superficial, número de habitantes etc., podemos estimar seu consumo.

Claro que os dados e modelos podem ser mais complicados, como imagens, mas a ideia permanece a mesma. Então qual é a diferença entre inteligência artificial (IA) e aprendizado de máquina (AM)?




Figura 176. Gráfico de casas com entrada de área superficial.

A inteligência artificial (IA) é um conceito geral para o desenvolvimento de sistemas computacionais capazes de realizar tarefas que normalmente requerem inteligência humana. Isto inclui robótica ou sistemas lógicos, por exemplo. Mas acima de tudo, hoje o aprendizado de máquina (AM), como vimos, utiliza as informações existentes para criar um modelo inteligente, e muitas vezes, quanto mais dados tivermos, melhor será o modelo a ser obtido (Fig.177).

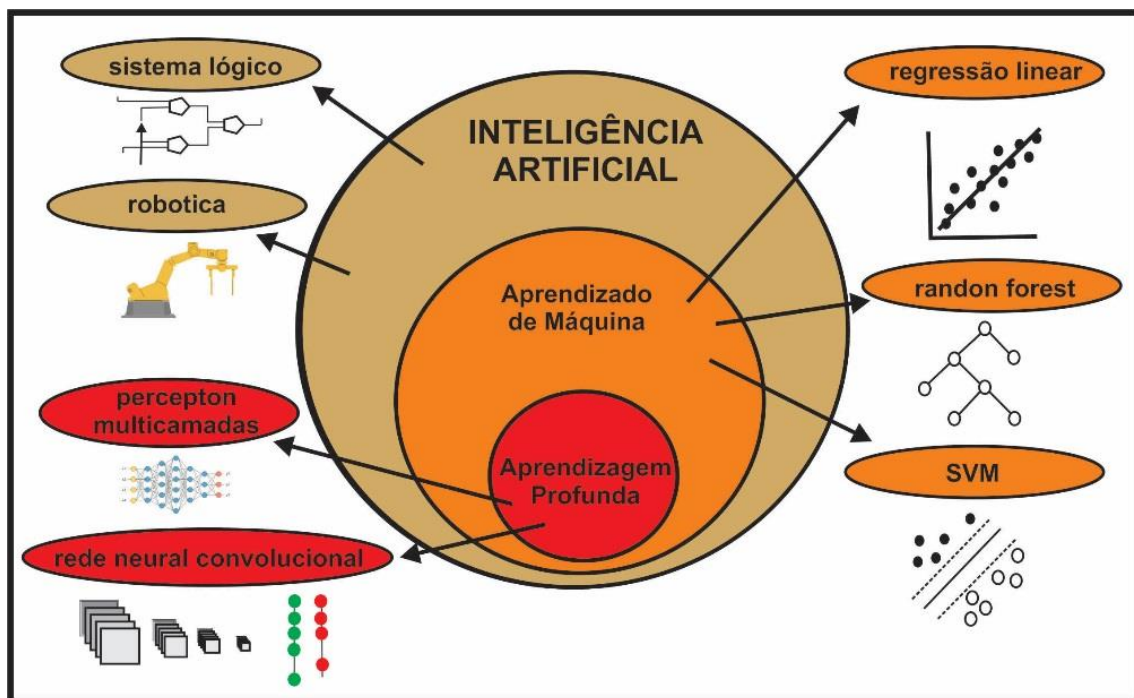


Figura 177. Esquema relacionando a inteligência artificial e o aprendizado de máquina.
(modificado: <https://www.ufsm.br/app/uploads/sites/791/2021/05/img1.png>)

Onde se encaixa o aprendizado profundo (AP) em tudo isso? Existem vários métodos ou famílias de algoritmos de aprendizado de máquina (AM). Já vimos regressão linear ou quadrática, mas também existem, por exemplo, florestas aleatórias (*random forest*) que se baseiam em árvores de decisão aleatórias. Outras famílias de métodos têm feito grandes progressos nos últimos anos, porque são métodos capazes de aproximar quase qualquer função com base numa sucessão de operações simples, mas muito numerosas. Isso é aprendizado profundo (AP), também chamado de redes neurais, o qual é particularmente eficaz para imagens.

9.2. Aprendizagem de máquina e imagens

Os modelos de aprendizagem profunda (AP) são muito eficazes em problemas onde os dados são imagens. Por exemplo, reconhecer um gato de um cachorro ou poder detectar anomalias.

Vejamos o que é uma imagem em preto e branco para simplificar. Esta é uma matriz bidimensional, uma grande tabela cujo valor de cada pixel equivale à sua intensidade. Em vez de ter algumas características como dados de entrada (como por exemplo: a casa, a área superficial etc.), se tem 200 x 250 pixels, ou mais de 50.000 caracteres (Fig.178). Isso é um pouco demais para regressão linear. Para os humanos, decodificar rapidamente esta informação é fácil, mas ao analisar o que o cérebro faz, rapidamente se percebe que se trata de um problema complexo e multiescalar.

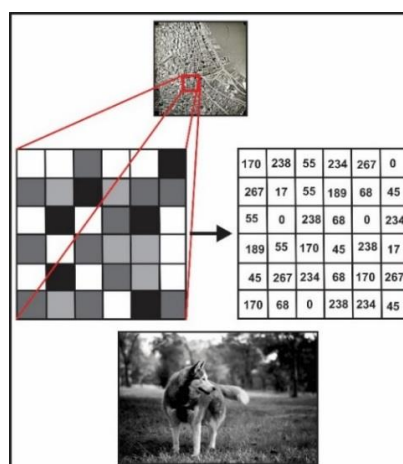


Figura 178. Imagem aérea com sua matriz bidimensional.
(modificado: <https://citrasetelit.wordpress.com/wp-content/uploads/2020/11/digital-number-pada-citra-satelit-pankromatik.gif?w=584>)

Será difícil estabelecer regras para que um algoritmo saiba detectar um cachorro, mas a vantagem é que também são dados ordenados. Então, esses 50.000 pixels estão ligados aos seus vizinhos. Se mudarmos a ordem, o cachorro não estará mais visível.

O método de aprendizagem profunda (AP), denominado rede neural convolucional (RNC), utiliza suas propriedades derivadas do funcionamento do córtex visual para criar um algoritmo capaz de aprender a partir de imagens.

Para fazer isso, alterna-se operações de convolução local com outras operações simples, mas não lineares. Em seguida, são necessários muitos exemplos de treinamento para melhorar os parâmetros do modelo durante o próprio treinamento. No exemplo da figura 179, a tarefa é descobrir se esta imagem é ou não um cachorro.




Figura 179. Rede neural convolucional (RNC).
(modificado: Montagnon et al., 2022)

Imagens, principalmente imagens de satélite, podem ser usadas como dados de entrada, para um algoritmo de aprendizado de máquina (AM), para resolver diversos problemas. Assim é possível automatizar ou melhorar tarefas complexas de processamento que exigem tempo de especialistas, como o desdobramento das fases do InSAR, a correlação de imagens ópticas, a supressão de ruído etc.

No exemplo da figura 180, o aprendizado de máquina (AM) torna possível eliminar o ruído das séries temporais do InSAR, para observar deformações tectônicas.

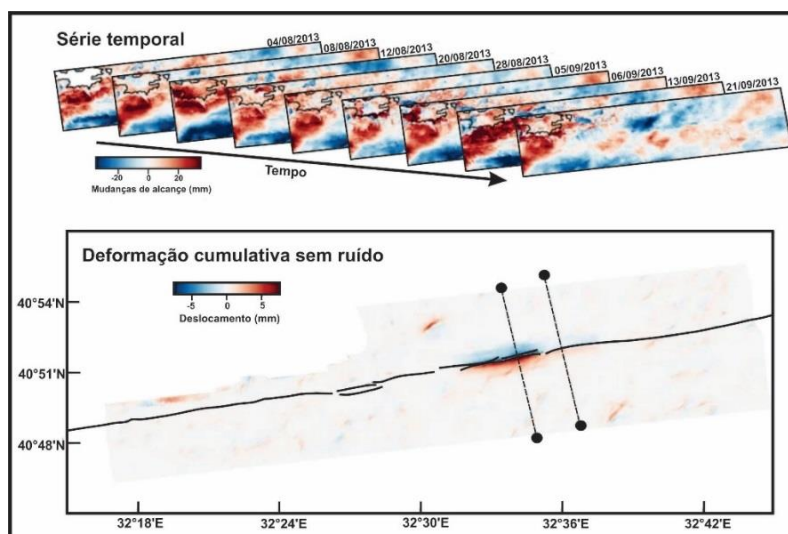


Figura 180. Automatização e melhoria de tarefas de processamento complexas. Aplicação a dados reais do terremoto lento da falha da Anatólia Norte de 2013.
(modificado: Rouet-Leduc et al. 2020)

Algoritmos de aprendizado de máquina (AM) também podem detectar eventos ou objetos, como detectar falhas ou deslizamentos de terra em uma paisagem, detectar fumaça de um vulcão, detectar uma avalanche. Estas são muitas vezes tarefas, hoje realizadas manualmente por especialistas, mas que consomem muito tempo. No exemplo da figura 181, o aprendizado de máquina (AM) detecta automaticamente movimentos vulcânicos em imagens InSAR.

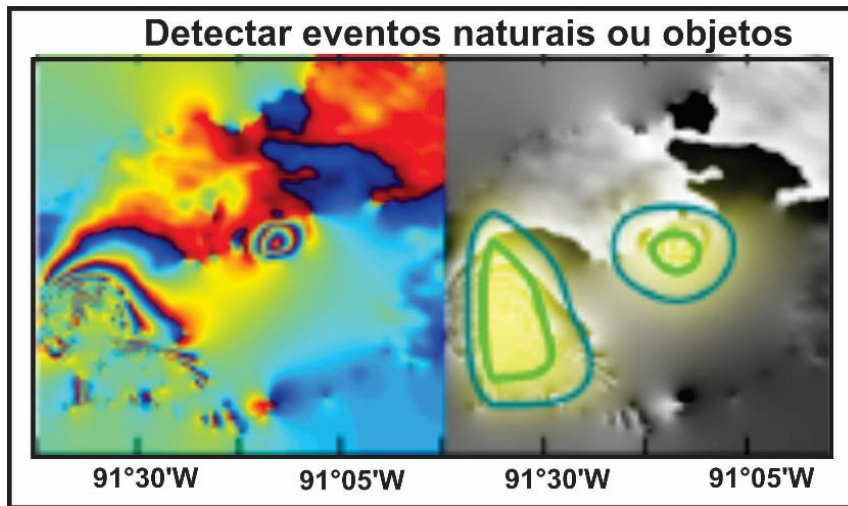


Figura 181. Detecção automática de vulcões em interferogramas.
(modificado: Anantrasirichai, et al., 2019)

Também é possível caracterizar estes eventos e objetos como a localização de um terremoto ou a quantificação do derretimento de uma geleira. No exemplo da figura 182, o modelo de aprendizado de máquina (AM) estima o movimento de massa a partir de duas imagens em duas datas diferentes.




