



**PEDRO RESENDE SILVA**

**USO DE REDES NEURAS ARTIFICIAIS E  
OBJETOS GEOGRÁFICOS NA  
CLASSIFICAÇÃO DIGITAL DE IMAGENS DE  
SENSORIAMENTO REMOTO**

**LAVRAS – MG**

**2012**

**PEDRO RESENDE SILVA**

**USO DE REDES NEURAS ARTIFICIAIS E OBJETOS GEOGRÁFICOS  
NA CLASSIFICAÇÃO DIGITAL DE IMAGENS DE SENSORIAMENTO  
REMOTO**

Dissertação apresentada à  
Universidade Federal de Lavras,  
como parte das exigências do  
programa de Pós-Graduação em  
Ciências Florestais, área de  
concentração em Manejo Florestal,  
para a obtenção do título de Mestre.

Orientador

Dr. Luiz Marcelo Tavares de Carvalho

Coorientador

Fausto Weimar Acerbi Júnior

**LAVRAS – MG**

**2012**

**Ficha Catalográfica Elaborada pela Divisão de Processos Técnicos da  
Biblioteca da UFLA**

Silva, Pedro Resende.

Uso de redes neurais artificiais e objetos geográficos na  
classificação digital de imagens de sensoriamento remoto / Pedro  
Resende Silva. – Lavras : UFLA, 2012.

106 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2012.

Orientador: Luis Marcelo Tavares de Carvalho.

Bibliografia.

1. Segmentação de imagens. 2. Séries temporais. 3. Uso do solo.  
4. Análise baseada em objetos. I. Universidade Federal de Lavras.  
II. Título.

CDD – 526.982

**PEDRO RESENDE SILVA**

**USO DE REDES NEURAIAS ARTIFICIAIS E OBJETOS GEOGRÁFICOS  
NA CLASSIFICAÇÃO DIGITAL DE IMAGENS DE SENSORIAMENTO  
REMOTO**

Dissertação apresentada a  
Universidade Federal de Lavras, como  
parte das exigências do programa de  
Pós-Graduação em Ciências Florestais,  
área de concentração em Manejo  
Florestal, para a obtenção do título de  
Mestre.

APROVADA em 16 de março de 2012.

Dr. Luis Marcelo Tavares de Carvalho      UFLA

Dr. Wilian Soares Lacerda      UFLA

Dr. Lucas Rezende Gomide      UFLA

Dr. Luiz Marcelo Tavares de Carvalho

Orientador

Fausto Weimar Acerbi Júnior

Coorientador

**LAVRAS – MG**

**2012**

## AGRADECIMENTOS

Ao professor Fausto, amigo de todas as horas, por acreditar na condução deste trabalho, pelo apoio, incentivo, motivação e pelas horas vividas e aproveitadas nos momentos de descontração.

Ao Passarinho, professor e grande amigo, pelas ideias e discussões que muito fizeram e contribuíram para este trabalho.

Ao LEMAF e ao professor José Roberto Scolforo pelas oportunidades e apoio técnico oferecido.

Ao professor Lucas Gomide pelas ideias trocadas e trabalhos conduzidos.

Aos amigos do laboratório de geoprocessamento Mário, Marcelo, Sérgio, Estopa, e todos os demais, pela força.

À Clara, pelos momentos e histórias vividas ao longo destes anos, pela paciência, carinho e motivação.

Aos meus pais pelo apoio incondicional em todas as horas e etapas, boas ou difíceis, de minha vida. A você, Maria Eduarda, por alegrar os meus dias e simplesmente existir em minha vida.

A todos aqueles que de alguma forma contribuíram para a conclusão deste trabalho, seja na forma de orientação, ideias, atenção e companheirismo os mais sinceros agradecimentos.

## RESUMO

O presente trabalho teve como objetivo o desenvolvimento de uma metodologia para a criação de um mapa de uso e cobertura do solo na região norte do estado de Minas Gerais, onde, além de atividades agropecuárias, predominam vegetações nativas de cerrado, florestas estacionais decíduais e extensas áreas de vereda. Utilizando parcelas inventariadas e imagens dos sensores Rapideye, Landsat TM e MODIS, foram traçados três objetivos específicos, que são: testar o uso de técnicas de segmentação de imagens para uma classificação baseada em objetos contemplando nessa técnica informações espectrais, espaciais e temporais; testar a viabilidade da classificação de imagens de alta resolução espacial, como as do sensor Rapideye, combinadas a séries temporais Landsat-TM e a classificação dos dados por meio de Redes Neurais Artificiais. Através da segmentação de uma série temporal de imagens MODIS e parcelas inventariadas no Mapeamento e Inventário da Flora Nativa e dos Reflorestamentos de Minas Gerais foram extraídas as assinaturas temporais das principais fisionomias presentes na região, de onde foi possível observar os melhores períodos do ano a serem representados no processo. Devido à incompatibilidade de resoluções espaciais entre imagens Rapideye e MODIS, uma nova série Landsat TM foi tomada nestes períodos. Os objetos criados na segmentação das imagens Rapideye, juntamente com as imagens Landsat TM, foram classificados por dez diferentes arquiteturas de redes *Mult Layer Perceptron*, com uma, duas e três camadas de neurônios, variando ainda o número dos mesmos em cada uma. Os resultados mostraram que metodologia atende aos propósitos do estudo e as características das fisionomias presentes na região. Com excelentes valores de acurácia para as classes nativas, o estudo mostra a importância da adequação da base de dados em trabalhos de classificação e da importância de séries temporais no mapeamento de florestas estacionais.

## **ABSTRACT**

The aim of this study was to develop a methodology for mapping land cover in northern Minas Gerais, Brazil. In addition to agricultural fields, the landscape in the region is dominated by cerrado (Brazilian savanna), deciduous forests, and extensive areas of palm swamp vegetation (veredas). Using forest inventory data, RapidEye, Landsat TM, and MODIS images, three specific objectives were defined: (1) to evaluate the use of image segmentation techniques for an object-based classification considering the spectral, spatial and temporal domains; (2) to evaluate the feasibility of using temporal information derived from a Landsat-TM time series for classification of high spatial resolution objects segmented from RapidEye images; (3) to evaluate Artificial Neural Networks classification algorithms. We used a MODIS time series and inventory plots to guide the construction of a Landsat TM time series that best represent the seasonality of different vegetation classes. Image objects and the respective attributes derived from the RapidEye images, as well as from the Landsat TM time series were input to ten different Multi Layer Perceptron network architectures. The results showed that the methodology meets the purposes of the study, being able to describe the landscape patterns of the region. With excellent accuracy for native classes, the study shows the importance of having a structured database for classification as well as the importance of having time series of images for mapping seasonal forests.

## LISTA DE FIGURAS

Figura 1 Princípio do sensoriamento remoto .....	16
Figura 2 Espectro eletromagnético.....	17
Figura 3 Representação das bandas espectrais de uma imagem de sensoriamento remoto.....	18
Figura 4 Assinaturas espectrais de diferentes alvos na superfície.....	19
Figura 5 Representação do registro de imagens.....	22
Figura 6 Relação entre os objetos em análise e resolução espacial.....	28
Figura 7 Pista do aeroporto de Lavras vista por imagens de diferentes resoluções espaciais.....	29
Figura 8 Atributos disponíveis no software de segmentação eCognition Developer 8.0 .....	31
Figura 9 Diagrama com a composição da homogeneidade no algoritmo <i>Multiresolution segmentation</i> .....	33
Figura 10 Estrutura de um neurônio biológico.....	35
Figura 11 Modelo de um neurônio artificial .....	36
Figura 12 Funções de ativação utilizadas em um neurônio artificial .....	38
Figura 13 Perceptron de Rosemblat .....	40
Figura 14 Arquiteturas de RNA mais comumente empregadas.....	42
Figura 15 Gráfico de validação cruzada com excesso de treinamento.....	46
Figura 16 Fluxograma da metodologia proposta.....	47
Figura 17 Área de estudo.....	48
Figura 18 Cenas Landsat TM utilizadas.....	51
Figura 19 Representação de uma mesma área vista por diferentes resoluções espaciais.....	52
Figura 20 Assinatura temporal das fisionomias e seleção das imagens Landsat TM .....	53
Figura 21 Mosaicos das imagens Rapideye .....	55
Figura 22 Mosaico Rapideye, imagens Landsat e imagem base para registro.....	56



Figura 23 Resultado dos pré-processamentos. Onde: (a) Mosaico Rapideye e (b) subset da imagem NDVI Landsat .....	57
Figura 24 Parâmetros do algoritmo <i>Multiresolution Segmentation</i> .....	58
Figura 25 Parte dos dados normalizados utilizados como amostras. ....	62
Figura 26 Trecho de uma rede MLP com duas camadas ocultas antes do treinamento .....	63
Figura 27 Parte do arquivo de amostras de treinamento .....	65
Figura 28 Conversão de uma rede para a linguagem C.....	66
Figura 29 Segmentação obtida em uma área altamente fragmentada .....	69
Figura 30 Amostras de validação do mapa .....	71
Figura 31 Classificação dos mosaicos obtida pela rede 7 .....	74
Figura 32 Nível de detalhamento do mapeamento. a) área de cerrado e eucalipto; b) veredas e áreas de inundação; c) estradas em meio a um cerrado em regeneração.....	75

## LISTA DE TABELAS

Tabela 1 Resolução radiométrica dos sensores.....	20
Tabela 2 Resolução temporal de diferentes sensores .....	21
Tabela 3 Cenas Rapideye utilizadas.....	49
Tabela 4 Características das imagens Rapideye.....	50
Tabela 5 Características das imagens Landsat TM .....	50
Tabela 6 Datas das imagens Landsat TM utilizadas .....	54
Tabela 7 Parâmetros testados na segmentação das imagens .....	59
Tabela 8 Número de amostras.....	60
Tabela 9 Arquiteturas testadas com diferentes números de neurônios e camadas ocultas.....	64
Tabela 10 Resultados dos treinamentos .....	69
Tabela 11 Número de amostras utilizadas na validação do mapa.....	72
Tabela 12 Valores de precisão do mapeamento para cada rede .....	73
Tabela 13 Proporção encontrada entre as classes no mapa da rede 7 .....	76

## SUMÁRIO

1	INTRODUÇÃO .....	12
2	REVISÃO DE LITERATURA.....	15
2.1	Sensoriamento remoto .....	15
2.1.1	Radiação eletromagnética.....	16
2.1.2	Conceitos de resoluções.....	19
2.1.3	Pré-processamento de imagens .....	21
2.1.4	Sensoriamento remoto da vegetação e índices espectrais .....	23
2.2	Classificação digital de imagens e mapas emáticos .....	25
2.2.1	Métodos de classificação .....	25
2.3	Segmentação de imagens.....	28
2.3.1	Algoritmo <i>Multiresolution Segmentation</i> .....	32
2.4	Redes Neurais Artificiais (RNA) .....	34
2.4.1	Neurônio artificial .....	39
2.4.2	Arquitetura .....	41
2.4.3	Treinamento.....	43
2.4.3.1	Algoritmo <i>Backpropagation</i> .....	44
3	MATERIAL E MÉTODOS.....	47
3.1	Área de estudo .....	48
3.2	Base de dados.....	49
3.2.1	Imagens Rapideye.....	49
3.2.2	Imagens Landsat.....	50
3.2.2.1	Seleção das imagens.....	51
3.3	Pré-processamento .....	54
3.3.1	Mosaicos das imagens Rapideye.....	54
3.3.2	Registro das imagens Landsat.....	55

3.3.3	NDVI e Subset das imagens Landsat TM.....	56
3.4	Segmentação de imagens.....	57
3.5	Classificação.....	59
3.5.1	Amostragem.....	60
3.5.2	Atributos utilizados .....	60
3.5.3	Redes Neurais Artificiais (RNA).....	61
3.5.4	Medidas de precisão .....	66
4	RESULTADOS E DISCUSSÃO .....	68
4.1	Segmentação .....	68
4.2	Treinamento das Redes Neurais.....	69
4.3	Classificação dos dados .....	70
5	CONCLUSÕES .....	79
	REFERÊNCIAS .....	81
	APÊNDICE .....	87

## 1 INTRODUÇÃO

Devido às constantes modificações do uso e da ocupação do solo, o trabalho de identificar e monitorar as fisionomias florestais existentes em cada região é de extrema importância para o planejamento e ações políticas, na construção de um Zoneamento Ecológico Econômico, para a manutenção da flora, fauna e dos recursos hídricos existentes.

Os mapas de uso e cobertura do solo são vitais para monitorar, entender e prever os efeitos da complexa interação homem-natureza em escala local, regional e global (CLARK et al., 2010). No entanto, a tarefa de conhecer e mapear essas áreas através de levantamentos de campo é um processo extremamente lento e demasiadamente caro.

Com o avanço da tecnologia e dos sensores orbitais, novas técnicas foram surgindo para suprir essa demanda e o uso de imagens de sensores remotos é uma alternativa cada vez mais utilizada. Devido à capacidade e ao potencial para observações sistemáticas em várias escalas, a tecnologia de sensoriamento remoto pode fornecer dados ao longo de décadas anteriores (XIE; SHA; YU, 2008) e o seu uso vem sendo empregado com grande êxito em mapeamentos através de técnicas de classificação de imagens. Contudo, a aquisição de dados em escala espacial e temporal adequadas é a chave para alcançar a precisão necessária para o mapeamento (CARVALHO et al., 2004).

Há algum tempo, uma série de pesquisas vem sendo realizadas sobre a integração de dados de diversas fontes e em múltiplas datas a fim de melhor representar a dinâmica e as classes que compõem a paisagem. Na classificação da cobertura do solo, o uso de dados de múltiplas fontes é desejável a fim de extrair o máximo possível de informações da área (GISLASON; BENEDIKTSSON; SVEINSSON, 2006). O uso de modelos digitais de elevação e inclinação por Bradter et al. (2011), de dados de levantamentos florísticos e

séries temporais por Hüttich et al. (2009, 2011) e de dados de diferentes sensores ópticos por Gibbes et al. (2010) ressaltam esta hipótese.

Silveira et al. (2008) demonstram em seu estudo a importância da utilização de séries temporais de imagens NDVI e EVI na caracterização do padrão sazonal do cerrado e de florestas estacionais decíduais no norte do estado de Minas Gerais. Hüttich et al. (2009), usando algoritmos de classificação *Random Forests* (BREIMAN, 2001) e imagens NDVI MODIS confirmam os valores de alta precisão no mapeamento de savanas na Namíbia, ressaltando ao final do trabalho que devido à estrutura altamente heterogênea das savanas, o uso de imagens do satélite Rapideye parece promissor para o mapeamento preciso dessa vegetação.

O norte do estado de Minas Gerais possui hoje remanescentes de mata Atlântica e as maiores áreas de cobertura por floresta nativa do estado. Composta principalmente por florestas estacionais decíduais e fragmentos de cerrado (savana brasileira), essa área hoje sofre forte pressão de atividades agropecuárias e silviculturais, sendo a região do estado que apresenta as maiores taxas de desmatamento nos últimos anos segundo Carvalho e Scolforo (2008) e Scolforo e Carvalho (2006).

Apesar da importância dos estudos científicos já conduzidos na região, como os de Oliveira et al. (2010) utilizando Redes Neurais Artificiais na classificação das florestas decíduais através de métodos de filtragem em uma série temporal MODIS e os estudos de Acerbi Júnior, Clevers e Schaeppman (2006) utilizando técnicas de fusão de imagens MODIS e Landsat TM na classificação do cerrado, constata-se a necessidade de um método de classificação flexível, capaz de captar não somente as variações espectrais entre as diferentes classes de cobertura do solo na região, mas também a variação intraclasse, como por exemplo, a variação espectral ao longo de um ano nas florestas decíduais.

Sendo assim, o presente estudo tem como objetivo geral o desenvolvimento de uma metodologia para a classificação da cobertura do solo na região norte do estado de Minas Gerais. Do ponto de vista técnico, a região apresenta um desafio ao mapeamento devido à alta heterogeneidade da paisagem composta por áreas de florestas estacionais decíduais, cerrado, áreas de transição entre essas fisionomias, áreas agrícolas, pastagens e áreas degradadas. Para atender o objetivo de uma classificação confiável da cobertura do solo na região, os seguintes objetivos específicos foram traçados:

- Testar o uso de técnicas de segmentação de imagens para uma classificação baseada em objetos contemplando nessa técnica informações espectrais, espaciais e temporais.
- Uso de imagens de Alta resolução espacial, como as do sensor Rapideye, combinadas a séries temporais Landsat-TM, visando captar os efeitos da sazonalidade.
- Classificação dos dados por meio de Redes Neurais Artificiais.

## 2 REVISÃO DE LITERATURA

### 2.1 Sensoriamento Remoto

Sensoriamento remoto é o ramo da ciência responsável pela obtenção de informações sobre um determinado objeto, área ou fenômeno, por meio da análise de dados adquiridos por um instrumento (sensor) que não está em contato direto com esse objeto, área ou fenômeno sob investigação (LILLESAND; KIEFER, 2000). Para fins práticos, Schowengerdt (2007) define como a medição das propriedades dos objetos sobre a superfície da terra usando dados adquiridos a partir de aviões e satélites.

Os dados de sensoriamento remoto são obtidos por dois tipos de sensores, os ativos e os passivos. Sensores ativos são aqueles que emitem uma radiação eletromagnética e capta aquela que é refletida pelos objetos, como o sonar, radar e o LIDAR (*Light Detection And Ranging*). Sensores passivos são aqueles que não possuem fonte de radiação e captam apenas aquela que é refletida e/ou emitida pelos alvos na superfície.

A energia eletromagnética originada de uma fonte, por exemplo, o sol, propaga-se pela atmosfera até atingir um alvo que absorve e reflete porções desta energia. Sensores a bordo de plataformas inseridas em aviões ou satélites captam a energia refletida e/ou emitida pelos corpos na superfície e as armazenam para posterior interpretação (Figura 1).



