

LABSIGDER

Laboratório de Sistemas de Informação Geográfica e Detecção Remota



FutureWater

Research and consultancy for a sustainable future of our water resources

Projecto de Reforço de Capacidades em Detecção Remota para o Desenvolvimento Agrícola de Angola” - K2K (*Knowledge to Knowledge*)

Programa de formação de formadores

INTRODUÇÃO AOS SISTEMAS DE INFORMAÇÃO GEOGRÁFICA E DETECÇÃO REMOTA PARA A GESTÃO AGRÍCOLA ATRAVÉS DO USO DO SOFTWARE QUANTUM GIS – Parte 3

MANUAL EM PORTUGÊS “TELEDETECÇÃO E SERVIÇOS AGRÁRIOS”

Módulo 3 – Projecto de consultoria: técnicas de teledetecção para avaliação de idoneidade agrícola

Módulo 4 – Classificação supervisionada de usos do solo

Módulo 5 – Análise multi-temporal de alterações de usos do solo

Laboratório de Sistemas de Informação Geográfica e Detecção Remota (LABSIGDER) - Faculdade de Ciências Agrárias da Universidade José Eduardo dos Santos (Huambo, Angola)

&

Wageningen University and Research (Netherlands)



Rijksdienst voor Ondernemend
Nederland

Huambo, Julho de 2021

FICHA TÉCNICA

TÍTULO: Introdução aos Sistemas de Informação Geográfica e Detecção Remota para a Gestão Agrícola Através do Uso do Software Quantum Gis – Parte 3: Manual em Português “Teledetecção e serviços agrários”: Módulos 3, 4 e 5

AUTOR: Laboratório de Sistemas de Informação Geográfica e Detecção Remota – LABSIGDER, Faculdade de Ciências Agrárias – FCA, Universidade José Eduardo dos Santos – UJES (Huambo, Angola) & Universidade de Wageningen (Holanda)

SITE LABSIGDER: www.labsigder.fcaujes.com

EDITOR: Isáú Alfredo Bernardo Quissindo

REDACÇÃO, COMPOSIÇÃO E TRADUÇÃO: Grupo de Trabalho

FINANCIAMENTO: Agência de Cooperação Holandesa

ISBN: 978-989-53264-0-2

Grupo de Trabalho:

Ángel de Miguel García (Wageningen Environmental and Research)

Claire Jacobs (Wageningen Environmental and Research)

Alberto de Tomás (FutureWater)

Ngoma Manuel Fortuna (LABSIGDER, FCA-UJES)

Isáú Alfredo Bernardo Quissindo (LABSIGDER, FCA-UJES)

Supervisão:

Professora Doutora Imaculada da Conceição F. H. Matias – PhD (FCA-UJES)

Professora Doutora Virgínia Lacerda Quartin - PhD (FCA-UJES)

Conteúdo

Módulo 3 - Tratamento de imagens de satélite e interpretação visual	5
Projeto de consultoria: técnicas de detecção remota para avaliação de adequação agrícola.....	5
Introdução	5
Exercício 1- Download e processamento de imagens Landsat8.....	10
Exercício 2 - Mascaramento de nuvens em imagens Landsat8.....	14
Exercício 3 - Visualização de composição de banda para o Landsat8	16
Análise do território / Interpretação visual de imagens.....	17
Exercício 4 - Criação de cartografia temática - Digitalização	25
Produtos MODIS.....	31
Exercício 5 – Download de dados MODIS	31
Exercício 6 - Análise estatística de séries temporais de produtos de Detecção Remota (dados raster)	33
Exercício 7 - Google Earth Engine app – Climate Engine.....	37
Módulo 4 - Classificação supervisionada de usos da terra	37
Cobertura do solo.....	37
Exercício 8 - Classificação supervisionada	37
Módulo 5 - Análise multitemporal da mudança do uso da terra.....	42
Análise multitemporal da mudança do uso da terra	42
Exercício 9 - Comparação de produtos de classificação de solos	42
Exercício 10 - Análise multitemporal das mudanças no uso da terra com a ferramenta MOLUSCE-QGIS.....	47
Exercício 11 - Análise multitemporal de áreas florestais.....	53

Este curso e todo o seu material constitui a segunda parte do curso "Introdução ao SIG e Detecção Remota para a gestão agrícola através do uso de QGIS", realizado no Huambo em Novembro de 2017, no âmbito do Projeto K2K.

Bibliografía de referêncía

Chuvieco Salinero, Emilio. Fundamentos de teledetección espacial. No. 528.8 CHU. 1990.

Chuvieco Salinero, Emilio. Teledetección ambiental: la observación de la Tierra desde el espacio. Ariel, 2006.

QGIS Training Manual - es, Release 2.8, 2015

QGIS User Guide - es, Release 2.8, 2015

Francisco Carreño. Taller de búsqueda y tratamiento de imágenes de satélite con datos y software libres para aplicaciones ambientales. Smart-hydro, Junio 2017.

Luca Congedo, Semi-Automatic Classification Plugin Documentation, Versión 5.3.6.1, Version Español.

T. Sutton, O. Dassau, M. Sutton, A Gentle Introduction to GIS, 2009

Módulo 3 - Tratamento de imagens de satélite e interpretação visual

Projeto de consultoria: técnicas de detecção remota para avaliação de adequação agrícola

Introdução

O governo angolano considera o sector agrícola como um sector económico que oferece grandes perspectivas e, por isso, visa desenvolver ainda mais este sector para diversificar a sua economia. O potencial para expandir a área na produção é excelente. O país tem solos férteis, um clima favorável, recursos hídricos suficientes e terras abundantes e inexploradas. Especificamente, a província do Huambo é mencionada como uma das áreas mais promissoras para um setor agrícola em crescimento.

Atualmente, o setor agrícola angolano é caracterizado por baixa produtividade e baixa competitividade. Para apoiar o planeamento efetivo de intervenções que aumentam a produção e expandem o setor agrícola, informações confiáveis são cruciais. A confiabilidade dos dados existentes sobre a produção agrícola em Angola não é clara. Além disso, não há ideia de quais regiões de terras não desenvolvidas mostrariam o maior potencial de rendimento se fossem colocadas em produção. Portanto, a incerteza relacionada ao investimento em novos recursos terrestres é alta.

Este projecto-piloto centra-se na utilização do detecção remota para fornecer dados e informações relevantes para apoiar a tomada de decisão e planeamento eficazes para a expansão do sector agrícola angolano.

Objetivos do projeto

- Analisar a distribuição espacial das culturas estudadas.
- Analisar o padrão de crescimento (fenologia) das culturas agrícolas durante um período histórico.
- Analisar as mudanças no uso de terras agrícolas e florestais na província do Huambo durante um período histórico.
- Preparar uma potencial cartografia agro-ecológica (análise de adequação) para as principais culturas na província do Huambo.

Dados iniciais

Todas as análises propostas neste documento serão levadas a cabo para toda a província angolana do Huambo. Como principal centro agrícola do país, Huambo é uma área prioritária para o desenvolvimento e expansão agrícola. A província central é mediterrânea e relativamente pequena, com uma área de pouco mais de 34.000 km². Geralmente, há três ciclos de produção agrícola na área. Ver figura 1.



Figura 1. Campo de acção do projecto, Província do Huambo, Angola

As principais culturas no Huambo são milho, batata e feijão.



1. No caso do milho, apenas duas safras (épocas) são utilizadas. nas primeiras chuvas (outubro) e dependendo do ciclo da variedade vai até maio. A chamada temporada de baixa temporada em julho (amplamente usada para consumo de cúrcuma fresca) dura até outubro, novembro e, às vezes, dezembro, dependendo da variedade e das chuvas de outubro.
2. Para as batatas é possível usar os três estações de crescimento, o primeiro de outubro a dezembro (esta é atacada por doenças, requer um tratamento fitossanitário alto, por isso muitos agricultores não use); o segundo de fevereiro a maio (este é o mais rentável e mais produtiva, começa com chuva e, eventualmente, pode acabar com a irrigação, dependendo da variedade, é usado por todos os produtores) eo último com irrigação plena, a partir de julho e até o final em outubro (isto é só para quem tem irrigação e é muito arriscado porque se começar a chover em setembro pode ser necessário colher antes do amadurecimento total).
3. O feijão geralmente é cultivados na segunda temporada, entre fevereiro e junho, porque se for plantada antes pode sofrer uma queda de flores com as chuvas de fevereiro.

Metodologia

Ao trabalhar com séries temporais de variáveis físicas em um determinado território, a detecção remota ou o uso de imagens de satélite torna-se a ferramenta de trabalho fundamental.

Sabemos que as imagens de satélite coletam informações espectrais sobre as diferentes coberturas do solo, o que nos permite fazer uma diferenciação de classe de uma maneira simples (Figura 2).

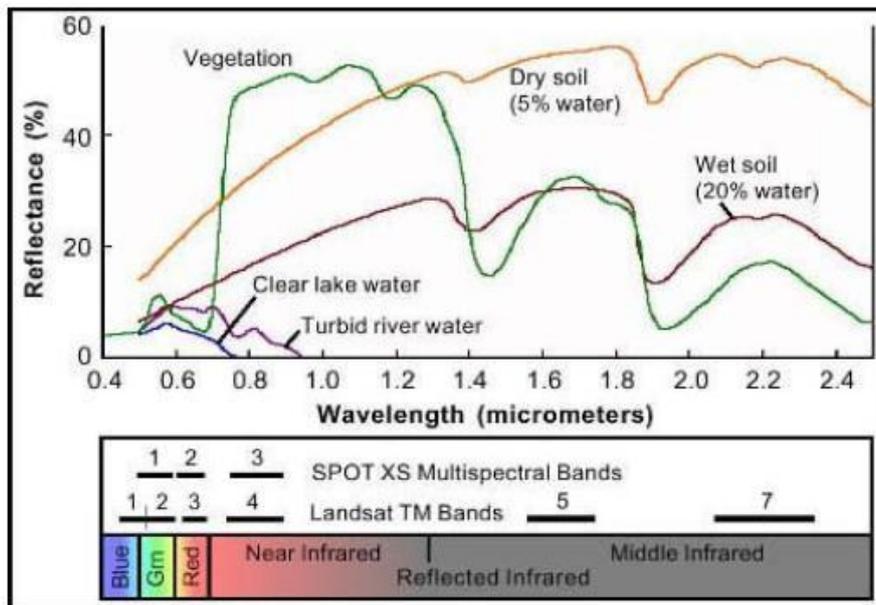


Figura 2. Comportamento espectrais dos alvos

Para o qual, surgem as seguintes questões:

1. Que tipo de imagens vamos usar? (Ex: Landsat, Sentinel, MODIS, AVHRR, etc.)
2. Quais são as datas de estudo que precisaremos?

A primeira pergunta pode ser respondida com base em nossas necessidades, que serão marcadas pelos objetivos do projeto:

- Resolução espacial: quão grandes são os objetos que queremos diferenciar?
- Resolução provisória: com que frequência precisamos analisar os dados?
- Resolução radiométrica: que bandas espectrais eu preciso para minha análise?
- Disponibilidade de dados: quantos dados eu preciso para minha análise?

Objectivo 1

O primeiro objetivo do projeto é analisar a distribuição espacial das culturas estudadas. Com base na atividade 1 do objetivo 1 do projeto, faremos as seguintes conclusões: trabalharemos com imagens Landsat8 por vários motivos:

- Precisamos trabalhar com imagens de satélites capazes de distinguir diferentes culturas -> alta resolução espacial e radiométrica.
- Precisamos trabalhar com imagens de satélite com alta disponibilidade (Tabela 1).

Tabela 1. Bandas espectrais de imagens Landsat8

Landsat-8 OLI and TIRS Bands (μm)		
30 m Coastal/Aerosol	0.435 - 0.451	Band 1
30 m Blue	0.452 - 0.512	Band 2
30 m Green	0.533 - 0.590	Band 3
30 m Red	0.636 - 0.673	Band 4
30 m NIR	0.851 - 0.879	Band 5
30 m SWIR-1	1.566 - 1.651	Band 6
100 m TIR-1	10.60 - 11.19	Band 10
100 m TIR-2	11.50 - 12.51	Band 11
30 m SWIR-2	2.107 - 2.294	Band 7
15 m Pan	0.503 - 0.676	Band 8
30 m Cirrus	1.363 - 1.384	Band 9

O gráfico seguinte mostra os comprimentos de onda do Landsat5 TM (linha inferior), Landsat7 ETM + (linha do meio) e Landsat8 (linha superior):

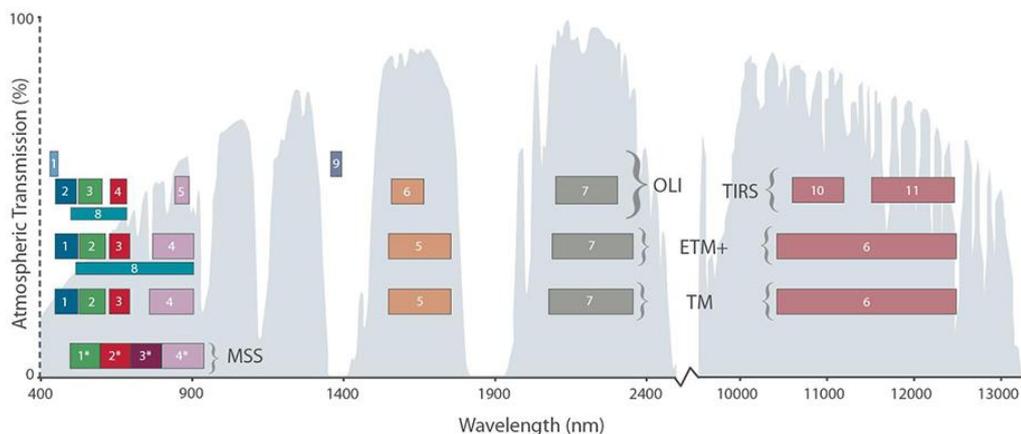


Figura 3. Comprimentos de onda do Landsat5 TM, Landsat7 ETM + e Landsat8

Abaixo estão algumas das combinações comuns de bandas em comparações RGB para Landsat7 ou Landsat5 e Landsat8. Ao ver onde as bandas caem ajudará a criar produtos RGB compostos do Landsat8 que serão comparáveis ao Landsat7 e 5. Ver figura 4.



Figura 4. Combinações comuns de bandas e RGB

Pergunta:

Que datas serão necessárias para diferenciar uma cultura da outra, bem como as massas da floresta (Figuras 5 e 6) com base na assinatura de referência espectral das culturas e suas diferentes fenologias?

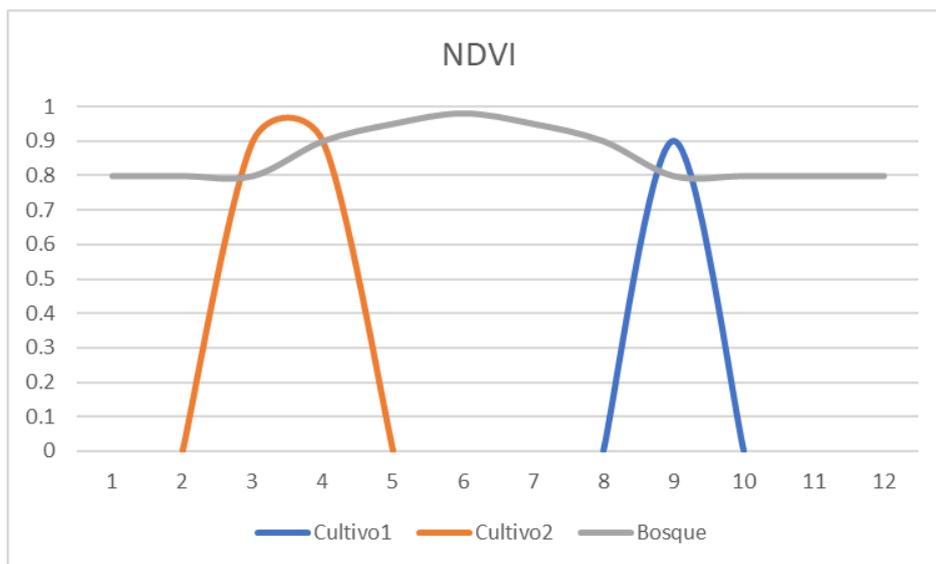


Figura 5. NDVI para diferentes coberturas vegetais

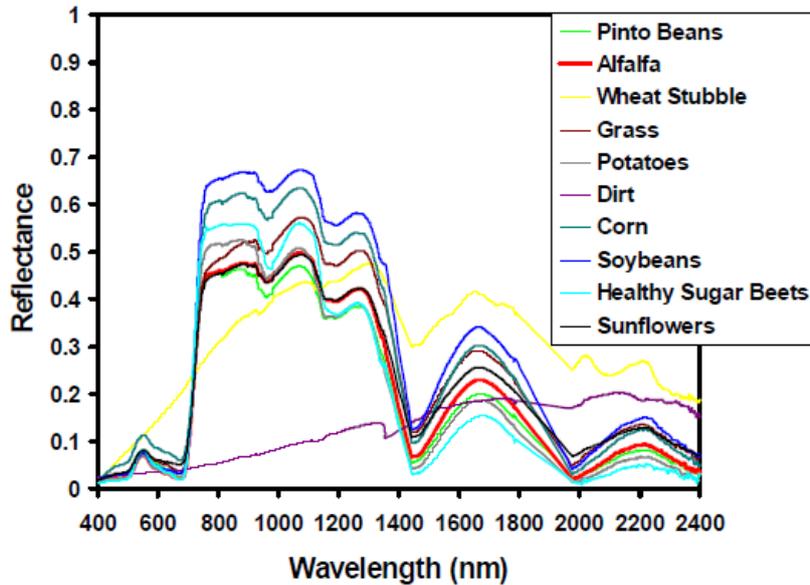


Figura 6. Assinaturas espectrais para diferentes culturas

Resposta:

Vamos seleccionar, pelo menos, as imagens nas seguintes datas (Figura 7):

- Janeiro, para distinguir as culturas de milho.
- Abril, para distinguir culturas de batata e feijão.
- Setembro, para distinguir culturas de milho e batata.
- Junho, para distinguir estandes florestais para o objetivo 2 do projeto.

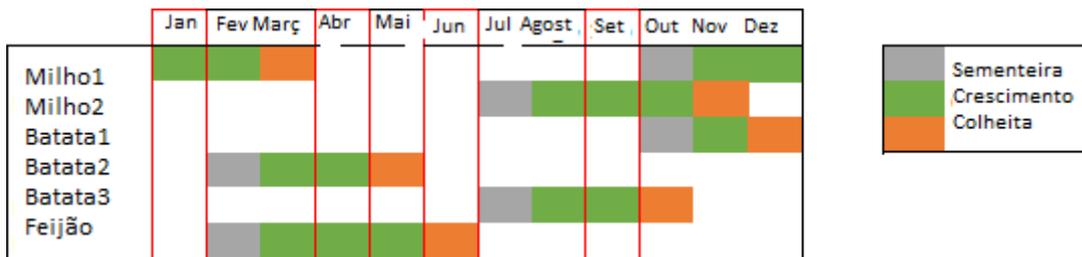


Figura 7. Época de crescimento de diferentes culturas no Planalto Central

Para cumprir o objetivo 1 do projeto, realizaremos os seguintes exercícios.

Exercício 1- Download e processamento de imagens Landsat8

Neste exercício realizaremos o download (Figura 8) e o processamento de imagens Landsat8

1. Abra o QGIS e agregue ao projecto o shapefile MATERIAL/Outline/Huambo_WGS84.shp.

2. Instalar o plugin OpenLayers e visualizar as camadas sobre a região do Huambo:

(Web>>OpenLayers plugin>>Google Maps)

- Google Physical
- Google Satellite

3. Abra o Módulo de Classificação Semi-Automática SCP e pesquise as imagens Landsat8 disponíveis para 2017 correspondentes aos meses de Janeiro, Abril, Junho e Setembro, com uma cobertura de nuvens inferior a 20%, sobre a região do Ukuma e Longonjo.