Figura 182. Estimativa de deslocamento entre duas datas a partir de imagens ópticas.
(modificado: Montagnon et al., 2022)

Seremos capazes de prever os riscos naturais para limitar as suas consequências? O aprendizado de máquina (AM) pode nos ajudar a prever desastres no futuro. Então todos os nossos problemas são resolvidos pela IA? Tenha cuidado, IA não é mágica. Em primeiro lugar, se necessita de uma base de dados de formação substancial onde se conheça os dados de saída, ou seja, a solução do que estamos a tentar estimar, como no exemplo das casas e do seu consumo de energia. No nosso caso, se quisermos prever a ocorrência de uma erupção vulcânica massiva, teríamos primeiro de ter centenas ou milhares de erupções ocorridas durante o período de aquisição de imagens pelos satélites. Portanto, em um ambiente natural, a verdade básica costuma ser difícil de saber. Além disso, com esses modelos, presume-se que exista um vínculo físico comprovado entre os dados que se possui e a saída. Mesmo que não o conheçamos. Por exemplo, se eu tentar prever o consumo de eletricidade da minha casa, com base na cor das paredes, não vai dar um bom modelo. Da mesma forma, se minhas imagens de satélite não tiverem resolução suficiente para ver um deslizamento, mesmo que eu tenha um algoritmo muito complicado, ele nunca funcionará.

Para prever riscos, a informação deve, portanto, estar presente nos dados. Temos que prestar atenção a um grande problema no aprendizado de máquina (AM) chamado *overfitting* (sobreajuste). Se voltarmos ao exemplo de cálculo do consumo de uma casa, vamos supor que se consiga ter dados muito fiáveis sobre uma cidade inteira, por exemplo Porto Alegre, com consumo real das casas ao longo de um ano. Posso treinar um algoritmo em uma parte da cidade e testar nas outras partes para ver se meu modelo funciona, podendo haver uma boa chance de que funcione, e então direi que posso usá-lo em qualquer lugar do Brasil. Isso seria um desastre. Pois se o modelo for aplicado em Belém, subestimarei completamente o consumo, devido que, obviamente, para características idênticas como a superfície, em Belém onde é muito mais quente, as casas são mais refrigeradas. O aprendizado de máquina (AM) aprende com os dados fornecidos, e às vezes nos apegamos demais aos dados. Isso é sobreajuste. Nesse caso, nosso modelo generaliza menos.

Por último, não devemos esquecer que estes algoritmos, e em particular a aprendizagem profunda (AP), requerem frequentemente um custo de cálculo que não é negligenciável, especificamente quando se utilizam GPUs ou unidades de processamento gráfico. É, portanto, necessário privilegiar primeiro modelos simples.

A combinação da aprendizagem automática (AA) com o sensoriamento remoto é uma oportunidade real para riscos naturais e já demonstrou avanços inovadores. Mas

temos que ter cuidado para não o usar ao acaso e em qualquer caso, sendo assim, devemos ter um olhar curioso e crítico continuamente para obtermos a melhor solução.

9.3. Vigilância para alerta precoce

Vejamos até que ponto os dados de satélite podem permitir o lançamento de um alerta precoce antes de um desastre natural. Em 4 de fevereiro de 1975, em Haicheng, na China, as autoridades decidiram evacuar a cidade, temendo um grande terremoto. Na mesma noite, um terremoto de magnitude 7,3 abalou a região. A decisão de evacuação se seguiu a observações de anomalias de comportamento de animais e de níveis de água em poços, combinadas com uma forte educação da sociedade civil sobre os riscos naturais. Este exemplo continua sendo o maior sucesso, mas não o único, na previsão de um grande fenômeno natural. Esta previsão é o objetivo último do estudo dos perigos naturais e deve permitir determinar antecipadamente a localização, a data e a dimensão da ocorrência de um fenômeno natural.

Numerosos estudos realizados após um desastre natural procuraram demonstrar, a posteriori, a existência de sinais de alerta, denominados precursoros. Esses precursoros são variados. Esses podem ser a ocorrência de pequenos sismos ou o aumento da deformação superficial, como é o caso do exemplo da figura 183, da diminuição da distância entre o cume do vulcão Merapi e o observatório de Kaliurang, localizado a 6 km do cume, no flanco sudoeste.

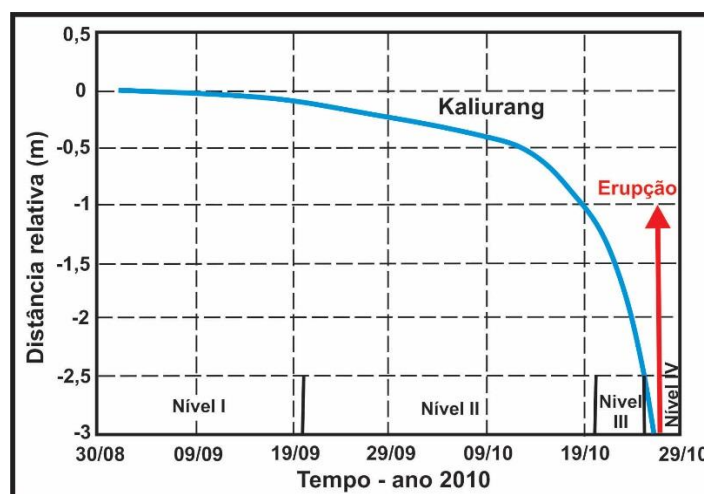


Figura 183. Gráfico mostrando a diminuição da distância entre o cume do vulcão Merapi e o observatório de Kaliurang antes da erupção de 2010. (modificado: Surono et al.,2013)

Também pode ser uma alteração anormal no nível da água dos poços, emissões de gases ou anomalias no comportamento dos animais. Esses sinais podem ser

identificados com bastante antecedência, vários meses ou pouco antes do evento catastrófico, ou seja, algumas horas. Esses sinais precursoros, às vezes mostram leis específicas de evolução. Até agora, todas estas análises realizadas a posteriori não permitem destacar um único sinal precursor, nem mesmo a presença de um sinal precursor sistemático antes de cada evento.

Na verdade, para poder detectar uma anomalia numa série temporal de observações, é necessário primeiro conhecer o comportamento habitual que pode ser descrito como comportamento de referência. Porém, esse comportamento pode estar sujeito a variações sem causa interna, variações causadas por ruídos nos dados ou fenômenos sazonais externos, como variações de temperatura ou precipitação, por exemplo (Fig.184).




Figura 184. Evolução temporal de deslocamento de superfície medido através de uma série temporal de dados SAR antes da erupção do vulcão Agung na Indonésia. (modificado: Albino et al.,2019)

A detecção de uma anomalia e a sua confirmação, podem ser feitas através da visualização cuidadosa das observações ou da utilização de métodos quantitativos existentes, ou mesmo recorrendo a métodos de inteligência artificial (IA). Assim, em 2016, no Tibete, um glaciar se rompeu subitamente em Aru, matando nove pastores. Ao analisar visualmente as imagens anteriores ao evento, os cientistas conseguiram detectar uma intensificação da rede de fendas nos dias anteriores ao descolamento. O mesmo fenômeno foi observado na geleira vizinha, o que possibilitou o alerta. Na mesma noite, esta segunda geleira se rompeu. Se uma anomalia for detectada sem que ocorra um evento subsequente, estamos no caso de um falso positivo que pode levar a um alarme falso e reduzir a credibilidade das previsões futuras entre a população em causa.

Em geral, as observações são integradas em termos de probabilidades de cenários futuros, utilizando árvores de probabilidade que são construídas a partir do conhecimento de acontecimentos passados e que permitem, dependendo das diferentes observações, chegar a uma previsão associada a uma probabilidade de realização.

Na figura 185, se pode observar um exemplo de uma árvore de probabilidade que permite, graças à medição da taxa de crescimento de uma cúpula vulcânica, obter uma probabilidade sobre a explosividade da próxima erupção, que é caracterizada pelo Índice de Explosividade Vulcânica (VEI).




Figura 185. Árvore de probabilidade para episódios de crescimento de cúpula de diferentes taxas de extrusão, onde a probabilidade é igual ao produto de cada probabilidade condicional.
 (modificado: Bgbrun et al., 2015)

9.3.1. As vantagens do sensoriamento remoto

Com uma cobertura global e um tempo de revisita cada vez mais curto para aquisições de satélites, o sensoriamento remoto oferece uma gama de recursos incomparáveis para a detecção de sinais precursoros, mesmo em áreas não instrumentadas do globo. O caminho está aberto para esta detecção de pequenos sinais. Em particular, os arquivos de satélite permitem a busca sistemática de precursoros a posteriori, mesmo em áreas não instrumentadas. Isto multiplicou as observações à escala de grandes zonas tectônicas e até mesmo de todo o planeta e puderam ser realizados estudos estatísticos da ligação entre diferentes sinais e eventos precursoros.

O trabalho de Furtney *et al.*, (2018), mostra que depois de 1998, a maior parte das erupções vulcânicas, cujo número por ano é representado pelos triângulos pretos no gráfico da figura 186, estão associadas a sinais, sejam eles térmicos, de deformação ou de emissão de gases, detectáveis por satélites, representados pelos triângulos azuis no gráfico. Ainda existem algumas erupções para as quais nenhum sinal pode ser detectado pelo satélite, representado pelos triângulos verdes. Mas estes são principalmente pequenos eventos. Aqui, estes não são necessariamente precursoros, porque estes sinais estão mais frequentemente associados à própria erupção, mas é muito encorajadora a busca por precursoros.




Figura 186. Erupções vulcânicas através do tempo.
(modificado: Furtney *et al.*,2018)

Um ponto crítico relativo à utilização de dados de satélite para a detecção de precursoros de curto prazo, ou seja, que ocorrem imediatamente antes de um evento, continua a ser o período de revisita, ou seja, a frequência das aquisições. No entanto, nos

últimos anos assistimos ao advento de constelações de microssatélites que oferecem uma frequência de aquisição cada vez maior. Assim, os satélites Planet permitem a aquisição de qualquer ponto do globo quase que diariamente, conforme mostra a figura 187.