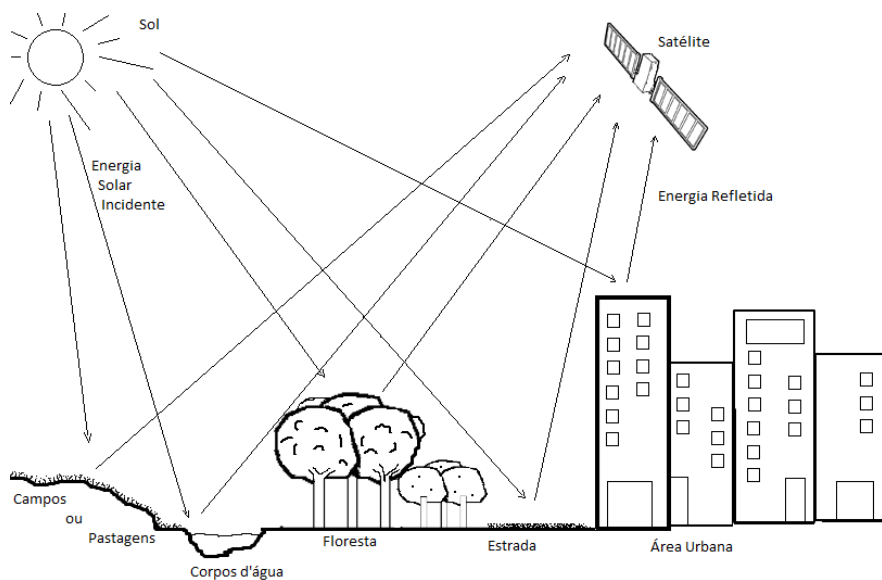


Figura 1 Princípio do sensoriamento remoto

### 2.1.1 Radiação eletromagnética

O espectro eletromagnético, como é conhecido, categoriza os tipos de radiação segundo o comprimento das ondas e, as unidades comumente utilizadas para isso, são o nanômetro (nm) e o micrômetro ( $\mu\text{m}$ ) (Figura 2).




Figura 2 Espectro eletromagnético

Câmeras a bordo de satélites ou aeronaves são sensíveis a diferentes intervalos de radiação do espectro eletromagnético e a cada diferente intervalo dá-se o nome de banda espectral. Cada banda pode ser representada por uma imagem no formato matricial (raster), onde os valores de  $x$  e  $y$  representam as coordenadas de cada *pixel* e  $z$ , a reflectância emitida ou refletida na região abrangente pelo mesmo. Um satélite pode possuir inúmeras bandas sendo cada uma responsável por imagear a mesma área em diferentes regiões do espectro eletromagnético (região do azul, verde, vermelho, infravermelho termal, etc.) (Figura 3). Com comprimentos de ondas variando da região do visível até o infravermelho termal, uma enorme constelação de diferentes satélites fornece diariamente uma infinidade de imagens com diferentes tipos de informações, cabendo ao especialista a interpretação a partir de seus conhecimentos sobre as propriedades físicas e químicas dos diferentes materiais que compõem a superfície e suas interações.




Figura 3 Representação das bandas espectrais de uma imagem de sensoriamento remoto

Os alvos na superfície terrestre apresentam-se de maneira bem característica e distinta quanto à radiação que é refletida pelos mesmos, e a esse comportamento singular de cada alvo dá-se o nome de assinatura espectral (Figura 4). O reconhecimento de curvas típicas de reflectância é essencial na escolha das bandas espectrais a serem utilizadas em trabalhos de Sensoriamento Remoto.

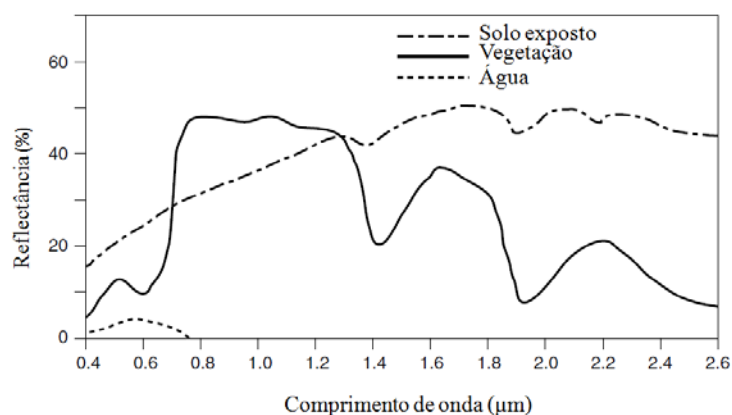


Figura 4 Assinaturas espectrais de diferentes alvos na superfície.  
Fonte: Navulur (2006)

### 2.1.2 Conceitos de resoluções

Nenhuma propriedade das imagens é mais amplamente citada, e ao mesmo tempo erroneamente usada, que a resolução. É um termo que transmite um significado forte intuitivo, mas é difícil de definir quantitativamente. A resolução de uma imagem pode ser expressa em quatro diferentes dimensões: espacial, espectral, radiométrica e temporal.

A **resolução espacial** é usualmente expressa pela área coberta em solo pela menor unidade da imagem, o *pixel*. Navulur (2006) categoriza as resoluções espaciais da seguinte maneira: (1) baixa resolução - imagens com *pixels* maiores ou iguais a 30 m, (2) média resolução - *pixels* de 2,0 a 30 metros, (3) alta resolução - de 0,5 a 2,0 metros e (4) altíssima resolução - menores que 0,5 metros.

A **resolução espectral** está relacionada com a quantidade, a localização e a largura das bandas medidas no espectro eletromagnético. A localização das

bandas espectrais de um sensor é limitada pelas bandas de absorção atmosféricas e mais determinada pelas reflectâncias das características a serem medidas (SCHOWENGERDT, 2007). Um exemplo para isso são os satélites desenvolvidos para estudos climáticos, que possuem suas bandas localizadas em diferentes regiões do infravermelho médio e termal (regiões que possibilitam estudos sobre nuvens, vapor d'água na atmosfera, etc.).

A **resolução radiométrica** está relacionada com a quantidade de níveis de cinza em que a energia refletida ou emitida pode ser representada pelo *pixel* depois de armazenada. Exemplos na Tabela 1.

Tabela 1 Resolução radiométrica dos sensores.

Satélite	Nº de bits	Forma binária	Níveis de cinza	Representação
MODIS	12	$2^{12}$	4096	0 a 4095
Landsat TM	8	$2^8$	256	0 a 255
SPOT 4 e 5	8	$2^8$	256	0 a 255
Quickbird	11	$2^{11}$	2048	0 a 2047

E por último a **resolução temporal**, que é o tempo de revisita do sensor, ou seja, o tempo que o mesmo leva para imagear uma mesma área (Tabela 2).

Tabela 2 Resolução temporal de diferentes sensores

Sensor	Resolução temporal (dias)
MODIS	12
Landsat TM	16
SPOT 4 e 5	26
Quickbird	1 a 3

### 2.1.3 Pré-processamento de Imagens

Nesta fase, técnicas são aplicadas às imagens brutas a fim de adequá-las ao estudo em questão, bem como proporcionar uma melhoria na qualidade dos dados.

Pré-processamento de imagens de satélite antes da extração da vegetação é essencial para remover ruídos e aumentar a interpretabilidade dos dados de imagem. Isto é particularmente verdadeiro quando uma série temporal de imagens é usada, ou quando uma área é abrangida por muitas imagens, uma vez que é essencialmente importante para fazer essas imagens compatível spectral e espacialmente (XIE; SHA; YU, 2008, p. 14).

Dentre as técnicas mais utilizadas pode-se destacar: Correção radiométrica e atmosférica, registro de imagens, recortes, mosaicos e fusão.

A **correção radiométrica** consiste na tentativa de corrigir degradações causadas por desajustes nos detectores (responsáveis pelo imageamento) dos satélites e erros na transmissão de dados. Os principais modelos de correção para as respectivas degradações são o *Stripping* e o *Dropped lines*.

Já a **correção atmosférica** trata-se de uma correção de distorções espectrais causadas pelo espalhamento da radiação eletromagnética devido a sua interação com a atmosfera. O mais conhecido método de correção é o do “corpo

negro”. Supõe-se que o “corpo negro” possui radiância uniforme em todas as bandas espectrais (zero) e que qualquer radiância medida diferente de zero deve ser devido ao espalhamento atmosférico (SCHOWENGERDT, 2007). Para isso são adotados sombras de nuvens densas e corpos d’água límpidos como tais corpos.

A técnica de **registro** de imagens é aplicada na correção das distorções geométricas causadas pela oscilação da plataforma do satélite no momento do imageamento. Registro é a transformação geométrica que relaciona as coordenadas da imagem (linha e coluna) com as coordenadas geográficas (latitude e longitude) de um mapa, ou outra imagem previamente georreferenciada. Para isso são coletados pontos de controles em feições facilmente identificáveis em ambas as imagens e por meio de um processo de interpolação (vizinho mais próximo, bilinear e convolução cúbica) realiza-se a reamostragem dos *pixels* e seu posicionamento (Figura 5). O resultado da correção geométrica pelo registro deve obter um erro dentro de mais ou menos um *pixel* de sua verdadeira posição, o que permite avaliações e medições espaciais precisas dos dados gerados a partir de imagens de satélite (XIE; SHA; YU, 2008).

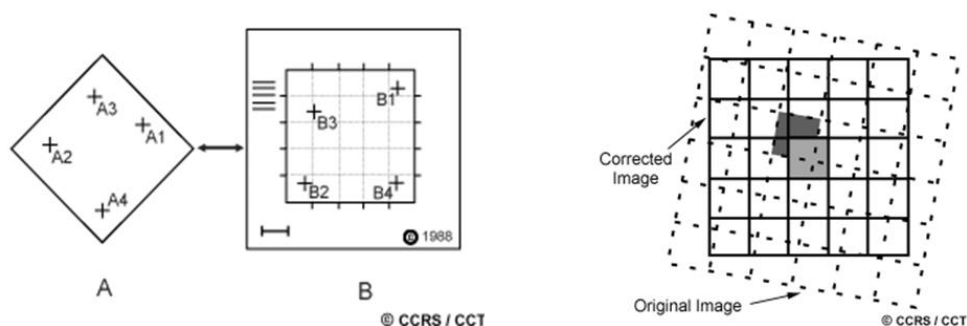


Figura 5 Representação do registro de imagens.

Fonte: Natural Resources Canada - NRCAN (2008)

A **fusão** de imagens multissensor tem como objetivo a integração da informação espacial e espectral de sensores diferentes para produzir uma imagem composta que tem uma descrição mais completa e exata da cena do que qualquer uma das imagens originais (ACERBI JÚNIOR; CLEVERS; SCHAEPMAN, 2006). Um grande exemplo é a fusão de uma banda pancromática de alta resolução espacial e baixa resolução espectral, com bandas multiespectrais de baixa resolução espacial e alta resolução espectral agregando o que há de melhor em ambas. Os principais métodos são os de transformada *wavelets*, *intensity-hue-saturation* (IHS), fusão *Gram-Schmidt* e a fusão por componentes principais.

Os **recortes** (*subset*) são aplicados às imagens a fim de reduzir seu tamanho caso a área de estudo seja menor que a imagem original, poupando assim memória e reduzindo os custos computacionais. Caso a área de estudo seja maior que a imagem faz-se necessário o uso de **mosaicos** de imagens.

Todos estes procedimentos podem ou não serem aplicados, cabendo ao especialista a análise de seus dados e adequação a sua metodologia.

#### 2.1.4 Sensoriamento remoto da vegetação e índices espectrais

Um dossel vegetal apresenta valores de reflectância relativamente baixos na região do visível (Figura 4), devido à ação dos pigmentos fotossintetizantes que absorvem a radiação eletromagnética para a realização da fotossíntese.

Definidos através de combinações de dados de duas ou mais bandas espectrais, selecionadas com o objetivo de melhorar a relação desses dados com os parâmetros da vegetação (MOREIRA, 2000), os índices espectrais de vegetação auxiliam muito na interpretação de imagens e no processo de



classificação, eliminando ou minimizando as limitações apresentadas pelo sensoriamento remoto na distinção de alvos na superfície terrestre.

São exemplos de índices de vegetação: o NDVI (*Normalized Difference Vegetation Index*) proposto por Rouse et al. (1973) (equação 1) que minimiza os efeitos causados pelo relevo e a interferência do solo na resposta da vegetação e o EVI (*Enhanced Vegetation Index*) (equação 2) proposto por Huete et al. (1997) para otimizar o sinal da vegetação, melhorando a sensibilidade em regiões com maiores densidades de biomassa, além do monitoramento da vegetação através de uma ligação do sinal de fundo do dossel e a redução das influências atmosféricas (JUSTICE et al., 1998).

$$\text{NDVI} = (\rho_{\text{NIR}} - \rho_{\text{r}}) / (\rho_{\text{NIR}} + \rho_{\text{r}}) \quad (1)$$

$$\text{EVI} = 2.5(\rho_{\text{NIR}} - \rho_{\text{r}}) / [(\rho_{\text{NIR}} + 6\rho_{\text{r}}) - 7.5\rho_{\text{B}} + 1] \quad (2)$$

Onde:  $\rho_{\text{B}}$  = banda do azul,  $\rho_{\text{r}}$  = banda do vermelho,  $\rho_{\text{NIR}}$  = banda infravermelho próximo.

Devido a sua pigmentação, a cor verde da vegetação sadia reflete mais no infravermelho próximo e menos no canal do visível, o que ocasiona altos valores para o NDVI (Índice de Vegetação por Diferenças Normalizada). Quando a folha começa a secar ela perde a sua pigmentação verde, aumentando um pouco sua reflectância no visível e diminuindo no infravermelho próximo, produzindo valores menores de NDVI.

Gurgel, Ferreira e Luiz (2003), em estudo que avaliou a variabilidade do NDVI sobre regiões do Brasil, afirma que os tipos de vegetação localizados em regiões com períodos secos e chuvosos marcantes, como é o caso do cerrado e da caatinga, apresentam ciclo anual bem caracterizado e respondem de forma rápida à ocorrência de chuva, e que vegetações densas e verdes todo o ano, como

a floresta Amazônica, apresentam maior variabilidade apenas quando ocorre anomalias climáticas.

Sendo assim, a dinâmica sazonal da vegetação captada por índices de vegetação, como NDVI e EVI, permite identificar o padrão sazonal dos principais tipos de uso e cobertura do solo.

## **2.2 Classificação digital de imagens e mapas temáticos**

A criação de mapas de vegetação que cobrem grandes áreas por levantamentos em campo é proibitivamente caro, então os mapas têm sido cada vez mais derivados de imagens aéreas ou de satélite (BRADTER et al., 2011). Um mapa temático mostra a distribuição espacial das características da superfície terrestre identificável, que fornece uma descrição de informação sobre uma determinada área, ao invés de uma descrição de dados (SCHOWENGERDT, 2007). Observações sobre o estado e a dinâmica da cobertura da terra são indicadores básicos para avaliar a degradação do solo, biodiversidade, conservação da natureza e a segurança alimentar (HÜTTICH et al., 2011).

Extração de vegetação a partir de imagens de sensoriamento remoto é o processo de extração de informações através da interpretação de imagens de satélite com base nos elementos de interpretação, como a cor, textura, tom, padrões, informações de associação, etc. (XIE; SHA; YU, 2008).

### **2.2.1 Métodos de classificação**

A criação de mapas temáticos a partir da classificação de imagens de satélite vem evoluindo muito até então, devido ao surgimento de diversos sensores a bordo das plataformas dos satélites capazes de fornecer imagens com resoluções cada vez mais altas e pelo esforço de pesquisadores na busca por métodos cada vez mais eficientes. Esses métodos podem ser agrupados em *Supervisionados* e *Não Supervisionados* (TAN; LIM; JAFRI, 2011) de acordo com a presença ou não de dados de verdade de campo inseridos como referência (XIE; SHA; YU, 2008).

Os métodos supervisionados são aqueles em que o algoritmo classificador encontra, em meio aos dados, características semelhantes às aquelas previamente apresentadas na forma de amostras (amostras de treinamento) para cada classe pré-estabelecida. O objetivo dos métodos não supervisionados é agrupar *pixels* com a mesma resposta espectral, em várias bandas espectrais, em grupos semelhantes (*Clusters*) ou classes que sejam estatisticamente separáveis (NAVULUR, 2006), não havendo aqui determinação prévia das classes a serem mapeadas, mas sim o número de grupos a serem divididos.

Algoritmos não supervisionados têm sido usados com sucesso na classificação de alvos distintos em imagens, entretanto para a obtenção de mapas temáticos de uso e cobertura do solo, em que várias classes se assemelham, o uso da classificação supervisionada é preferível na maioria dos casos (HEINL et al., 2009).

Segundo Schowengerdt (2007), os métodos podem ainda ser agrupados em dois tipos: paramétricos e não paramétricos. Os métodos paramétricos, como a Máxima Verossimilhança, pressupõem que os dados partem de uma distribuição estatística, comumente distribuição normal ou gaussiana, e usam este modelo de probabilidade para determinar os limites de decisão na classificação. O classificador Máxima Verossimilhança é geralmente considerado como clássico e mais amplamente utilizado classificador

supervisionado para imagens de satélite (XIE; SHA; YU, 2008). Os parâmetros necessários para o modelo são estimados a partir de dados de treinamento. Já os algoritmos não paramétricos, como classificadores por Redes Neurais Artificiais, *Random Forests* (BREIMAN, 2001) e por vizinhança (*nearest neighbor*), não fazem suposição alguma sobre a distribuição da probabilidade dos dados e são muitas vezes considerados robustos (SCHOWENGERDT, 2007).

A classificação por métodos aperfeiçoados com uso de inteligência computacional ou por algoritmos de tomadas de decisão (árvores de decisão) esquentam o meio acadêmico na busca por métodos mais precisos e usos em diversas aplicações. Redes Neurais Artificiais (RNA), teoria dos conjuntos *Fuzzy* e algoritmos genéticos são os principais componentes da área de inteligência computacional (STATHAKIS; VASILAKOS, 2006) sendo aplicados individualmente ou associados na classificação de imagens como os sistemas *neurofuzzy* (HAN et al., 2002).

Outro método que tem sido fortemente pesquisado no meio é o *Random Forests*. Proposto por Breiman (2001), é um algoritmo de comitê, ou seja, para determinar a classe de uma instância, o método combina o resultado de várias árvores de decisão por meio de um mecanismo de votação (GHIMIRE; ROGAN; MILLER, 2010). Este método junto às Redes Neurais Artificiais é hoje amplamente testado e tem produzido excelentes resultados, como em Erbek, Özkan e Taberner (2004), Jarvis e Stuart (1996) e Tan, Lim e Jafri (2011) comparando classificadores por RNA e em Bradter et al. (2011), Hüttich et al. (2011) e Smith (2010) usando Random Forests.