Exercício: comparar a busca com o USGS Global Visualization Viewer (GlobVis): <https://glovis.usgs.gov/>.

4. Baixe apenas as imagens correspondentes a path/row (181/69) e as datas:

- 2017-02-06
- 2017-04-11
- 2017-06-14
- 2017-09-02

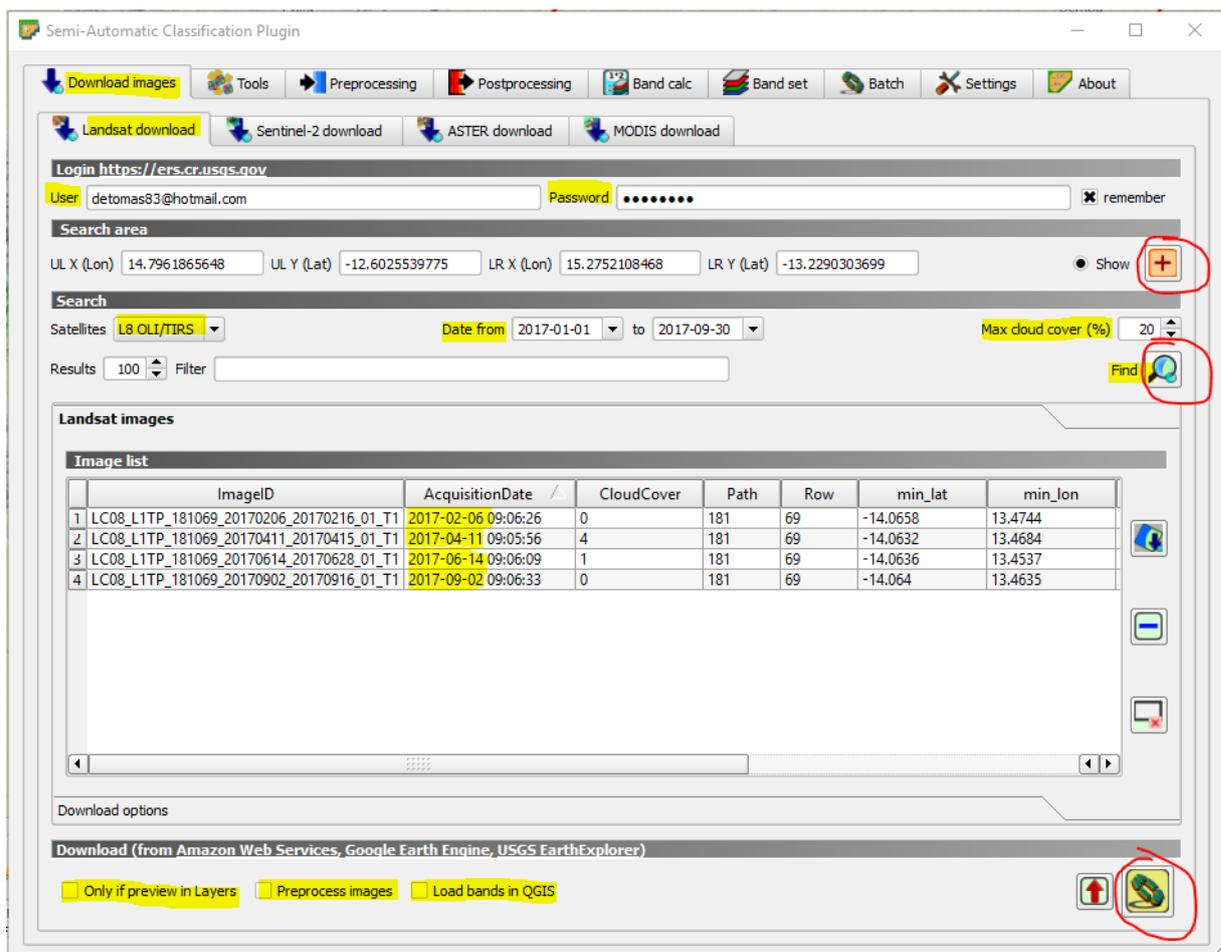


Figura 8. Descarga de imagen de satélite

Área de interesse para pesquisa de imagens (Figura 9).

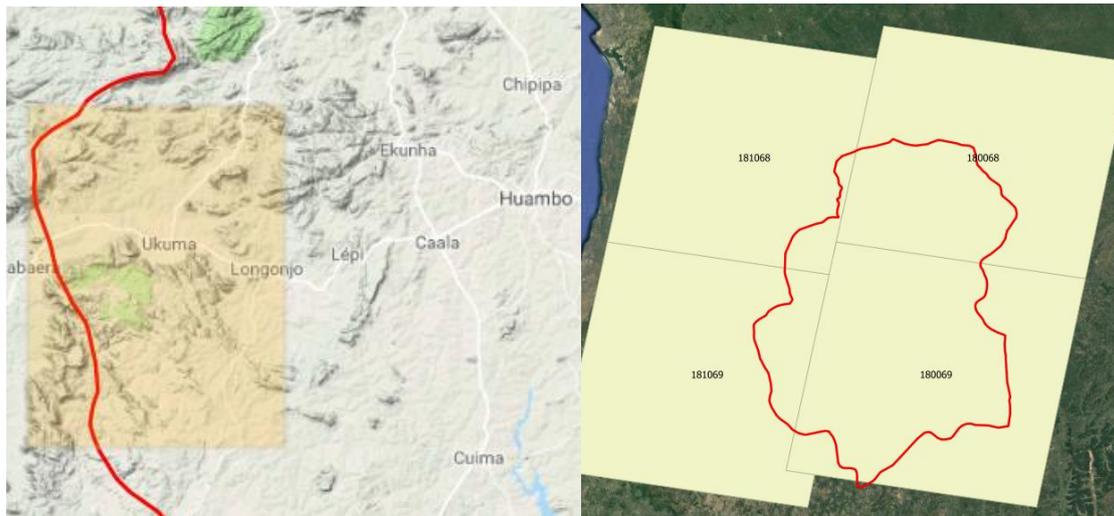
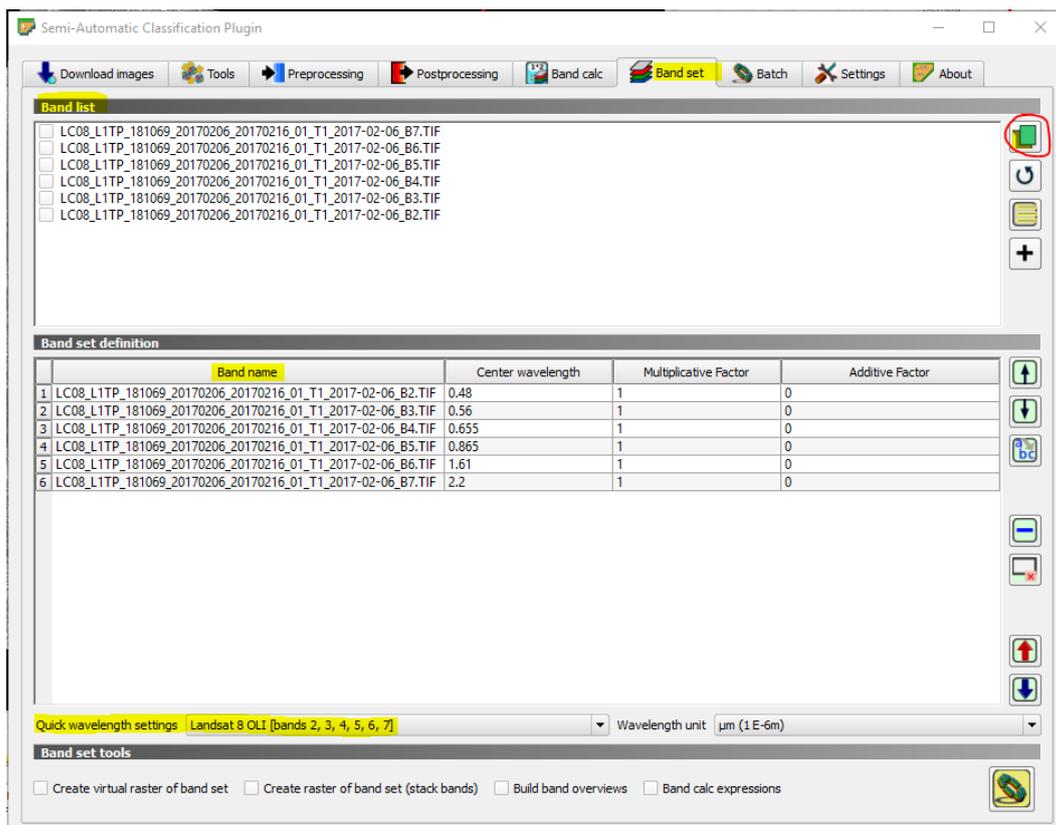


Figura 9. Área de interesse

Path / Row do Landsat sobre a região do Huambo:

5. Recorte todas as imagens, fazendo um clipe ao redor da área de estudo usando a cobertura do shp (Huambo_WGS84) previamente carregada no projecto, apenas para as bandas 2, 3, 4, 5, 6 e 7. Ver figura 10.



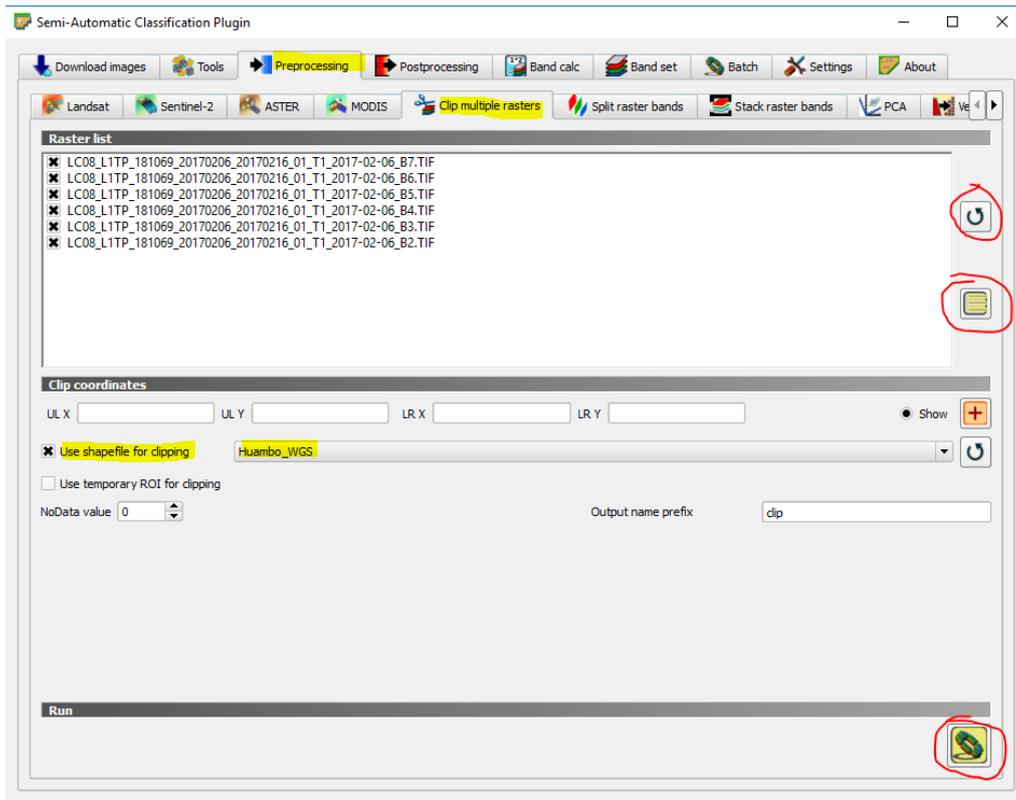


Figura 10. Corte da imagem

6. Converta as imagens recortadas para reflectividade (figura 11):

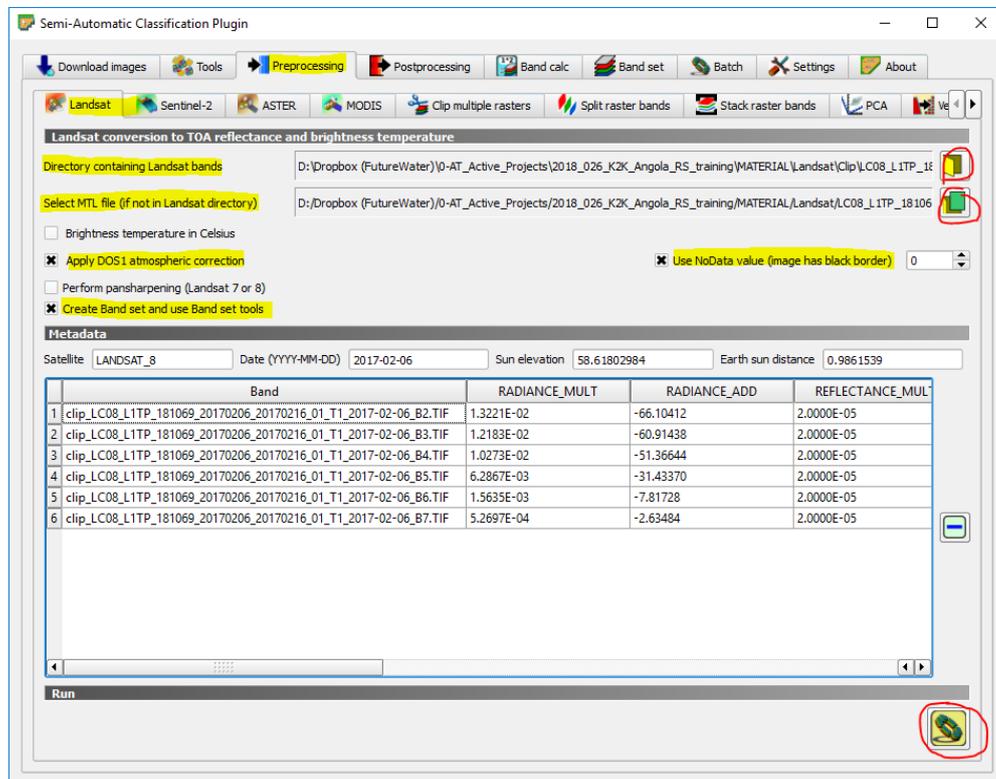


Figura 11. Conversão das imagens para reflectividade

7. Repita o processo para todas as datas, excepto a data de 2017-04-11 que contém uma percentagem maior de nuvens. Faça o Exercício 2 para a data 2017-04-11 etapa anterior para a conversão dos valores digitais de suas bandas para refletividade.

Exercício 2 - Mascaramento de nuvens em imagens Landsat8

Neste exercício, eliminaremos as nuvens presentes em uma imagem Landsat8 usando o plugin QGIS Cloud Masking.

1. Instale no QGIS plugin Cloud Masking.
2. Abra o plugin Cloud Masking e carregue o ficheiro MTL que se descarregou para a imagem da data 2017-04-11. Ver figura 12.

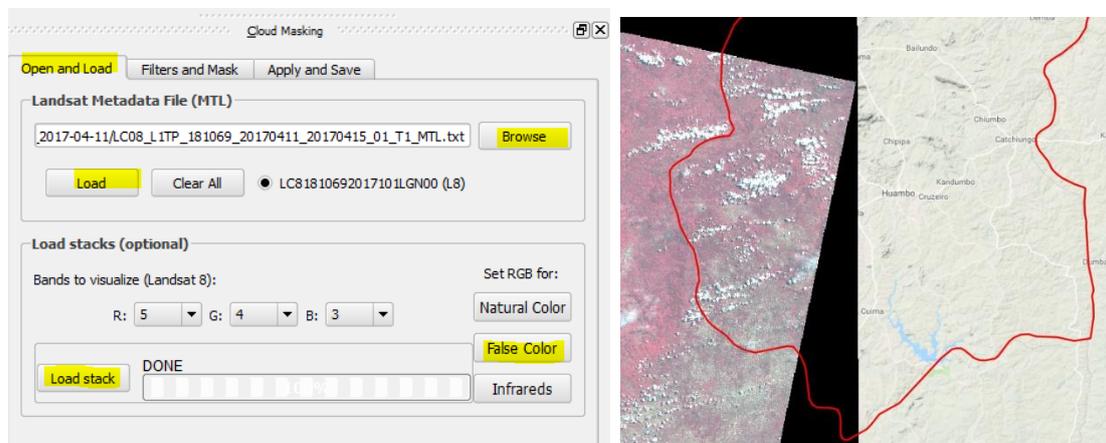


Figura 12. Ferramenta de remoção de nuvens

Nota: Se, depois de abrir o arquivo MTL, quando você clicar no botão Carregar, aparecerá um erro do tipo ilustrado na figura 13:

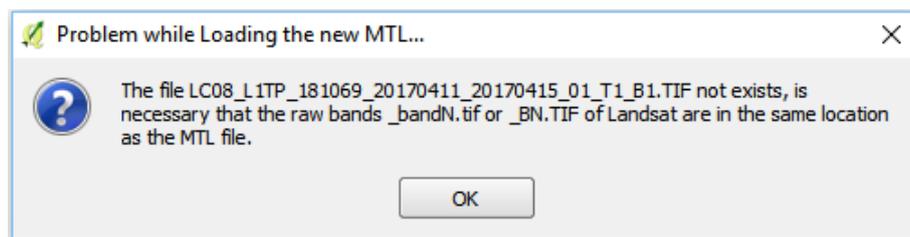


Figura 13. Problema durante a abertura do arquivo MTL

Debe-se renomear as bandas para corresponder ao formato do nome do arquivo MTL, ou seja (Figura 14):

- MTL:
LC08_L1TP_181069_20170411_20170415_01_T1_MTL.txt
- B1 original: LC08_L1TP_181069_20170411_20170415_01_T1_2017-04-11_B1.TIF

- B1

renomeado:

LC08_L1TP_181069_20170411_20170415_01_T1_B1.TIF

3. Aplique os filtros para gerar a máscara:

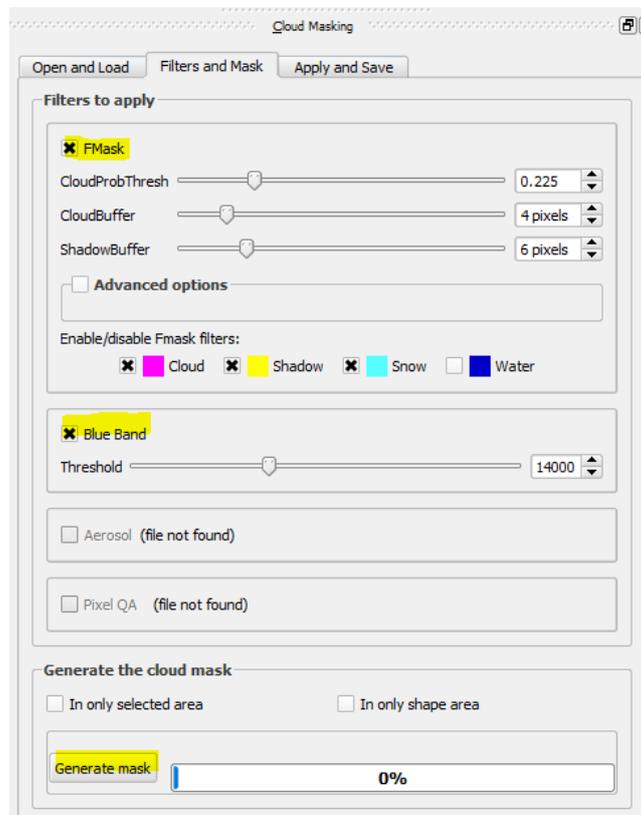


Figura 14. Máscara para renomeação das bandas

4. Guarde a máscara (Figura 15).

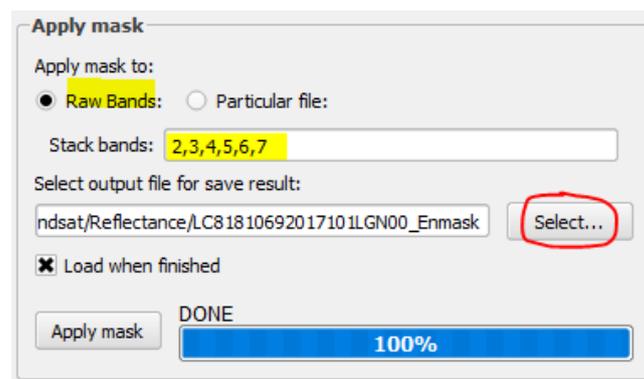


Figura 15. Processo de selecção do directorio para salvar as bandas renomeadas

5. Aplique a máscara somente nas bandas 2,3,4,5,6,7 (Figura 15) e gera um único arquivo de saída (pilha).

6. Separe as bandas do único arquivo gerado na etapa 5 com a ferramenta SCP (Figura 16).

Nota: quando terminar, renomeie as bandas para seus nomes originais: B2, B3, B4, B5, B6, B7.