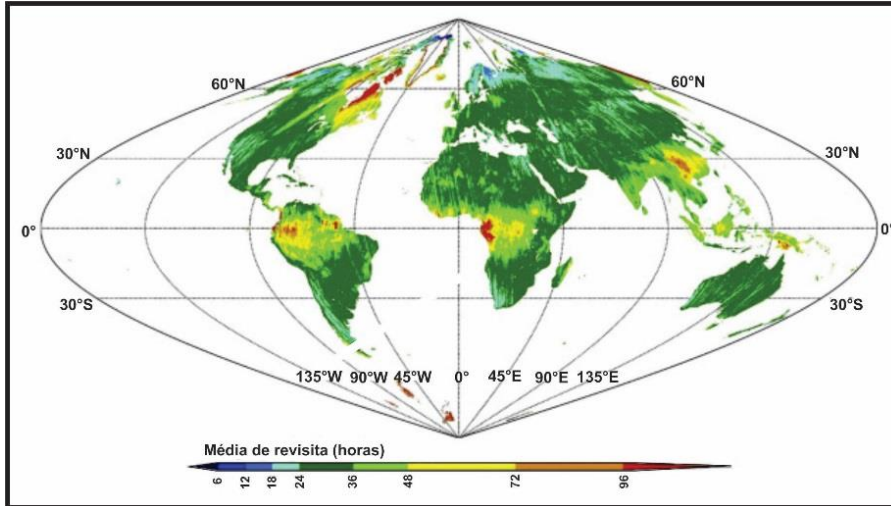


Figura 187. Tempo médio de revisita dos sensores PlanetScope-0,-1 e -2 de aquisição consecutivas. (modificado: Roy et al.,2021)

Este curto tempo de revisita permite imagear comportamentos transitórios, como aqui a aceleração do deslizamento de terra de Achoma no Peru, nos dois meses anteriores à sua ruptura catastrófica (Fig.188). Além disso, outra vantagem das medições por satélite é que elas permitem manter a continuidade das observações durante o evento, quando os instrumentos de campo são susceptíveis de serem destruídos. Isto fornece informações críticas sobre a evolução do evento atual, particularmente no caso de erupções vulcânicas que podem durar e aumentar de intensidade.




Figura 188. Movimento de deslocamento da superfície próxima do vulcão Achoma nos dois meses antes da sua ruptura. (modificado: Lacroix, et al.,2023)

A figura 189, mostra a erupção do vulcão Merapi em 2010, localizado na ilha de Java, na Indonésia, que ilustra perfeitamente a utilidade das medições de sensoriamento remoto.



Figura 189. Erupção do vulcão Merapi em Java na Indonésia em 2010.

a) Fase efusiva, b) Fase explosiva e c) Domo vulcânico.

(fonte: a) <https://cloudfront-us-east-1.images.arcpublishing.com/estadao/HDSYVV4D4FCWZIFOS3RWPW2OPM.jpg>; b) <https://california-times-brightspot.s3.amazonaws.com/2Fdb%2Fb1%2Fa145e65e3c5cacdee5f04bbcdabf%2Fsdut-mount-merapi-spews-volcanic-mat-20160901-011>; c) <https://boombastis.sgp1.digitaloceanspaces.com/wp-content/uploads/2019/11/Illustrasi-Geger-Boyo-di-Merapi-yang-melindungi-sisi-bagian-selatan.jpg>).

O Merapi é um vulcão ativo, alternando fases efusivas com construção de domo e explosões que podem gerar depósitos distantes do cume e impactar a população. Em setembro de 2010, um aumento significativo da sismicidade e do deslocamento do solo levou a um aumento do nível de alerta (Fig.190).

Em 25 de outubro, foi definida uma zona de exclusão de 10 km ao redor do cume e a erupção começou em 26 de outubro. Uma imagem TerraSAR-X adquirida em 26 de outubro mostra que a cúpula presente na cratera foi parcialmente destruída por esta erupção (Fig.191a). Uma nova imagem adquirida poucos dias depois, em 4 de novembro, mostra a presença de uma nova cúpula na cratera com volume de $6 \times 10^6 \text{ m}^3$ (Fig.191b). Isto prova que a taxa de crescimento da cúpula é superior a $25 \text{ m}^3/\text{s}$. O que se traduz numa grande probabilidade de termos rapidamente uma erupção muito explosiva. Esta informação levou a que a zona de evacuação fosse alargada para 20 km do cume do vulcão. O pico da erupção foi atingido na noite de 4 para 5 de novembro com materiais projetados a 15 km do cume. Bom trabalho dos Satélites!

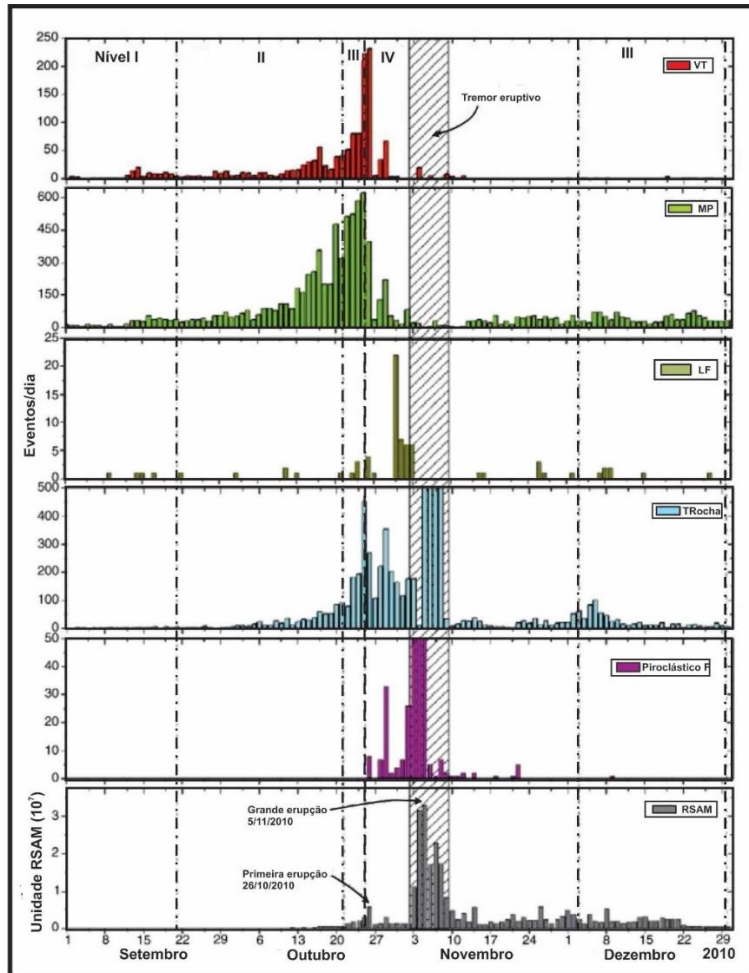


Figura 190. Contagem diária da sismicidade registrada em Merapi durante a erupção de 2010.

VT = Vulcano-tectônica; MP = Multifásico (=Terremoto híbrido); LF = baixa frequência;
TRocka = Terremotos de queda de rochas; Piroclástico F = Fluxo piroclásticos;
RSAM = Medição de Amplitude Sísmica em Tempo Real.

(modificado: Surono et al., 2012)




Figura 191. Imagem TerraSAR-X do vulcão Merapi. a) mostra a cúpula da cratera parcialmente destruída; b) presença de uma nova cúpula de lava na cratera poucos dias depois.

(modificado: Surono et al., 2012)

X. QUESTÕES DE CONHECIMENTO

- 1) Qual a resolução terrestre fornecida pelo primeiro satélite não militar de observação da Terra, Landsat:
 - a. Metros.
 - b. Centena de metros.
 - c. Quilômetros.

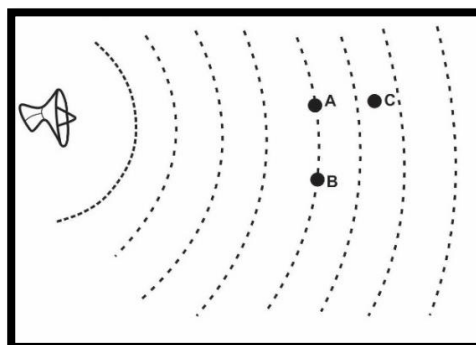
- 2) A partir da excelente resolução temporal dos satélites, estes permitem monitorizar continuamente as variações ocorridas nos minutos anteriores a um desastre natural.
 - a. Verdadeiro.
 - b. Falso.

- 3) Quais dos seguintes dados são dados de sensoriamento remoto (no sentido estrito).
 1. Fotografias aéreas:
 - a. Verdadeiro.
 - b. Falso.

 2. Imagens de radar de abertura sintética adquiridas por satélite:
 - a. Verdadeiro.
 - b. Falso.

 3. Levantamentos magnéticos realizados por drone:
 - a. Verdadeiro.
 - b. Falso.

- 4) Os pontos A, B e C, mostrados na imagem abaixo, estão localizados a uma certa distância e em uma determinada direção do sensor. Avalie as seguintes afirmações.



1. Os pontos A e C podem ser distinguidos em uma imagem óptica.
 - a. Verdadeiro.
 - b. Falso.

2. Os pontos A e C podem ser distinguidos numa imagem de radar.
 - a. Verdadeiro.
 - b. Falso.

3. Os pontos B e C podem ser distinguidos em uma imagem óptica.
 - a. Verdadeiro.
 - b. Falso.

- 5) Numa região vulcânica, a elevação do solo de 8 mm/ano ocorre sobre uma área circular de 40 km de diâmetro, durante 5 anos. Para estudar esse fenômeno, que tipo de dados é mais adequado?
 - a. Dados ópticos.
 - b. Um par de dados de radar adquiridos com 3 meses de intervalo.
 - c. Uma série temporal de dados de radar adquiridos ao longo de 5 anos

- 6) O objetivo de detectar alterações em imagens de satélite é:
 - a. Mapear áreas que apresentam alterações temporais nas condições da superfície.
 - b. Detectar transições entre diferentes áreas de uma imagem.
 - c. Para atribuir os diferentes pixels de uma imagem as classes baseadas no uso do solo.

- 7) Entre os seguintes casos padrões, qual pode ser qualificado como alteração e detectado a partir de apenas duas imagens adquiridas em duas datas diferentes?
 1. Alterações radiométricas devido a ruído ou variações naturais:
 - a. Verdadeiro.
 - b. Falso.