### 2.3 Segmentação de imagens

A segmentação de imagens não é nada novo (BLASCHKE, 2010) e em 1980 sua aplicação já era bem sucedida nas áreas de segmentação de imagens médicas e engenharia de telecomunicações (SCHIEWE, 2002).

Análise de imagens baseadas em objeto utiliza algoritmos de segmentação de imagem para criar grupos de *pixels* espectralmente semelhantes (objetos-imagem) e tratam esses objetos como unidade atômica para análise espacial e classificação de dados de imagem (SMITH, 2010). Sendo assim, todo o processamento da imagem é feito em cima dos objetos criados pela segmentação e não mais nos *pixels*.

O paradigma da Análise de Imagens Baseada em Objetos surgiu com o advento das imagens de alta resolução espacial (Figura 6). Com o surgimento desses novos sensores, as técnicas baseadas em *pixel* passaram a apresentar problemas quanto à precisão das análises devido à maior variação espectral e consequente variabilidade intraclasse.




Figura 6 Relação entre os objetos em análise e resolução espacial

Sendo: (a) baixa resolução: *pixels* significativamente maiores do que objetos, técnicas de subpixel são necessárias. (b) resolução média: tamanhos de *pixel* e objetos são da mesma ordem, Técnicas *pixel a pixel* são apropriadas. (c) alta resolução: *pixels* são significativamente menores que o objeto, a regionalização de *pixels* em grupos de *pixels* e, finalmente, objetos é necessário.

Tomemos como exemplo a Figura 7. A pista de um aeroporto possui diversas marcações com respostas espectrais distintas, que podem ser observadas apenas em imagens de melhor resolução. Uma classificação supervisionada baseada em *pixels* requer que amostras de treinamento sejam criadas de forma a representar todas as características da pista. Contudo, em imagens de alta resolução, *pixels* coletados como amostras teriam uma grande variabilidade espectral (*pixels* com asfalto, tinta branca, concreto, etc.) sendo facilmente confundido com topos de prédios e outros, acarretando em erros de classificação e redução dos valores de precisão do mapeamento.




Figura 7 Pista do aeroporto de Lavras vista por imagens de diferentes resoluções espaciais

Onde: a) 15 m. b) 4 m. c) 0,6 m e d) detalhe da pista na imagem 0,6 m

Aos *pixels* isolados erroneamente classificados em meio a uma fisionomia dá-se o nome de efeito *sault and pepper* (sal e pimenta) que dá uma

aparência salpicada ao mapa classificado, o que não ocorre em uma abordagem baseada em objetos.

Imagine agora se para classificar a mesma pista de aeroporto pudéssemos agrupar seus *pixels* em regiões. Essas regiões possuem não apenas a informação espectral de seus respectivos *pixels*, mas também forma, comprimento, largura, etc. que podem ser incorporados ao processo de classificação baseado em objetos.

A precisão da classificação e a acuidade de separação a serem obtidas através da interpretação baseada em objetos dentro das classes temáticas desejadas, dependem, inicialmente, de uma segmentação com sucesso (JANOTH et al., 2004). Um dos mais importantes pré-requisitos para a classificação de dados de sensoriamento remoto por meio de concepções baseadas em objeto, é que a segmentação de objetos tenha força descritiva que contenha somente *pixels* de uma classe semântica no mesmo grupo (BAATZ; SCHÄPE, 2000).

Para cada objeto formado no processo de segmentação, são calculadas suas características e estas, arquivadas em bancos de dados que podem ser facilmente manipulados em um ambiente SIG (Sistemas de Informações Geográficas). Em comparação com as concepções de classificação baseadas em *pixel*, que somente utilizam as características espectrais, os objetos de imagem conhecem, já no estado não classificado, os seus vizinhos e contêm diversas informações adicionais, tais como textura, forma, relações com, sobre, ou sub-objetos e diversas outras (ANDERSEN et al., 2004). A Figura 8 mostra algumas das opções de atributos em uma abordagem baseada em objetos.

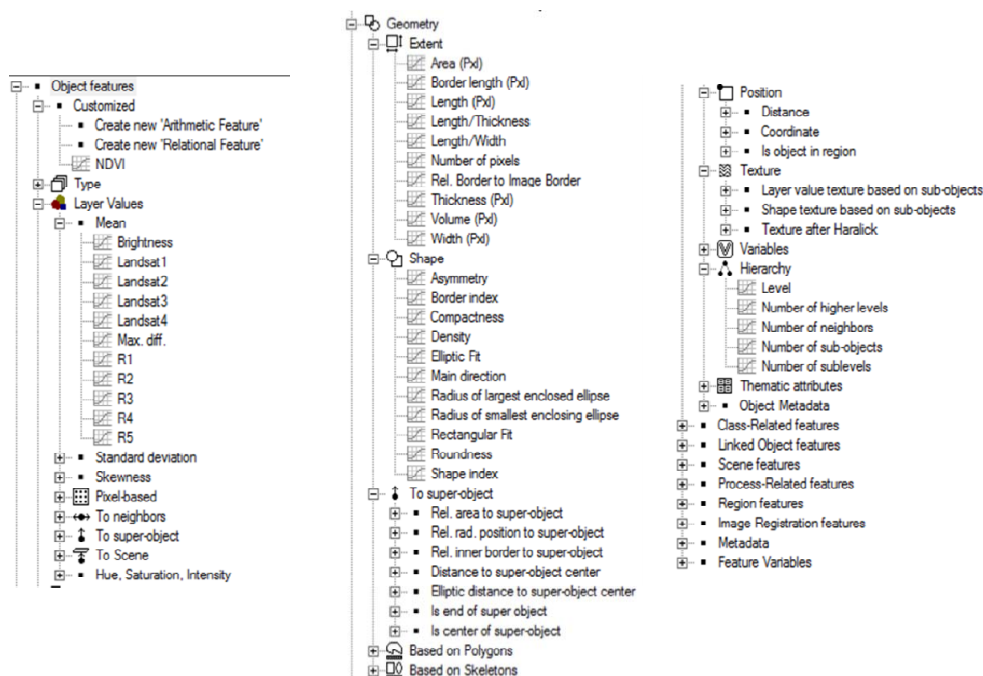


Figura 8 Atributos disponíveis no software de segmentação eCognition Developer 8.0

Além de trabalhar com valores de média e desvio padrão da reflectância dentro dos objetos, Navulur (2006) afirma que as vantagens da abordagem baseada em objetos podem ser espectrais (bandas multiespectrais incluindo a banda pancromática), espaciais (área, comprimento, largura, direção), morfológicas (parâmetros de forma, textura), contextuais (relação aos vizinhos, análise de proximidade) e temporais (séries temporais).

Para criação dos objetos em uma imagem, os algoritmos de segmentação baseiam-se em duas propriedades dos valores de níveis de cinza dos *pixels*: a descontinuidade e a similaridade (GONZALEZ; WOODS, 2000).

Enquanto os algoritmos baseados na descontinuidade buscam mudanças abruptas nos valores de nível de cinza para determinar os limites dos objetos, os



baseados na similaridade podem ser divididos em: crescimento de regiões, clusterização e divisão e fusão.

### 2.3.1 Algoritmo *Multiresolution Segmentation*

Proposto por Baatz e Schäpe (2000) esse algoritmo utiliza de métodos fusão de regiões onde a similaridade é obtida por meio da minimização do parâmetro de heterogeneidade interna dos objetos.

O algoritmo de segmentação por multirresolução (*Multiresolution Segmentation*) é hoje um dos principais algoritmos de segmentação de imagens de sensoriamento remoto. Baseado na técnica de fusão de regiões *pairwise*, o algoritmo funde pares de *pixels*, ou regiões já existentes, em unidades maiores através de diversas iterações contanto que o limiar superior de homogeneidade não seja excedido (DEFINIENS, 2009). O critério de homogeneidade é definido como uma combinação da homogeneidade espectral e da homogeneidade da forma.

Para a realização da segmentação, o algoritmo baseia-se em quatro diferentes critérios intimamente ligados: escala, cor (espectral), suavidade e compacidade.

Escala é um termo abstrato que determina a heterogeneidade máxima contida nos objetos resultantes, de modo que um parâmetro de escala alto resulta em objetos grandes, e parâmetros baixos em objetos pequenos, influenciando assim no número total de objetos em uma cena.

A homogeneidade dos segmentos e regiões é controlada pelos três demais critérios (BAATZ; SCHÄPE, 2000). A cor é o critério mais importante para a criação de objetos significativos (NAVULUR, 2006). O parâmetro cor

define a contribuição dos valores espectrais para definir a homogeneidade. Já o fator forma é representado pelos critérios suavidade e compacidade. O fator de suavidade pode ser usado para otimizar objetos de imagem para as fronteiras mais suaves, enquanto que o de compacidade pode ser usado para otimizar para fronteiras mais compactas (Figura 9).




Figura 9 Diagrama com a composição da homogeneidade no algoritmo *Multiresolution segmentation*.

Onde:

- $Cor = 1 - Forma$
- $Forma = Compacidade + Suavidade$
- $Suavidade = (1 - \beta compacidade) \times Forma$
- $Compacidade = \beta compacidade \times Forma$

A equação (3) mostra a relação e ponderação entre os coeficientes de heterogeneidade para a forma e a cor dos objetos na composição do critério de similaridade  $f$ , em que  $w_{cor}$  é o peso do parâmetro cor,  $\alpha_{cor}$  é o coeficiente de heterogeneidade do atributo cor e  $\alpha_{forma}$  é o coeficiente de heterogeneidade do atributo forma.

$$f = w_{cor} \cdot h_{cor} + (1 - w_{cor}) \cdot h_{forma} \quad (3)$$

Deste modo, o valor de  $f$  é comparado com o valor de escala fornecido pelo usuário e caso o parâmetro escala seja menor que o quadrado da similaridade os dois subobjetos são agrupados.

#### 2.4 Redes Neurais Artificiais (RNA)

As técnicas de inteligência computacional buscam na natureza sua inspiração para o desenvolvimento de sistemas inteligentes que imitem aspectos do comportamento humano, como: aprendizado, adaptação e percepção.

O trabalho em Redes Neurais Artificiais (RNA) tem sido motivado desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional (HAYKIN, 2001). Composto por bilhões de neurônios, o cérebro humano é responsável pelas atividades e funcionamento do organismo. Unidos apenas por uma semelhança ideológica, as RNA são modelos simplificados do sistema nervoso central e têm uma grande capacidade de desenvolver atividades e solucionar problemas como de classificação e regressão.

Para uma melhor compreensão e fundamentar a discussão sobre RNA é necessário um conhecimento prévio sobre a estrutura biológica e seu funcionamento. O neurônio biológico tem um corpo celular chamado *Soma* e diversas ramificações. A partir do corpo celular - o centro dos processos metabólicos da célula nervosa – projetam-se extensões filamentosas, os dendritos e o axônio (KOVACS, 2006) (Figura 10).




Figura 10 Estrutura de um neurônio biológico

Fonte: Neurônios... (2012)

Os neurônios são ligados entre si por uma ligação dendrito – axônio. Os dendritos são responsáveis pela recepção dos estímulos nervosos, através das conexões sinápticas. É no corpo celular (*soma*) que o impulso é processado e novos impulsos são gerados com destino ao exterior da célula via axônio.

Na organização neural, assume-se que uma sinapse é uma conexão simples que pode impor ao neurônio receptivo excitação ou inibição, mas não ambas (HAYKIN, 2001). Uma conexão excitatória provoca alterações no potencial da membrana que contribui para a formação de um impulso nervoso no axônio de saída enquanto que uma conexão inibitória age no sentido oposto (KOVACS, 2006).

O estímulo nervoso que chega à sinapse é transferido ao dendrito através de substâncias conhecidas como *neurotransmissores*. Os diferentes neurotransmissores existentes no organismo são responsáveis pela polarização da conexão sináptica (excitatória ou inibitória). Já a magnitude da polarização é uma função da concentração de neurotransmissores, da dimensão da sinapse e do comprimento do neurônio. Sendo assim, podemos perceber que todo o conhecimento atribuído aos neurônios biológicos está implícito nas sinapses.

Haykin (2001, p. 28) propõe então a seguinte definição para as RNA:

Uma rede neural é um processador maciçamente e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Em uma RNA as sinapses são representadas pelos pesos sinápticos ( $w$ ) que são atribuídos às entradas de um neurônio e podem ser negativos, positivos e de magnitudes diversas. O processamento de cada neurônio é realizado por uma função conhecida como *função de ativação*, que a partir da soma ponderada dos valores de entrada e seus respectivos pesos fornece um valor de saída, podendo ou não ser usado pelo próximo neurônio (Figura 11).

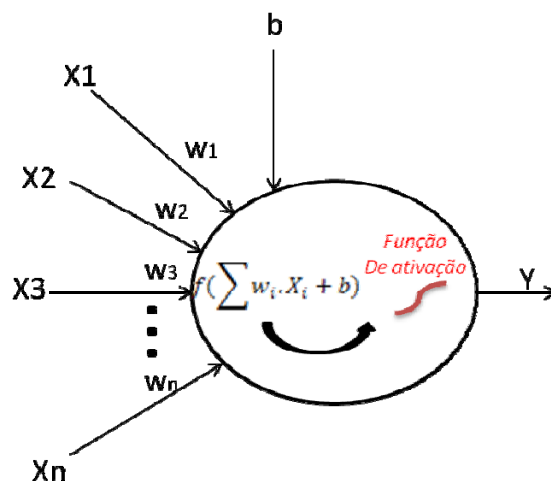


Figura 11 Modelo de um neurônio artificial

Sendo:  $X_{1,2,3,n}$ = Valores numéricos de entrada  
 $W_{1,2,3,n}$ = Pesos sinápticos das ligações  
 $b$  = Bias  
 $Y$ = Valor de saída do neurônio

Dentre as funções de ativação mais utilizadas podemos destacar a função limiar (Figura 12-a), função sigmoideal (Figura 12-b) e função tangente hiperbólica (Figura 12-c). A função de ativação do tipo limiar, ou função degrau unitário, fornece apenas dois tipos de saída, 1 e 0, ativada ou não ativada, sendo que o uso da função sigmoide permite que as saídas sejam interpretadas como probabilidades, fornecendo mais que uma simples decisão de classificação e é potencialmente um resultado muito poderoso (BISHOP, 1995).

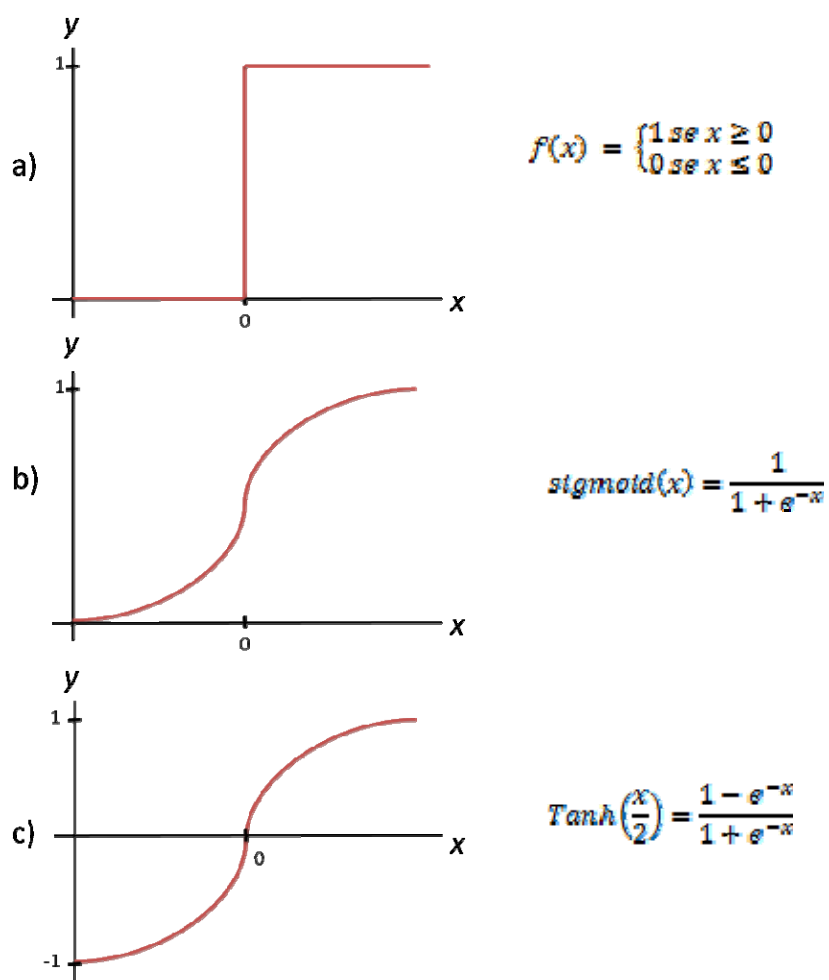


Figura 12 Funções de ativação utilizadas em um neurônio artificial

Sendo: (a) função limiar, (b) função sigmoide, (c) função tangente hiperbólica

A função sigmoide é de longe a forma mais comum de função de ativação utilizada na construção de RNA (HAYKIN, 2001). A função tangente hiperbólica usada em neurônios de camadas intermediárias é equivalente à sigmoide, mas com valores diferentes para pesos ( $w$ ) e *bias* ( $b$ ), apresentando

em alguns casos uma convergência mais rápida do erro durante o processo de treinamento (BISHOP, 1995).

#### **2.4.1 Neurônio artificial**

Proposto em 1943, pelo neuroanatomista e psiquiatra Warren McCulloch e pelo estatístico Walter Pitts, o primeiro modelo de neurônio artificial, o MCP, era uma simplificação do que se conhecia na época sobre o neurônio biológico. Basicamente o neurônio proposto possuía  $n$  entradas binárias, e uma saída. Com uma função de ativação do tipo degrau unitário para determinar a saída do neurônio, calculava-se a soma ponderada das entradas e se esse valor fosse maior ou igual a um certo limiar então a saída do neurônio era ativada (1), e caso contrário, não (0). Capaz de resolver apenas problemas linearmente separáveis, esse modelo de neurônio não perdurou muito, mas é tido como marco zero das Redes Neurais Artificiais.