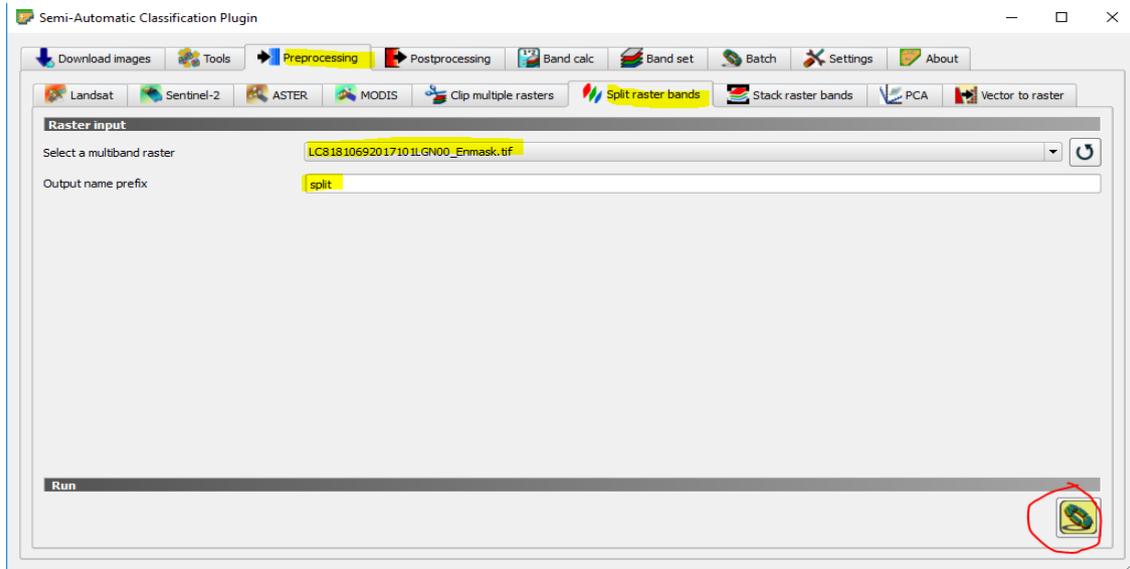


Figura 16. Ferramenta e processo de separação das bandas de um único arquivo

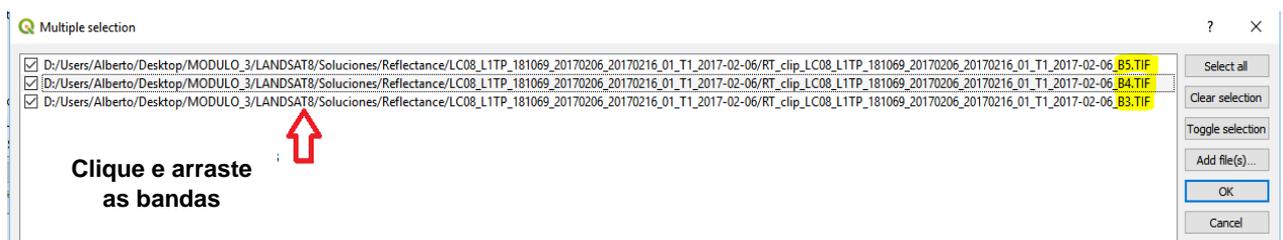
7. Converta os valores digitais das bandas da imagem em refletividade seguindo as instruções do Exercício 1, mas primeiro fazendo o passo 6 e depois o passo 5.

Exercício 3 - Visualização de composição de banda para o Landsat8

Neste exercício, faremos a criação de composições de cores de imagens de satélite.

1. Abra a Ferramenta Build Virtual Raster (*Raster>>Miscellaneous>>Build Virtual Raster*). Ver figura 17.
2. Gera rasters virtuais de composições em cores falsas (5/4/3) para cada uma das quatro datas do estudo seguindo as etapas indicadas na imagem.

Nota: na versão 3.xx do QGIS, o ícone de lápis para editar o código não existe. A ordem das bandas deve ser selecionada ao carregar, clicar e arrastar banda por banda até que a ordem desejada seja alcançada:



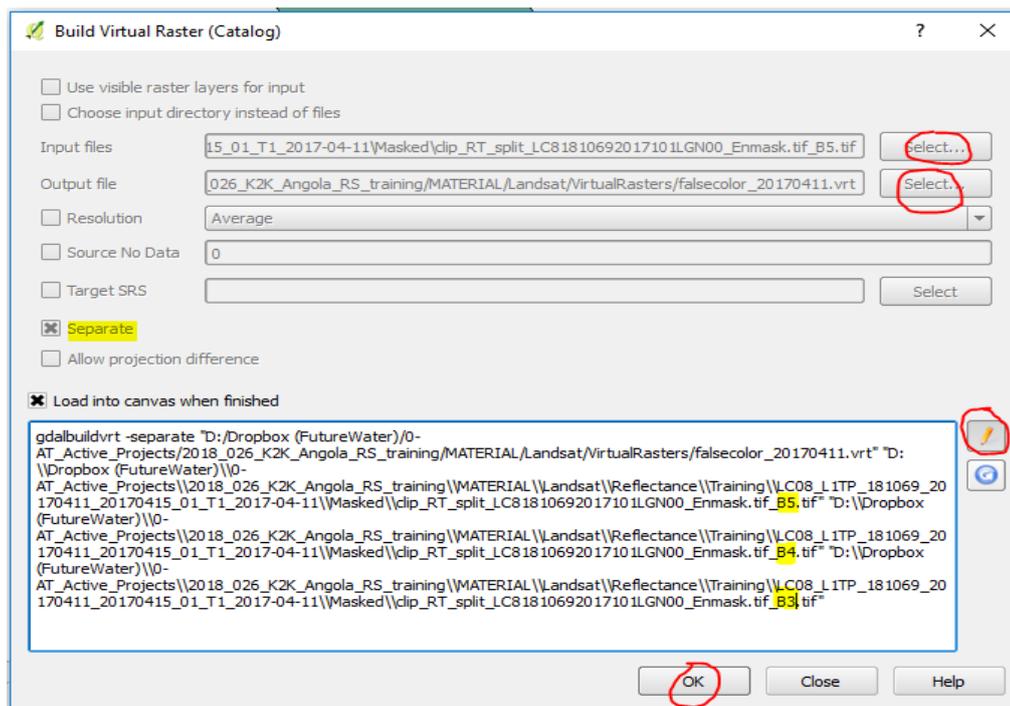


Figura 17. Criação de um raster virtual

Análise do território / Interpretação visual de imagens

- Bibliografia de referência: Chuvieco Salinero, Emilio. Detecção remota ambiental: a observação da Terra a partir do espaço. Ariel, 2006.

Uma interpretação detalhada das imagens requer a consideração das principais características de sua aquisição, bem como os tratamentos que podem ter abordado as antenas receptoras. Por exemplo, a data de aquisição é hipótese essencial interpretação adequada, considerando o ciclo fenológico das espécies cultivadas ou florestais (taxa de decídua e marcescente). Da mesma forma, os ângulos solares são de interesse para conhecer as condições de iluminação da zona observada e, por conseguinte, a hipótese de interpretação baseia-se na combinação alívio-iluminação: encostas que são sombrias e ensolaradas e sua relação com a identificação das sombras.

Uma primeira maneira de se familiarizar com as imagens é compará-las com uma fonte cartográfica convencional. Este exercício pode ser abordado em várias fases. No primeiro, baseado em um mapa de escala semelhante, podem ser localizados os reservatórios e cursos de água mais importantes da região. A partir deles, uma segunda inspeção da imagem permite identificar aspectos humanos do território, como as cidades mais importantes e as principais rotas de comunicação. Os acidentes de montanha serão identificados em uma terceira fase, pois são aspectos mais representados abstratamente no mapa e, portanto, difíceis de delimitar. Massas de vegetação ou feições efêmeras relacionadas com a imagem (como, por exemplo, incêndios ou agentes poluidores), podem

ser interpretadas numa fase final, uma vez que raramente serão recolhidas no mapa. Este exercício pode ser feito a partir das carto- imagens que produzem diferentes centros cartográficos. Essa primeira familiarização serve como um preâmbulo para considerar os principais critérios usados para interpretar visualmente uma imagem. Muitos deles são comuns à fotointerpretação clássica de fotogramas aéreos.

Critérios para a interpretação visual

Uma das principais vantagens da análise visual sobre o digital é a capacidade de incorporar critérios complexos à interpretação da imagem. Enquanto o tratamento digital é baseado, quase exclusivamente, na intensidade radiométrica de cada pixel - nas diferentes bandas usadas para interpretação -, a análise visual pode usar outros elementos, como a textura, estrutura, localização ou arranjo, muito difícil de definir em termos digitais.

Esses critérios nos permitem discriminar categorias com um comportamento espectral similar, embora com um significado temático muito diferente. Por exemplo, algumas culturas irrigadas geralmente oferecem uma resposta espectral muito semelhante aos parques urbanos, já que ambas as coberturas são formadas pela mesma espécie de planta ou por espécies semelhantes. No entanto, seu significado temático é claramente diferente e, portanto, deve ser incluído na cartografia final. Digitalmente, a distinção é complexa, uma vez que os valores numéricos de ambas as capas são muito semelhantes. Agora, basta incorporar um critério visual simples, como o contexto geográfico, para separá-los.

Entre as diretrizes visuais gerenciadas na detecção remota espacial, algumas são comuns com fotografia aérea: tom, textura, estrutura, sombras, contexto, etc. outros são mais típicos de imagens espaciais, principalmente no que diz respeito à dimensão multi-espectral e multi-temporal das observações, severamente limitada na fotografia aérea. Os critérios visuais devem ser tratados com alguma cautela nas imagens de satélite, porque as escalas de trabalho e a geometria de aquisição são diferentes daquelas usadas na fotografia aérea. Dependendo de como as imagens de solução espacial estão disponíveis, essas diferenças serão atenuadas, até que se tornem praticamente inexistentes.

Vale a pena ter em conta que estes critérios são utilizados de forma integrada, em códigos visuais complexos. Diversos autores sugeriram classificar esses critérios em uma escala hierárquica, de acordo com seu grau de complexidade e as variáveis consideradas. O brilho e a cor seriam os critérios mais elementares, pois caracterizam espectralmente uma cobertura, e estão diretamente relacionados à maneira como refletem a radiação incidente nas diferentes bandas do espectro. A forma, o tamanho e a textura têm a ver com as propriedades espaciais dos objetos, em si mesmas consideradas, enquanto a sombra e o contexto (localização) também expressam aspectos espaciais, mas,

neste caso, em relação aos objetos circundantes. Finalmente, a dimensão temporal refere-se a como as capas são modificadas ao longo do ano (sazonalidade). A seguir, revisaremos em detalhes os critérios de interpretação visual mais utilizados, e tentaremos vinculá-los em um esquema mais amplo para entender corretamente seu uso na análise de imagens. Ver figura 18.

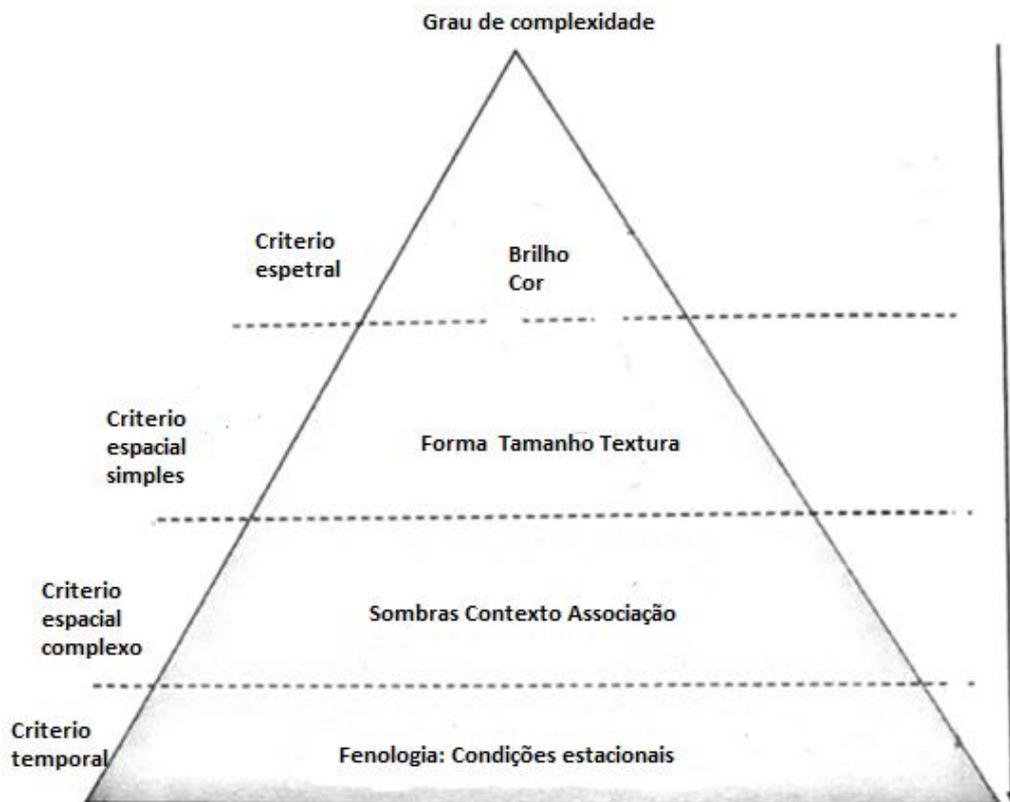


Figura 18. Organização hierárquica de critérios de interpretação visual (Chuvieco, 2006)

➤ **Brilho**

O brilho refere-se à intensidade da radiância recebida pelo sensor em um pixel, para uma determinada banda do espectro. Visualmente, os pixels com tons escuros indicam as áreas sobre as quais o sensor detectou uma radiância fraca (que indica baixa refletividade se estamos trabalhando no espectro solar) enquanto as zonas de luz correspondem a áreas com maior brilho. Em outras palavras, o brilho está intimamente relacionado ao comportamento espectral das diferentes capas, de modo que suas assinaturas espectrais são a base para entender a distribuição de tons de cinza na imagem resultante.

Como a energia refletida de uma cobertura varia em diferentes comprimentos de onda, seu brilho característico também varia em imagens adquiridas para várias bandas do espectro. Assim, uma superfície ocupada por vegetação vigorosa terá uma baixa radiância nas bandas visíveis do espectro, especialmente azul e vermelho, como consequência da alta absorção de luz solar que os pigmentos das folhas produzem nesses comprimentos de onda. Consequentemente, nas

imagens adquiridas nessas bandas, a vegetação aparecerá em cinza escuro. Ao contrário, será mostrado em cinza claro se a imagem corresponder ao infravermelho próximo, já que nessa região do espectro a folha saudável oferece alta refletividade. Em suma, para interpretar o brilho oferecido pela imagem, devemos ter em mente o comportamento espectral das diferentes capas de interesse nas bandas espectrais que estão sendo analisadas. Caso contrário, o intérprete pode treinar para reconhecer algumas categorias mecanicamente, mas não entenderá completamente as razões para as diferenças tonais observadas.

O brilho é um dos principais critérios de interpretação visual. Agora, o número de intensidades de cinza que podemos distinguir na imagem é limitado pela nossa própria percepção visual e pelo suporte físico usado para visualizar (papel ou filme). Tradicionalmente, na fotointerpretação convencional, as diferenças de brilho são observadas em uma única banda, uma vez que a maioria das fotografias era pancromática. No caso de imagens de satélite, a observação do brilho é realizada simultaneamente em várias bandas, o que facilitará um reconhecimento mais preciso de algumas capas.

➤ **Cor**

A fim de facilitar a sua interpretação, pode ser aconselhável incluir uma chave de cores simples, a fim de familiarizar o intérprete com este tipo de representações. Os tons mais comuns correspondem às seguintes capas:

- *Vermelho-magenta*: Denota vegetação vigorosa, como culturas irrigadas, prados de montanha ou florestas caducifólias em imagens de verão, e culturas herbáceas de crescimento seco em imagens de primavera. O estudo detalhado da intensidade e saturação do vermelho permite identificar diversas coberturas vegetais, bem como estimar seu ciclo de crescimento e vigor.
- *Rosa*: Mostra áreas de plantas menos densas e / ou vegetação em um estágio inicial de crescimento. As áreas suburbanas ao redor das grandes cidades, com seus pequenos jardins e árvores dispersas, às vezes aparecem nessa cor.
- *Branco*: Áreas de pouca ou nenhuma vegetação, mas de máxima refletividade: nuvens, areias, depósitos de sal, pedreiras, solos nus, neve.
- *Preto azul escuro*: Superfícies totalmente ou parcialmente cobertas por água: rios, canais, lagos, reservatórios. Em áreas vulcânicas. os tons pretos podem identificar fluxos de lava
- Cinza para azul de metila. Cidades povoadas tarefas, embora também possa ser rocha nua.
- *Marrom*: Vegetação arbustiva, muito variável dependendo da densidade e do tom do substrato. Tons mais escuros indicam a presença de materiais paleozóicos (folhelhos), enquanto arbustos menos densos geralmente oferecem um tom mais claro.

- *Bege-dourado*: Identifica prados, zonas de transição secas frequentemente associadas a matas esparsas.

Entre as múltiplas combinações de cores que foram usadas na análise visual, a mais proeminente é, sem dúvida, a chamada cor infravermelha. É obtido movendo as bandas do espectro visível para comprimentos maiores, substituindo a composição das bandas R, V e A pela correspondente ao IRC, R e V.

Para objetivos parciais como base para a interpretação visual de imagens, pode ser interessante considerar outros tipos de combinações de cores. A partir de imagens de TM, a eficácia da composição formada pelas bandas 7/4/1 para detectar áreas queimadas, daquela formada pelas bandas 7/4/3 para discriminação de lavouras em áreas irrigadas ou alagadas, e de o formado pelas bandas 7/3/1 para aplicações oceanográficas. Apesar do interesse dessas composições, o papel principal da combinação na cor infravermelha convencional (IRC, R, V) ainda é válido

Ao alterar a ordem da atribuição de cores, a cor mencionada anteriormente não faz sentido, uma vez que as sombras resultantes serão diferentes. Por exemplo, se modificarmos o infravermelho colorido melhorado (IRC: SWIR, R), atribuindo o caminhão verde ao IRC e o R ao SWIR, a vegetação mais vigorosa aparecerá em tons de verde, em vez de tons de vermelho.

➤ **Textura**

Essa variável refere-se à heterogeneidade espacial de uma determinada cobertura, enfim, ao contraste espacial entre os elementos que a compõem. Visualmente manifesta-se como a rugosidade ou suavidade de tons de cinza. Quanto mais semelhantes forem, a tonalidade será mais homogênea dentro da capa e a textura será mais suave. Pelo contrário, se houver uma alta heterogeneidade nos níveis de cinza dessa cobertura, ela aparecerá como muito áspera, com uma textura rugosa.