 2. Uma mudança abrupta chamada “*stepwise*”:
 - a. Verdadeiro.
 - b. Falso.

 3. Uma mudança de impulso:
 - a. Verdadeiro.
 - b. Falso.

- 8) Quais dos métodos abaixo são métodos de aprendizado de máquina?
 1. Calculamos o valor absoluto da diferença entre duas imagens e o usuário define um limite acima do qual os pixels são colocados na classe de alteração.

- a. Verdadeiro.
 - b. Falso.
2. Nas janelas deslizantes, estimamos os parâmetros das distribuições de pixels (média e variância, por exemplo) e deduzimos uma distância entre essas distribuições. Máscaras de alteração e zonas sem alteração são utilizadas para determinar a distância além da qual a presença de alteração é detectada com uma taxa de falsos alarmes (detecção errônea) definida em 5%.
- a. Verdadeiro.
 - b. Falso.
3. Pares de miniaturas com ou sem alteração são apresentados a uma rede neural convolucional (CNC), indicando a resposta esperada (1 se houver alteração, 0 caso contrário). No final da fase de aprendizagem, utilizamos esta rede em modo de inferência apresentando-lhe pares de miniaturas da mesma natureza (mesmos sensores, mesma resolução etc.) e decidimos se há ou não alteração com base no valor do neurônio de saída (próximo de 1 ou 0).
- a. Verdadeiro.
 - b. Falso.
- 9) Qual a precisão de movimento que normalmente pode ser alcançada com a correlação de imagens, em termos de pixels?
- a. 1:100
 - b. 1:1000
 - c. 1:10
- 10) Desde quando se pode medir os movimentos de massa usando correlação de imagens?
- a. 1920
 - b. 1950
 - c. 1990
 - d. 2000
- 11) O que é paralaxe?
- a. O método usado para identificar pontos homólogos entre imagens estereoscópicas.
 - b. O movimento aparente de um ponto entre duas imagens estereoscópicas.
 - c. Dois raios de luz que não se cruzam.
 - d. O movimento do solo paralelo à superfície.

12) O que é um modelo digital de terreno (MDT).

- a. Uma imagem de satélite da superfície terrestre.
- b. Uma nuvem de pontos representando a posição 3D de cada pixel.
- c. Um mapa do deslocamento vertical da superfície.
- d. Uma representação em uma grade regular da topografia.

13) O que é ortorretificação?

- a. Projetar as imagens originais em um plano para sobrepô-las em um mapa.
- b. Correção de defeitos de georreferenciamento no MDT.
- c. O deslocamento em uma direção normal à superfície considerada.
- d. Aquisição de duas imagens com mira em ângulo reto.

14) As duas imagens abaixo formam um par estereoscópico?




- a. Verdadeiro
- b. Falso

15) Qual é o número mínimo de imagens de radar necessárias para fazer um interferograma?

- a. 1
- b. 2
- c. 3
- d. 4

16) A figura abaixo mostra um exemplo de interferograma diferencial (sem perturbações atmosféricas) produzido a partir de imagens de radar com comprimento de onda de 5,6 cm (banda C). Encontre a afirmação certa.



- a. Comparado ao ponto A, o ponto B moveu-se verticalmente 11,2 cm.
 - b. Comparado ao ponto A, o ponto B aproximou-se 2,8 cm do satélite.
 - c. Comparado ao ponto A, o ponto B afastou-se do satélite 5,6 cm.
 - d. Comparado ao ponto A, o ponto B permaneceu à mesma distância do radar.
- 17) Em quantos dias a constelação de dois satélites de radar Sentinel-1 capta imagens de toda a Terra em órbita ascendente (aquisição de Sul para Norte)?
- a. 3
 - b. 6
 - c. 12
 - d. 24
- 18) Quais são as diferentes formas de obter o deslocamento no tempo t_3 em relação ao tempo t_1 a partir das medições possíveis, D_{ij} , entre os pares de imagens 1,2,3,4?
- a. $D_{12}+D_{23}$; D_{13} ; $D_{14}-D_{34}$; $D_{12}+D_{24}-D_{34}$
 - b. D_{13} ; $D_{14}+D_{13}$; $D_{12}+D_{13}$
 - c. D_{13} ; $D_{24} - D_{34}$
- 19) Quais são as vantagens de construir séries temporais por interferometria de radar ou correlação de imagens ópticas?
1. Isto torna possível observar o movimento de massa em 3 dimensões.
 - a. Verdadeiro.
 - b. Falso.
 2. Isto permite quantificar e eliminar efeitos sazonais indesejáveis.
 - a. Verdadeiro.
 - b. Falso.
 3. Isto permite a identificação de componentes lineares (por exemplo, carregamento intersísmico) ou não lineares de deformação (por exemplo, saltos cossísmicos ou pós-sísmicos).
 - a. Verdadeiro.
 - b. Falso.
- 20) Como a geodésia espacial é usada para estudar terremotos?
- a. Medindo a velocidade dos deslizamentos de terra.
 - b. Registrando as ondas P e S liberadas durante terremotos.
 - c. Medindo deslocamentos de superfície perto de falhas antes e depois do terremoto.


21) Quais são as principais técnicas de sensoriamento remoto utilizadas para mapear falhas?

- a. GPS e extensômetros.
- b. Imagens ópticas e modelo digital de terreno.
- c. Interferometria de radar e correlação de imagens ópticas.

22) Como o InSAR e a óptica são complementares para o estudo de terremotos superficiais de magnitude superior a 6,5 em profundidades rasas (menos de 10 km) e que rompem a superfície terrestre?

- a. Eles fornecem deformações de campo próximo (óptico) e campo distante (InSAR).
- b. Eles fornecem informações em diferentes comprimentos de onda.
- c. Eles fornecem informações em diferentes períodos.

23) Nesta imagem óptica aérea onde está localizada a falha?



- a. A
- b. B
- c. C

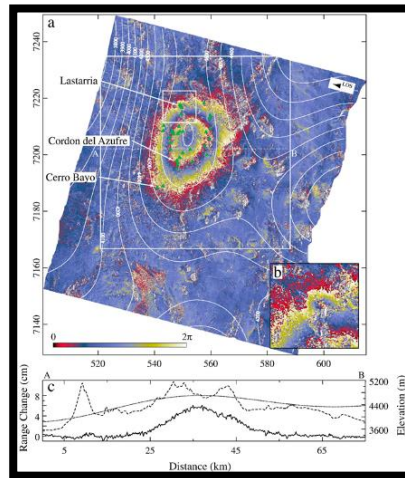
24) Quais de todos esses sinais são sinais de alerta de um rompimento? (mais de uma resposta)

- a. Mudança na composição dos gases.
- b. Aumento de chuva.
- c. Deformação do solo.
- d. Aumento da sismicidade.

25) Que tipos de sinais podem ser detectados em vulcões usando imagens de radar? (mais de uma resposta)

- a. Movimentos de massa.
- b. Mudanças na topografia.
- c. Mudanças de superfície.
- d. Anomalias térmicas.

26) A figura abaixo mostra um interferograma no vulcão chileno Cordón del Azufre. A qual processo o sinal de deformação está associado?



- a. Pressurizando um reservatório de magma.
- b. Deslizamento de terra.
- c. Drenando um lago.

27) Que produto derivado de imagens de radar permite aos vulcanologistas calcular a espessura dos fluxos de lava?

- a. Um mapa de coerência
- b. Um modelo digital de terreno
- c. Um mapa meteorológico

28) O conhecimento dos movimentos de massa passados pode ajudar-nos a prever a localização dos movimentos futuros?

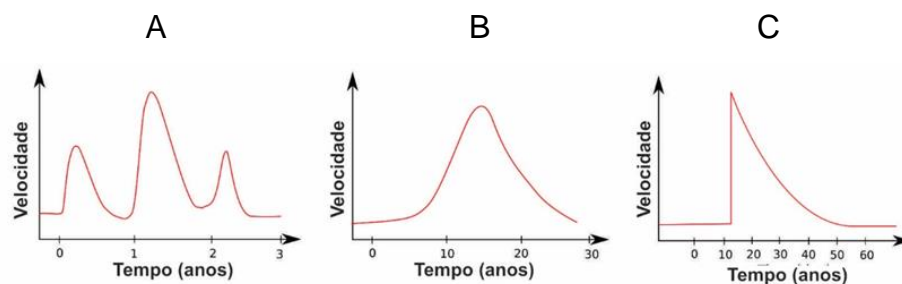
- a. Não, porque um movimento de massa nunca ocorre duas vezes no mesmo lugar.
- b. Sim, porque uma área afetada uma vez por um movimento de massa irá inevitavelmente sofrer outros.
- c. Sim, porque as características dos movimentos de massa passados permitem conhecer as características morfológicas e geológicas das encostas susceptíveis de movimentos de massa numa determinada região.

29) O sensoriamento remoto permite conhecer diferentes propriedades dos movimentos de massa. Quais?

- 1. Sua localização.
 - a. Verdadeiro.
 - b. Falso.

2. Seu tamanho.
 - a. Verdadeiro.
 - b. Falso.
3. Seu volume.
 - a. Verdadeiro.
 - b. Falso.
4. Sua velocidade.
 - a. Verdadeiro.
 - b. Falso.
5. Seu tempo de ruptura.
 - a. Verdadeiro.
 - b. Falso.

30) As séries temporais de deslocamento nos falam sobre os fatores que controlam a dinâmica dos movimentos de massa. Você pode relacionar a forçante e a série temporal de velocidade resultante? (imagens abaixo) / As séries temporais de deslocamentos são a nossa proporção das informações sobre os fatores que controlam a dinâmica dos movimentos da Terra.



1. Recuo glacial no sopé do deslizamento.
 - a. A
 - b. B
 - c. C
2. Chuva sazonal.
 - a. A
 - b. B
 - c. C
3. Terremoto.
 - a. A

- b. B
- c. C

31) Qual você acha que é a melhor série de imagens para obter cada uma dessas séries temporais? Conectar as três séries temporais anteriores ao seu tipo de imagem?

1. Satélite de alta frequência PlanetScope.

- a. A
- b. B
- c. C

2. Série temporal Sentinel-1 ou Sentinel-2 dependendo da magnitude da velocidade.

- a. A
- b. B
- c. C

3. Série temporal Landsat 4-5-7-8.

- a. A
- b. B
- c. C

32) Onde as geleiras são encontradas?

1. Nos trópicos.

- a. Verdadeiro.
- b. Falso.

2. Somente a grandes altitudes.

- a. Verdadeiro.
- b. Falso.

3. Nas regiões polares.

- a. Verdadeiro.
- b. Falso.

4. Onde o acúmulo de neve pode persistir e se transformar em gelo.

- a. Verdadeiro.
- b. Falso.