Mais de uma década depois, em 1958, Rosenblatt criou uma rede de múltiplos neurônios e a chamou de *Perceptron* (Figura 13).






Figura 13 Perceptron de Rosemblat

O *Perceptron* de Rosemblat era formado por três camadas de neurônios: a camada de entrada, as camadas intermediárias conhecidas como camadas ocultas e a camada de saída. Um vetor  $X$  de  $n$  dimensões, após dar entrada na rede, é processado pela camada de entrada gerando como resultado um vetor  $U$   $n$ -dimensional. Esse mesmo vetor  $U$  serve como entrada da camada seguinte, e assim sucessivamente até a camada final, a camada de saída.

Usando o Perceptron para reconhecimento de caracteres, Rosemblat propôs o primeiro método de aprendizagem supervisionada. Por este método desejava-se obter um valor que aplicado ao vetor de pesos  $(\omega)$  produzisse uma solução  $\omega(t+1)$  melhor que  $\omega(t)$  (GÖRGENS, 2006). Por possuir características adaptativas apenas na camada de saída, os pesos das camadas ocultas eram fixos e definidos antes do período de treinamento (KOVACS, 2006). O trabalho de Rosemblat foi consagrado quando em 1962 ele demonstrou a *Teoria de Convergência do Perceptron*, onde dizia que o algoritmo de treinamento do Perceptron sempre convergia a uma solução para o problema de duas classes linearmente separáveis.

Contudo, em 1969, Minsky e Papert demonstram as limitações do Perceptron. Por ser capaz de tratar apenas problemas linearmente separáveis e por não existir algoritmo de treinamento para redes de múltiplas camadas, sua aplicação era muito limitada, uma vez que os problemas de natureza real são, na maioria das vezes, não-lineares. Isso fez com que as pesquisas em RNA ficassem paradas por cerca de dez anos.

Somente em 1982 com Hopfield e em 1986 com Rumelhart, Hinton e Williams estudando algoritmos de treinamento é que as pesquisas foram retomadas. Desde então progredem significativamente até os dias de hoje (RUMELHART; HINTON; WILLIAMS, 1986).

#### **2.4.2 Arquitetura**

À maneira como os neurônios estão estruturados e ligados entre si dá-se o nome de arquitetura. Essa está intimamente ligada com o algoritmo de aprendizado usado para treinar a rede e ao tipo de problema a ser solucionado pela RNA.

Dentre as arquiteturas mais comuns e amplamente empregadas, podemos destacar as redes de camada única, as de múltiplas camadas e as redes recorrentes (Figura 14).




Figura 14 Arquiteturas de RNA mais comumente empregadas

Onde: a) Redes de camada única; b) redes de múltiplas camadas; c) redes recorrentes

As redes de camada única são redes onde os neurônios da camada de entrada projetam-se sobre uma camada de saída, e não vice-versa. São conhecidas como *redes alimentadas adiante* ou *acíclica*.

As redes de múltiplas camadas diferenciam-se pela presença de uma ou mais camadas ocultas, que são responsáveis por intervir entre as camadas de entrada e saída. Uma configuração comum é o Perceptron Multi-Camada (MLP), onde cada neurônio recebe entradas a partir de camadas anteriores, com fluxo unidirecional de informações para a saída (PRATOLA et al., 2011). O número de nós na(s) camada(s) intermediária(s) define a complexidade e o poder do modelo de rede neural para descrever relações subjacentes e estruturas inerentes a um dado de treinamento (poder de generalização) (KAVZOGLU, 2009) e que mais nós nestas camadas podem ser necessários para a classificação de imagens de satélite com maior complexidade e granularidade (JARVIS; STUART, 1996).

Cada neurônio de uma rede multicamadas possui uma função de ativação não-linear e diferenciável, o que torna possível o cálculo do gradiente responsável pela indicação da direção de ajustes de pesos no processo de treinamento. Os neurônios das camadas ocultas são responsáveis pelo poder de

generalização da rede e adicionando-se uma ou mais camadas, tornamos a rede capaz de extrair estatísticas de ordem elevada (HAYKIN, 2001).

Aumentando-se o número de neurônios da camada oculta aumenta-se a capacidade de mapeamento não-linear de uma rede. Entretanto, o excesso de neurônios nas camadas ocultas pode levar a rede à memorização de ruídos e, conseqüentemente, baixo poder de generalização (*overfitting*). Entretanto uma rede com poucos neurônios nas camadas ocultas pode não ser capaz de realizar a tarefa desejada, não apresentando convergência durante o treinamento (*underfitting*).

O número de neurônios nas camadas de entrada e saída segue as características do problema a ser resolvido. No entanto, a melhor maneira de estimar o número de neurônios nas camadas ocultas é o modo de tentativa e erro, já que os modelos para isso existentes na literatura não são muito aceitos.

Uma rede recorrente se difere das demais por possuírem pelo menos um laço de realimentação. Essas redes são amplamente empregadas em processos dinâmicos como a previsão de dados em uma série histórica, processamento de sinais e robótica.

### **2.4.3 Treinamento**

Como já dito anteriormente, todo o conhecimento de uma RNA está embutido nos pesos sinápticos das ligações entre os neurônios. Entretanto, para que uma RNA seja capaz de solucionar um determinado problema é preciso que estes pesos sejam ajustados segundo as características do mesmo.

O processo de treinamento de uma RNA consiste no ajuste dos pesos sinápticos a fim de obter um conjunto de saídas desejado, ou consistente, a partir

de um conjunto de entrada. Segundo Erbek, Özkan e Taberner (2004), dois são os principais tipos de treinamento, os supervisionados e os não supervisionados.

O treinamento supervisionado consiste em apresentar à rede um conjunto de pares amostras-resultados a fim de que ela aprenda e armazene este conhecimento para que possa ser aplicado em demais dados. Calculando-se o erro entre a saída desejada e a obtida, o algoritmo de treinamento ajusta os pesos de cada neurônio de modo a minimizar este erro. Sem sombra de dúvida o algoritmo de treinamento supervisionado mais popular é o *Backpropagation* e junto às redes *Multi Layer Perceptron* (MLP) são amplamente aplicados em sensoriamento remoto.

Em um treinamento não supervisionado não existe o conhecimento *a priori* das saídas obtidas por cada amostra de treinamento e seu funcionamento baseia-se em distinguir classes de padrões diferentes dos dados apresentados à rede, reconhecendo grupo de vetores de entradas semelhantes. Os algoritmos utilizados nesse tipo de treinamento são geralmente baseados em conceitos de vizinhança e agrupamento (*clusters*).

#### **2.4.3.1 Algoritmo *Backpropagation***

Proposto por Rumelhart, Hinton e Williams (1986), o algoritmo *Backpropagation* (retropropagação do erro) é baseado em duas fases: a propagação e a adaptação.

Durante a propagação, amostras apresentadas à camada de entrada propagam-se camada por camada em um fluxo unidirecional até produzirem um conjunto de saída. Na adaptação, um sinal de erro é calculado a partir do conjunto de saída e a resposta desejada. Esse sinal é propagado no sentido oposto da rede e seus pesos ajustados buscando minimizar o erro.

Todo o procedimento de treinamento é realizado em cinco etapas:

1. Apresentação dos dados de entrada e propagação até a camada de saída (propagação).
2. Determinação do erro.
3. Retropropagação do erro e determinação das correções.
4. Correção dos erros.
5. Repetir passo de 1 a 4 caso algum critério de parada seja satisfeito.

Os critérios de parada mais utilizados em treinamento de redes MLP pelo algoritmo *Backpropagation* são os de minimização do erro, por número de iterações e o de validação cruzada.

O método de minimização do erro quadrático médio (EQM) consiste em treinar a rede até que um valor desejável seja obtido. Já o critério de parada pelo número de iterações não é muito recomendado por não levar em conta o estado do processo iterativo de treinamento.

O critério de parada por validação cruzada permite que o usuário tenha uma avaliação da capacidade de generalização da rede após cada época de treinamento. Isso é de grande importância, uma vez que longos períodos de treinamento, buscando erros cada vez menores, façam com que a rede fique especializada para os dados usados no treinamento e tenha baixa generalização para dados desconhecidos (*overfitting*). Isso é feito separando dois conjuntos de amostras, um de treinamento e outro para a validação da rede. A cada iteração no processo de treinamento, os dados contendo as amostras de validação são apresentados à rede e o erro obtido por esse conjunto representados em um gráfico *erro x nº de iterações* juntamente com os valores de treinamento (Figura 15). Vale ressaltar que os dados contidos nas amostras de validação não interferem no treinamento da rede, bem como no ajuste dos pesos, sendo sua utilização definida somente para visualização do desempenho do treinamento e melhor época para interromper o mesmo.




Figura 15 Gráfico de validação cruzada com excesso de treinamento

Outro fator importante do algoritmo de treinamento *Backpropagation*, é o parâmetro *taxa de aprendizado*. Geralmente com valores pequenos (próximos de um) e sempre positivos, este parâmetro controla a intensidade das alterações dos pesos. Ao passo que baixos valores de taxa de aprendizagem tornam o treinamento mais lento, valores altos provocam oscilações no mesmo, impedindo a convergência do erro.

A convergência do erro em mínimos locais faz com que o mesmo pare de diminuir não atingindo o treinamento ideal (mínimo global da função). Um método encontrado para solucionar este problema, é a adição de um termo de *momentum*. Com valores também variando de zero a um, este termo aumenta a taxa de aprendizado da rede, sem causar oscilações, bem com diminui o risco de convergência em mínimos locais.

### 3 Material e Métodos

De modo a auxiliar a compreensão da metodologia e a ordem dos processos, todas as principais etapas deste estudo foram resumidas em um fluxograma que pode ser visto na Figura 16.

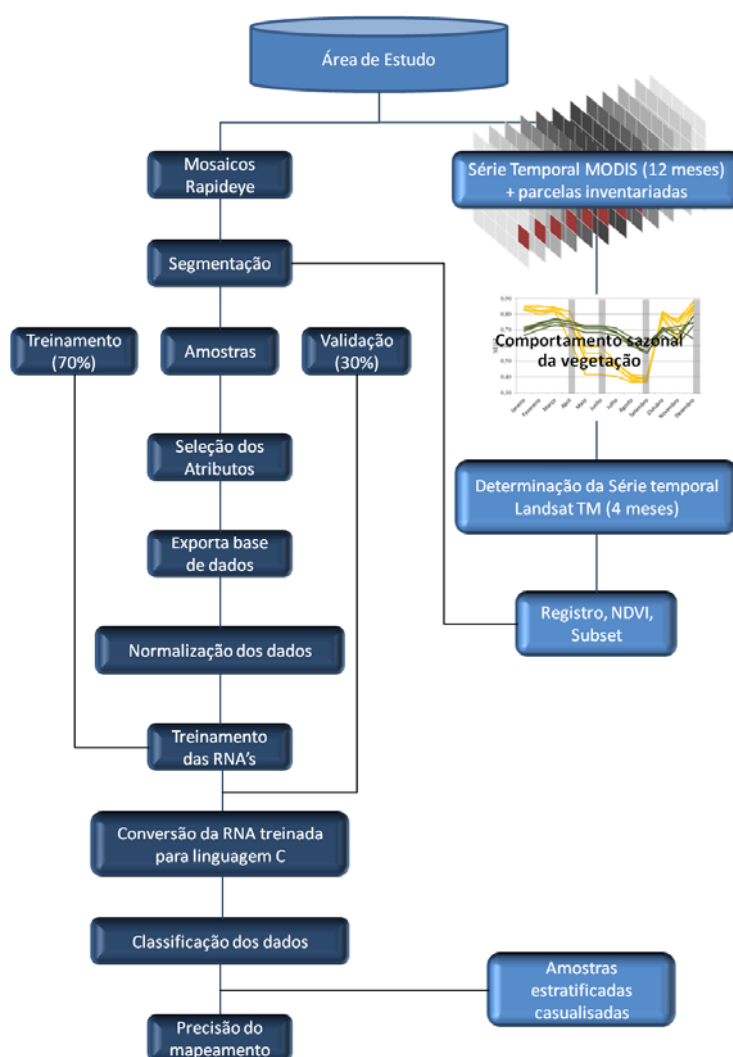


Figura 16 Fluxograma da metodologia proposta



### 3.1 Área de estudo

A área selecionada para o presente estudo localiza-se ao norte do estado de Minas Gerais e foi delimitada por três mosaicos com quatro imagens Rapideye cada (Figura 17). Segundo o Mapeamento e Inventário da Flora Nativa e dos Reflorestamentos de Minas Gerais (SCOLFORO; CARVALHO, 2006), o mosaico ao centro, cruzado pelo Rio São Francisco, representa uma zona de transição entre as áreas de predominância de florestas estacionais decíduais, mosaico à direita, e Cerrado, mosaico à esquerda. Com vegetações peculiares, como as veredas do Parque Estadual Veredas do Peruaçu, essa região mantém hoje remanescentes de mata Atlântica e os maiores fragmentos de floresta nativa do estado, abrigando uma fauna e flora riquíssimas com espécies ameaçadas de extinção.

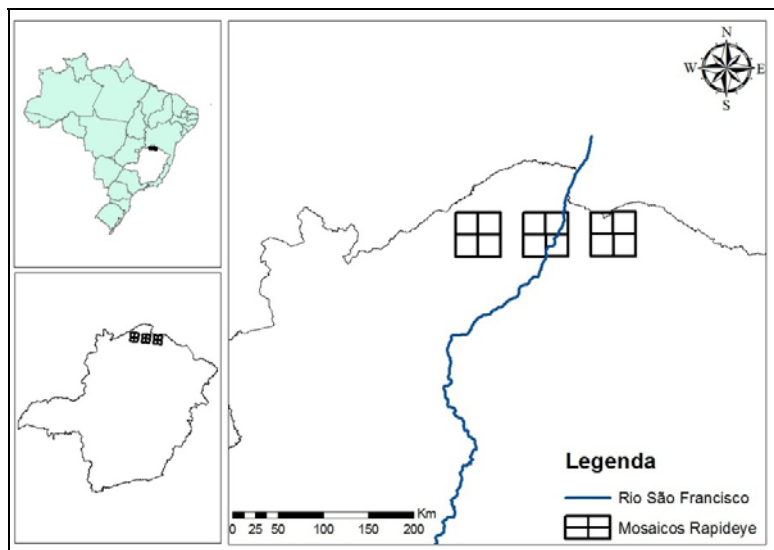


Figura 17 Área de estudo

## 3.2 Base de dados

### 3.2.1 Imagens Rapideye

Para a realização do estudo, foram utilizadas 12 imagens Rapideye (Tabela 3) que compõem três diferentes regiões (Figura 17). Com uma resolução espacial de 5 m, o sensor Rapideye é composto por 5 bandas espectrais, sendo três na faixa do visível, uma quarta conhecida como *Red-Edge*, e a quinta na faixa do infravermelho próximo (Tabela 4).

Tabela 3 Cenas Rapideye utilizadas

ID da cena	Data de aquisição
2332115	27/06/2010
2332116	05/07/2010
2332215	27/06/2010
2332216	13/07/2010
2332118	01/05/2010
2332119	18/06/2010
2332218	18/06/2010
2332219	18/06/2010
2332121	12/06/2010
2332122	12/06/2010
2332221	12/06/2010
2332222	12/06/2010

Tabela 4 Características das imagens Rapideye

Banda	Comprimento de onda ( $\mu\text{m}$ )	Resolução espacial (m)	Resolução temporal (dias)
1	0,44 – 0,51 (Azul)		
2	0,52 – 0,59 (Verde)		
3	0,63 – 0,69 (Vermelho)	5	5,5
4	0,69 – 0,73 (Red edge)		
5	0,76 – 0,88 (IV próximo)		

### 3.2.2 Imagens Landsat

As imagens Landsat TM contam com sete bandas espectrais indo da região do visível (RGB) ao infravermelho médio e mais uma banda no infravermelho termal (Tabela 5).

Tabela 5 Características das imagens Landsat TM

Banda	Comprimento de onda ( $\mu\text{m}$ )	Resolução espacial (m)	Resolução temporal (dias)
1	0,45 – 0,52 (Azul)	30	
2	0,52 – 0,60 (Verde)	30	
3	0,63 – 0,69 (Vermelho)	30	
4	0,76 – 0,90 (IV próximo)	30	16
5	1,55 – 1,75 (IV médio)	30	
6	10,40 – 12,50 (IV termal)	120	
7	2,08 – 2,35 (IV médio)	30	

Para que houvesse a sobreposição da área de estudo pelas imagens Landsat TM, foram necessárias duas diferentes cenas (Figura 18). Para cada uma delas foi adquirida uma série de imagens em diferentes datas com o objetivo de captar as variações sazonais da vegetação.

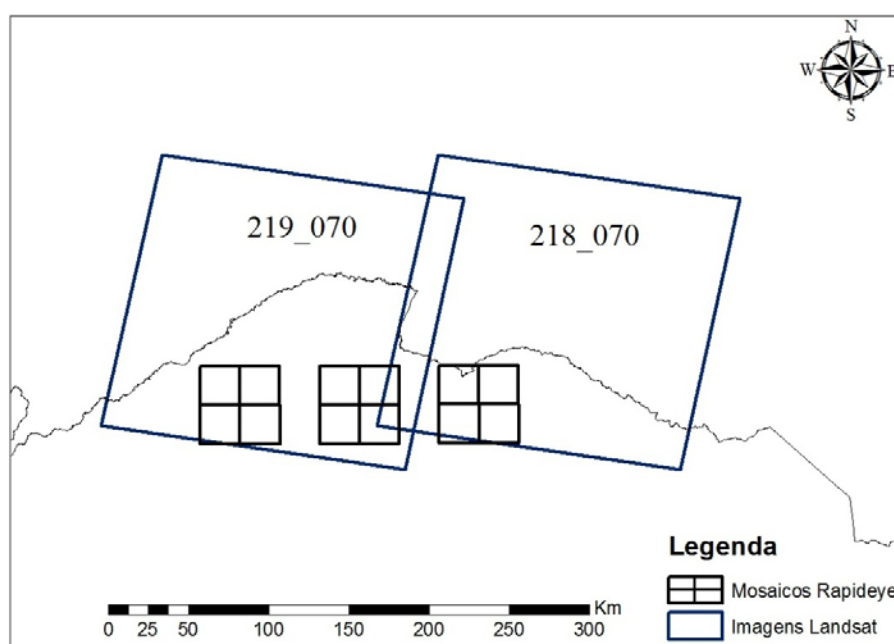


Figura 18 Cenas Landsat TM utilizadas

### 3.2.2.1 Seleção das imagens

A alta resolução temporal do satélite MODIS (diário) fornece uma informação valiosíssima para estudos climáticos e ambientais, além de servir como base de séries temporais em diversos estudos de mapeamento da vegetação e de uso e cobertura do solo (CLARK et al., 2010; HÜTTICH et al., 2009, 2011; OLIVEIRA et al., 2010; SILVEIRA et al., 2008).