A textura de uma capa vem da relação entre o tamanho dos objetos que a formam e a resolução do sensor. Quando um objecto ocupa uma área inferior a 1 mm² (a resolução da imagem) não podem ser identificados individualmente, mas apenas através da variabilidade espacial causada.

Estritamente falando, além do tamanho dos objetos que formam uma certa cobertura, a textura com a qual ela aparece na imagem pode variar dependendo de vários fatores. Os mais importantes são o sensor de ângulo de visão (um observação nítida aumenta a rugosidade), condições de iluminação (sol baixo ângulos o efeito de sombra é mais evidente), e o comprimento de onda (uma superfície lisa para longos comprimentos pode parecer áspero em breve). Trabalhando no espectro visível e no IRC, a rugosidade é modificada principalmente em termos de condições de iluminação solar. Uma floresta

natural, por exemplo, pode oferecer uma textura muito variada dependendo da altura do sol no horizonte e de seu desenvolvimento sazonal.

O critério de textura é muito importante para discriminar as coberturas acabadas que podem oferecer um comportamento espectral uniforme. Por exemplo, árvores frutíferas irrigadas e árvores decíduas oferecem uma refletividade muito semelhante, uma vez que, em muitas ocasiões, apresentam grandes afinidades fisiológicas. Desta forma, o critério de textura pode ser o único viável para distingui-los. As árvores frutíferas oferecem uma estrutura de plantio regular, o que implica uma variedade menos parcial na cobertura, enquanto as árvores decíduas aparecem com um desenvolvimento muito mais heterogêneo. Conseqüentemente, as árvores frutíferas têm uma textura mais fina, facilitando a separação do intérprete das espécies florestais naturais. A textura pode facilitar a discriminação das áreas urbanas em frente aos espaços agrícolas, que sempre terão uma textura mais suave. Entre as áreas urbanas, a textura pode permitir bairros de diferenciação, onde são dominantes as áreas típicas de novas casas de residência e parcelário meticulosa e centros históricos, de frente para polígonos grandes blocos de casas, geralmente associada a bairros periféricos.

➤ **Forma / Tamanho**

A forma de um determinado objeto é um fator determinante para identificá-lo, já que seu contorno nos permite assimilá-lo a um dos padrões que nos são familiares. Como em outros critérios visuais, a forma é mais determinante em imagens de alta resolução espacial, uma vez que permite reconhecer o perfil específico de muitos mais objetos, limitado apenas aos grandes nas imagens de média resolução. A partir do formulário, por exemplo, podemos determinar a presença de certos elementos urbanos: instalações esportivas, shopping centers, aeroportos ou fábricas (Figura 5.9). Também facilita a discriminação entre estradas e linhas ferroviárias (menos sinuosas), ou rios versus canais artificiais, que oferecerão uma aparência mais geométrica. Também permite reconhecer estruturas geológicas bem definidas: vulcões, domos ou linhas de orientação, bem como algumas perturbações atmosféricas (ciclones tropicais).

Em caso de possível dúvida com relação a forma, complementa bastante a identificação da cobertura. Por exemplo, a forma de um campo de tênis e futebol é semelhante, porém diferem no seu tamanho. A utilização deste critério é marcada pela resolução espacial das margens e, nas de maior resolução, podem ser identificados objetos particulares (edifícios singulares), enquanto que, nos de menor detalhe, apenas intervalos de sujeitos podem ser indicados para determinados tipos de superfície (reservatórios, áreas alagadas). Como resultado dessa pior resolução, às vezes não seremos capazes de identificar a forma de um objeto específico, mas de um agrupamento de objetos, servindo no final para identificar um tipo de cobertura. Por exemplo, um pinhal de reflorestamento aparecerá com um perímetro mais geométrico do que um pinhal

natural (ou o resultado de um repovoamento que já foi consolidado e transformado).

➤ **Contexto espacial**

Por localização ou contexto espacial, queremos indicar a localização das capas de interesse em relação aos elementos vizinhos da imagem. Um bom exemplo do uso desse critério de interpretação refere-se, novamente, ao mundo urbano. Um jardim localizado dentro da cidade e consiste de espécies de folha caduca, tende a apresentar um tom, uma cor textura muito semelhante que pode oferecer uma floresta estacional decidual natural. A confusão é devida ao fato de que ambas as tampas são formadas pela mesma espécie ou espécie similar, mesmo com densidades e heterogeneidade muito semelhantes (textura). Nesta situação, não há mais discriminação para separá-los para colocá-los em relação ao meio geográfico: as que aparecem dentro de uma superfície construída mais ou menos densa, eles podem ser considerados como parques urbanos, enquanto que aqueles cercar num contexto de vegetação natural irá ser atribuído às florestas categoria em termos similares ser expressas em conta a separação entre as árvores ciliares e outras espécies de folha caduca, uma vez que o primeiro, como o nome sugere, estão associados com linhas de água.

➤ **Sombras**

A variação das condições de iluminação em um telhado introduz uma notável variedade em sua assinatura espectral característica, de tal forma que o mesmo teto pode oferecer valores de refletividade altamente contrastantes, dependendo se ele está localizado em uma inclinação diretamente iluminada pelo sol ou na sombra. Este aspecto deve ser levado em conta, a fim de evitar apontar as fronteiras entre as coberturas, onde há apenas mudanças nas condições de iluminação.

Agora, no campo da análise visual, a sombra produzida pela iluminação recebida por um determinado objeto é, em muitos casos, um critério fundamental para detectá-lo ou identificá-lo, já que nos dá uma idéia de sua altura e profundidade. Além disso, permite melhorar a interpretação das características geomorfológicas e a textura da imagem, especialmente em áreas florestais.

➤ **Padrão espacial**

Este conceito indica uma organização peculiar dos objetos que formam uma certa cobertura. Este critério é amplamente utilizado em fotografia aérea (por exemplo, para distinguir um olival - em uma plantação regular - de um pasto). Nas imagens de satélite, ela tem sido bastante limitada, como resultado da baixa resolução da maioria dos sensores disponíveis até alguns anos atrás. Com o maior uso de equipamentos de alta resolução, ganhará maior destaque no futuro. No entanto, mesmo em imagens Landsat -ETM + por exemplo, pode permitir-nos identificar algumas capas artificiais, como seria plantações florestais (que podem ocorrer na imagem alternando caminhos / muito particular de vegetação)

ou os campos de golfe, que oferecem infravermelho próximo peculiares pequenos setores alemães de alta refletividade (as ruas e campos de golfe) e meia (a vegetação original do ambiente). Critérios semelhantes podem ser usados para identificar tipos de cobertura do solo, estruturas geológicas ou marinhas.

➤ **Período de aquisição**

As características orbitais de um satélite permitem que as imagens sejam adquiridas periodicamente e em condições similares de observação, facilitando assim qualquer estudo que exija uma dimensão temporal. A análise multitemporal pode ter uma dupla orientação:

- Por um lado, para detectar mudanças entre duas datas de referência, deduzindo-se daí a dinâmica do ambiente natural ou as repercussões da ação humana naquele ambiente, e planejando, assim, as medidas apropriadas para evitar sua deterioração ou garantir sua melhor conservação. Essa abordagem poderia ser nomeada na medida em que o fator tempo é usado para acompanhar a evolução plurianual de uma área em um período relativamente longo.
- Por outro lado, poderíamos falar sobre uma abordagem multi-sazonal, onde a dimensão de tempo seria usada para melhorar a interpretação da imagem, graças à incorporação de informações sobre o ciclo sazonal de cobertura vegetal. Esta abordagem é muito útil para discriminar tipos de culturas e espécies florestais. Anteriormente, o intérprete deve conhecer bem o calendário sazonal dessas espécies, a fim de selecionar os períodos mais adequados para discriminá-los, ao contrário de outros que possam apresentar um comportamento espectral semelhante em algumas épocas do ano. Algo semelhante acontece quando estamos trabalhando apenas com uma imagem: a data escolhida deve ser a mais adequada para separar a capa de interesse. Por exemplo, um mapa de irrigação requer trabalhar com imagens da estação seca, enquanto um estudo geomorfológico tenderá a enfatizar as imagens de navegação, onde os alinhamentos estruturais são mais evidentes devido ao efeito das sombras. Ver figura 19.
- Independentemente do tipo de abordagem a ser seguido, qualquer estudo multitemporal implica um trabalho de correção anterior, a fim de combinar adequadamente as duas ou mais imagens que irão intervir na análise. Deve-se levar em conta que o brilho-cor-textura está relacionado às condições ambientais e de aquisição, portanto não devem ser considerados em sentido absoluto; ou seja, é aconselhável aplicar esses critérios à discriminação de capas em cada imagem e não ao conjunto das diferentes datas envolvidas no projeto.

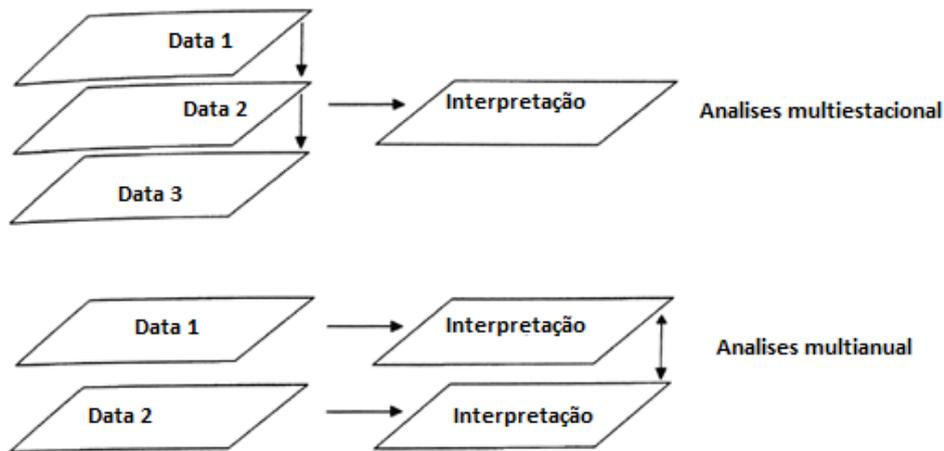


Figura 19. Dimensões temporais na interpretação das imagens (Chuvieco, 2006)

Exercício: com base nos critérios já explicados, tente realizar uma análise multi-sazonal do território das imagens Landsat baixadas. Ver figura 20.

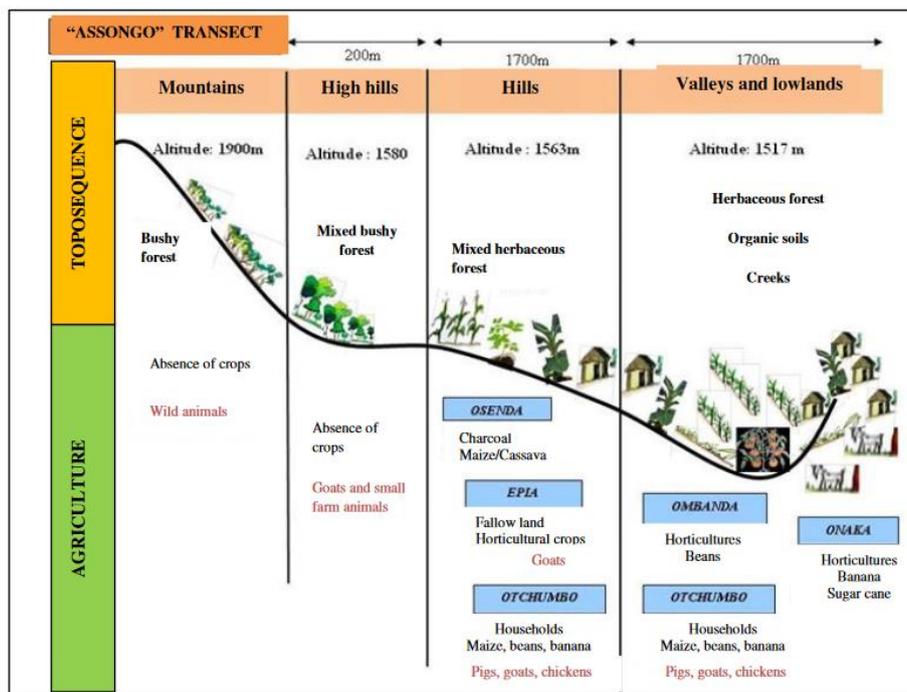


Figura 20. Diagnóstico do sistema agrário terrestre no Huambo em 2012

Exercício 4 - Criação de cartografia temática - Digitalização

Digitalizando, no campo GIS, poderíamos defini-lo como criando nossos dados ou passando informações para a informação geográfica. A primeira coisa que precisamos saber é quais dados queremos representar, já que precisamos criar uma camada ou outra. No nosso caso, vamos digitalizar o contorno da Floresta Mandando, por isso vamos usar polígonos. No caso de querer digitalizar estradas, vamos fazê-lo com dados lineares, e outros elementos podem ser

pontos, como lâmpadas de rua, pontos de esgoto, números de portal. Tudo vai depender da escala e do tema.

1. Mostra a camada OpenLayers do Google Physical (*Web>>OpenLayers plugin>>Google Maps*);
2. Exibe a barra de ferramentas da digitalização;
3. Crie um novo shapefile (*Mundundo_forest.shp*) e defina os atributos de interesse (*Layer>>Create Layer>>New Shapefile Layer*). Ver figura 21.

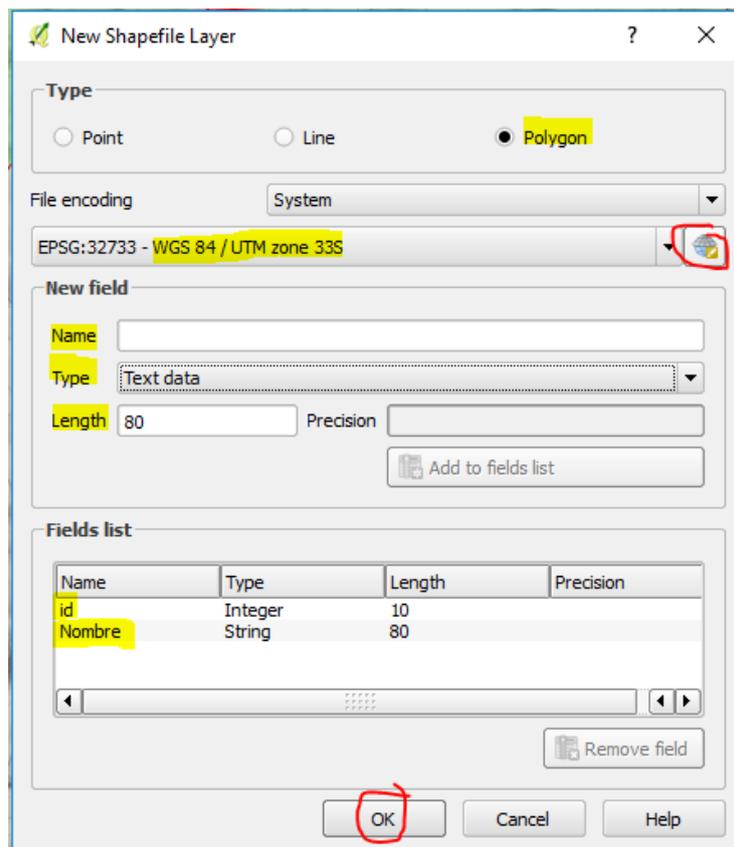


Figura 21. Criação de uma nova camada shapefile

4. Comece a editar o polígono usando a camada física do Google como referência.

O QGIS possui muitas ferramentas para edição de dados, bem como para edição avançada (Figura 22). Neste caso, veremos o mais simples, a criação de polígonos. Uma vez que a ferramenta é seleccionada, nos posicionamos nos elementos que queremos digitalizar e vamos criar o polígono. Uma vez criado, com o botão direito, vamos fechá-lo e veremos que o formulário de inserção do atributo aparece. O formulário de criação de atributos mostrará os atributos que definimos anteriormente e que devemos inserir ao digitalizar. Agora será hora de inseri-los. Escreve-se 1 no ID, um 10 na área (por exemplo) e o nome será deixado à sua escolha. Depois disso, vamos aceitar e vê-se como o primeiro polígono já foi inserido. Apenas deve-se repetir este processo tantas vezes quanto o número de polígonos que se precisa.



Icono	Propósito	Icono	Propósito
	Ediciones actuales		Conmutar edición
	Adicionar Característica: Capturar Punto		Add Feature: Capture Line
	Add Feature: Capture Polygon		Mover objeto espacial
	Agregar Cadena Circular		Add Circular String By Radius
	Herramienta de nodos		Borrar lo seleccionado
	Cortar objetos espaciales		Copiar objetos espaciales
	Pegar objetos espaciales		Guardar cambios de la capa
Icono	Propósito	Icono	Propósito
	Habilitar herramientas de digitalización avanzada		Habilitar Trazado
	Deshacer		Rehacer
	Rotar objeto(s) espacial(es)		Simplificar objeto espacial
	Añadir anillo		Añadir parte
	Rellenar anillo		Borrar anillo
	Borrar parte		Remodelar objetos espaciales
	Desplazar curva		Dividir objetos espaciales
	Dividir partes		Combinar objetos espaciales seleccionados
	Combinar atributos de objetos espaciales seleccionados		Rotar símbolos de puntos

Figura 22. Ferramentas do Quantum Gis

5. Snapping. O snap é a maneira como o QGIS define as intersecções de objectos. Quando digitalizamos uma camada de polígonos, é importante que eles não se sobreponham, porque os dados serão melhores (para cálculos

posteriores, eles ocuparão menos, etc.). Definimos isso no menu Settings > Snapping options, e seleccionamos nossa camada, vértice e segmento, e tolerância, que será a distância do mouse até o vértice mais próximo daquele que será colado. Por exemplo, se definirmos 15 pixels, vemos que quando o ponteiro está desenhando e é menor que 15 pixels de um vértice, ele criará automaticamente o próximo vértice. Desta forma, sabemos que os polígonos nunca se sobrepõem.

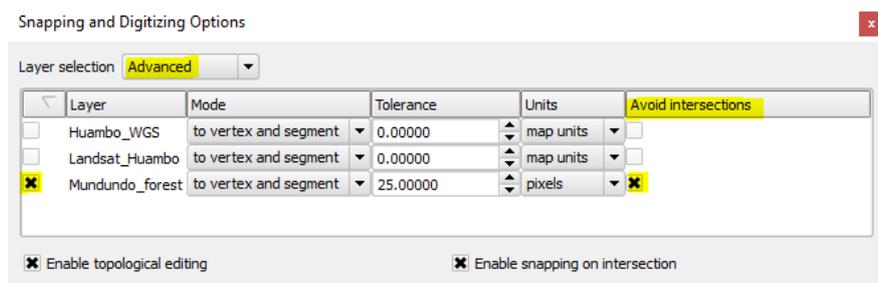


Figura 23. Ferramenta para evitar sobreposição de objectos

6. Também é importante saber que, se não salvarmos a edição, os dados não serão salvos e perderemos nosso trabalho. Eu recomendo salvar de vez em quando e fechar a edição no final.

7. Topologia

Instalar o plugin Topology Checher.

A topologia permite encontrar geometrias correspondentes ou comuns em entidades de pontos, linhas e polígonos, bem como verificar a integridade da informação e a validação da veracidade nela contida. Descrever os relacionamentos entre pontos, linhas e polígonos que representam os objectos espaciais de uma região geográfica. A criação de topologias tem três objectivos fundamentais:

- Implementar condições e restrições do ponto de vista espacial.
- Permite controlar a digitalização das geometrias com base em uma série de condições impostas antecipadamente. Isso garante a qualidade dos dados geométricos.
- Permite racionalizar o armazenamento das geometrias. Todas as geometrias que participam da topologia são decompostas em primitivas geométricas compartilhadas.