- 33) A nível global, a principal questão ligada à evolução atual dos glaciares é a da subida do nível do mar. A contribuição das geleiras de montanha é:
1. De vários centímetros por ano.
 - a. Verdadeiro.
 - b. Falso.
 2. Equivalente ao das duas calotas polares da Groenlândia e da Antártica.
 - a. Verdadeiro.
 - b. Falso.
 3. Perto de um milímetro por ano.
 - a. Verdadeiro.
 - b. Falso.
- 34) A diferença entre dois modelos digitais de terreno permite:
- a. Quantificar o volume mobilizado pelo colapso de uma geleira.
 - b. Acompanhar a evolução da área coberta de neve na geleira.
 - c. Quantificar a presença de uma bolsa de água dentro da geleira.
 - d. Para saber a espessura da geleira.
- 35) A correlação de imagens de satélite pode permitir:
1. Quantificar a temperatura da superfície da geleira.
 - a. Verdadeiro.
 - b. Falso.
 2. Quantifique a velocidade do fluxo na superfície da geleira.
 - a. Verdadeiro.
 - b. Falso.
 3. Identifique eventos de surto glacial.
 - a. Verdadeiro.
 - b. Falso.
 4. Quantificando a velocidade de drenagem de um lago proglacial.
 - a. Verdadeiro.
 - b. Falso.
- 36) Como quantificamos as variações na espessura e no volume das geleiras?
- a. Pela diferença entre dois modelos digitais de terreno adquiridos em datas diferentes.
 - b. Por correlação de imagem.
 - c. Por interferometria de radar.

d. Medindo velocidades de fluxo.


37) O que significa *overfitting*?

- Ter muitos dados de treinamento.
- O erro entre a previsão obtida e o verdadeiro valor a ser estimado.
- O fato de o modelo não generalizar para novos dados.

38) O que é necessário para treinar uma rede neural convolucional (CNN) cuja tarefa é detectar deslizamentos de terra em imagens ópticas de satélite? Mais de uma resposta correta.

- Um grande número de imagens ópticas de satélite do mesmo deslizamento, mas em muitas datas diferentes.
- Um grande número de imagens ópticas de satélite de diferentes deslizamentos, bem como imagens sem deslizamentos.
- O rótulo, ou seja, a verdade básica de cada imagem: 'sim' se contiver um deslize, 'não' se não contiver.
- Um modelo físico capaz de modelar um deslizamento de terra em uma paisagem.

39) Aqui está uma série temporal do deslocamento cumulativo registrado no movimento terrestre da mina de ouro Cadia, na Austrália, entre dezembro de 2016 e março de 2018, pouco antes de sua ruptura em 9 de março de 2018. Esta série de medições foi produzida pelo InSAR com uma frequência de 12 dias. Por que você acha que prever o momento do rompimento é difícil?



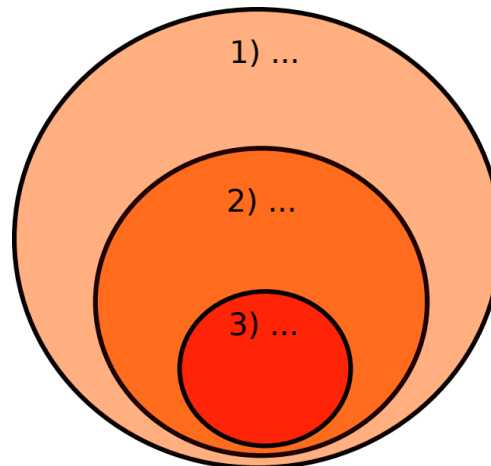
- O nível de ruído de medição é muito alto.
 - Verdadeiro.
 - Falso.
- Existem poucos pontos que mostram claramente a aceleração final.
 - Verdadeiro.
 - Falso.

3. A aceleração do deslizamento pode ser seguida por uma desaceleração.

- a. Verdadeiro.
- b. Falso.

40) Coloque os 3 termos a seguir na ordem correta, do mais geral para o menos geral:

Aprendizagem profunda; Inteligência artificial; Aprendizado de máquina.



- a. 1) Aprendizado profundo > 2) Aprendizado Automático > 3) Inteligência artificial.
- b. 1) Inteligência Artificial > 2) Aprendizado Automático > 3) Aprendizado Profundo.
- c. 1) Inteligência Artificial > 2) Aprendizado Profundo > 3) Aprendizado Automático.
- d. 1) Aprendizado Automático > 2) Inteligência artificial > 3) Aprendizado profundo.



Imagens do Complexo do Guaíba e de Porto Alegre – RS, antes e depois da cheia de 06/05/2024.
(fonte: <https://scc10.com.br/wp-content/uploads/2024/05/Imagens-de-satelite-mostram-antes-e-durante-enchente-em-Porto-Alegre.jpg.webp>)

XI. REFERÊNCIA BIBLIOGRÁFICA

- Albino, F., Biggs, J. & Syahbana, D.K. 2019. Dyke intrusion between neighboring arc volcanoes responsible for 2017 pre-eruptive seismic swarm at Agung. *Nat Commun* 10: 748. <https://doi.org/10.1038/s41467-019-08564-9>
- Albino, F., Smets, B., d'Oreye, N. & Kervyn, F. 2015. High-resolution TanDEM-X DEM: An accurate method to estimate lava flow volumes at Nyamulagira Volcano (D. R. Congo). *Journal of Geophysical Research: Solid Earth*, 120: 4189–4207. doi:10.1002/2015JB011988.
- Alpers, W. & Hühnerfuss, H. 1989. The damping of the ocean waves by surface films: a new look at an old problem. *Journal of Geophysical Research*, 94: 6251-6265.
- Anantrasirichai, N., Biggs, J., Fabien, A. & Bull, D. 2019. A deep learning approach to detecting volcano deformation from satellite imagery using synthetic datasets. *Remote Sensing of Environment* 230(8), DOI: 10.1016/j.rse.2019.04.032
- Angier, A. 2020. Interférométrie radar: principes et utilisation dans la surveillance de la déformation du sol. *Planet Terre*. Ressource scientifiques pour l'enseignement des sciences de la Terre et de l'Univers. <https://planet-terre.ens-lyon.fr/ressource/interferometrie-radar.xml>.
- Atto, A.M., Kemavo, A., Rudan, J.P. & Mercier, G. 2018. Geometric Multi-Wavelet Total Variation for SAR Image Time Series Analysis. Conference: FUSION 2018. At: Cambridge, UK. p. 1-8. DOI: 10.23919/ICIF.2018.8455223.
- Augier, A. 2020. Interférométrie radar : principes et utilisation dans la surveillance de la déformation du soldans la surveillance de la déformation du sol. *Planet Terre*. 13p. <https://planet-terre.ens-lyon.fr/pdf/interferometrie-radar.pdf>.
- Betancurt, J.J.V. & Santos, J.R. 1981. Sensoriamento Remoto na conservação e manejo de ecossistemas naturais vegetais. São José dos Campos: Inpe, 27 p. INPE-2264-PRE045.
- Booth, A.M., Lamb, M.P., Avouac, J.P. & Delacourt, C. 2013. Landslide velocity, thickness, and rheology from remote sensing: La Clapière landslide, France. *Geophysical Research Letters*. 40: 4299–4304, doi:10.1002/grl.50828.
- Calò, F., Ardizzone, F., Castaldo, R., Lollino, P., Tizzani, P., Guzzetti, F., Lanari, R. Angeli, M.G., Pontoni, F. & Manunta, M. 2014. Enhanced landslide investigations through advanced DInSAR techniques: The Ivancich case study, Assisi, Italy. *Remote Sensing of Environment*, 142: 69-82. Elsevier.

- Carlà, T., Intrieri, E., Raspini, F., Bardi, F., Farina, P., Ferretti, A., Colombo, D., Novali, F. & Casagli, N. 2019. Perspectives on the prediction of catastrophic slope failures from satellite InSAR. *Scientific Reports*, 9:14137. <https://doi.org/10.1038/s41598-019-50792-y>.
- Charbonnier, S.J., Germa, A., Connor, C.B., Gertisser, R., Preece, K., Komorowski, J.C., Lavigne, F., Dixon, T. & Conner, L. 2013. Evaluation of the impact of the 2010 pyroclastic density currents at Merapi volcano from high-resolution satellite imagery, field investigations and numerical simulations. *Journal of Volcanology and Geothermal Research*, 261: 295-315. <https://doi.org/10.1016/j.jvolgeores.2012.12.02>.
- Chevrel, S., Oliveiros, C. & Thierry, P. 2002. Progrès continus dans le résolution spatiale et spectrale. *Géochronique*, 81:28-30.
- Costa, A.M., Oliveira, N.E.G., Leal, V.F.B., Molena, C., Melillo, R.C.S. & Soares, E.R. 2022. Análise das áreas com risco de inundações urbanas e escorregamentos de terra em três bairros do município de Jundiaí/SP. *South American Sciences*, 3(1): e22158-e22158. <https://doi.org/10.52755/sas.v3i1.158>.
- Dal Zilio, L. & Ampuero, J.P. 2023. Earthquake doublet in Turkey and Syria. *Commun Earth Environ* 4: 71. <https://doi.org/10.1038/s43247-023-00747-z>
- Dieng, H.B., Cazenave, A., Meyssignac, B. & Michaël, A. 2017. New estimate of the current rate of sea level rise from a sea level budget approach: Sea level budget. *Geophysical Research Letters*, 44:8. DOI: 10.1002/2017GL073308.
- Dzurisin, D., Lu, Z., Poland, M.P. & Wicks Jr, C.W. 2019. Space-Based Imaging Radar Studies of U.S. Volcanoes. *Frontiers in Earth Science*, 6. Doi: 10.3389/feart.2018.00249.
- ERDAS, 2010. LPS Project Manager. User's Guide. http://geography.middlebury.edu/data/gg1002/handouts/lps_pm.pdf.
- Espín Bedón, P.A., Audin, L., Doim, M.P., Pinel, V., Pathier, E., Mothes, P., García, A., Samaniego, P. & Pacheco, D. 2022. Unrest at Cayambe Volcano revealed by SAR imagery and seismic activity after the Pedernales subduction earthquake, Ecuador (2016). *Journal of Volcanology and Geothermal Research*. 428: 107577. <https://doi.org/10.1016/j.jvolgeores.2022.107577>
- Fingas, M. & Brown, C. 2014. Review of oil spill remote sensing. *Marine Pollution Bulletin*, 83(1): 9-23, 15 Jun.
- Fischer, W.A. 1960. A tour of the earthquake area. *Yellowstone Nature Area*. V.33. https://www.nps.gov/parkhistory/online_books/yell/vol33m.htm