Com uma resolução espacial de 250 m, a utilização de imagens MODIS nesse estudo ficaria comprometida devido à grande discrepância com a resolução espacial da imagem Rapideye (5 m) a ser classificada (Figura 19).

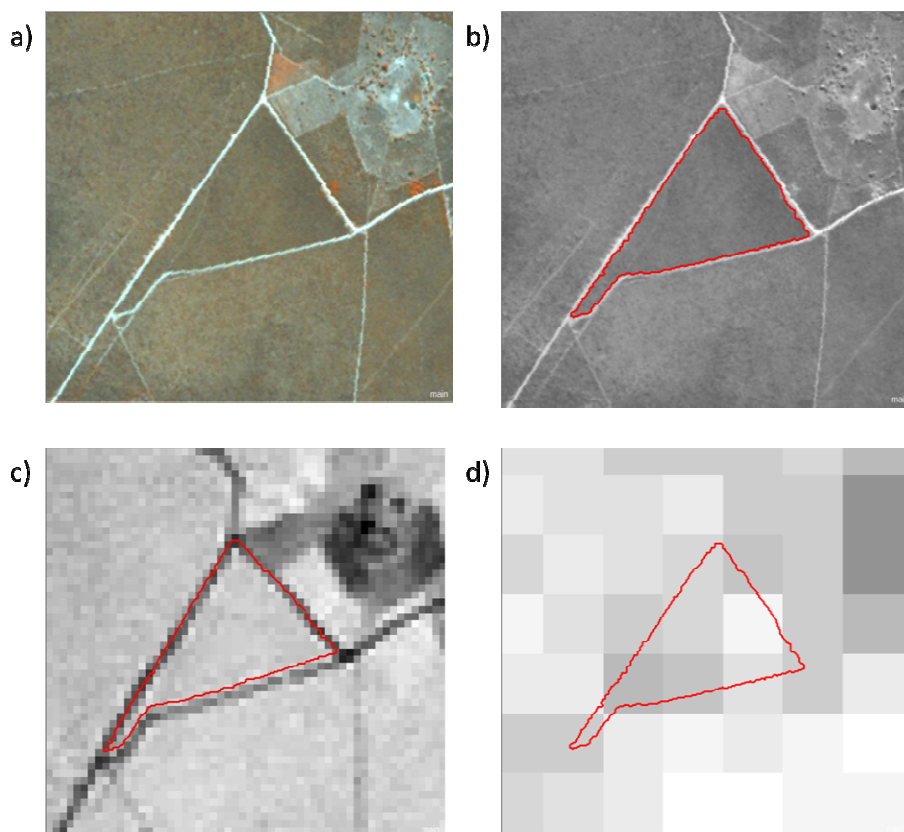


Figura 19 Representação de uma mesma área vista por diferentes resoluções espaciais. Onde: a) Imagem Rapideye em composição falsa cor; b) Banda 5 Rapideye – 5 m; c) NDVI Landsat TM – 30 m; d) NDVI MODIS – 250 m.

Entretanto a informação temporal contida nestas imagens pode ainda ser de grande valia para este estudo fornecendo a “localização” dos melhores períodos do ano para a aquisição das imagens Landsat TM.

Para isso, utilizou-se uma série temporal de 12 imagens NDVI MODIS do satélite TERRA, produto de 16 dias, do ano de 2010 e as parcelas amostradas no Inventário Florestal de Minas Gerais (SCOLFORO; CARVALHO, 2006) como verdade de campo. Em seguida, a imagem Rapideye foi segmentada e os objetos formados nos locais das parcelas foram identificados de acordo com a fisionomia a que pertenciam. A Figura 20 apresenta o comportamento espectral dos valores de NDVI no ano de 2010 para as áreas de Floresta Estacional Decidual e Cerrado.

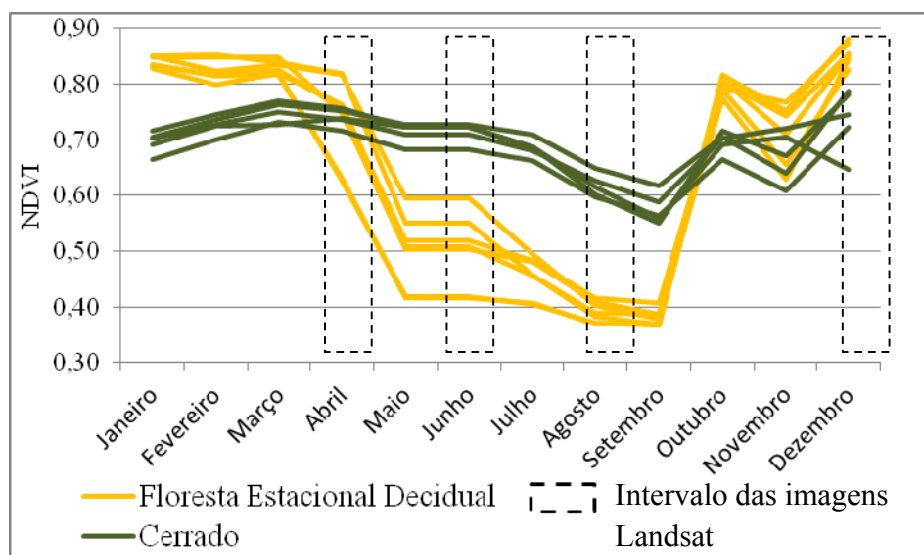


Figura 20 Assinatura temporal das fisionomias e seleção das imagens Landsat TM

Por perder mais de 50% das folhas na estação seca, os valores mínimos de NDVI das florestas estacionais deciduais, bem como seus valores de amplitude, fornecem uma característica distinta dos demais tipos de cobertura da terra, fornecendo informações valiosas a serem usadas na classificação do uso e cobertura do solo (SILVEIRA et al., 2008).

Baseado nessas informações, as imagens foram selecionadas buscando uma melhor representação da variabilidade dos valores de NDVI, sendo observados os seus máximos, mínimos e médios.

Um fator limitante na seleção das imagens foi a presença de nuvens. As mesmas foram escolhidas atentando para a ausência ou mínima presença de nuvens e pela disponibilidade das datas no site do INPE (Instituto Nacional de Pesquisas Espaciais) que serviu como fonte de dados. Sendo assim, foram selecionadas imagens em quatro diferentes datas para cada região (Tabela 6), de modo a representar todo o ciclo anual da vegetação.

Tabela 6 Datas das imagens Landsat TM utilizadas

218_070	219_070
11/04/2010	04/05/2010
14/06/2010	07/07/2010
01/08/2010	09/09/2010
23/12/2010	31/01/2011

### **3.3 Pré Processamento**

#### **3.3.1 Mosaicos das imagens Rapideye**

Para a cobertura das três diferentes regiões da área de estudo, foram confeccionados três mosaicos com as imagens Rapideye, contendo quatro cenas cada (Figura 21).




Figura 21 Mosaicos das imagens Rapideye

### 3.3.2 Registro das imagens Landsat

A fim de comparar imagens tomadas em diferentes épocas, ou a partir de diferentes sensores, as mesmas devem estar registradas em um mesmo sistema de coordenadas (ERBEK; ÖZKAN; TABERNER, 2004). Para uma perfeita sobreposição dos dados, todas as imagens Landsat foram georreferenciadas tomando como base um novo mosaico contendo quarenta imagens Rapideye, dentre elas as doze constituintes dos três mosaicos que cobrem a área de estudo (Figura 22). Após ter seus *pixels* reamostrados para 30 metros, esse mosaico serviu para coleta de pontos de controle, nos quais foram feitos os registros de cada uma das oito imagens Landsat na projeção UTM e sistemas de coordenadas WGS 84. Todos os registros foram feitos mantendo o erro quadrático médio abaixo de um *pixel*.



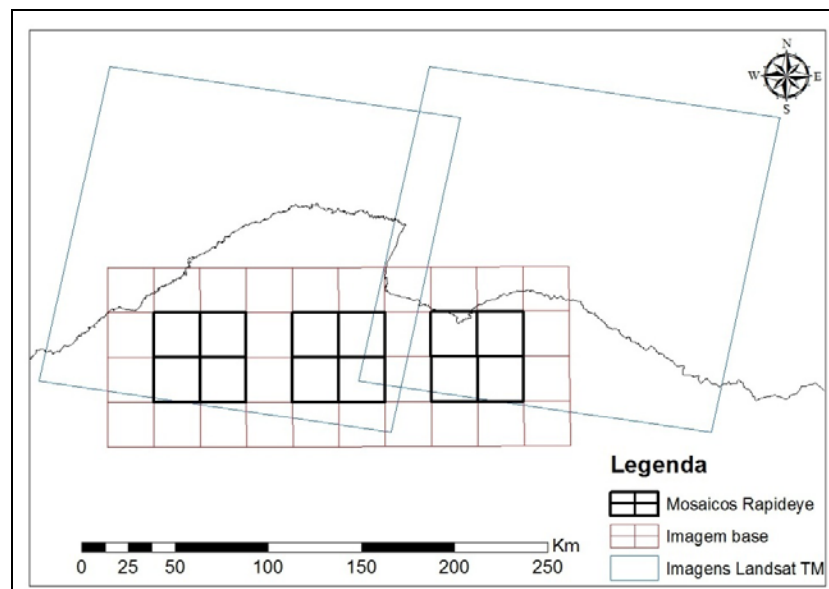


Figura 22 Mosaico Rapideye, imagens Landsat e imagem base para registro

### 3.3.3 NDVI e Subset das imagens Landsat TM

Após o registro, cada imagem Landsat teve extraído seus valores de NDVI. Para reduzir o custo computacional dos processos, foi feito um *subset* em cada cena NDVI de modo a deixá-las apenas com as dimensões dos respectivos mosaicos da área de estudo (Figura 23).

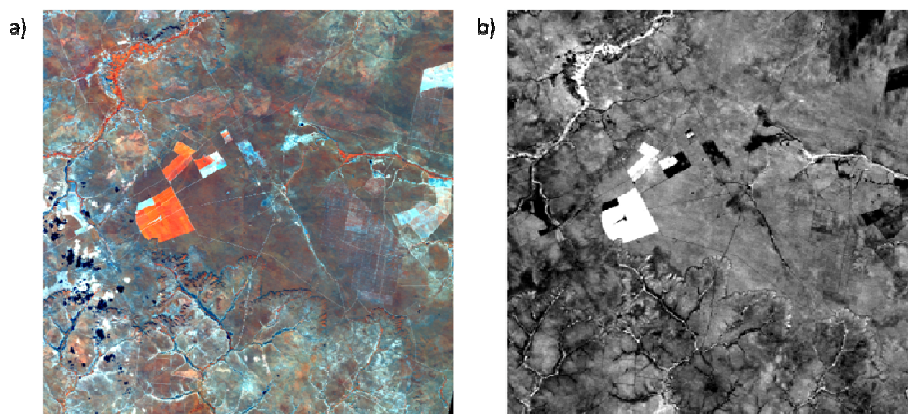


Figura 23 Resultado dos pré-processamentos. Onde: (a) Mosaico Rapideye e (b) subset da imagem NDVI Landsat

### 3.4 Segmentação de Imagens

Para a criação dos objetos foi utilizado o algoritmo de segmentação *Multiresolution Segmentation* disponível no software eCognition Developer 8.0, que permite extrair segmentos com base, tanto no valor de *pixel* (refletância), como na forma do objeto.

No software foram criados três diferentes projetos, sendo inserido em cada um deles um mosaico Rapideye e as suas quatro respectivas imagens NDVI – Landsat TM.

A Figura 24 mostra a janela onde são determinados os parâmetros do algoritmo de segmentação. O valor do campo *Shape* (Forma) modifica a relação entre os critérios forma e cor ( $cor = 1 - forma$ ). Alterando-se o valor desse campo define-se a porcentagem com que a informação espectral e espacial irá contribuir para o critério de homogeneidade, sendo que valores altos resultam na formação de objetos mais otimizados para homogeneidade espacial. O campo

*Compactness* (Compacidade) age da mesma maneira com o critério suavidade na hora de formar junto o critério *Forma*.

Por possuírem melhor resolução espacial, todo o processo de segmentação foi realizado com pesos apenas nas bandas da imagem Rapideye, enquanto as quatro imagens NDVI – Landsat TM foram utilizadas apenas na extração de atributos (informação temporal) para o processo de classificação (Figura 24).

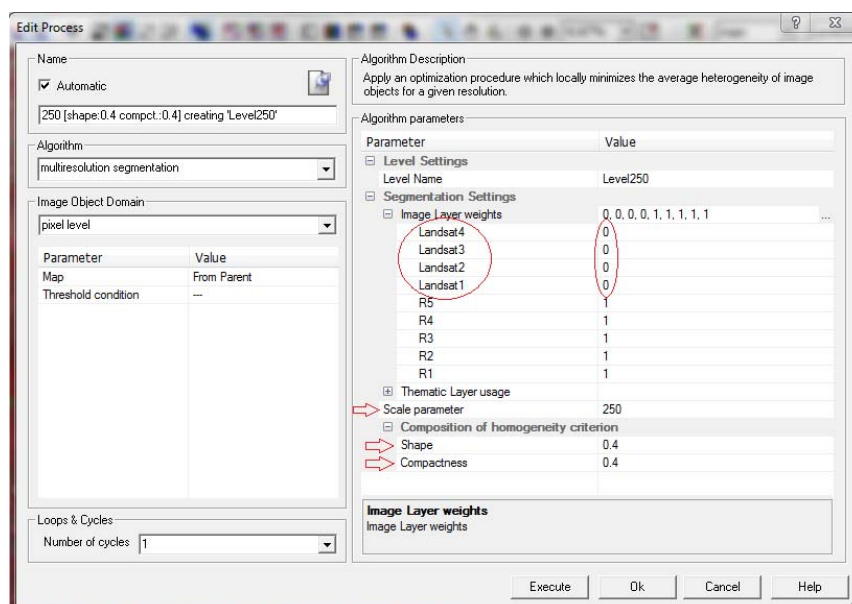


Figura 24 Parâmetros do algoritmo *Multiresolution Segmentation*

Com o intuito de se obter uma segmentação mais significativa possível em relação aos objetos que compõe a paisagem, testou-se diferentes valores para os campos de forma e suavidade em uma segmentação em múltiplas escalas (Tabela 7).

Tabela 7 Parâmetros testados na segmentação das imagens

Forma	Compacidade	Escalas
0,3	0,8	250, 350, 450, 550, 650, 750, 800, 900
0,3	0,4	250, 350, 450, 550, 650, 750, 800, 900
0,4	0,8	250, 350, 450, 550, 650, 750, 800, 900
0,4	0,4	250, 350, 450, 550, 650, 750, 800, 900

A avaliação da qualidade da segmentação para os diferentes parâmetros de entrada testados foi feita através da análise visual, comparando-se a forma e o tamanho dos objetos formados bem como sua representatividade.

Após um resultado de segmentação que atenda aos propósitos do estudo, os objetos e os  $n$  atributos pertencentes a cada um deles, foram exportados para o formato vetorial (.Shp) para uso posterior no processo de treinamento e classificação dos dados.

### 3.5 Classificação

As classes utilizadas no estudo foram as presentes na região de acordo com o Mapeamento e Inventário da Flora Nativa e dos Reflorestamentos de Minas Gerais (SCOLFORO; CARVALHO, 2006). São elas: Cerrado, Floresta Estacional Decidual, Vereda, Eucalipto, Água e Outros (Agricultura, pastagens, solo exposto, etc). Pensando na melhoria do mapeamento existente e no ganho de informação, as classes Agricultura e Pastagem foram mapeadas individualmente formando o conjunto de oito classes.

### 3.5.1 Amostragem

Após a segmentação, em todos os três mosaicos Rapideye foram coletadas amostras significativas pertencentes a cada uma das classes presentes, ficando reservado para validação dos resultados de treinamento 30% do total que serão utilizados nos cálculos de precisão (Tabela 8).

Tabela 8 Número de amostras

Classe	Mosaico 1	Mosaico 2	Mosaico 3	Total	V	T
					30%	70%
Agricultura	0	72	0	72	22	50
Água	0	20	15	35	10	25
Cerrado	100	50	0	150	45	105
Eucalipto	30	25	0	55	16	39
Decidual	0	50	100	150	45	105
Outros	50	50	50	150	45	105
Pastagem	0	60	12	72	22	50
Vereda	40	0	0	40	12	28
TOTAL	220	327	177	724	217	507

Onde: T = amostras de treinamento e V = amostras de validação

### 3.5.2 Atributos utilizados

Além dos quatro valores de NDVI das imagens Landsat TM, foram selecionados mais 13 atributos referentes às imagens Rapideye para a descrição de cada objeto perfazendo um total de 17. São eles:

- Reflectância: reflectância média dos objetos em suas cinco bandas (Mean1, Mean2, Mean3, Mean4 e Mean5).
- Brilho Total: atributo que leva em consideração o somatório da reflectância média dos objetos em todas as bandas da imagem (Brightness).
- Razão da banda: a quantidade com que uma dada banda da imagem contribui para o brilho total (Ratio4 e Ratio5).
- Máxima diferença: maior diferença entre as intensidades médias de cada banda do objeto (Max\_Diff).
- Máxima diferença no valor de *pixel*: relação feita através dos valores máximos e mínimos encontrados nos *pixels* em uma dada banda (Max\_Diff\_pixel\_R5).
- NDVI: índice formado pelas bandas três e cinco da imagem Rapideye.
- Desvio Padrão: desvio padrão encontrado nos valores dos *pixels* de um determinado objeto em uma dada banda (SD4 e SD5).