As regras mais comuns são:

- Must Be Inside /*deve estar dentro*.
- Must Not Overlap/Não deve se sobrepor.
- Must Not Have Duplicates/não deve ter duplicatas.
- Must Not Have Gaps/Não deve ter pontas soltas

Crie as seguintes regras de topologia e verifique seus polígonos:

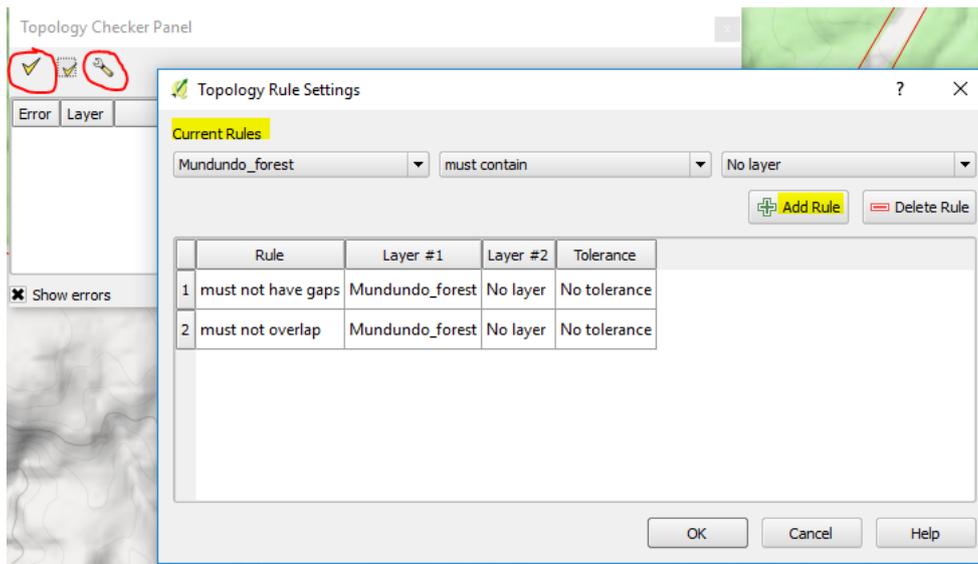


Figura 24. Ferramenta de regra topológica

8. Adicione um campo à tabela de atributos do shapefile criado que calcula a área de cada elemento.

Abra a tabela da atributos (click direito) e pressione o botão Calculadora de campo ou *Field Calculator* . Ver figura 24.

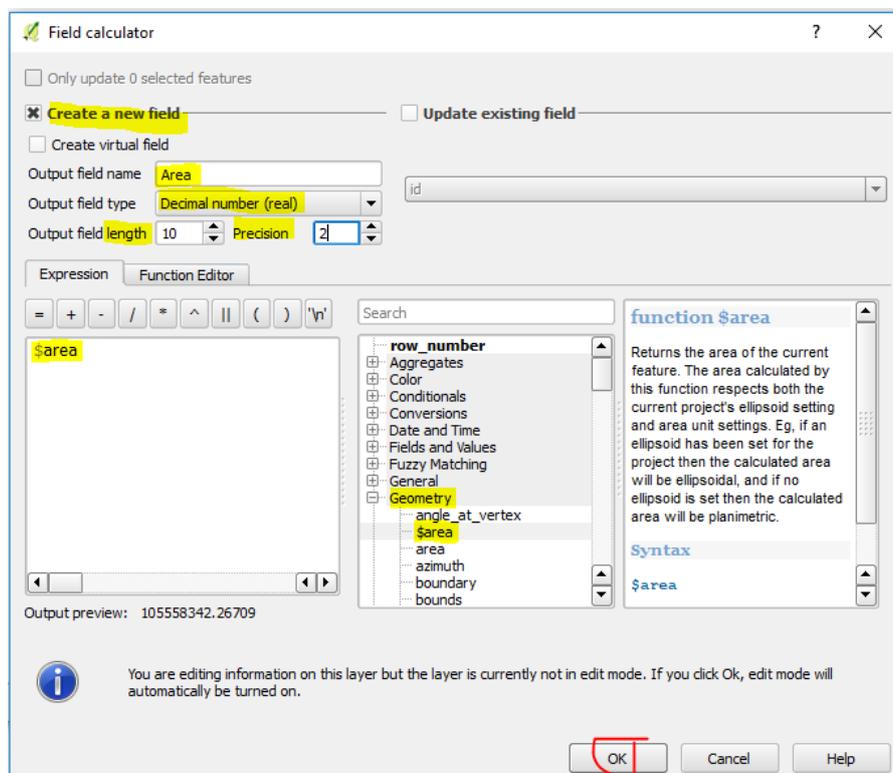


Figura 25. Calculadora de campo

Objectivo 2

O segundo objectivo do projecto é analisar o padrão de crescimento (fenologia) das culturas agrícolas durante um período histórico de 10 anos. Para tanto, utilizaremos séries temporais de imagens NDVI obtidas a partir de dados MODIS. Para cumprir o objectivo 2 do projecto, vamos realizar os seguintes exercícios.

Monitores de acesso a imagens de satélite (Figura 26)

- Para acessar a maioria dos monitores é necessário um registo de usuário, para o caso do EarthData é necessário um prévio registo de usuário:

<https://urs.earthdata.nasa.gov/home>

- NASA-LAADS DAAC

<https://ladsweb.modaps.eosdis.nasa.gov/>

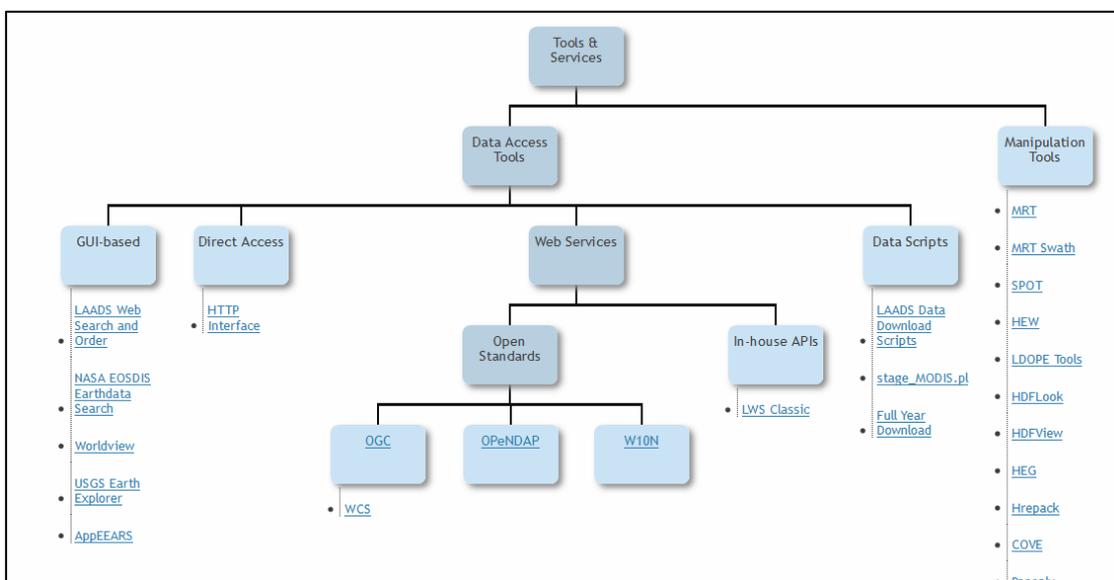


Figura 26. Ferramentas e serviços

- NASA-Earthdata Search
- <https://search.earthdata.nasa.gov/>
- USGS-EarthExplorer
- <https://earthexplorer.usgs.gov/>
- USGS-LP DAAC
- <https://lpdaac.usgs.gov/>
- Productos: LP DAAC – USGS: MODIS Products Table
- https://lpdaac.usgs.gov/dataset_discovery/modis/modis_products_table
- Herramientas de descarga:
 - LP DAAC2Disk download manager:
https://lpdaac.usgs.gov/data_access/daac2disk
 - Global Subsets Tool: MODIS Collection 6 Land Products:
<https://modis.ornl.gov/cgi-bin/MODIS/global/subset.pl>

Produtos MODIS

O sensor MODIS (Espectrorradiômetro de Imagem de Resolução Moderada), como o Landsat, pertence à Agência Espacial da América do Norte (NASA). O MODIS é um instrumento que viaja a bordo dos satélites Terra (EOS a.m.) e Aqua (EOS p.m.). A órbita de Terra ao redor da Terra viaja do norte para o sul cruzando o Equador pela manhã, enquanto o Aqua viaja de sul a norte através do Equador na parte da tarde.

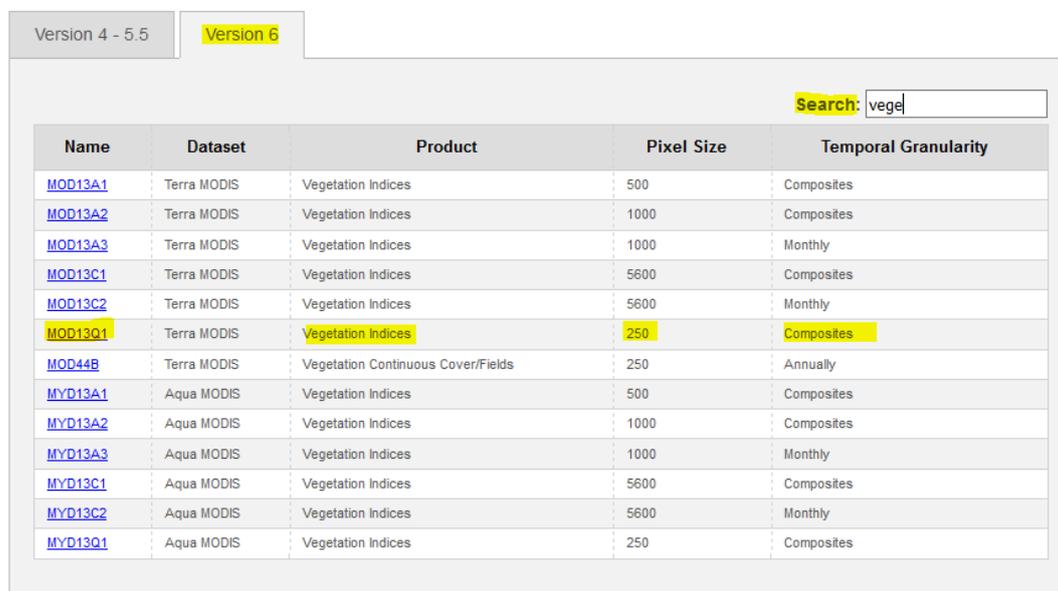
O Terra-MODIS e o Aqua-MODIS cobrem a superfície da Terra a cada 1 ou 2 dias, adquirindo dados em 36 bandas espectrais. Tem uma resolução espacial de 250 m (bandas 1-2), 500 m (bandas 3-7) e 1 km (bandas 8-36). Esses dados nos ajudam a entender a dinâmica global da Terra; comportamento na superfície da Terra, nos oceanos e na atmosfera.

Exercício 5 – Download de dados MODIS

Para o desenvolvimento do Exercício 6, usaremos o produto composto NDVI dos dados MODIS, portanto, neste exercício, vamos baixar previamente os conjuntos de dados a serem utilizados.

1. Encontre o conjunto de dados de interesse na lista de produtos MODIS disponíveis (Figura 27):

https://lpdaac.usgs.gov/dataset_discovery/modis/modis_products_table
Full List



Name	Dataset	Product	Pixel Size	Temporal Granularity
MOD13A1	Terra MODIS	Vegetation Indices	500	Composites
MOD13A2	Terra MODIS	Vegetation Indices	1000	Composites
MOD13A3	Terra MODIS	Vegetation Indices	1000	Monthly
MOD13C1	Terra MODIS	Vegetation Indices	5600	Composites
MOD13C2	Terra MODIS	Vegetation Indices	5600	Monthly
MOD13Q1	Terra MODIS	Vegetation Indices	250	Composites
MOD44B	Terra MODIS	Vegetation Continuous Cover/Fields	250	Annually
MYD13A1	Aqua MODIS	Vegetation Indices	500	Composites
MYD13A2	Aqua MODIS	Vegetation Indices	1000	Composites
MYD13A3	Aqua MODIS	Vegetation Indices	1000	Monthly
MYD13C1	Aqua MODIS	Vegetation Indices	5600	Composites
MYD13C2	Aqua MODIS	Vegetation Indices	5600	Monthly
MYD13Q1	Aqua MODIS	Vegetation Indices	250	Composites

Figura 27. Lista de produtos MODIS disponíveis

1. Veja as informações do produto e acesse o download dos dados (Figura 28):

MOD13Q1: MODIS/Terra Vegetation Indices 16-Day L3 Global 250 m SIN Grid V006

Description

The MOD13Q1 Version 6 product provides a Vegetation Index (VI) value at a per pixel basis. There are two primary vegetation layers. The first is the Normalized Difference Vegetation Index (NDVI) which is referred to as the continuity index to the existing National Oceanic and Atmospheric Administration-Advanced Very High Resolution Radiometer (NOAA-AVHRR) derived NDVI. The second vegetation layer is the Enhanced Vegetation Index (EVI), which has improved sensitivity over high biomass regions.

The grid consists of 4,800 rows and 4,800 columns of 250 meter pixels. The algorithm chooses the best available pixel value from all the acquisitions from the 16 day period. The criteria used is low clouds, low view angle and the highest NDVI/EVI value.

Along with the Vegetation layers and the two QA layers, the HDF file will have MODIS Reflectance bands 1 (Red), 2 (NIR), 3 (Blue), and 7 (MIR), as well as four observation layers. Validation at stage 3 has been achieved for all MODIS MOD/MYD13 vegetation products.

Improvements/Changes from Previous Versions

- The 16-day composite VI is generated using the two 8-day composite Surface Reflectance granules (MxD09A1) in the 16-day period.
- This Surface Reflectance Input is based on the Minimum Blue compositing approach used to generate the 8-day Surface Reflectance product.
- The product format is consistent with the Version 5 product generated using the Level 2 Gridded daily Surface Reflectance product.

Citation

PI Name: Kamel Didan

DOI: 10.5067/MODIS/MOD13Q1.006

[Citing Our Data](#)



Figura 28. Informações do produto

3. Acesse a Ferramenta Global Subsets: MODIS Collection 6 Land Products e selecione a área de Huambo. (<https://modis.ornl.gov/cgi-bin/MODIS/global/subset.pl>).

4. Selecione o produto MOD13Q1 numa janela (acima e abaixo / esquerda e direita) de 100x100 km no Huambo.

5. Selecione as datas de interesse disponíveis e a opção de download: Gere GeoTIFF e Reproject para Geographic Lat / Long.

6. Digite seu endereço de e-mail.

7. Clique em Review Order.

8. Revise o pedido e pressione Create Order.

9. Verifique sua caixa de entrada de spam no email.

10. Abra o email que você recebeu (MODIS MOD13Q1 Col. 6 Subset Order (ORNL DAAC)) e clique no botão Access Order.

11. Faça o download dos dados do GeoTIFFs (tar.gz):

- Produto GeoTIFF Data
- Landcover GeoTIFF Data

12. Descompacte as pastas .rar e observe os arquivos que ela contém. Qual é o arquivo que contém o índice NDVI?

13. Carregue as informações no QGIS e observe os conjuntos de dados.
 14. Abra a imagem (* .tif) contendo os valores calculados de verificação já NDVI para pixels que possuem estudo (Coberturas_punto.shp).
- Nota: você verificará se os valores excedem os valores 0-1 nos quais normalmente são encontrados. Isso ocorre porque a varredura é dimensionada. Você terá que redimensioná-lo com a Calculadora Raster (/ 10000).
15. Abra as imagens (* .tif) correspondentes às bandas NIR e Network e calcule o NDVI você mesmo usando a ferramenta Raster Calculator. Compare os resultados do NDVI que você calculou com os do NDVI da imagem que já foi calculada.

Exercício 6 - Análise estatística de séries temporais de produtos de Detecção Remota (dados raster)

Para a realização deste exercício, usaremos os dados contidos na pasta: NDVI

1. Instale o plug-in de digitalização Rectangles Ovals Digitizing.
2. Crie um novo shapefile de polígono (Polygons_stats.shp).
3. Abra uma imagem de varredura NDVI da série MODIS e coloque-a como uma imagem base a ser digitalizada, colocando a camada Polygons_stats.shp em cima dela e, por sua vez, acima da camada Coberturas_punto.shp da seguinte forma:



4. Com a ajuda da ferramenta de Rectangles Ovals Digitizing, crie quadrados correspondentes à camada Covers_punto.shp do tamanho das imagens MODIS NDVI. Você deve atribuir aos novos polígonos os mesmos atributos (id e Tipo) que possuem os pontos da camada Coberturas_punto.shp.
- Nota: os quadrados devem ser menores que o tamanho real do pixel de um produto MODIS. Ver figura 29.

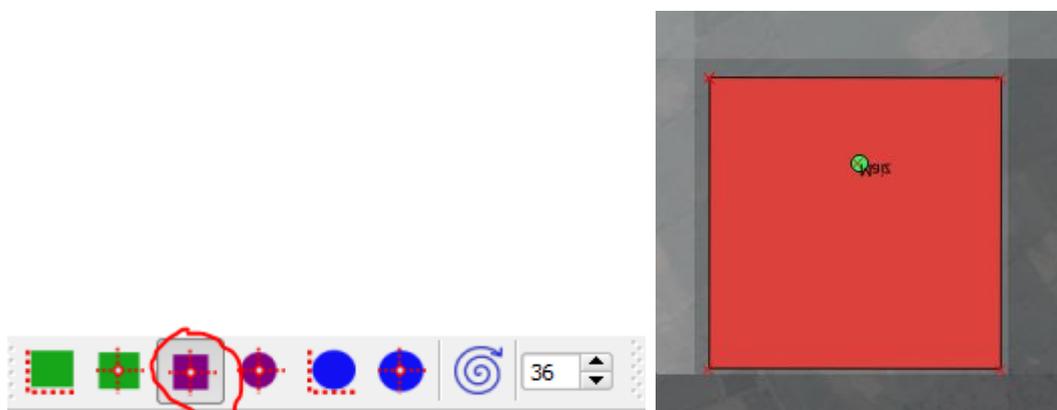


Figura 29. Tamanho real do pixel de um producto MODIS

5. Encontre a ferramenta Estatísticas de varredura para polígonos no Processing ToolBox e abra-a no modo Lote (Executar como um processo em lote).

Nota: Nomeação de Grade = Nome da Grade; Quantis = 0



6. Abra a tabela de atributos do shapefile gerado (Statistics.shp) e observe os resultados. Ver figura 30.

7. Copie os resultados para uma planilha do Excel e analise os resultados por tipo de corte e mês para toda a série de dados.

id	Tipo	20070101200	20070115200	20070129200	20070212200
1	Bosque 1	0.7619317174	0.7746729851	0.7997923493	0.8023445010
2	Papa	0.5475675464	0.5609228611	0.5578886270	0.5458210707
3	Maiz 1	0.5916740298	0.5897832513	0.5259648561	0.6171384454
4	Maiz 2	0.7163966894	0.6771147847	0.7033001184	0.6803724170
5	Bosque2	0.7562431693	0.7594868541	0.7406938076	0.7382265925
6	Suelo desnudo	0.4849013090	0.5108165145	0.5362127423	0.5367335081
7	Ciudad	0.4826892912	0.5031167269	0.5296099186	0.5255121589
8	Matorral	0.6031650901	0.6175699830	0.6019878983	0.6272680163

Figura 30. Estatística da camada raster

Perguntas:

- Que diferenças fenológicas você observa entre as culturas?
- Qual é a variabilidade inter-anual e intra-anual de cada uma das culturas?
- Que diferenças fenológicas existem entre as culturas anuais e a vegetação perene (floresta)?
- Você considera as imagens MODIS adequadas para realizar este tipo de análise nesta área de estudo?