- Froger, J.L., Fukushima, Y., Briole, P., Staudacher, T., Souriot, T. & Villeneuve, N. 2004. The deformation field of the August 2003 eruption at Piton de la Fournaise, Reunion Island, mapped by ASAR interferometry. *Geophysical Research Letters* 31(14):14601. DOI: 10.1029/2004GL020479.
- Froger, J.L., Remy, D., Bonvalot, S. & Legrand, D. 2007. Two scales of inflation at Lastarria-Cordon del Azufre volcanic complex, central Andes, revealed from ASAR-ENVISAT interferometric data. *Earth and Planetary Science Letters*. 255(1-2): 148-163.
- Furtnay, M.A., Pritchard, M.E., Biggs, J., Carn, S.A., Ebmeier, S.K., Jay, J.A., Kilbried, B.T.M. & Reath, K.A. 2018. Synthesizing multi-sensor, multi-satellite, multi-decadal datasets for global volcano monitoring. *Journal of Volcanology and Geothermal Research*. 365: 38-56. <https://doi.org/10.1016/j.jvolgeores.2018.10.002>.
- Gorum, T., Fan, X., van Westen, C.J., Huang, R.Q., Xu, Q., Tang, C. & Wang, G. 2011. Distribution pattern of earthquake-induced landslides triggered by the 12 May 2008 Wenchuan earthquake. *Geomorphology*, 133: 152–167. doi:10.1016/j.geomorph.2010.12.030.
- Grandin, R., 2015. Interferometric processing of SLC Sentinel-1 TOPS data, in Presented at the FRINGE'15: Advances in the Science and Applications of SAR Interferometry and Sentinel-1 InSAR Workshop, ESA, Frascati, Italy, 23-27.
- He, I., Feng, G., Li, Z., Feng, Z., Gao, H. & Wu, X. 2019. Source parameters and slip distribution of the 2018 Mw 7.5 Palu-Indonésia earthquake estimated from space-based geodesy. *Tectonophysics*, 772: 228216.
- Henderson, S.T., Delgado, F., Elliott, J., Pritchard, M.E., & Lundgren, P.R., 2017, Decelerating uplift at Lazufre volcanic center, Central Andes, from A.D. 2010 to 2016, and implications for geodetic models: *Geosphere*, 13(5): 1489–1505, doi:10.1130/GES01441.1.
- Hollingsworth, J., Ayoub, F., Doin, M.P., Daout, S., Perfettini, H., Peltzer, G. & Samsonov, S. 2017. Characterization and removal of shadow bias from Optical Image Correlation; application to the 2013 Balouchistan earthquake. American Geophysical Union, Fall Meeting 2017, abstract #G43A-09090. <https://doi.org/10.1029/2022JB026251>.
- Hugonnet, R., McNabb, R., Berthier, E., Menounos, B., Nuth, C., Girod, L., Farinotti, D., Huss, M., Dussaillant, I., Brun, F. & Kääb, A. 2021. Accelerated global glacier mass loss in the early twenty-first century. *Nature* 592: 726–731. <https://doi.org/10.1038/s41586-021-03436-z>
- James, M.R., Robson, S. & Smith, M.W. 2017. 3-D uncertainty-based topographic change detection with structure-from-motion photogrammetry: precision maps for ground control and directly georeferenced surveys. *Earth Surface Processes and Landforms*, 42 (12): 1769-1788. ISSN 0197-9337. <https://doi.org/10.1002/esp.4125>.

- Kääb, A., Leinss, S., Gilbert, A., Bühler, Y., Gascoin, S., Evans, S.G., Bartelt, P., Berthier, E., Brun, F., Chao, W.A., Farinotti, D., Gimbert, F., Guo, W., Huggel, C., Kargel, J.S., Leonard, G.J., Tian, L., Treichler, D. & Yao, T. 2018. Massive collapse of two glaciers in western Tibet in 2016 after surge-like instability. *Nature Geoscience*. 11: 114–120. <https://doi.org/10.1038/s41561-017-0039-7>
- Krøgli, I.K., Devoli, G., Colleuille, H., Sund, M., Boje, S. & Engen, I.K. 2017. The Norwegian forecasting and warning service for rainfall- and snowmelt-induced landslides. *Nat. Hazards Earth Syst. Sci. Discuss.*, <https://doi.org/10.5194/nhess-2017-426>.
- Lacroix, P., Huanca, J., Albinez, L., & Taipei, E. 2023. Precursory motion and time-of-failure prediction of the Achoma landslide, Peru, from high frequency PlanetScope satellites. *Geophysical Research Letters*, 50, e2023GL105413. <https://doi.org/10.1029/2023GL105413>.
- Lê, T.T., Atto, A.M., Trouvé, E., Solikhin, A. & Pinel, V. 2015. Change detection matrix fou multitemporal filtering and change analysis of SAR and PolSAR image time series. *ISPRS Journal of Photogrammetry and Remote Sensing*. 107: 64-76. <https://doi.org/10.1016/j.isprsjprs.2015.02.008>.
- Lê, T.T., Atto, A., Trouvé, E. & Karbou, F. 2023. Deep Semantic Fusion of Sentinel-1 and Sentinel-2 Snow Products for Snow Monitoring in Mountainous Regions. In: *IGARSS 2023. IEEE International Geoscience and Remote Sensing Symposium - 2023*. 4 p. DOI: 10.1109/IGARSS52108.2023.10282065.
- Leifer, I., Lehr, W.J., Simecek-Beatty, D., Bradley, E., Clark, R., Dennison, P., Hu, Y., Matheson, S., Jones, C.E., Holt, B., Reif, M., Roberts, D.A., SvejkovskY, J., Swayze, G. & Wozencraft, J. 2012. State of the art satellite and airborne marine oil spill remote sensing: application to the BP Deepwater Horizon oil spill. *Remote Sensing of Environment*, 124: 185-209.
- Lemrabet, L., Doin, M.P., Lasserre, C. & Durand, P. 2023. Referencing of continental-scale InSAR-derived velocity fields: Case study of the eastern Tibetan Plateau. *Journal of Geophysical Research: Solid Earth*, 128: e2022JB026251.
- Lima, D.M. 2021. Abordagens distribuídas para simulação do escoamento superficial baseadas no modelo digital de elevação. Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia Civil e Ambiental, Universidade Federal da Paraíba, 121p.
- Marambio, A., Pucci, B., Jungner, A., Núñez, M. & Buill, F., 2009. Terrestrial laser scanner,terrestrial synthetic aperture radar and topographic data: an integration proposal. In: *Proc 8th Int. Geomat. Week Barc*. 7p.

- Marc, O., Behling, R., Andermann, C., Turowski, J.M., Illien, L., Roessner, S. & Hovius, N. 2019. Long-term erosion of the Nepal Himalayas by bedrock landsliding: the role of monsoons, earthquakes and giant landslides. *Earth Surface Dynamics*, 7(1): 107–128. <https://doi.org/10.5194/esurf-7-107-2019>
- Marin, C., Bovolo, F. & Bruzzone, L. 2015. Building Change Detection in Multitemporal Very High-Resolution SAR Images. *IEEE Trans. Geosci. Remote Sens.*, 53(5): 2664–2682.
- Martin, J.G. & Rathje, E.M. 2014. Lateral spread deformations from the 2011 Christchurch, New Zealand earthquake measured from satellite images and optical image correlation. *Proceedings of the 10 th National Conference in Earthquake Engineering, Earthquake Engineering Research Institute, Anchorage, Alaska*. 11p. DOI: 10.4231/D3CF9J71P
- Marques da Silva, J.R. 2021. Skills Alliance for Sustainable Agriculture. Project Acronym SAGRI. Universidade de [Evora, Portugal. 48 p. Available from: https://www.researchgate.net/publication/349762302_Precision_Agriculture_lessons_for_non-specialists_EN_PT_versions [accessed Aug 21 2024].
- Millan, R., Mougnot, J., Rabatel, A., & Morlighem, M. 2022. Ice velocity and thickness of the world's glaciers. *Nature Geoscience*. DOI: 10.1038/s41561-021-00885-z
- Miola, A.C. 2013. Planejamento para comunidades rurais em situações de enchentes. Tese de Doutorado. Programa de Pós-Graduação em Engenharia Agrícola. Centro de Ciências Rurais. Universidade Federal de Santa Maria. 216 p.
- Molnar, P. & Tapponnier, P. 1978. Active Tectonics of Tibet. *Journal of Geophysical Research*, 83(Nb11):5361-5373.
- Montagnon, T., Hollingsworth, J., Pathier, E. & Marchandon, M. 2022. Sub-pixel optical satellite image registration for ground deformation using deep learning. 2022 IEEE International Conference on Image Processing (ICIP). 2716-2720. DOI: 10.1109/ICIP46576.2022.9897214.
- Moreira, A., Prats-Iraola, P., Yoiunis, M., Krieger, G., Hajnsek, I. & Papathanassiou, K. 2013. A Tutorial on Synthetic Aperture Radar, *IEEE Geoscience and Remote Sensing Magazine*, vol. 1, nº1, DOI:10.1109/MGRS.2013.2248301.
- Moreira, M.A. 2011. Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação. 4a. Edição. ed. Viçosa: UFV, v. I. 422 p. ISBN: 978-85-7269-381-3.
- Ogburn, S.E., Loughlin, S.C. & Calder, E.S. 2015. The association of lava dome growth with major explosive activity ($VEI \geq 4$): DomeHaz, a global dataset. *Bull Volcanology*. 77:40. <https://doi.org/10.1007/s00445-015-0919-x>