### 3.5.3 Redes Neurais Artificiais (RNA)

A classificação dos dados por RNA foi feita usando o software *JavaNNS* (UNIVERSITÄT TUBINGEN, 2012).

Foram utilizadas redes *Multi Layer Perceptron* (MLP) com função de ativação do tipo sigmoidal treinadas pelo algoritmo *Backpropagation*. Para diminuir os efeitos da zona de saturação da função sigmoidal, todos os atributos tiveram seus valores normalizados entre 0,1 e 0,9 pela Equação 4, que segundo Gorgens et al. (2009) realiza também a equalização dos dados, provocando uma melhora na capacidade de predição da rede neural.

$$\text{Valor transformado} = 0,1 + \left( 0,8 \frac{x - \text{mín}}{\text{máx} - \text{mín}} \right) \quad (4)$$

Os valores de máximo e mínimo utilizados na normalização, tanto das amostras, quanto dos mosaicos a serem classificados, foram os observados na base de dados.

Id	Class_name	Brightness	Diff_pixel	Landsat1	Landsat2	Landsat3	Landsat4	Max_diff	Mean_R1	Mean_R2	Mean_R3
11764	Agricultura	0,355758	0,334497	0,477724	0,806012	0,485102	0,833133	0,766054	0,307941	0,283577	0,176400
12175	Agricultura	0,378386	0,381913	0,822950	0,750698	0,475763	0,853295	0,663049	0,319263	0,314555	0,199812
16897	Agricultura	0,338610	0,473115	0,633501	0,687355	0,703442	0,664395	0,611008	0,309749	0,288581	0,192989
17580	Agricultura	0,319093	0,308450	0,789689	0,824125	0,800645	0,811749	0,730844	0,308086	0,268472	0,172718
17583	Agricultura	0,310919	0,353771	0,778787	0,820986	0,792727	0,776927	0,667174	0,307964	0,266921	0,176899
17887	Agricultura	0,355455	0,263547	0,477607	0,730619	0,818498	0,800476	0,366558	0,350091	0,320182	0,250994

Figura 25 Parte dos dados normalizados utilizados como amostras.

O número de neurônios na camada de entrada foi definido segundo o número de atributos por amostras a serem utilizados, sendo cada neurônio responsável por receber apenas uma entrada. Desse modo, tendo cada objeto 17 atributos como características, 17 será o número de neurônios na primeira camada (Figura 26).

O número de neurônios na camada de saída foi determinado segundo o número de classes a serem reconhecidas na classificação. Sendo as classes Agricultura, Água, Cerrado, Eucalipto, Floresta Estacional Decidual, Outros,

pastagem e Vereda, a resposta fornecida à camada de saída é um vetor com oito posições binárias (1 = pertence e 0 = não pertence). Sendo assim, a saída desejada por uma amostra apresentada da classe Cerrado seria  $\langle 0, 0, 1, 0, 0, 0, 0, 0 \rangle$ .




Figura 26 Trecho de uma rede MLP com duas camadas ocultas antes do treinamento

Mesmo possuindo apenas valores binários nos dados de saída de cada amostra de treinamento, o resultado da classificação obtido pela rede treinada serão valores compreendidos entre zero e um, contidos no contradomínio da função sigmoideal  $[1,0]$  utilizada. Estes valores serão adotados como o valor de pertinência de cada objeto na respectiva classe e como em Chini et al. (2008)



será adotado um modelo de competição (vencedor leva tudo) na decisão da classificação final.

O número de camadas escondidas, bem como o número de neurônios em cada uma delas é um processo empírico e determinado a partir de testes. Sendo assim, foram testadas redes com uma, duas e três camada(s) escondida(s) e diferentes números de neurônios em cada uma delas (Tabela 9).

Tabela 9 Arquiteturas testadas com diferentes números de neurônios e camadas ocultas.

Rede	Neurônios de Entrada	Camada(s) Oculta(s)	Neurônios de Saída
1	17	16	8
2	17	34	8
3	17	51	8
4	17	35_15	8
5	17	40_20	8
6	17	51_24	8
7	17	40_30_20	8
8	17	40_40_40	8
9	17	60_60_60	8
10	17	70_40_20	8

Todas as redes foram treinadas pelo algoritmo *Backpropagation* com passo de atualização dos pesos igual a 0,01; taxa de momento de 0,1 e um erro máximo propagado igual a zero. Em todos os treinamentos o conjunto de amostras foi apresentado de maneira aleatória, bem como a inicialização dos pesos dos neurônios entre os valores -1 e 1. O critério de parada adotado para o treinamento foi o de validação cruzada.

Definidas as arquiteturas, as planilhas contendo as amostras de treinamento e validação da rede foram convertidos para o formato do software (.pat), podendo ser vistos na Figura 27.

```

SNNS pattern definition file v4.2
generated at Sun Feb 26 21:09:41 2012

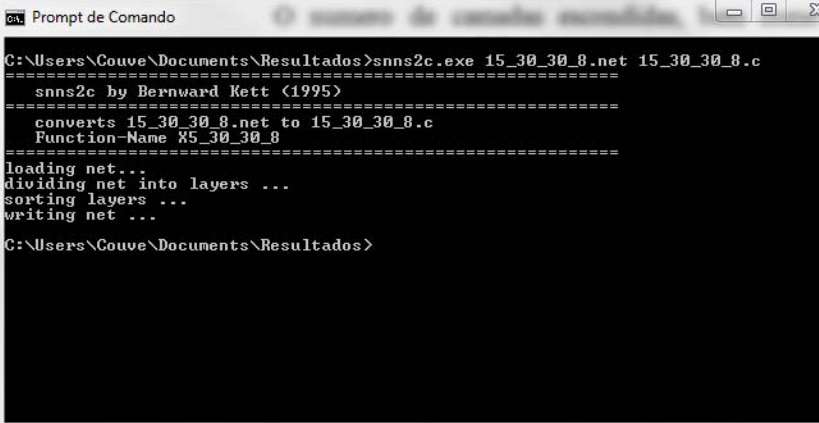
No. of patterns : 869
No. of input units : 17
No. of output units : 8

# Input pattern 1:
0.260678 0.169417 0.689558 0.676211 0.645 0.701394 0.328808 0.253816 0.231341 0.19843
0.258954 0.396488 0.670573 0.293911 0.541151 0.124129 0.191522
# Output pattern 1:
0 0 1 0 0 0 0 0
# Input pattern 2:
0.249744 0.164033 0.686676 0.66393 0.643909 0.701751 0.318366 0.243111 0.220792 0.193823
0.25232 0.371813 0.659603 0.304761 0.531908 0.122913 0.18033
# Output pattern 2:
0 0 1 0 0 0 0 0
# Input pattern 3:
0.253504 0.16511 0.685525 0.664257 0.635855 0.699771 0.318719 0.244936 0.224461 0.195819
0.258462 0.378423 0.660446 0.310628 0.531478 0.127244 0.178449
# Output pattern 3:
0 0 1 0 0 0 0 0
# Input pattern 4:
0.252448 0.180152 0.708579 0.67658 0.637544 0.726641 0.334428 0.249267 0.224989 0.18938
0.251386 0.380069 0.681514 0.295372 0.538664 0.123989 0.187064
# Output pattern 4:
0 0 1 0 0 0 0 0

```

Figura 27 Parte do arquivo de amostras de treinamento

Após o treinamento de cada rede, um arquivo .net é criado pelo software sendo responsável pelo armazenamento da topologia da RNA, suas unidades e ligações. Estes arquivos contendo os padrões de rede gerados pelo JavaNNS foram convertidos para arquivos fonte em linguagem de programação C pelo aplicativo snns2c.exe disponível na versão anterior do software (Figura 28).



```
C:\Users\Couve\Documents\Resultados>snns2c.exe 15_30_30_8.net 15_30_30_8.c
=====
snns2c by Bernward Kett (1995)
=====
converts 15_30_30_8.net to 15_30_30_8.c
Function-Name X5_30_30_8
=====
loading net...
dividing net into layers ...
sorting layers ...
writing net ...

C:\Users\Couve\Documents\Resultados>
```

Figura 28 Conversão de uma rede para a linguagem C

Para a classificação dos mosaicos, bem como as amostras de validação para os cálculos de precisão das redes, foi criada uma rotina em linguagem C (apêndice A) para a classificação de dados. Essa rotina lê as amostras contidas em um arquivo texto e cria um novo arquivo em mesmo formato com a classificação de cada amostra, segundo as características da rede treinada.

### 3.5.4 Medidas de precisão

Para a avaliação do mapeamento, foi coletado um terceiro conjunto independente de amostras para os cálculos de precisão do mesmo. Esse conjunto baseou-se no mapa de uso e cobertura do solo gerado por Scolforo e Carvalho (2006) para a estratificação das amostras. Desta forma, foram gerados 450 pontos aleatórios distribuídos em todas as imagens e fisionomias presentes.

Todos os pontos gerados, em cada uma das classes de cobertura do solo, foram checados quanto a sua veracidade com o auxílio das imagens Rapideye e

do *software* Google Earth. Pontos lançados na divisa de dois, ou mais objetos, foram excluídos para que não houvesse qualquer comprometimento dos resultados.

## 4 Resultados e Discussão

### 4.1 Segmentação

Os parâmetros ideais de uma segmentação podem diferir de acordo com a região. A presença de uma área muito fragmentada e heterogênea faz com que valores de escala mais baixos sejam utilizados, de modo que cada objeto formado contenha apenas *pixels* de uma mesma classe (Figura 29).

Uma vez que a área em questão conta com uma paisagem diversificada entre planícies, montanhas e vales com diferentes tipos de cobertura, optou-se pela seleção dos parâmetros que produziram a melhor segmentação independente da região, ou seja, para os três diferentes mosaicos foram adotados os mesmos parâmetros de Forma, Compacidade e Escala.

Os valores que apresentaram melhores resultados, de um modo geral, foram 0,4 para os parâmetros Forma e Compacidade, e 350 para o parâmetro Escala.




Figura 29 Segmentação obtida em uma área altamente fragmentada

O nível de detalhamento alcançado em um mapeamento por meio da análise baseada em objetos deve-se à resolução espacial da imagem a ser classificada e de uma segmentação de sucesso. Observa-se na Figura 29 que mesmo regiões altamente fragmentadas tiveram seus objetos bem definidos e em correspondência com a paisagem. O mesmo ocorreu em outras regiões da área de estudo, demonstrando o sucesso e a eficiência do processo de segmentação.

#### 4.2 Treinamento das Redes Neurais

Todas as arquiteturas testadas apresentaram uma convergência satisfatória do erro, sendo os gráficos de treinamento de cada uma delas apresentados no Apêndice B e os dados referentes aos treinamentos vistos na Tabela 10.

Tabela 10 Resultados dos treinamentos

Rede	Épocas	Erro	Validação da Rede
1	55.000	0,222446	0,9892
2	60.000	0,210362	0,9919
3	55.000	0,195837	0,9919
4	25.000	0,022392	0,9866
5	22.000	0,020633	0,9892
6	19.000	0,030989	0,9919
7	8.500	0,011953	0,9866
8	15.000	0,003716	0,9973
9	12.000	0,005294	0,9919
10	7.000	0,023566	0,9946

Todas as redes testadas apresentaram valores de precisão extremamente similares em seus treinamentos, diferenciando-se mais pelo número de iterações (épocas) em que houve a convergência e estabilidade do erro.

O número de iterações para o treinamento de cada rede apresentou-se intimamente ligado ao número de camadas ocultas e neurônios em suas arquiteturas. Por possuírem apenas uma camada oculta e por conseguinte maior dificuldade em aprender padrões complexos, as redes 1, 2 e 3 foram as que necessitaram de um maior número de iterações para o treinamento.

O número de épocas de treinamento não deve ser encarado como o tempo de treinamento, uma vez que arquiteturas com número de neurônios muito grande fazem com que cada iteração seja mais demorada devido ao ajuste de todos os pesos. Todas as redes apresentaram tempo de treinamento similar e sem grande destaque para os resultados deste estudo.

### 4.3 Classificação dos dados

Após o treinamento, todas as redes foram convertidas para códigos fontes em linguagem C pelo aplicativo “snns2c” e gerada uma classificação dos três mosaicos pela rotina desenvolvida nesse estudo (Apêndice A).

Os arquivos contendo os dados de treinamento das redes em linguagem C, juntamente com a rotina desenvolvida, podem ser utilizados em qualquer computador sem necessidade da instalação de softwares de Redes Neurais Artificiais, podendo ainda ser utilizado em outros trabalhos conduzidos na região, desde que seja seguida a mesma metodologia.

Por se tratar de uma rotina em linguagem C e trabalhar com planilhas de texto (.txt), esta metodologia permite a classificação de um arquivo com milhares de objetos em poucos segundos, podendo ser muito útil na classificação de áreas extensas como o estado de Minas Gerais, uma vez que são necessárias 1.234 cenas Rapideye para a cobertura de toda a região.

O resultado da amostragem a ser confrontada com os mapas de classificação pode ser vistos na **Figura 30** e Tabela 11. É importante observar a boa distribuição espacial das amostras assegurando assim a representatividade do processo de validação.




Figura 30 Amostras de validação do mapa



Tabela 11 Número de amostras utilizadas na validação do mapa

Classe	Número de amostras
Agricultura	34
Água	34
Cerrado	106
Decídua	102
Eucalipto	14
Outros	49
Pastagem	62
Vereda	19
<b>Total</b>	<b>420</b>

Com a interseção dos pontos amostrais e os mapas obtidos por cada rede, obteve-se a matriz de confusão para cada uma delas (Apêndice C) e seus respectivos valores de Índice Kappa, Acurácia Global, do Usuário e Produtor (Tabela 12).

Tabela 12 Valores de precisão do mapeamento para cada rede

Redes	Acurácia Usuário		Acurácia Produtor															
	Ac. Global	Índice Kappa	Classes								Classes							
			I	II	III	IV	V	VI	VII	VIII	I	II	III	IV	V	VI	VII	VIII
1	0,8071	0,7683	0,9355	0,970	0,9167	0,9231	0,9286	0,5000	0,6111	1	0,8529	0,9706	0,8302	0,8235	0,9286	0,8367	0,5323	0,9474
2	0,8000	0,7595	0,9655	1	0,9184	0,9310	0,9286	0,5286	0,5143	0,9500	0,8235	0,9412	0,8491	0,7941	0,9286	0,7551	0,5806	1
3	0,8095	0,7711	0,9355	1	0,9375	0,9111	0,9286	0,5467	0,5556	0,9474	0,8529	0,9412	0,8491	0,8039	0,9286	0,8367	0,5645	0,9474
4	0,8095	0,7713	0,9118	1	0,9239	0,8947	0,8125	0,5333	0,6140	1	0,9118	0,9412	0,8019	0,8333	0,9286	0,8163	0,5645	1
5	0,8095	0,7707	0,9333	1	0,8958	0,8854	0,8667	0,5616	0,6034	1	0,8235	0,9706	0,8113	0,8333	0,9286	0,8367	0,5645	1
6	0,8095	0,7711	0,9677	1	0,9140	0,8936	0,9286	0,5256	0,6034	1	0,8824	0,9706	0,8019	0,8235	0,9286	0,8367	0,5645	1
7	0,8310	0,7963	0,7805	1	0,9271	0,8738	0,9286	0,6094	0,6800	1	0,9412	0,9706	0,8396	0,8824	0,9286	0,7959	0,5484	1
8	0,8095	0,7710	0,8824	0,970	0,8878	0,9111	0,9286	0,5652	0,5968	1	0,8824	0,9706	0,8208	0,8039	0,9286	0,7959	0,5968	1
9	0,8095	0,7707	0,9032	1	0,9175	0,9043	0,9286	0,5417	0,5667	1	0,8235	0,9706	0,8396	0,8333	0,9286	0,7959	0,5484	1
10	0,8119	0,7741	0,9091	0,942	0,9348	0,9063	0,9286	0,5200	0,6182	0,9500	0,8824	0,9706	0,8113	0,8529	0,9286	0,7959	0,5484	1

Onde:

Classe I: Agricultura

Classe V: Eucalipto

Classe II: Água

Classe VI: Outros

Classe III: Cerrado

Classe VII: Pastagem

Classe IV: Floresta Estacional Decidual

Classe VIII: Vereda

A rede de número sete foi a que apresentou os maiores valores de acurácia global e índice Kappa, sendo o resultado da classificação visto na Figura 31. Visualmente nota-se a qualidade da classificação expressa nas medidas de acurácia (Tabela 12), uma vez que nenhuma técnica de pós-classificação ou edição foi adotada.




Figura 31 Classificação dos mosaicos obtida pela rede 7

O resultado obtido na segmentação das imagens foi crucial na determinação do detalhamento dos mapas finais conforme pode ser observado na Figura 32.