Exercício: Crie tabelas dinâmicas que permitem analisar os resultados de maneira simples. Ver figuras 31a, 31b, 31c, 31d, 31e e 31f.

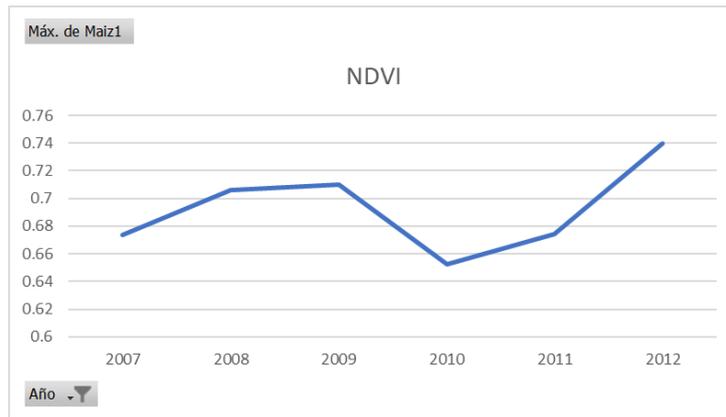


Figura 31a. NDVI - variabilidad inter-anual do milho

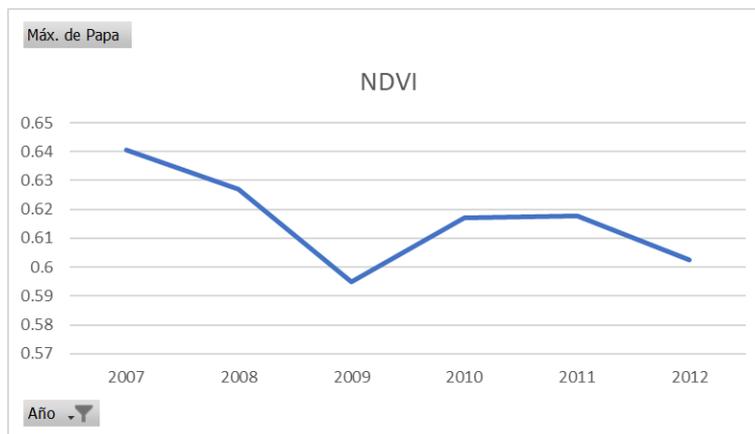


Figura 31b. NDVI - variabilidad inter-anual do mamão

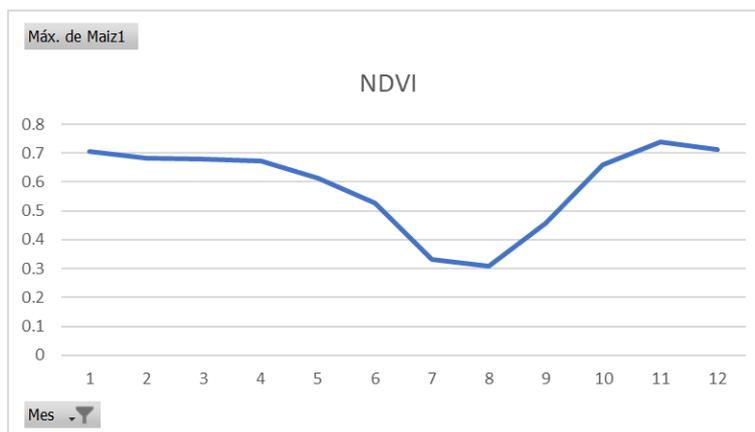


Figura 31c. NDVI - variabilidad inter-anual do milho

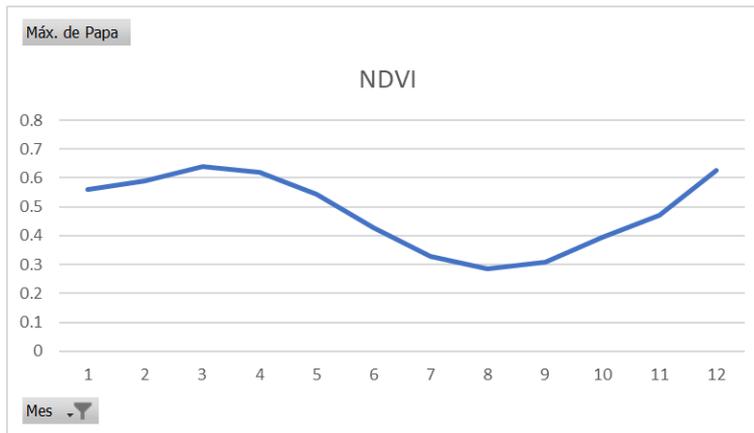


Figura 31d. NDVI - variabilidade inter-anual do mamão

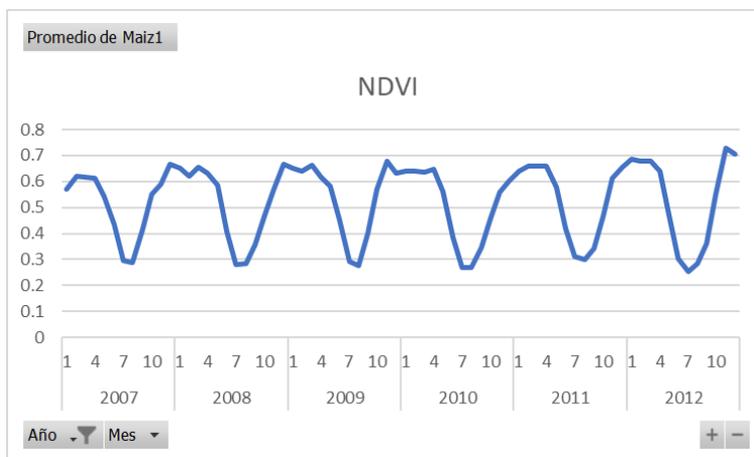


Figura 31e. NDVI - variabilidade inter-anual do milho

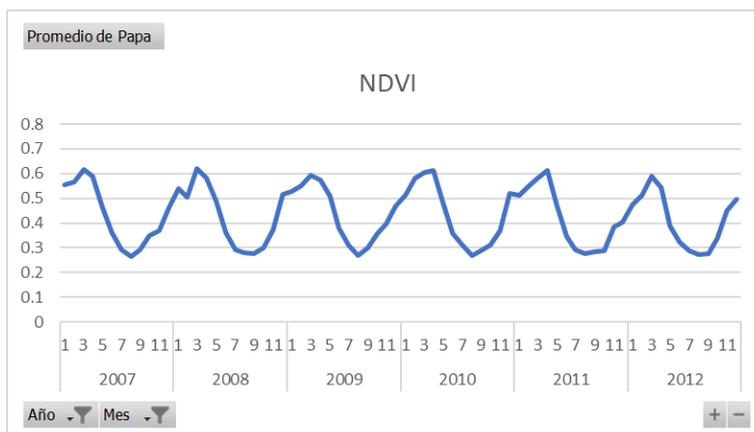


Figura 31f. NDVI - variabilidade inter-anual do mamão

Exercício 7 - Google Earth Engine app – Climate Engine

Use o aplicativo Climate Engine para executar uma análise multi-anual e multi-sazonal semelhante à anterior.

Climate Engine: <http://climateengine.org/>

Módulo 4 - Classificação supervisionada de usos da terra

Cobertura do solo

Este termo abrange uma ampla gama de aplicações. Por cobertura da terra entendemos o tipo de ocupação existente nela, seja esta vegetação natural, culturas agrícolas ou espaços urbanos. Este tipo de cartografia é fundamental no planejamento do território, pois é necessário conhecer a dedicação atual da terra para propor qualquer melhoria.

Morfologia urbana

Dada a grande complexidade espacial do fenômeno urbano, onde convivem atividades variadas em um pequeno espaço, a aplicação do detecção remota para essas áreas é recente e ainda limitada, embora tenha sido grandemente beneficiado pelo lançamento de os sensores de alta resolução espacial.

A análise de imagem para inferir características de morfologia urbana requer o uso de critérios mistos, integrando brilho, cor, textura e localização. Uma vez que pode ser deduzida a primeira densidade de construção, porque essas áreas que possuem menos influência do traçado viário proporcionar um brilho mais escuro. Além disso, a cor indica se a área tem ou espaços verdes, quer contínua (manchas uniformes) ou descontínuas (sob a corante vermelho polvilhado entre o próprio azul do edifício em caso de uma cor convencional composição falso) . Quanto à textura, indica o grau de mistura de um setor específico. A partir desses dois critérios podem ser testados para delimitação dos setores morfológicas dentro de uma área urbana.

Exercício 8 - Classificação supervisionada

Neste exercício, vamos realizar uma Classificação supervisionada de uma imagem Sentinel-2 de Janeiro para tentar localizar as culturas de batata / feijão na área de estudo.

1. Use o Navegador de Observação da Terra para procurar uma imagem do Sentinel2 da área de estudo correspondente ao mês de Janeiro e com uma cobertura de nuvem inferior a 20%:

<https://apps.sentinel-hub.com/eo-browser/>

2. Baixe a imagem de 2017-01-13 (Figura 32):

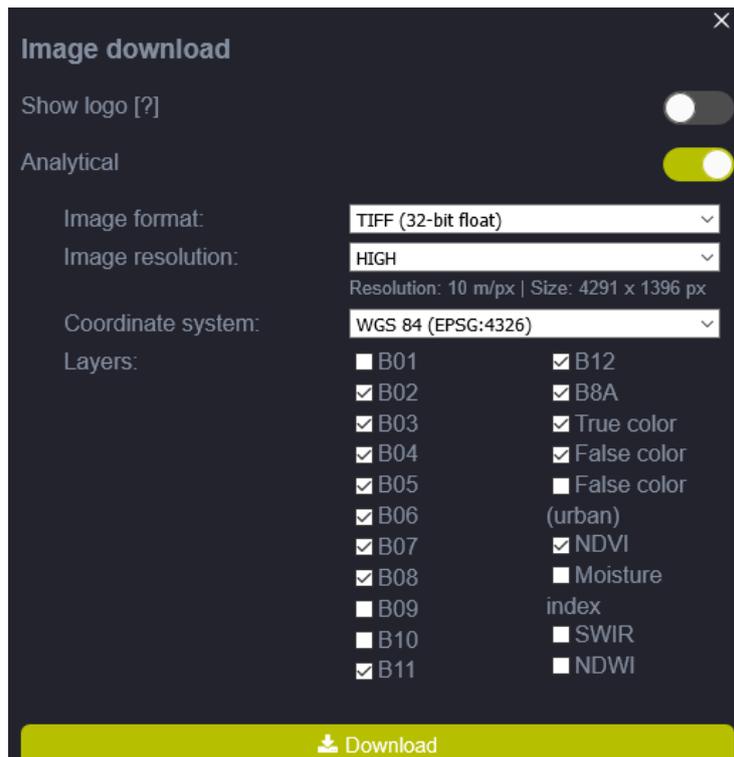


Figura 32. Ilustração de download de imagem sentinel

3. Carregue a imagem no QGIS com o módulo SCP e configure as configurações de comprimento de onda rápido correspondentes.
4. Adicione a tela da combinação de falsa cor para Sentinel2 (7-3-2), (3-7-10).



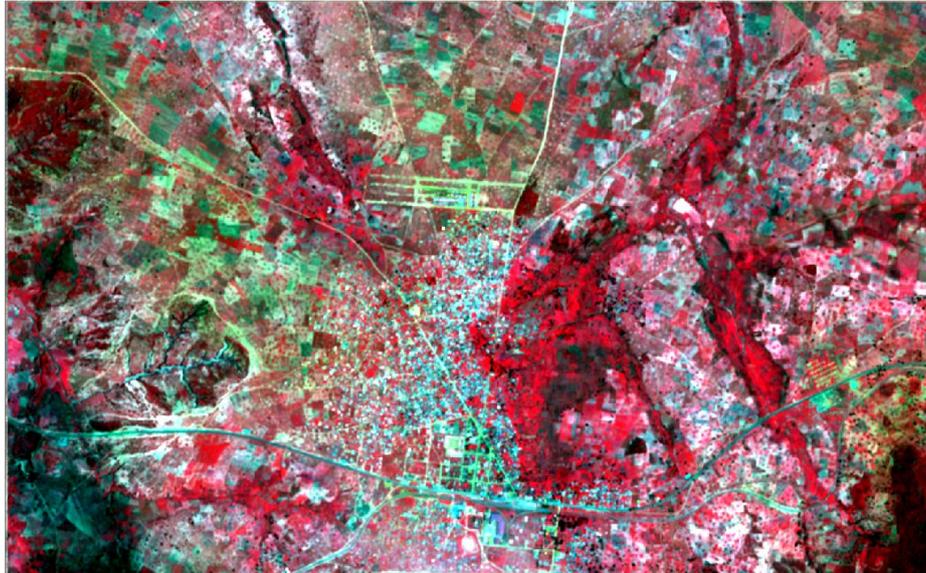
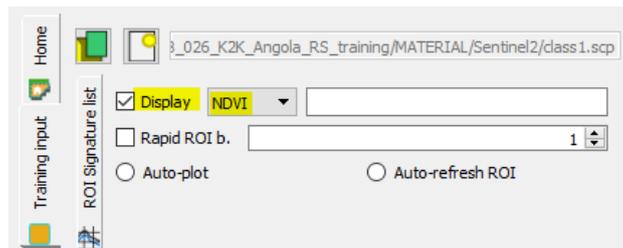


Figura 33. Combinações de cor 7-3-2 e 3-7-10

5. Verifique a opção Display NDVI values para mostrar os valores NDVI da imagem e ajudá-lo a seleccionar e classificar uma certa cobertura:



6. Comece a seleccionar o ROI (Região de Interesse) correspondente a cada cobertura (Figura 34).



	S	Type	MC ID	C ID	C Info	Color
1	<input checked="" type="checkbox"/>	B	1	1	Maiz	Green
2	<input checked="" type="checkbox"/>	B	2	2	Carretera	Black
3	<input checked="" type="checkbox"/>	B	3	3	Suelo desnudo	Orange
4	<input checked="" type="checkbox"/>	B	2	4	Edificio	Red
5	<input checked="" type="checkbox"/>	B	2	5	Viviendas	Red
6	<input checked="" type="checkbox"/>	B	1	6	Arboles	Green
7	<input checked="" type="checkbox"/>	B	1	7	Arboles2	Teal
8	<input checked="" type="checkbox"/>	B	1	8	Sin cultivar	Yellow
9	<input checked="" type="checkbox"/>	B	3	9	Suelo desnudo2	Orange
10	<input checked="" type="checkbox"/>	B	1	10	Pasto	Yellow
11	<input checked="" type="checkbox"/>	B	1	11	Sin cultivar/Arboles	Yellow
12	<input checked="" type="checkbox"/>	B	3	12	Suelo desnudo3	Orange
13	<input checked="" type="checkbox"/>	B	1	13	Maiz2	Green
14	<input checked="" type="checkbox"/>	B	1	14	Maiz3	Green
15	<input checked="" type="checkbox"/>	B	1	15	Matorral	Brown

	MC ID	MC Info	Color
1	1	Vegetation	Green
2	2	Built-up	Red
3	3	Bare	

Figura 34. Criação das regiões de interesse

7. Analise o espectro das assinaturas espectrais das ROIs que você seleccionou para verificar se elas correspondem adequadamente à sua classificação. Ver figura 35.

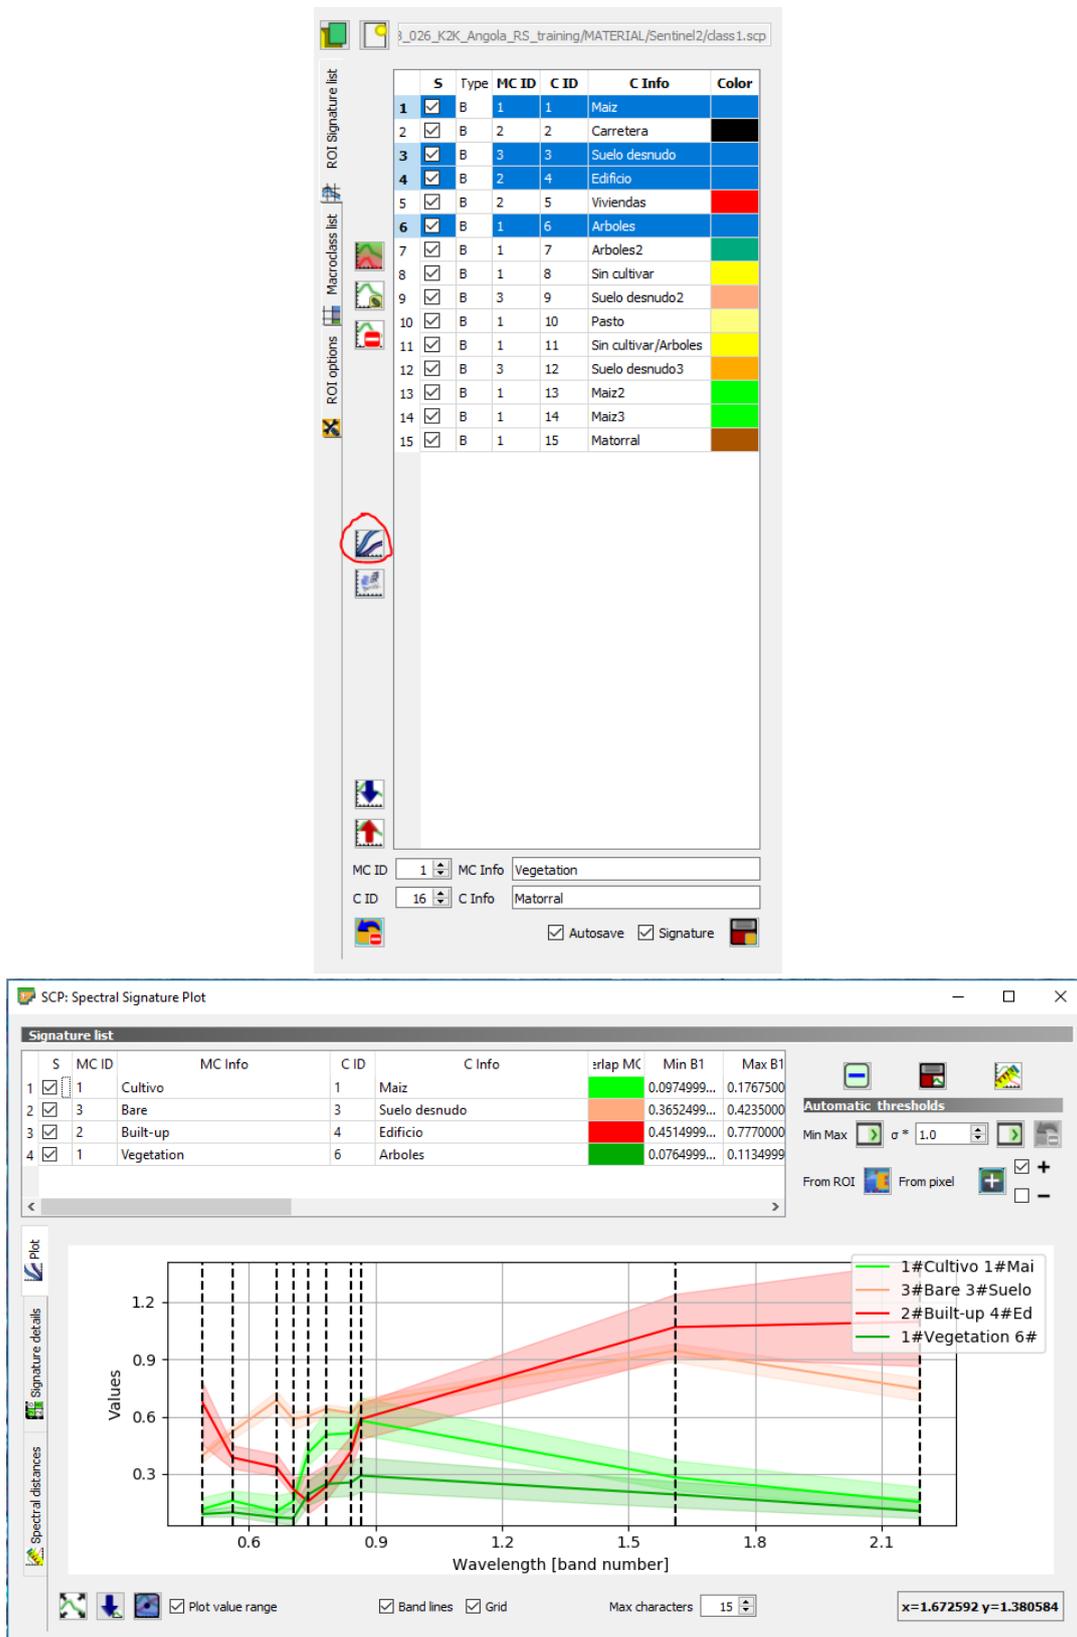


Figura 35. Assinatura espectrais das regiões de interesse

8. Realize a classificação automática da imagem com a opção ID de Classe (ID C) e o algoritmo de classificação Máxima Verossimilhança (Figura 36).