- Pereira, M.C. 1987. Detecção, monitoramento e análise de alguns efeitos ambientais de queimadas na Amazônia através da utilização de imagens dos Satélites NOAA e LANDSAT, e dados de aeronave. Dissertação (Mestrado) – Inpe/DSR, São José dos Campos. INPE-4503-TDL/326.
- Pinel, V. & Albino, F. 2022. Contribution to IAVCEI Book Modern Vulcano Monitoring.
- Quevedo, R.P. 2019. Mapeamento de suscetibilidade a movimentos de massa a partir de aprendizado de máquina. Dissertação de Mestrado. Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia. Programa de Pós-Graduação em Sensoriamento Remoto, UFRGS. 71 p.
- Reinoza, C., Jouanne, F., Audemard, F.A., Schmitz, M. & Beck, C. 2015. Geodetic exploration of strain along the El Pilar Fault in northeastern Venezuela. *J. Geophys. Res. Solid Earth*, 120, doi:10.1002/2014JB011483.
- Rivera, A., Bown, F., Napoleoni, F., Muñoz, C. & Vuille, M. 2016. Balance de masa glaciar. Ediciones CECs, Valdivia, Chile. 207p. <http://www.glaciologia.cl>.
- Rouet-Leduc, B., Jolivet, R., Dalaison, M., Johnson P.A. & Hulbert, C. 2021. Autonomous extraction of millimeter-scale deformation in InSAR time series using deep learning. *Nat Commun* 12:0 6480. <https://doi.org/10.1038/s41467-021-26254-3>
- Roy D.P., Huang H., Houborg R., Martins V.S. 2021. A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. *Remote Sensing of Environment*, 264: 112586. <https://doi.org/10.1016/j.rse.2021.112586>.
- Rudant, J.P., Classeau, N. & Trébossen, H. 2002. La télédétection infrarouge. *Géochronique*, 81 :32-33.
- Shukla, A., Garg, P.K. & Srivastava, S. 2018. Evolution of Glacial and High-Altitude Lakes in the Sikkim, Eastern Himalaya Over the Past Four Decades (1975-2017). *Front. Environ. Sci.* 6:81. doi: 10.3389/fenvs.2018.00081.
- Six, D. & Vincent, C. 2024. Les glaciers de montagne, sentinelles des changements climatiques. *Encyclopédie de l'Environnement*. Consulté le 7 avril 2024. ISSN 2555-0950] url : <https://www.encyclopedie-environnement.org/climat/glaciers-montagne-changements-climatiques/>.
- Solikhin, A., Pinel, V., Vandemeulebrouck, J., Thouret, J.C. & Hendrasto, M. 2015. Mapping the 2010 Merapi pyroclastic deposits using dual-polarization Synthetic Aperture Radar (SAR) data. *Remote Sensing of Environment* 158:180-192. DOI: 10.1016/j.rse.2014.11.002

Stumpf, A., Malet, J.P. & Delacourt, C. 2017. Correlation of satellite image time-series for the detection and monitoring of slow-moving landslides. *Remote Sensing of Environment*. 189: 40-55. <https://doi.org/10.1016/j.rse.2016.11.007>.

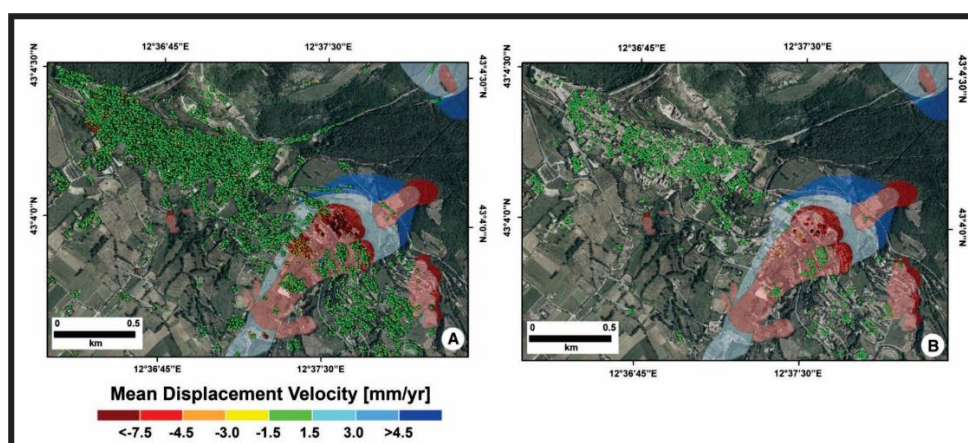
Surono, P.J., Pallister, J., Boichu, M., Buongiorno, M.F., Budisantoso, A., Costa, F., Andreastuti, S., Prata, F., Schneider, D., Clarisse, L., Humaida, H., Sumarti, S., Bignami, C., Griswold, J., Carn, S., Oppenheimer, C. & Lavigne, F. 2012. The 2010 explosive eruption of Java's Merapi volcano—A '100-year' event. *Journal of Volcanology and Geothermal Research*, 241-242: 121-135. doi:10.1016/j.jvolgeores.2012.06.018.

Thollard, F., Clesse, D., Doin, M.P., Donadieu, J., Durand, P., Grandin, R., Lasserre, C., Laurent, C., Deschamps-Ostanciaux, E., Pathier, E., Pointal, E., Proy, C. & Specht, B. 2021. FLATSIM: the ForM@Ter LARge-scale multi-Temporal Sentinel-1 InterferoMetry service. *Remote Sensing*, MDPI, 13(18): 3734. 10.3390/rs13183734. hal-03397350.

Uber, J.A., Zêzere, J.L. & Santos, L.J.C. 2012. Análise da suscetibilidade aos movimentos de vertente na Bacia do Marumbi (Morretes/PR): aplicação do método estatístico multivariado da regressão logística. In: XI Simpósio Nacional de Geomorfologia. Anais..., Rio de Janeiro. 3p. <http://www.sinageo.org.br/2012/trabalhos/1/1-566-621.html>.

Vincendon, S. 2023. Quels endroits du monde sont les plus exposés aux tremblements de terre? *BFMTV*. https://www.bfmtv.com/international/quels-sont-les-endroits-du-monde-les-plus-exposes-aux-tremblements-de-terre_AN-202302070529.html

Yamagishi, H. & Iwahashi, J. 2007. Comparison between the two triggered landslides in Mid-Niigata, Japan by July 13 heavy rainfall and October 23 intensive earthquakes in 2004. *Landslides* 4: 389–397. <https://doi.org/10.1007/s10346-007-0093-0>



Mapas de velocidade de deformação do solo em resolução total obtidos por meio do processamento SBAS-DInSAR de imagens SAR para Assis (Itália) sobrepostas ao mapa de inventário de deslizamentos de terra. Deslocamentos medidos ao longo da Linha de Visão (LOS) dos satélites. (A) Mapa de velocidade de deformação obtido processando 39 imagens SAR de banda X do período de 12/2009 a 02/2012. (B) Mapa de velocidade de deformação obtido processando 130 imagens SAR de banda C, do período de 04/1992 a 11/2010. (fonte: Caló et al., 2014)

XII. LEITURAS RECOMENDADAS

- Ferreira, R.S. & Santos, R. 2016. Mapeamento de Áreas Susceptíveis a Inundação no Perímetro Urbano de Ferreira Gomes–AP. XI SINAGEO. Maringá-PR. <http://www.sinageo.org.br/2016/trabalhos/6/6-452-1324.html>.
- Gomes, J.V.P. & Cubas, M.G. 2021. Fundamentos do sensoriamento remoto. Ed. InterSaberes. 238 p. ISBN 9786555178890.
- Liu, W.T.H. 2015. Aplicações de Sensoriamento Remoto. 2ª Edição. E-Book. 908 p. ISBN: 978-85-7975-177-6.
- Moreira, M.A. 2012. Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação. Ed. UFV. 422 p.
- Novo, E.M.L.M., 2010, Sensoriamento Remoto: princípios e aplicações. 4ª Ed. São Paulo. Blucher. 387 p.
- Quevedo, R.P., Belloli, T.F., Oliveira, G.G., Guasselli, L.A., Etchelar, C.B. & Brubacher, J.P. 2017. Espacialização da Suscetibilidade à Inundação na Bacia Hidrográfica do Arroio Demétrio, Gravataí – RS. Revista Brasileira de Cartografia, 69(7): 1371-1386. ISSN: 1808-0936.
- Santos, M.S., Gonçalves, G.M.S., Possa, T.M., Bartels, G.K. & Collares, G.L. 2018. Análise da Extensão de Áreas Inundadas no Canal São Gonçalo/ Lagoa Mirim com Sensoriamento Remoto. XXVII Congresso de Iniciação Científica-UFPEL. 4 p.
- Sausen, T.M. & Lacruz, M.S.P. 2015. Sensoriamento Remoto para Desastres. Oficina de Textos. São Paulo. 285 p. ISBN 978-85-7975-175-2.




Imagem dos deslizamentos em Nova Friburgo-RJ em 2011.
(fonte: https://blogger.googleusercontent.com/img/b/R29vZ2xl/AVvXsEiFJi-w-RFHRFEpHk0MuMo7JMKqVLuh2eJKjRCjUmn4bJvzJCHCWKXslw0xwVXdXe-sCvahFNL8FrvB8hW2Nb7R8779YF3neTWWOGrcsXvg20g4c277Y7Cy_eEMHr4POKUeT6tBQ/s1600/agua-MaPaGoogleEarth2-NovaFriburgo.jpg)

XIII. ABREVIATURAS

- AA** – Aprendizagem Automática.
ALOS - Satélite Avançado de Observação da Terra.
AM – Aprendizado de Máquina.
AP – Aprendizado Profundo.
BAF – Fluxo de Blocos e Cinzas.
CNES – Centro Nacional de Estudos Espaciais.
ENVISAT – Satélite Ambiental.
ERS - Satélite Europeu de Sensoriamento Remoto.
ESA – Agência Espacial Europeia.
GeoEye – Fonte de Imagens de Satélite.
GFZ – Centro Alemão de Geopesquisa.
GLIMS - Medições Globais de Gelo Terrestre a partir do Espaço.
GPS – Sistema de Posicionamento Global.
GPV – Unidade de Processamento Gráfico.
IA – Inteligência Artificial.
InSAR – Radars Interferométricos de Abertura Sintética.
IVT – Infravermelho Termal
LASER - Amplificação de Luz Estimulada por Emissão de Radiação.
LIDAR – Detecção e Alcance de Luz.
LOS - Linha de Visão do Radar.
M3C2 - O plugin M3C2 é a única maneira de calcular distâncias sinalizadas diretamente entre duas nuvens de pontos.
MDET – Modelo Digital Extremo do Terreno
MDT – Modelo Digital do Terreno.
NASA - Administração Nacional da Aeronáutica e Espaço.
nm – nanômetro.
NP – Nuvem de pontos
OL – Outros Lagos.
PANM – Parque Arqueológico Nacional de Machupicchu
PCS – Pontos de Controle no Solo
PDC – Corrente de Densidade Piroclástica.
PGLA – Lagos Pró/Periglaciais Distantes das Geleiras.
PGLC – Lagos Pró/Periglaciais em Contato com as Geleiras.
PIMP – Ponto Interativo Mais Próximo.
RADARSAT-1 - Satélite de observação da terra desenvolvido para monitorar mudanças ambientais e recursos naturais.
RDC – República Democrática do Congo.
RNC – Rede Neural Convolutacional.
SAR – Monitoramento Rápido por Satélite.
SGL – Lagos Supraglaciais.
SIFT – Transformação de Recursos Invariáveis em Escala.
SiMCosta - Sistema de Monitoramento da Costa Brasileira

- SPOT** – Satélite Experimental de Observação da Terra.
TanDEM-X - Satélite Alemão de Observação da Terra usando SAR.
TerraSAR-X - Satélite de Observação da Terra, resultado de uma cooperação público-privada entre o Centro Aeroespacial Alemão e a EADS Astrium.
URSS – União Socialista das Repúblicas Soviéticas
USGS – Serviço Geológico dos Estados Unidos.
VEI – Índice de Explosividade Vulcânica.
Web - nome pelo qual a rede mundial de computadores internet se tornou conhecida a partir de 1991.