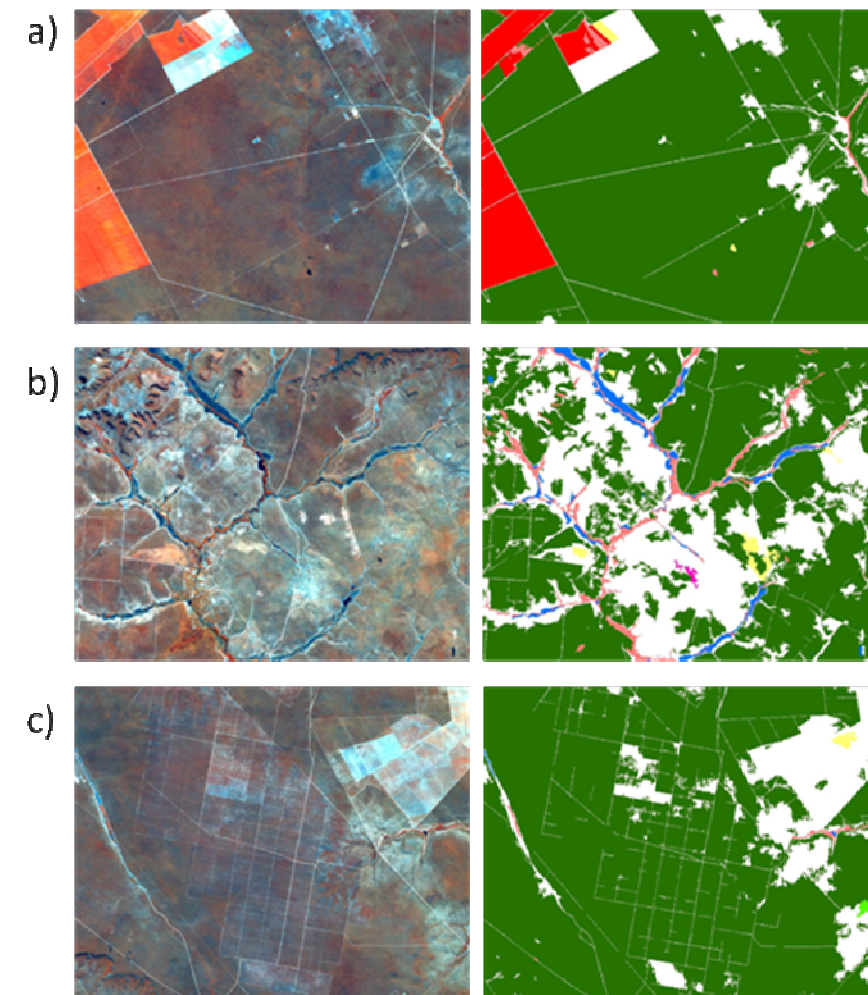


Figura 32 Nível de detalhamento do mapeamento. a) área de cerrado e eucalipto; b) veredas e áreas de inundação; c) estradas em meio a um cerrado em regeneração.

Assim como na validação das redes, todos os mapas apresentaram valores de exatidão muito próximos, não apresentando uma correlação clara com o número de camadas ocultas e neurônios nas mesmas.

Com bons valores de precisão nas demais, as classes Outros e Pastagem certamente são responsáveis pela queda nos valores de acurácia global e índice Kappa. Mesmo para um analista experiente, em algumas situações, a diferenciação de áreas como pastagem, áreas degradadas e agricultura em diferentes períodos fenológicos pode se apresentar como uma tarefa de difícil solução. O uso de técnicas de análise multivariada, técnicas de KDD (*Knowledge Discovery in Databases*) como a mineração de dados, podem ser incorporadas à metodologia a fim de determinar os melhores atributos a serem utilizados na distinção das classes, elevando ainda mais a precisão do mapeamento.

As classes Cerrado, Floresta Estacional Decidual e Vereda, apresentaram uma alta conformidade com as amostras de validação. Com valores de precisão próximos de 90% e chegando a 100%, no caso das Veredas, a metodologia mostrou-se eficiente no reconhecimento do comportamento sazonal e espectral das fisionomias nativas da região.

Tabela 13 apresenta as proporções encontradas na cobertura e uso do solo para cada classe na região obtidas pelo mapa da rede 7.

Tabela 13 Proporção encontrada entre as classes no mapa da rede 7

Classe	Número de objetos	Área (ha)	%
Agricultura	2.204	17.941,30	2,49
Água	1.938	15.186,15	2,10
Cerrado	8.717	252.325,46	34,96
Floresta Estacional Decidual	11.161	231.416,80	32,06
Eucalipto	334	4.813,87	0,67
Outros	18.972	102.477,52	14,20
Pastagem	9.663	91.405,30	12,66
Vereda	645	6.204,36	0,86
<b>Total</b>	<b>53.634</b>	<b>721.770,75</b>	<b>100,00</b>

Apresentando cerca de 70% de cobertura do solo por floresta nativa, a região se destaca por possuir os maiores fragmentos de floresta do estado. Representando uma parcela quase que mínima na cobertura do solo e sendo muito bem delimitadas e mapeadas, as Veredas apresentam-se como uma vegetação bem característica da região e de grande importância ambiental. Região tipicamente de brejos onde há afloramento do lençol freático e nascentes de água, essas áreas são um grande abrigo para fauna e flora locais, devendo-se assim conhecer toda a sua extensão para preservação e manutenção.

Devido à sua alta resolução temporal (diária), as imagens do satélite MODIS são utilizadas no mapeamento de savanas e florestas estacionais com sucesso em diversos trabalhos, como nos estudos de Hüttich et al. (2009, 2011) e Silveira et al. (2008). Entretanto a falta de compatibilidade de sua resolução espacial com as imagens Rapideye tornou inviável a sua utilização direta no processo de classificação.

A série temporal de imagens MODIS utilizadas no presente estudo desempenhou papel fundamental na determinação da época de aquisição das imagens Landsat TM. Estas por sua vez, forneceram informações valiosas sobre as variações espectro-temporais das fisionomias encontradas na região. Integrando a informação espacial e espectral das imagens Rapideye com as informações espectrais e temporais das imagens Landsat TM, a técnica de segmentação de imagens permitiu unir o que há de melhor em ambas, sem que haja perda ou o comprometimento de informação por suas partes, o que não ocorre quando aplicado outras técnicas como a fusão de imagens. Trabalhos como o de Gibbes et al. (2010) integrando imagens Ikonos e Landsat TM na classificação de savanas por meio de análises baseadas em objetos também ressaltam a eficiência desta metodologia, ficando aqui confirmada.

Sendo assim, a metodologia proposta mostrou-se altamente eficiente no mapeamento de uso e cobertura do solo de regiões com grande diversidade

florística e de classes de ocupação, sendo a utilização de dados de múltiplas fontes incorporadas às técnicas de análises baseadas em objetos desejável e recomendada.

## 5 Conclusões

Apesar da heterogeneidade da paisagem que compõe os três mosaicos a opção de seleção dos parâmetros de segmentação (Forma, Compacidade e Escala), independente das características de cada região foi acertada, uma vez que produziu objetos bem definidos em todos os mosaicos. Esse resultado é extremamente importante do ponto de vista técnico, pois permitiu alcançar um bom nível de detalhamento no mapa, bem como uma boa classificação.

Uma das grandes vantagens observada na análise baseada em objetos é a integração de dados de múltiplas fontes e diferentes resoluções sem a necessidade do uso de técnicas de fusão de imagens.

O nível de detalhamento alcançado em um mapeamento por meio da análise baseada em objetos deve-se à resolução espacial da imagem a ser classificada e de uma segmentação de sucesso.

O uso de séries temporais de imagens na detecção do comportamento sazonal da vegetação é crucial para o mapeamento de florestas estacionais e as imagens Landsat TM junto às imagens Rapideye apresentaram ótima adequação, ficando aqui recomendado seu uso.

A técnica de Redes Neurais artificiais mostrou-se eficiente na classificação de objetos criados a partir de dados de múltiplos sensores e capaz de aprender os padrões de classificação através de diferentes arquiteturas testadas, diferindo-se apenas no número de iterações necessárias para que ocorra o aprendizado. O número de camadas ocultas nas redes *Mult Layer Perceptron*, bem como o número de neurônios em cada uma delas, não apresentou relações claras com os valores de precisão, dando a entender que esse tipo de rede pode ser usado com sucesso na classificação de dados orbitais nas mais diversas arquiteturas.



Sendo assim, a metodologia proposta por este estudo apresenta-se como uma boa alternativa para o mapeamento de uso e cobertura do solo da região. Com grande potencial para ser aplicado em demais áreas do estado e do país, onde a diversidade encontrada é similar e muitas das vezes menor, o uso de dados de múltiplas fontes, técnicas de análises baseadas em objetos, e classificação por Redes Neurais Artificiais fica aqui recomendado.

**REFERÊNCIAS**

ACERBI JUNIOR, F. W.; CLEVERS, J. G. P. W.; SCHAEPMAN, M. E. The assessment of multi-sensor image fusion using wavelet transforms for mapping the Brazilian Savanna. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 8, n. 4, p. 278-288, 2006.

ANDERSEN, T. et al. Análise orientada a objetos de dados de sensoriamento remoto para a obtenção de parâmetros aquáticos/terrestres. In: BLASCHKE, T.; KUX, H. (Ed.). **Sensoriamento remoto e SIG avançados: novos sistemas sensores métodos inovadores**. São Paulo: Oficina de Textos, 2004. p. 286.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: STROBL, J. (Ed.). **Angewandte geographische informationsverarbeitung XII**. Karlsruhe: H. W. Verlag, 2000. p. 12-23.

BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Clarendon, 1995. 482 p.

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

BRADTER, U. et al. Prediction of National Vegetation Classification communities in the British uplands using environmental data at multiple spatial scales, aerial images and the classifier random forest. **Journal of Applied Ecology**, Oxford, v. 48, n. 4, p. 1057-1065, Aug. 2011.

BREIMAN, L. Random forests. **Machine Learning**, Boston, v. 45, n. 1, p. 5-32, Oct. 2001.

CARVALHO, L. M. T. et al. Selection of imagery data and classifiers for mapping Brazilian semideciduous Atlantic forests. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 5, n. 3, p. 173-186, June 2004.

CARVALHO, L. M. T.; SCOLFORO, J. R. S. **Inventário florestal de Minas Gerais: monitoramento da flora nativa 2005-2007**. Lavras: UFLA, 2008. 357 p.

CHINI, M. et al. Comparing statistical and neural network methods applied to very high resolution satellite images showing changes in man-made?: structures at rocky flats. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 46, n. 6, p. 1812-1821, Dec. 2008.

CLARK, M. L. et al. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: a case study in the Dry Chaco ecoregion of South America. **Remote Sensing of Environment**, New York, v. 114, n. 11, p. 2816-2832, Nov. 2010.

DEFINIENS. **Definiens eCognition developer 8**: reference book. München, 2009. 276 p.

ERBEK, F. S.; ÖZKAN, C.; TABERNER, M. Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 9, p. 1733-1748, Sept. 2004.

GHIMIRE, B.; ROGAN, J.; MILLER, J. Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic. **Remote Sensing Letters**, Washington, v. 1, n. 1, p. 45-54, Jan. 2010.

GIBBES, C. et al. Application of object based classification and high resolution satellite imagery for savanna ecosystem analysis. **Remote Sensing**, New York, v. 2, n. 12, p. 2748-2772, Dec. 2010.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. **Pattern Recognition Letters**, Amsterdam, v. 27, n. 4, p. 294-300, Apr. 2006.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: E. Blucher, 2000. 509 p.

GÖRGENS, E. B. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006. 84 p. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2006.

GÖRGENS, E. B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, Viçosa, MG, v. 33, n. 6, p. 1141-1147, nov./dez. 2009.

GURGEL, H. D. C.; FERREIRA, N. J.; LUIZ, A. J. B. Estudo da variabilidade do NDVI sobre o Brasil, utilizando-se a análise de agrupamentos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 7, n. 1, p. 85-90, 2003.

HAN, J. et al. Comparison of neuro-fuzzy, neural network, and maximum likelihood classifiers for land cover classification using IKONOS multispectral data. **Geoscience and Remote Sensing Symposium**, New York, v. 6, p. 3471-3473, June 2002.

HAYKIN, S. S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HEINL, M. et al. Classifiers vs. input variables: the drivers in image classification for land cover mapping. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 11, n. 6, p. 423-430, Dec. 2009.

HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, New York, v. 59, n. 3, p. 440-451, 1997.

HÜTTICH, C. et al. Assessing effects of temporal compositing and varying observation periods for large-area land-cover mapping in semi-arid ecosystems: implications for global monitoring. **Remote Sensing of Environment**, New York, v. 115, n. 10, p. 2445-2459, Oct. 2011.

\_\_\_\_\_. Integrating in-situ, Landsat, and MODIS data for mapping in Southern African savannas: experiences of LCCS-based land-cover mapping in the Kalahari in Namibia. **Environmental Monitoring and Assessment**, Dordrecht, v. 176, n. 1/4, p. 531-547, 2011.

\_\_\_\_\_. On the suitability of MODIS time series metrics to map vegetation types in dry savanna ecosystems: a case study in the Kalahari of NE Namibia. **Remote Sensing**, New York, v. 1, n. 4, p. 620-643, 2009.

JANOTH, J. et al. Procedimentos baseados em segmentação para análise de mudanças e classificação florestal com dados de satélite de alta resolução. In: BLASCHKE, T.; KUX, H. (Ed.). **Sensoriamento remoto e SIG: métodos inovadores**. São Paulo: Oficina de Textos, 2004. p. 286.

JARVIS, C. H.; STUART, N. The sensitivity of a neural network for classifying remotely sensed imagery. **Computers and Geosciences**, New York, v. 22, n. 9, p. 959-967, 1996.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 36, n. 4, p. 1228-1249, Aug. 1998.

KAVZOGLU, T. Increasing the accuracy of neural network classification using refined training data. **Environmental Modelling & Software**, Oxfordshire, v. 24, n. 7, p. 850-858, July 2009.

KOVACS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. 4. ed. São Paulo: Livraria da Física, 2006. 174 p.

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. 4<sup>th</sup> ed. New York: J. Wiley, 2000. 736 p.

MOREIRA, R. C. **Influência do posicionamento e da largura de bandas de sensores remotos e dos efeitos atmosféricos na determinação de índices de vegetação**. 2000. 179 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2000.

NATURAL RESOURCES CANADA. **Pre-processing**. Vancouver, 2008. Disponível em: <<http://www.nrcan.gc.ca/earth-sciences/geography-boundary/remote-sensing/fundamentals/2321>>. Acesso em: 10 mar. 2012.

NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm**. Davis: CRC, 2006. 184 p.

NEURÔNIOS e neurotransmissores: imagens, ilustrações e funcionamento. Disponível em: <<http://www.psiqweb.med.br/site/?area=NO/LerNoticia&idNoticia=290>>. Acesso em: 10 mar. 2012.

OLIVEIRA, T. C. A. et al. Mapping deciduous forests by using time series of filtered MODIS NDVI and neural networks. **Cerne**, Lavras, v. 16, n. 2, p. 123-130, abr./jun. 2010.

PRATOLA, C. et al. Characterizing land cover from X-band COSMO-SkyMed images by neural networks. In: URBAN REMOTE SENSING EVENT, 1., 2011, Rome. **Proceedings...** Rome: JURSE, 2011. p. 49-52.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: EARTH RESOURCES PROGRAM SYMPOSIUM, 3., 1973, Washington. **Proceedings...** Washington: ERTS, 1973. p. 309-317.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. (Ed.). **Parallel distributed processing: explorations in the microstructure of cognition**. Cambridge: MIT, 1986. v. 1, p. 318-362.

SCHIEWE, J. Segmentation of high resolution remotely sensed data: concepts, applications and problems. In: SYMPOSIUM ON GEOSPATIAL THEORY, PROCESSING AND APPLICATIONS, 1., 2002, Ottawa. **Proceedings...** Vechta: University of Vechta, 2002. Disponível em: <<http://www.isprs.org/proceedings/XXXIV/part4/pdfpapers/358.pdf>>. Acesso em: 10 abr. 2012.

SCHOWENGERDT, R. A. **Remote sensing models and methods for image processing**. San Diego: Academic, 2007. 560 p.

SCOLFORO, J. R.; CARVALHO, L. M. T. **Mapeamento e inventário da flora nativa e dos reflorestamentos de Minas Gerais**. Lavras: UFLA, 2006. 288 p.

SILVEIRA, E. M. D. O. et al. The assessment of vegetation seasonal dynamics using multitemporal NDVI and EVI images derived from MODIS. **Cerne**, Lavras, v. 14, n. 2, p. 177-184, abr./jun. 2008.

SMITH, A. Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm. **Journal of Spatial Science**, Perth, v. 55, n. 1, p. 69-79, Jan. 2010.

STATHAKIS, D.; VASILAKOS, A. Comparison of computational intelligence based classification techniques for remotely sensed optical image classification. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 44, n. 8, p. 2305-2318, Aug. 2006.

TAN, K. C.; LIM, H. S.; JAFRI, M. Z. M. Comparison of neural network and maximum likelihood classifiers for land cover classification using landsat multispectral data. In: INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS CONFERENCE, 2., 2011, Langkawi. **Proceedings...** Langkawi: IEEE, 2011. p. 241-244.

UNIVERSITÄT TUBINGEN. **JavaNNS**: Java Neural Network Simulator. Tübingen, 2011. Disponível em: <[http://www.ra.cs.uni-tuebingen.de/software/JavaNNS/welcome\\_e.html](http://www.ra.cs.uni-tuebingen.de/software/JavaNNS/welcome_e.html)>. Acesso em: 10 mar. 2012.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, Oxford, v. 1, n. 1, p. 9-23, Jan. 2008.