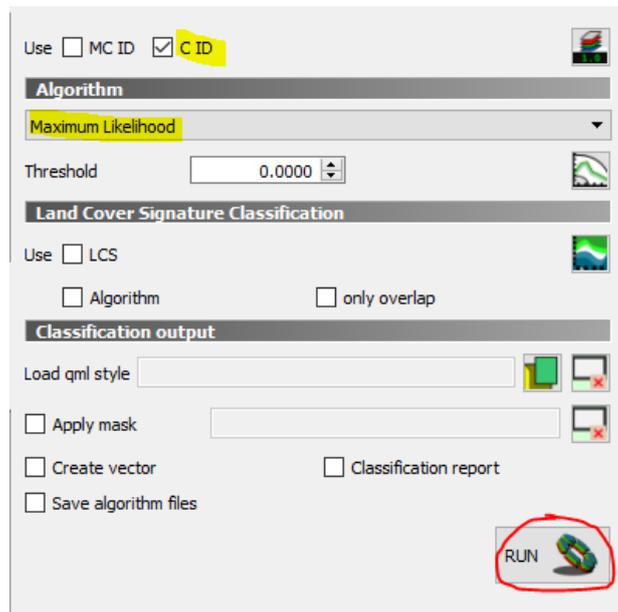


Figura 36. Algoritmo de classificação Máxima Verossimilhança

9. Observe os resultados finais conforme a figura 37.

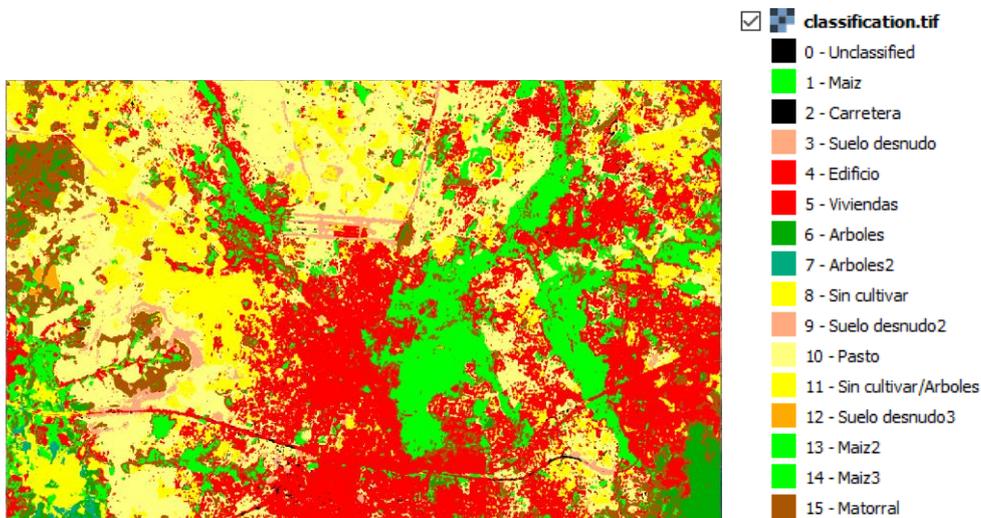


Figura 37. Classificação final

Você pode seguir este tutorial no YouTube para fazer isso sozinho:

<https://www.youtube.com/watch?v=FcETq8OWM0k&t=215s>

Módulo 5 - Análise multitemporal da mudança do uso da terra

Análise multitemporal da mudança do uso da terra

Em geral, os estudos de mudança do uso da terra florestal avaliam a velocidade do desmatamento / reflorestamento, determinam sua extensão geográfica e compreendem as causas sociais e econômicas das mudanças, nas escalas global, regional e local. A análise multitemporal permite detectar mudanças entre diferentes datas de referência, inferindo a evolução do ambiente natural ou as repercussões da ação humana nesse ambiente.

Os ecossistemas terrestres sofreram grandes transformações, a maioria devido à conversão da cobertura da terra e à degradação e intensificação do uso da terra. A atividade humana tem sido o grande transformador da paisagem nos últimos 300 anos. Por exemplo, as florestas e florestas da América Latina para o ano 2000 foram reduzidas em mais de 50% de sua cobertura original; em particular, países como o Brasil, o México e a Costa Rica foram o centro das maiores alterações.

A análise da mudança do uso da terra no PTP MM pode ser usada para reorientar os programas de manejo e a restauração de ecossistemas degradados da área protegida. Por outro lado, os resultados podem mostrar o grau de fragmentação da área, referido por atributos (número de fragmentos, tamanho, forma, abundância, riqueza e grau de isolamento dos fragmentos).

Objetivo 3

O terceiro objectivo do projecto é analisar as mudanças no uso de terras agrícolas e florestais na província do Huambo durante um período histórico.

Exercício 9 - Comparação de produtos de classificação de solos

Neste exercício, compararemos diferentes conjuntos de dados existentes com informação de uso e classificação de cobertura de solo (Tabela 2). Faça o download de cada um dos produtos e compare-os.

Tabela 2. Comparação de diferentes productos com informação de uso e classificação de cobertura de solo

Fonte	Satélite	Resolução espacial	Resolução temporal	Domínio espacial	Link
ESA – Globcover	MERIS	300	2009	Global	http://due.esrin.esa.int/page_globcover.php
ESA-Copernicus Land Cover	Proba-V	100 m	2015	África	https://land.copernicus.eu/global/products/lc

ESA -Climate Change Institute	MERIS	300 m	1992-2015	Global	http://maps.elie.ucl.ac.be/CCI/viewer/index.php
ESA -Climate Change Institute	Sentinel-2	20 m	2016	África	http://2016africalandcover20m.esrin.esa.int/
NASA-MODIS (MCD12Q1)	Terra-MODIS	500 m	Anual (2001-2016)	Global	https://lpdaac.usgs.gov/dataset_discovery/modis/modis_products_table/mcd12q1_v006

➤ ESA – Globcover 2009 (Tabela 3):

Tabela 3. Legenda dos produtos do Globcover 2009

Value	GlobCover global legend	
11	Post-flooding or irrigated croplands	
14	Rainfed croplands	
20	Mosaic Cropland (50-70%) / Vegetation (grassland, shrubland, forest) (20-50%)	
30	Mosaic Vegetation (grassland, shrubland, forest) (50-70%) / Cropland (20-50%)	
40	Closed to open (>15%) broadleaved evergreen and/or semi-deciduous forest (>5m)	
50	Closed (>40%) broadleaved deciduous forest (>5m)	
60	Open (15-40%) broadleaved deciduous forest (>5m)	
70	Closed (>40%) needleleaved evergreen forest (>5m)	
90	Open (15-40%) needleleaved deciduous or evergreen forest (>5m)	
100	Closed to open (>15%) mixed broadleaved and needleleaved forest (>5m)	
110	Mosaic Forest/Shrubland (50-70%) / Grassland (20-50%)	
120	Mosaic Grassland (50-70%) / Forest/Shrubland (20-50%)	
130	Closed to open (>15%) shrubland (<5m)	
140	Closed to open (>15%) grassland	
150	Sparse (>15%) vegetation (woody vegetation, shrubs, grassland)	
160	Closed (>40%) broadleaved forest regularly flooded - Fresh water	
170	Closed (>40%) broadleaved semi-deciduous and/or evergreen forest regularly flooded - Saline water	
180	Closed to open (>15%) vegetation (grassland, shrubland, woody vegetation) on regularly flooded or waterlogged soil - Fresh, brackish or saline water	
190	Artificial surfaces and associated areas (urban areas >50%)	
200	Bare areas	
210	Water bodies	
220	Permanent snow and ice	

➤ ESA-Copernicus Land Cover 2015 (Figura 38).

no ProbaV 100m data available (0)	herbaceous vegetation (30)
evergreen needleleaf closed forest (111)	cropland (40)
evergreen broadleaf closed forest (112)	urban (50)
deciduous needleleaf closed forest (113)	bare / sparse vegetation (60)
deciduous broadleaf closed forest (114)	snow & ice (70)
evergreen needleleaf open forest (121)	permanent water bodies (80)
evergreen broadleaf open forest (122)	temporary water bodies (81)
deciduous needleleaf open forest (123)	herbaceous wetland (90)
deciduous broadleaf open forest (124)	open sea (200)
shrubs (20)	continental land mass not classified (255)

Figura 38. Legenda dos produtos ESA-Copernicus Land Cover 2015

➤ ESA -Climate Change Institute (1992-2015). Ver figura 39.

Value	Label	Color
0	No Data	
10	Cropland, rainfed	
11	Herbaceous cover	
12	Tree or shrub cover	
20	Cropland, irrigated or post-flooding	
30	Mosaic cropland (>50%) / natural vegetation (tree, shrub, herbaceous cover) (<50%)	
40	Mosaic natural vegetation (tree, shrub, herbaceous cover) (>50%) / cropland (<50%)	
50	Tree cover, broadleaved, evergreen, closed to open (>15%)	
60	Tree cover, broadleaved, deciduous, closed to open (>15%)	
61	Tree cover, broadleaved, deciduous, closed (>40%)	
62	Tree cover, broadleaved, deciduous, open (15-40%)	
70	Tree cover, needleleaved, evergreen, closed to open (>15%)	
71	Tree cover, needleleaved, evergreen, closed (>40%)	
72	Tree cover, needleleaved, evergreen, open (15-40%)	
80	Tree cover, needleleaved, deciduous, closed to open (>15%)	
81	Tree cover, needleleaved, deciduous, closed (>40%)	
82	Tree cover, needleleaved, deciduous, open (15-40%)	
90	Tree cover, mixed leaf type (broadleaved and needleleaved)	
100	Mosaic tree and shrub (>50%) / herbaceous cover (<50%)	
110	Mosaic herbaceous cover (>50%) / tree and shrub (<50%)	
120	Shrubland	
121	Evergreen shrubland	
122	Deciduous shrubland	
130	Grassland	
140	Lichens and mosses	
150	Sparse vegetation (tree, shrub, herbaceous cover) (<15%)	
151	Sparse tree (<15%)	
152	Sparse shrub (<15%)	
153	Sparse herbaceous cover (<15%)	
160	Tree cover, flooded, fresh or brakish water	
170	Tree cover, flooded, saline water	
180	Shrub or herbaceous cover, flooded, fresh/saline/brakish water	
190	Urban areas	
200	Bare areas	
201	Consolidated bare areas	
202	Unconsolidated bare areas	
210	Water bodies	
220	Permanent snow and ice	

Figura 39. Legenda dos produtos da ESA -Climate Change Institute (1992-2015)

- ESA -Climate Change Institute 2016 (Figura 40).



Figura 40. Legenda dos produtos da ESA -Climate Change Institute 2016

- MCD12Q1 (2001-2016). Ver figura 41.



Figura 41. Legenda dos produtos da MCD12Q1 (2001-2016)

MCD12Q1:

1. Procure na tabela de produtos MODIS o produto Land Cover (MCD12Q1) e observe suas características, incluindo as informações das camadas que contém e o manual do usuário.
2. Acesse o monitor EarthData para fazer o download.
3. Seleccione a área que deseja (Figura 42) baixar com um quadrado e baixe os produtos disponíveis de 2002 e 2015.

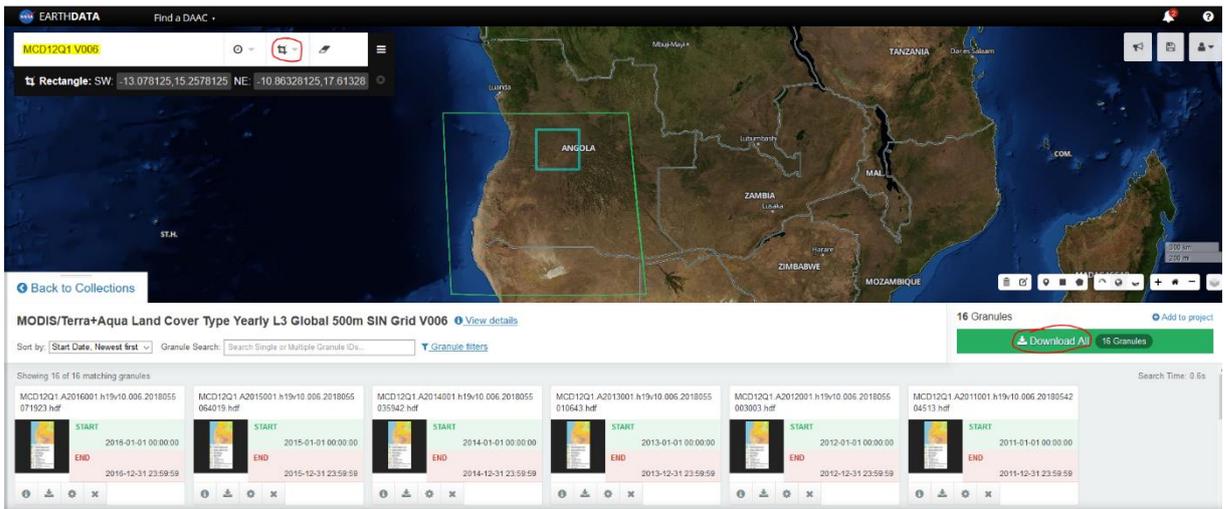


Figura 42. Selecção da área de interesse

Configure as seguintes opções de download (Figura 43):

Direct Download
 Download data as-is now from your browser or access script.

Stage for Delivery
 Submit a request for data to be staged for delivery. You will get an email when they are ready.

Customize Product
 Select custom service options to be performed. (e.g. subsetting, etc.)

Email Address:

Include Metadata and Processing History

Reformat Output (Optional)

Output File Format:

Spatial Subsetting (Optional)

Enter bounding box

North:
 West:
 East:
 South:

Projection Options

Re-projection Options:

Advanced Settings (Optional)

Resample Dimension:

Percent:

Interpolation Method:

Used to calculate data of resampled and reprojected pixels.

Access these granules again with different options

Figura 43. Opções de configuração de download:

5. Quando receberes o e-mail de download, faça o download do produto Type1:

For Input Granule: 2292707760

[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Prop1_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Prop1_Assessment_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Prop2_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Prop2_Assessment_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Prop3_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Prop3_Assessment_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Type1_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Type2_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Type3_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Type4_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LC_Type5_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_LW_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)
[MCD12Q1_A2003001_h19v10_006_2018054094815_MCD12Q1_QC_817a3b47.tif](#) (<1 MB, SCIENCE, image/tiff)

6. Abra a imagem de 2015 e aplique o estilo à camada (MODIS_LandCover_style.qml) para sua correcta visualização. Compare a classificação com a realidade e avalie o resultado.

Exercício 10 - Análise multitemporal das mudanças no uso da terra com a ferramenta MOLUSCE-QGIS

Neste exercício, realizaremos uma análise multi-temporal dos diferentes revestimentos de pisos com a ferramenta de análise de mudanças MOLUSCE. Para este exercício, usaremos o conjunto de dados do ESA -Climate Change Institute 1992-2015 (por ano: 1992,2002,2012,2015). MOLUSCE, é o acrônimo de Modules for Land Use Change Simulations - Módulos para Simulações de Mudança na superfície da Terra, um plugin para o software QGIS, projectado para analisar a dinâmica do estado de cobertura de um território. O plugin incorpora algoritmos bem conhecidos, que podem ser usados em mudanças de análise / cobertura de uso da terra, análise urbana e aplicações florestais. MOLUSCE é adequado para:

- Analisar o uso ou superfície da terra e revelar as mudanças entre diferentes períodos de tempo;
- Modelar o uso / cobertura do solo e suas potenciais transições, bem como áreas de risco de desmatamento;
- Simular usos futuros da terra ou mudanças na cobertura florestal.

Como requisitos, MOLUSCE precisa:

- Mapas dos estados inicial e final do território. Estas são imagens raster classificadas (por exemplo, 1 = floresta, 2 = agrícola, 3 = urbano, etc.). A extensão requer pelo menos dois mapas desse tipo: um para o estado inicial (Start_date) e o segundo para o estado final (Start_date + N). No entanto, para avaliar a qualidade do modelo de previsão construído, recomenda-se usar uma terceira imagem (Start_date + 2N), com a qual o valor previsto será comparado. Aqui, o número N é a duração da previsão, que é medida dependendo da tarefa em dias, semanas, meses, anos, etc.

• Mapas de factores que afectam a mudança de território. O usuário constrói hipóteses sobre quais factores podem afectar as mudanças observadas e fornece um mapa da intensidade desses factores. Por exemplo, se um usuário está trabalhando no problema da degradação florestal, esses factores podem ser: um mapa do solo (cada tipo de solo é codificado pelo seu número), um mapa de distâncias para as estradas (pixels do mapa) eles contêm um número, distância menor do ponto associado a esse pixel à estrada), um mapa de densidade populacional, etc. Ver figura 44.

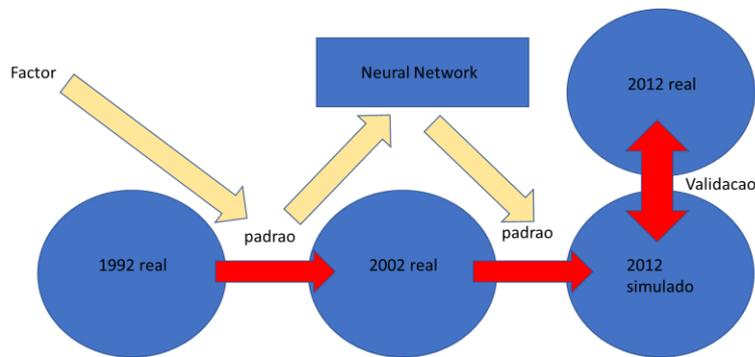


Figura 44. Factores relacionados ao mapeamento de florestas degradadas

1. Baixe as imagens classificadas por ano: 1992,2002,2012,2015:

[ftp://geo10.elie.ucl.ac.be/v207/](http://geo10.elie.ucl.ac.be/v207/).

2. Recorte as imagens com o shape da província do Huambo (*Raster>>Extraction>>Clipper*).

3. Mudar o Sistema de referência de Coordenadas das imagens baixadas: de WGS84 (EPSG:4326) a WGS/UTM 33S (EPSG:32733) (*Raster>>Projections>>Warp*). Ver figura 45.