XIV. ALGUNS SITES PARA VISUALIZAR IMAGENS

- Agência Espacial Europeia – <http://www.esa.int/export/esaCP/index.html>
ALMAZ – <http://www.almaz.spb.ru/>
ASTER – <http://asterweb.jpl.nasa.gov/>
AVIRIS – <http://makalu.jpl.nasa.gov/>
CNES – <http://www.cnes.fr/>
EUMETSAT – <http://www.eumetsat.de/en/top.html>
IGN – <http://www.ign.fr/>
MODIS – <http://modis.gsfc.nasa.gov/>
NASA – <http://www.nasa.gov/>
NASDA – <http://www.eoc.nasda.go.jp/homepage.html/>
NOAA – <http://www.noaa.gov/>
Publicações da Agência Espacial Europeia – <http://esapub.esrin.esa.it/>
RADARSAT – http://www.space.gc.ca/csa_sectors/
SIRIUS – <http://sirius.spotimage.fr/>
SPOT IMAGE – <http://spotimage.fr/spot-fr.htm>
USGS – <http://edcns17.cr.usgs.gov/earthexplorer/>
VEGETAÇÃO – <http://www.spotimage.fr/accueil/appli/apvege/welcome.htm>



O rio Indo e a cidade de Hala, no sul do Paquistão. A imagem da esquerda foi adquirida no dia 2 de agosto e a da direita no dia 28 de agosto de 2022. (© Planet Labs PBC)

XV. GLOSSÁRIO

Ablação - remoção, vaporização, lascamento ou destruição por outros processos erosivos.

Antrópico - relativo ou pertencente ao homem ou ao seu período de existência na Terra.

ASTER - instrumento do satélite Terra que oferece melhor resolução espacial (15 a 90 m) e opera nas regiões do visível, infravermelho próximo, infravermelho de ondas curtas e infravermelho termal.

Banda espectral - intervalo entre dois comprimentos de onda no espectro eletromagnético.

Cisalhamento - fenômeno de deformação ao qual um corpo está sujeito quando as forças que sobre ele agem provocam um deslocamento em planos diferentes, mantendo o volume constante.

Colinearidade – propriedade de um conjunto de pontos de estarem em uma única linha. Um conjunto de pontos com esta propriedade é dito colinear.

Convolutacional - procedimento ordenado em que duas fontes de informação estão interligadas; é uma operação que transforma uma função em outra. As convoluções são usadas no processamento de imagens para desfocar e tornar as imagens mais nítidas, mas também para realizar outras operações, como melhorar bordas e fazer relevo.

Coplanaridade - um conjunto de pontos no espaço possui coplanaridade, se todos os pontos estão no mesmo plano geométrico.

COSMO-SkyMed - sistema composto por satélite de observação da Terra, conduzido pela Agência Espacial Italiana, contemplando usos militares e civis.

Deslizamento de terra - fenômeno provocado pelo escorregamento de materiais sólidos, como solos, rochas, vegetação e/ou material de construção ao longo de terrenos inclinados, denominados de “encostas”, “pendentes” ou “escarpas”.

Drone - pequeno dispositivo voador, controlado à distância, geralmente usado para fins recreativos, comerciais ou científicos.

Elipsoide - figura geométrica utilizada como modelo para representar a forma da Terra.

Estereofotogrametria – utilização de duas ou mais fotografias aéreas simultâneas do objeto para, após análise em programa de computação, produzir um modelo geométrico em três dimensões.

Falha deslizante – também conhecida como rejeito direcional ou falha transcorrente (*strike slip fault*); o deslocamento é predominantemente horizontal, paralelo ao traço da falha, ou seja, os blocos deslocam-se predominantemente segundo a direção da falha.

Falha Inversa – também chamada de falha compressiva – manifesta-se de forma oposta ao tipo de falha normal, com o bloco deslocado movimentando-se acima do plano original.

Falha Normal – também chamada de falha distensiva – ocorre quando o bloco deslocado posiciona-se abaixo do plano da falha.

Falha Sinistral – é uma falha que se move para a esquerda, também denominada falha transcorrente sinistral, enquanto uma falha que se move para a direita é denominada falha transcorrente dextral.

Glacial – relativo a gelo, a frio extremo.

Glaciar - grande e espessa massa de gelo formada em camadas sucessivas de neve compactada e recristalizada, de várias épocas, em regiões onde a acumulação de neve é superior ao degelo.

ICESat - satélite da NASA destinado a medir a folha de balanço de massa das nuvens, bem como características da topografia e da vegetação terrestre.

Interferograma - consiste do registro da energia da fonte modulada pelo interferômetro.

Interferometria - é uma técnica que utiliza a interferência de ondas sobrepostas para extrair informações.

Lahar - designação dada a um movimento de massa exclusivo das regiões vulcânicas, formado pelo deslocamento ao longo de vales ou de encostas íngremes, em forma de avalanche, de lama composta por materiais piroclásticos e água.

Landsat - programa contínuo de missões de satélite de observação da Terra desenvolvido em conjunto pelo USGS e pela NASA

LIDAR - (Light Detection and Ranging) é um sensor remoto ativo a bordo de plataformas tripuladas ou não tripuladas e um método direto de captura de dados, o mesmo possui sua própria fonte de energia, neste caso, uma fonte de luz, o laser.

MODIS - Espectrorradiômetro de imagem de resolução moderada, instrumento científico lançado na órbita da Terra pela NASA em 1999 a bordo do satélite Terra, e em 2002 a bordo do satélite Aqua.

Movimento de Massa - São movimentos gravitacionais responsáveis pela mobilização de solo, sedimentos, vegetação ou rocha pela encosta abaixo, geralmente potencializados pela ação da água.

Ortofoto - é uma fotografia aérea ou imagem de satélite corrigida geometricamente de modo que a escala seja uniforme: a foto ou imagem segue uma determinada projeção do mapa.

Ortoretificação - processo que visa corrigir uma imagem, de modo que cada pixel é colocado na posição geométrica teórica como se eles tivessem sido imageados na vertical ou mais próximo desta situação

PALSAR - radar de abertura sintética que opera na Banda L, capaz de obter imagens diurnas ou noturnas e em quaisquer condições atmosféricas.

Paralaxe - é a diferença na posição aparente de um objeto em relação a um plano de fundo, tal como visto por observadores em locais distintos ou por um observador em movimento.

Pixel - elementos com os quais são construídas as imagens digitais. Um pixel é a menor unidade que consegue conter uma informação individual de cor.

Plêiades - constelação composta por dois satélites ópticos de imagem terrestre de altíssima resolução. Plêiades-1A e Plêiades-1B fornecem a cobertura da superfície da Terra com um ciclo de repetição de 26 dias.

Polarimetria - relativo a ciência da medição da polarização da luz.

Raster - é um formato de imagem que contém a descrição de cada pixel de forma sequencial/forma contínua sendo assim salvo como uma matriz.

Reflectância - proporção entre o fluxo de radiação eletromagnética incidente numa superfície e o fluxo que é refletido.

Resolução espacial - tamanho que a área abarcada em um pixel corresponde na realidade.

Seiche - onda de longo período ($30 < T < 500$ s), em geral estacionária, que se gera em estuários, bacias portuárias, lagos e outros corpos de água confinados, em resultado da amplificação por ressonância da energia de ondas incidentes ou de outra qualquer fonte de excitação ondulatória.

Semântica – é o estudo do significado. Incide sobre a relação entre significantes, tais como palavras, frases, sinais e símbolos, e o que eles representam, a sua denotação.

Sérac - é um bloco de gelo de grandes dimensões, fragmentado e gretado, pertencente a um glaciar, e cuja ruptura se deve ao movimento do gelo em zonas de grandes pendentes.

Speckle - fenômeno óptico causado pela interferência de frentes de ondas eletromagnéticas que sofreram dispersão após a interação com um meio físico.

Tefra - designação extensiva a qualquer material piroclástico expelido em erupção vulcânica.

Wavelet – representação de uma função de quadrado integrável (valor real ou valor complexo) por certas séries ortonormais geradas por uma onduleta.



Imagem de satélite mostrando a devastação das inundações ocorridas em Valência na Espanha, em 2/11/2024.

(modificado: <https://npr.brightspotcdn.com/dims3/default/strip/false/crop/1816x2349+649+548/resize/1100/quality/85/format/jpeg/?url=http%3A%2F%2Fnpr-brightspot.s3.amazonaws.com%2F30%2Fc2%2F54c676814b97b6efe5226bbc3880%2Fvalenciaflooding-oli-20241030-lrg.jpg>)

XVI. RESPOSTAS DAS QUESTÕES DE CONHECIMENTO

- | | |
|---|--|
| 1) B | 25) A,B,C |
| 2) Falsa | 26) A |
| 3) 1. Verdadeiro;
2. Verdadeiro
3. Verdadeiro | 27) B |
| 4) 1. Falso
2. Verdadeiro
3. Verdadeiro | 28) C |
| 5) C | 29) 1. Verdadeiro
2. Verdadeiro
3. Verdadeiro
4. Verdadeiro
5. Falso |
| 6) A | 30) 1. B
2. A
3. C |
| 7) 1. Falso
2. Verdadeiro
3. Verdadeiro | 31) 1. C
2. A
3. B |
| 8) 1. Falso
2. Verdadeiro
3. Verdadeiro | 32) 1. A
2. B
3. A
4. A |
| 9) C | 33) 1. B
2. A
3. A |
| 10) A | 34) A |
| 11) B | 35) 1. B
2. A
3. A
4. B |
| 12) D | 36) A |
| 13) A | 37) C |
| 14) B | 38) B,C |
| 15) B | 39) 1. B
2. A
3. A |
| 16) B | 40) B |
| 17) B | |
| 18) A | |
| 19) 1. Falso
2. Verdadeiro
3. Verdadeiro | |
| 20) C | |
| 21) B | |
| 22) A | |
| 23) B | |
| 24) A,C,D | |