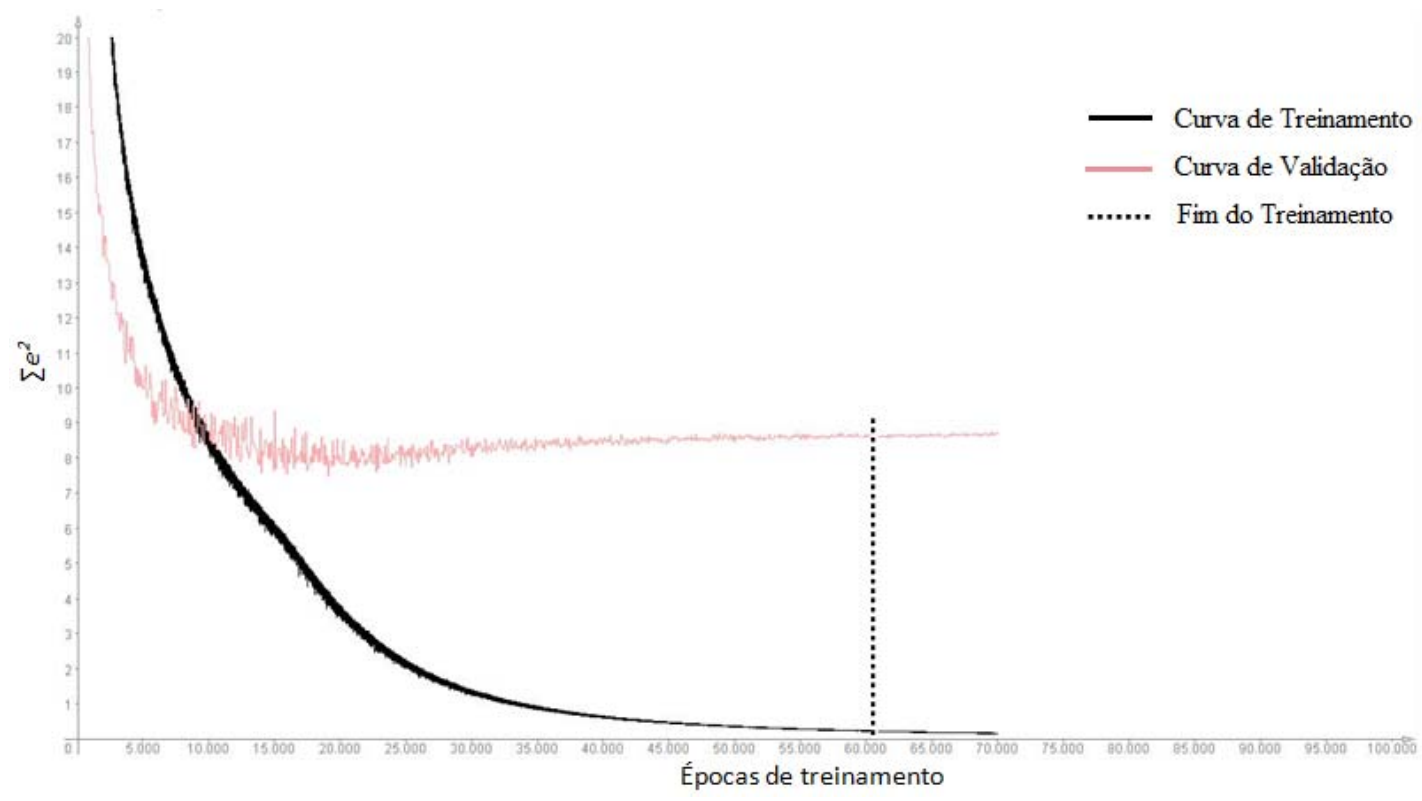
## Apêndice B

Gráficos de treinamento das redes


Rede 1: 17 – 16 – 8




Rede 2 (17 - 34 - 8)




Rede 3 (17 - 51 - 8)



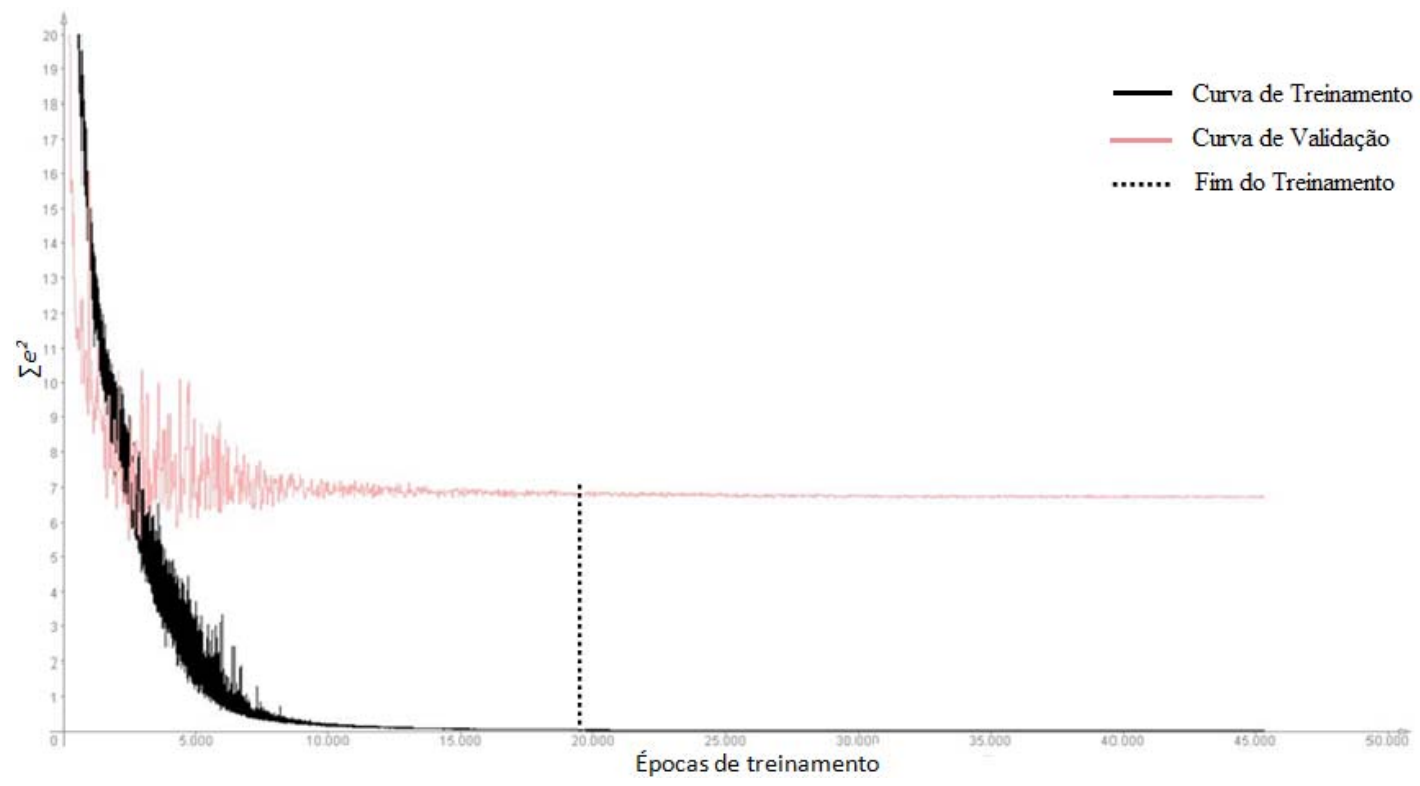
Rede 4 (17 - 35 - 15 - 8)




Rede 5 (17 - 40 - 20 - 8)



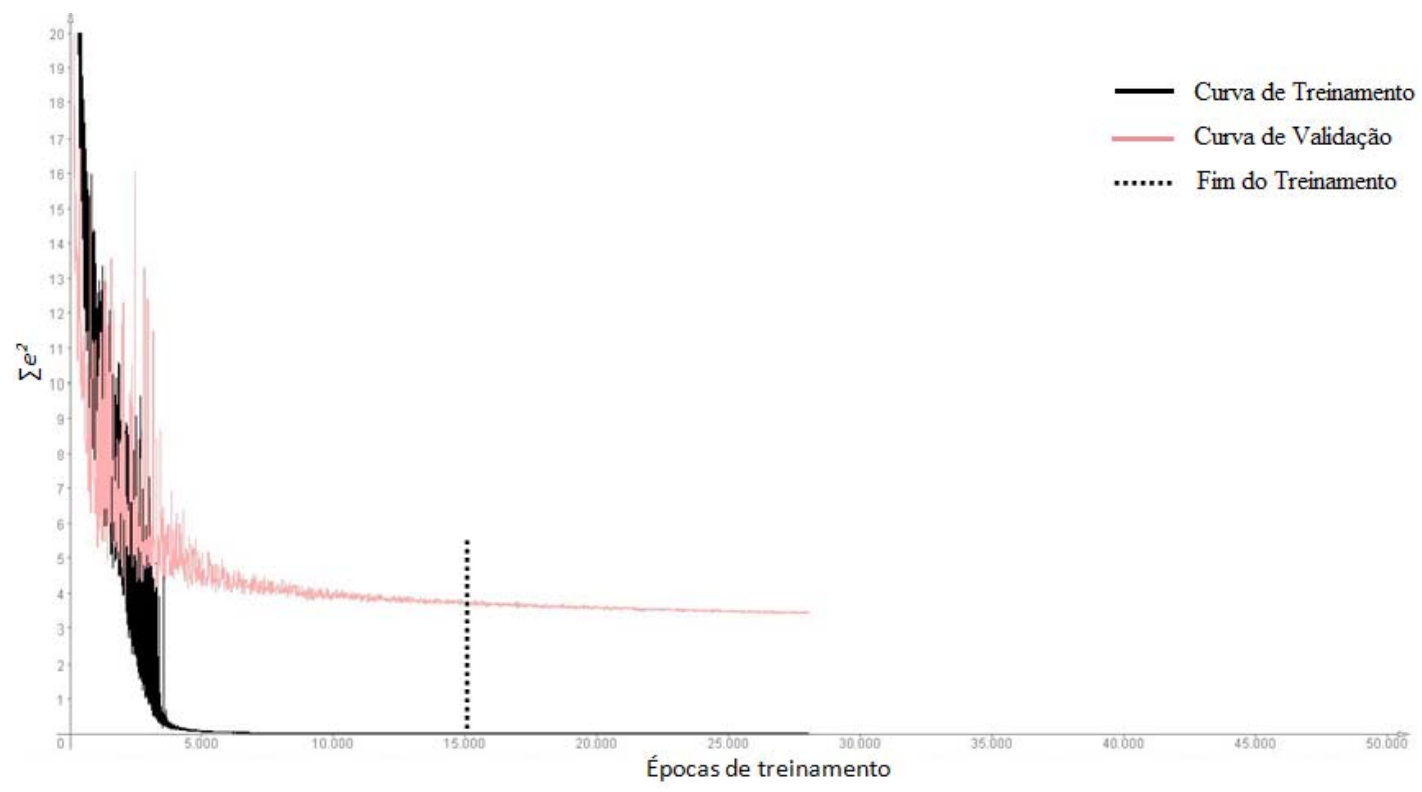
Rede 6 (17 – 51 – 24 – 8)



Rede 7 (17 – 40 – 30 – 20 – 8)




Rede 8 (17 - 40 - 40 - 40 - 8)






Rede 9 (17 - 60 - 60 - 60 - 8)



Rede 10 (17 - 70 - 40 - 20 - 8)



**Apêndice C** - Matrizes de confusão dos mapas produzidos por cada rede.

## Rede 1

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	<b>Total</b>
Agricultura	29				1			1	<b>31</b>
Água		33		1					<b>34</b>
Cerrado	1		88	6			1		<b>96</b>
Decídua				84		1	6		<b>91</b>
Eucalipto	1				13				<b>14</b>
Outros		1	16	2		41	22		<b>82</b>
Pastagem	3		2	9		7	33		<b>54</b>
Vereda								18	<b>18</b>
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 2

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	28				1				29
Água		32							32
Cerrado	1		90	5			2		98
Decídua				81			6		87
Eucalipto	1				13				14
Outros		1	14			37	18		70
Pastagem	4		2	16		12	36		70
Vereda		1						19	20
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 3

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	29				1			1	31
Água		32							32
Cerrado	1		90	4			1		96
Decídua			1	82			7		90
Eucalipto	1				13				14
Outros		1	13	1		41	19		75
Pastagem	3		2	15		8	35		63
Vereda		1						18	19
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 4

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	31		2		1				<b>34</b>
Água		32							<b>32</b>
Cerrado			85	6			1		<b>92</b>
Decídua			1	85		1	8		<b>95</b>
Eucalipto	1		2		13				<b>16</b>
Outros		2	14	1		40	18		<b>75</b>
Pastagem	2		2	10		8	35		<b>57</b>
Vereda								19	<b>19</b>
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 5

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	28		1		1				<b>30</b>
Água		33							<b>33</b>
Cerrado			86	8			2		<b>96</b>
Decídua			1	85		1	9		<b>96</b>
Eucalipto	1		1		13				<b>15</b>
Outros		1	15			41	16		<b>73</b>
Pastagem	5		2	9		7	35		<b>58</b>
Vereda								19	<b>19</b>
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 6

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	30				1				31
Água		33							33
Cerrado			85	7			1		93
Decídua			2	84			8		94
Eucalipto	1				13				14
Outros		1	17	1		41	18		78
Pastagem	3		2	10		8	35		58
Vereda								19	19
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 7

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	32		7		1	1			41
Água		33							33
Cerrado			89	6			1		96
Decídua			2	90		1	10		103
Eucalipto	1				13				14
Outros		1	7			39	17		64
Pastagem	1		1	6		8	34		50
Vereda								19	19
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 8

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total geral
Agricultura	30		3		1				<b>34</b>
Água		33	1						<b>34</b>
Cerrado			87	9			2		<b>98</b>
Decídua			2	82			6		<b>90</b>
Eucalipto	1				13				<b>14</b>
Outros		1	12			39	17		<b>69</b>
Pastagem	3		1	11		10	37		<b>62</b>
Vereda								19	<b>19</b>
<b>Total geral</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 9

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	28		2		1				<b>31</b>
Água		33							<b>33</b>
Cerrado	1		89	6			1		<b>97</b>
Decídua			1	85			8		<b>94</b>
Eucalipto	1				13				<b>14</b>
Outros		1	12	1		39	19		<b>72</b>
Pastagem	4		2	10		10	34		<b>60</b>
Vereda								19	<b>19</b>
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>

## Rede 10

	Agricultura	Água	Cerrado	Decídua	Eucalipto	Outros	Pastagem	Vereda	Total
Agricultura	30		2		1				<b>33</b>
Água		33	1			1			<b>35</b>
Cerrado			86	5			1		<b>92</b>
Decídua			2	87		1	6		<b>96</b>
Eucalipto	1				13				<b>14</b>
Outros		1	13	1		39	21		<b>75</b>
Pastagem	2		2	9		8	34		<b>55</b>
Vereda	1							19	<b>20</b>
<b>Total</b>	<b>34</b>	<b>34</b>	<b>106</b>	<b>102</b>	<b>14</b>	<b>49</b>	<b>62</b>	<b>19</b>	<b>420</b>



## Apêndice D

Trecho do arquivo de uma rede treinada

```

1  SNNS network definition file V1.4-3D
2  generated at Tue Feb 28 09:33:37 2012
3
4  network name : 17-35-15-8
5  source files :
6  no. of units : 75
7  no. of connections : 1240
8  no. of unit types : 0
9  no. of site types : 0
10
11
12 learning function : BackpropMomentum
13 update function   : Topological_Order
14
15
16 unit default section :
17
18 act      | bias      | st | subnet | layer | act func      | out func
19 -----|-----|---|-----|-----|-----|-----
20 0.00000 | 0.00000 | h  |      0 |      1 | Act_Logistic | Out_Identity
21 -----|-----|---|-----|-----|-----|-----
22
23
24 unit definition section :
25
26 no. | typeName | unitName | act      | bias      | st | position | act func
27 ---|-----|-----|-----|-----|---|-----|-----
28 1 |          | noName  | 0.26541 | -0.21232 | i  | 1, 1, 1 |||
29 2 |          | noName  | 0.22221 | -0.33927 | i  | 1, 2, 1 |||
30 3 |          | noName  | 0.13329 | -0.95605 | i  | 1, 3, 1 |||
31 4 |          | noName  | 0.14473 | 0.09745  | i  | 1, 4, 1 |||
32 5 |          | noName  | 0.14702 | -0.30271 | i  | 1, 5, 1 |||
33 6 |          | noName  | 0.12948 | 0.50652  | i  | 1, 6, 1 |||
34 7 |          | noName  | 0.54416 | 0.58409  | i  | 1, 7, 1 |||
35 8 |          | noName  | 0.33648 | -0.15751 | i  | 1, 8, 1 |||
36 9 |          | noName  | 0.31548 | -0.42686 | i  | 1, 9, 1 |||

```

```

105
106 connection definition section :
107
108 target | site | source:weight
109 -----|-----|-----
110 18 | | | 1:-3.81942, 2: 0.83659, 3: 1.89288, 4: 0.46038, 5: 4.89534, 6:-0.
111 10:-2.07994, 11:-2.33476, 12:-2.85111, 13:-1.02056, 14: 0.52597, 15: 0.
112 19 | | | 1:-0.26507, 2:-1.39020, 3:-1.85869, 4:-1.36804, 5:-0.49049, 6: 0.
113 10:-0.58147, 11:-0.63454, 12: 0.60867, 13: 0.99525, 14: 2.70804, 15:-0.
114 20 | | | 1: 0.29529, 2:-0.09227, 3:-3.95530, 4: 2.31156, 5: 2.31673, 6:-0.
115 10: 2.30242, 11:-0.71794, 12:-1.40166, 13:-1.03383, 14:-4.30842, 15:-0.
116 21 | | | 1:-3.91916, 2:-1.99918, 3: 2.98705, 4:-3.28894, 5:-1.05053, 6: 0.
117 10:-2.82932, 11:-3.37554, 12:-5.17400, 13:-3.12495, 14: 6.11867, 15:-0.
118 22 | | | 1: 0.70602, 2: 2.13299, 3: 1.33342, 4: 0.68804, 5: 1.92616, 6: 0.
119 10: 0.39804, 11: 1.15432, 12: 2.62597, 13:-0.36866, 14:-0.66871, 15: 0.
120 23 | | | 1:-0.83106, 2: 0.31023, 3: 0.61457, 4:-0.26328, 5:-0.54855, 6: 0.
121 10: 0.67633, 11: 0.11112, 12: 0.24942, 13: 1.05324, 14:-0.18197, 15: 0.
122 24 | | | 1:-3.54904, 2: 0.57725, 3: 8.69208, 4:-0.46621, 5: 0.20575, 6: 0.
123 10:-2.43624, 11:-2.22352, 12:-5.45820, 13:-1.36583, 14: 5.49592, 15:-0.
124 25 | | | 1: 6.69190, 2: 1.65039, 3:-3.12003, 4: 0.01871, 5:-1.98003, 6:-0.
125 10: 3.44775, 11: 3.00124, 12: 8.85872, 13: 1.53731, 14:-2.74436, 15: 0.
126 26 | | | 1:-3.04045, 2: 1.32713, 3: 3.88328, 4: 0.27217, 5: 2.99612, 6: 0.
127 10:-2.11137, 11:-2.69797, 12:-3.88882, 13:-0.89789, 14: 0.44725, 15:-0.
128 27 | | | 1: 1.15058, 2: 1.56692, 3: 2.12004, 4: 2.29392, 5: 1.95777, 6: 0.
129 10: 0.27331, 11: 0.63047, 12:-0.04619, 13: 2.59363, 14: 0.07655, 15: 0.
130 28 | | | 1: 0.02133, 2: 2.56111, 3:-3.01857, 4: 2.18936, 5: 0.20754, 6: 0.
131 10: 0.07100, 11:-0.83994, 12:-1.38901, 13:-0.00403, 14:-1.97967, 15:-0.

```