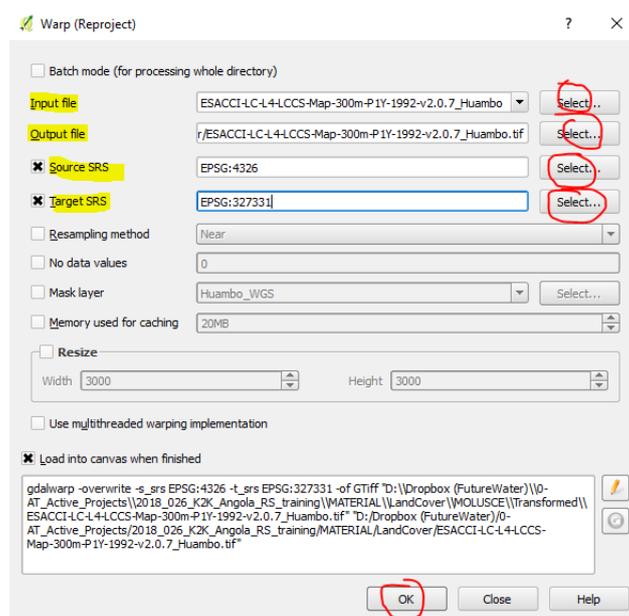


Figura 45. Corte e reprojeção de imagem

4. Instale o plugin MOLUSCE QGIS.

5. Vamos realizar uma análise temporal das mudanças para o período 1992-2002. Carregue as camadas e os estilos correspondentes.

6. A análise temporal das mudanças requer uma variável explicativa da mudança produzida na cobertura da terra. Para isso, primeiro geraremos um factor de mudança reclassificando a imagem classificada de 2015 da seguinte maneira: dando mais valor às classes, que actualmente são verdadeiramente culturas e menos valor aquelas que não são, interpolando o valor das classes intermediárias, dado seu potencial de ser transformado em terra agrícola. O factor explica o grau de facilidade de uma cobertura para ser convertida em uma cultura. Use a legenda das classes do mapa para executar os critérios de classificação. Ver figura 46.

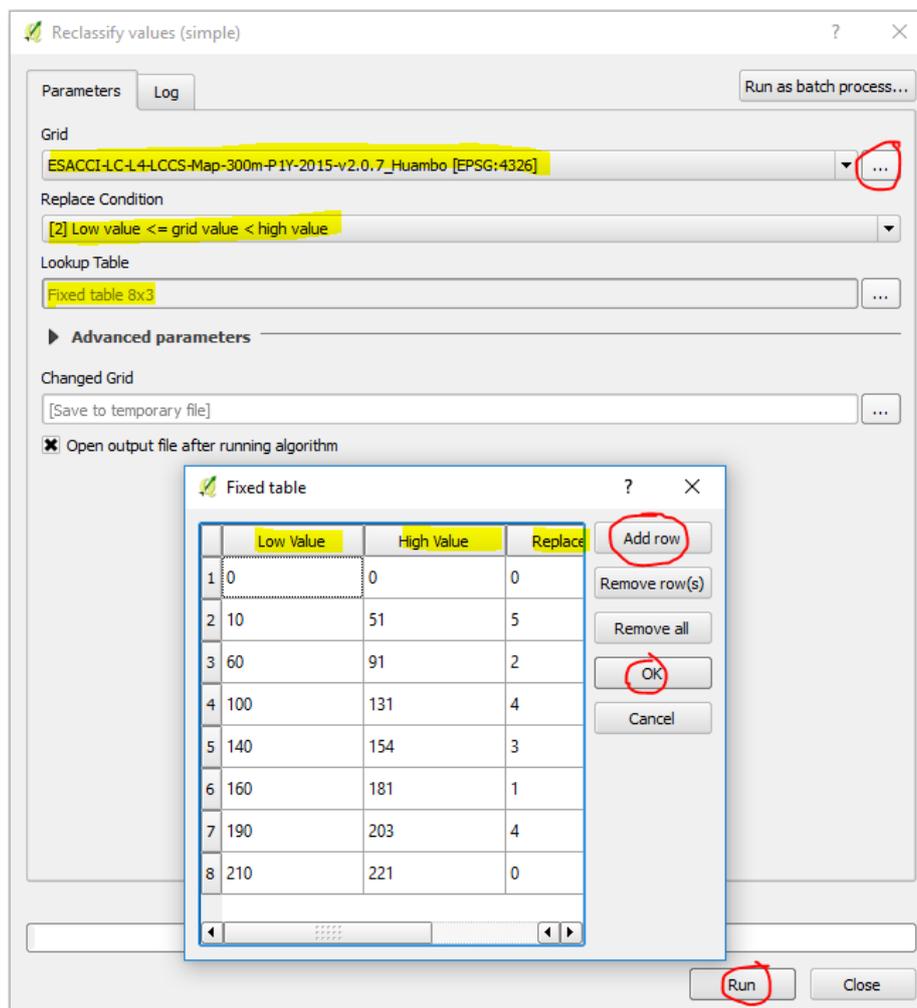


Figura 46. Reclassificar de valores de um raster

7. Adicione as imagens inicial e final (dentro da pasta Transformada: reprojectada), bem como o factor de mudança e verifique sua geometria. Ver figura 47.

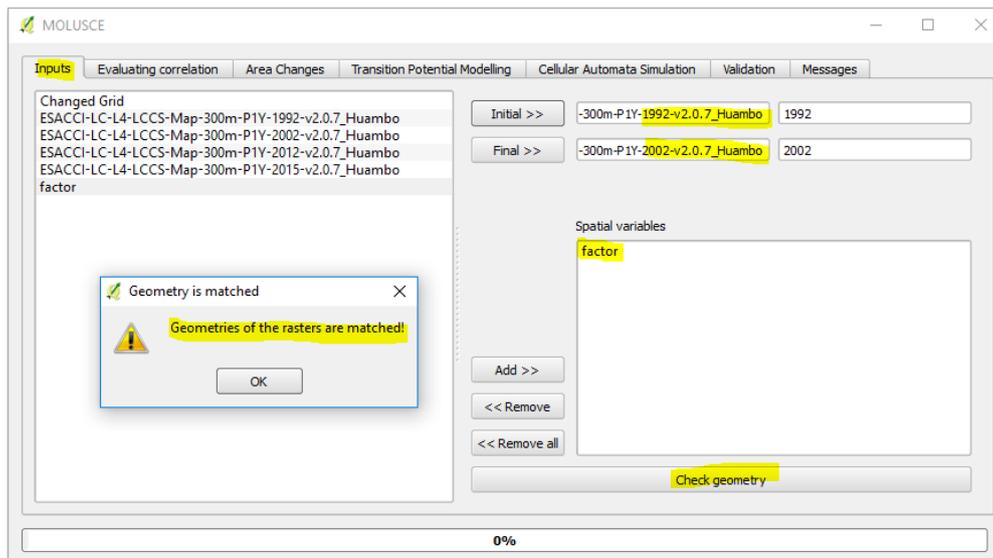


Figura 47. Verificação de geometria

Analise as áreas de interesse (Figura 48).

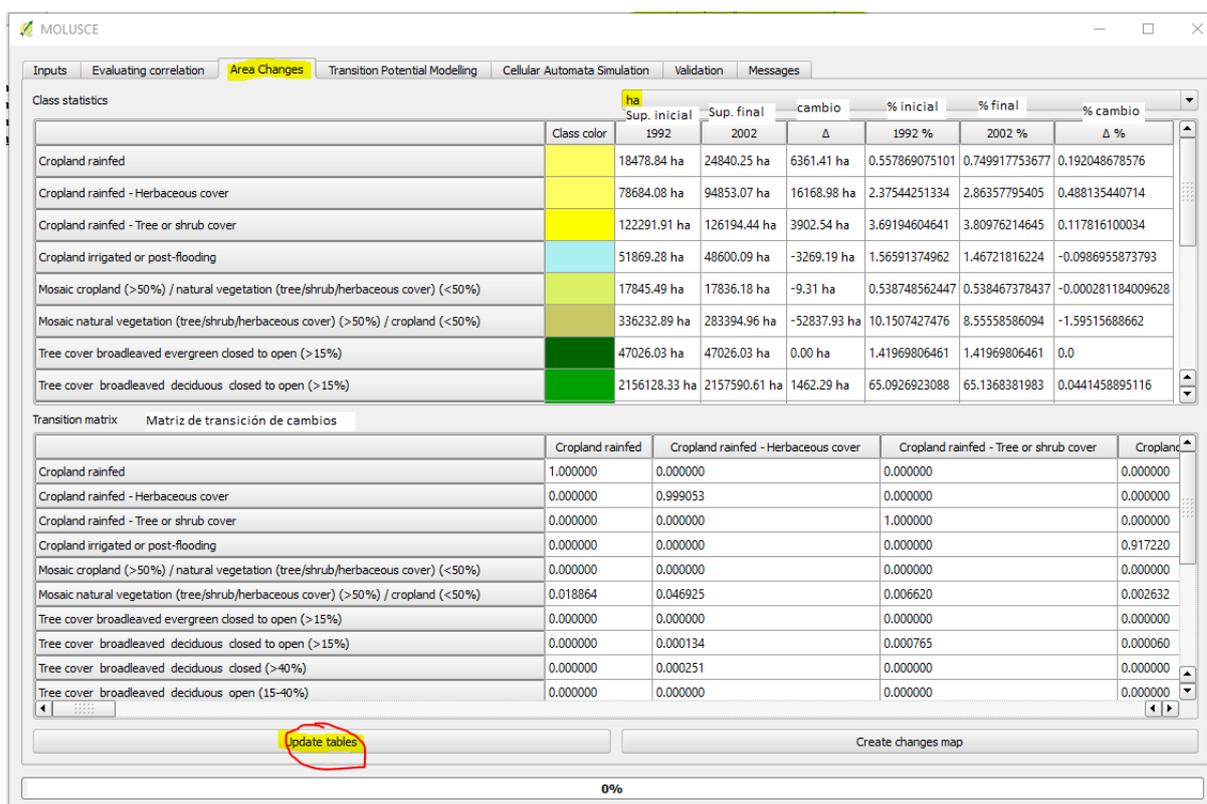


Figura 48. Área de interesse

Pergunta: Quais coberturas sofreram as mudanças mais positivas / negativas? Em que outras capas elas foram transformadas?

9. Crie o mapa de mudança: (Mudança de área >> Criar mapa de mudanças). Pergunta: Em quais áreas houve grandes mudanças de coberturas para terras

agrícolas? Nota: para saber quais alterações correspondem aos valores do mapa de alterações, acesse sua legenda, nas propriedades da camada.

10. Crie uma transição potencial e treine a curva neural (figura 49):

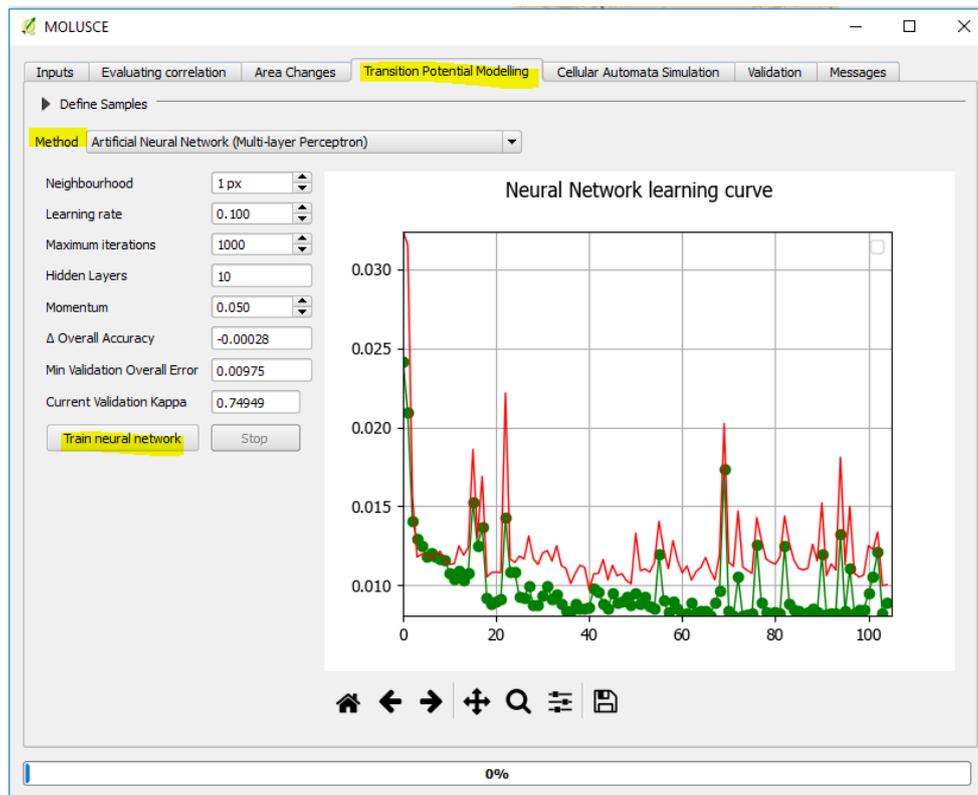


Figura 49. Curva neural

11. Gere a simulação para 2012 (Figura 50):

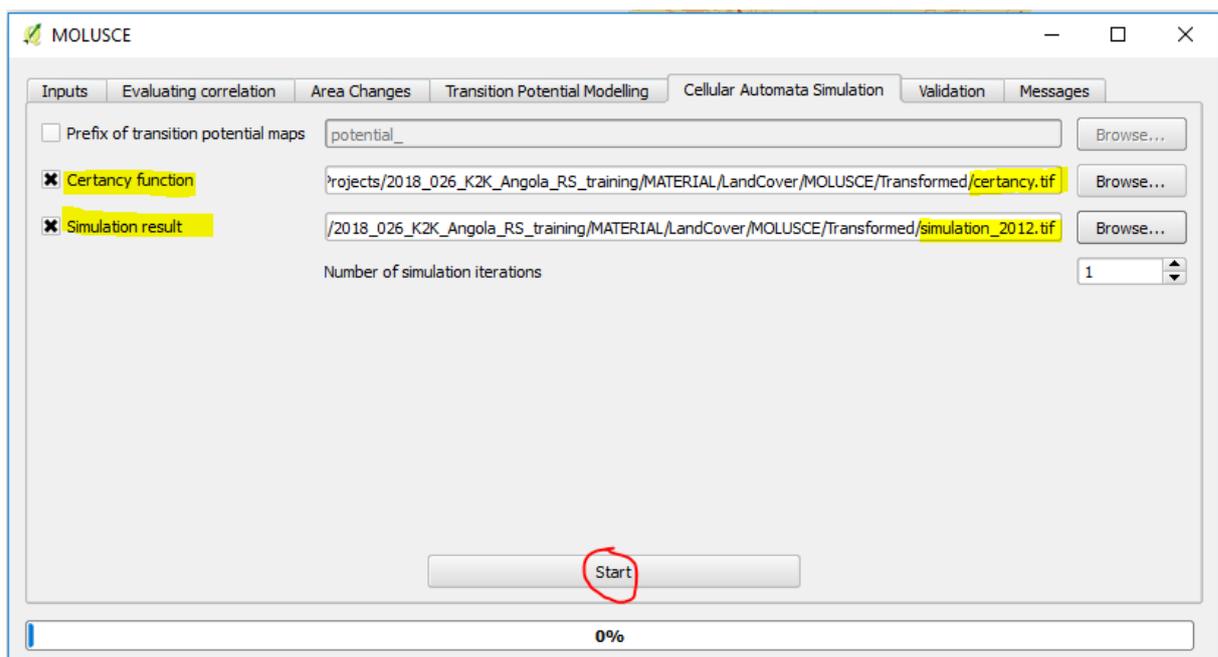


Figura 50. Geração e simulação de resultados

12. Analise o mapa simulado de 2012 e valide os resultados com o mapa real de 2012 (dentro da pasta Transformed: reprojected). Ver figura 51.



Figura 51. Validação de resultados

O coeficiente Kappa é uma medida estatística de avaliação da classificação resultante de uma imagem. Um coeficiente Kappa igual a 1 significa uma concordância perfeita e um valor próximo de zero significa que o acordo não é melhor do que o esperado por acaso. Ver tabela 4.

Tabela 4. Tabela de significado estatístico do coeficiente Kappa (Rwanga and Ndambuki, 2017)

Table 6. Rating criteria of Kappa statistics.

S.No	Kappa statistics	Strength of agreement
1	<0.00	Poor
2	0.00 - 0.20	Slight
3	0.21 - 0.40	Fair
4	0.41 - 0.60	Moderate
5	0.61 - 0.80	Substantial
6	0.81 - 1.00	Almost perfect

Exercício 11 - Análise multitemporal de áreas florestais

Neste exercício, realizaremos uma análise multitemporal dos diferentes revestimentos de superfície com o aplicativo Global Forest Watch do Google Earth Engine do trabalho de Hansen *et al.* (2013). Ver figura 52.

<https://www.globalforestwatch.org/>

<https://www.globalforestwatch.org/map>

<http://data.globalforestwatch.org/items/63f9425c45404c36a23495ed7bef1314>

https://earthenginepartners.appspot.com/science-2013-global-forest/download_v1.4.html

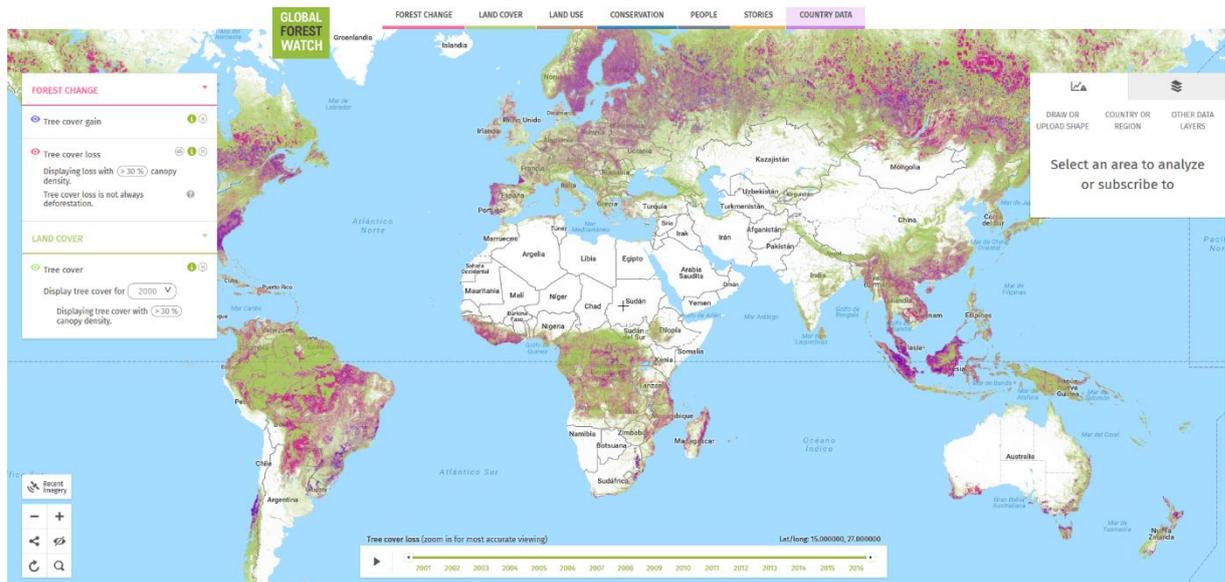


Figura 52. Interface da visor Global Forest Watch (Hansen *et al.*, 2013)

Projecto de Reforço de Capacidades em Detecção Remota para o Desenvolvimento Agrícola em Angola “K2K”

Programa de formação de formadores

Manual em Português “Teledetecção e serviços agrários”

Introdução aos Sistemas de Informação Geográfica e Detecção Remota para a Gestão Agrícola Através do Uso do Software Quantum Gis – Parte 3

Módulo 3 – Projecto de consultoria: técnicas de teledetecção para avaliação de idoneidade agrícola.

Módulo 4 – Classificação controlada de usos do solo.

Módulo 5 – Análise multi-temporal de alterações de usos do solo



ISBN 978-989532640-2



Netherlands Enterprise Agency



FutureWater

Research and consultancy for a sustainable future of our water resources

LABSIGDER