

UNIVERSIDADE FEDERAL DE VIÇOSA

ALINE DANIELE JACON

**ANÁLISE DE SÉRIES TEMPORAIS EVI/MODIS PARA DISCRIMINAÇÃO
DE FITOFISIONOMIAS DO CERRADO**

VIÇOSA – MINAS GERAIS

2013

ALINE DANIELE JACON

**ANÁLISE DE SÉRIES TEMPORAIS EVI/MODIS PARA DISCRIMINAÇÃO
DE FITOFISIONOMIAS DO CERRADO**

Monografia apresentada ao Departamento de Engenharia Florestal da Universidade Federal de Viçosa, como parte das exigências do curso de graduação em Engenharia Florestal.

Orientador: Prof. José Marinaldo Gleriani

VIÇOSA – MINAS GERAIS

2013

Esta Monografia foi aprovada pela Banca Examinadora como requisito à conclusão do curso de Engenharia Florestal, do Departamento de Engenharia Florestal, da Universidade Federal de Viçosa – UFV, em 25 de novembro de 2013.

Professor José Marinaldo Gleriani

Presidente/ Orientador/ UFV, Viçosa-MG

Professor Vicente Paulo Soares

Membro da Banca/ UFV, Viçosa-MG

Professor Sebastião Venâncio Martins

Membro da Banca/ UFV, Viçosa-MG

*“Mesmo que já tenha feito uma longa caminhada,
sempre haverá mais um caminho a percorrer”.*

Santo Agostinho

AGRADECIMENTOS

À Universidade Federal de Viçosa (UFV), ao Departamento de Engenharia Florestal (DEF), ao Grupo de Estudos em Economia Ambiental (GEEA) e à Universidade Federal do Paraná (UFPR) por todo aprendizado e pelas conquistas profissionais e pessoais.

Em especial, agradeço ao professor José Marinaldo Gleriani, pela sua orientação, por seu profissionalismo e pela sua amizade. Ao professor Vicente Paulo Soares, agradeço pelas contribuições iniciais para o desenvolvimento do trabalho. Ao Pesquisador Flávio Jorge Ponzoni do Instituto Nacional de Pesquisas Espaciais (INPE), pela oportunidade de conhecer o INPE e pela ideia base deste trabalho.

Aos meus pais, Sergio e Marcia, por todos os esforços feitos para conseguirem me manter em Viçosa e também pelas palavras de carinho e conforto nas horas difíceis. Agradeço as minhas irmãs, Morgana e Tassiane, pelo carinho e companheirismo ao longo da vida.

Ao Gabriel, pelo infinito apoio e pelo seu amor ao longo de todos esses anos. Agradeço por me incentivar e dar forças, para que eu possa sempre querer ser uma pessoa cada vez melhor.

Aos meus familiares, avós, tios, primos e a família Schneider que, mesmo tão distantes, sempre me deram forças para prosseguir.

Aos meus queridos amigos do Paraná e os grandes amigos de Viçosa, agradeço por me mostrarem o valor das verdadeiras amizades. Em especial à Ana Carolina, Caroline, Eliana, Julia, Claudiane e Amanda pelo companheirismo em todas as horas.

A todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho, muito obrigada!

BIOGRAFIA

Aline Daniele Jacon, filha de Sergio Luiz Jacon e Marcia Regina Teixeira Jacon, nasceu em 6 de outubro de 1988, na cidade de Jacarezinho, Paraná.

Em 2006, concluiu o ensino médio no colégio Decisivo, em Curitiba, Paraná.

Em 2008, ingressou no curso de Engenharia Florestal da Universidade Federal do Paraná (UFPR), em Curitiba, Paraná.

Em 2010 transferiu o curso para Universidade Federal de Viçosa (UFV), em Viçosa, Minas Gerais, concluindo este no ano de 2013.

CONTEÚDO

1.	INTRODUÇÃO	1
2.	REVISÃO DE LITERATURA	3
2.1.	O Bioma Cerrado.....	3
2.2.	Interação da Vegetação com a Radiação Eletromagnética.....	5
2.3.	Sensor MODIS	7
2.4.	Índices de vegetação.....	12
2.5.	Classificação de imagens e Redes Neurais Artificiais (RNA)	14
3.	MATERIAL E MÉTODOS	18
3.1.	Área de estudo	18
3.2.	Aquisição de imagens EVI/MODIS	20
3.3.	Obtenção das amostras de treinamento	22
3.4.	Treinamento das Redes Neurais	26

3.5.	Classificação.....	28
3.6.	Mapa Temático.....	28
3.7.	Avaliação da classificação.....	28
4.	RESULTADOS E DISCUSSÃO	31
5.	CONCLUSÕES.....	36
6.	REFERÊNCIAS BIBLIOGRÁFICAS.....	37

ÍNDICE DE TABELAS

Tabela 1. Especificações Técnicas do Sensor MODIS.	9
Tabela 2. Produtos da superfície terrestre gerados pelo sensor MODIS.....	10
Tabela 3. Número de imagens selecionadas e as respectivas datas para o ano de 2003. 21	
Tabela 4. Matriz de confusão genérica para a avaliação da classificação.	29
Tabela 5. Valor do índice Kappa e seus conceitos de desempenho da classificação.	30
Tabela 6. Matriz de confusão entre a classificação por RNA e as amostras de referência IEF/UFLA, com os parâmetros avaliativos, Exatidão Global, índice Kappa e Acurácia do Produtor e do Usuário para cada classe.....	32

ÍNDICE DE FIGURAS

Figura 1. Principais fitofisionomias encontradas no bioma Cerrado.	4
Figura 2. Representação esquemática da interação da radiação eletromagnética com diferentes alvos.....	6
Figura 3. Sistema de referência dos dados MODIS. Em destaque o <i>tile</i> de referência horizontal 12, e vertical 09.....	11
Figura 4. Estrutura de um neurônio biológico.	16
Figura 5. Modelo de um neurônio Artificial.	16
Figura 6. Rede de múltiplas camadas com arquitetura 4-3-5.....	17
Figura 7. Identificação da área de estudo em vermelho.....	19
Figura 8. Etapas da metodologia desenvolvida neste estudo.	19
Figura 9. Identificação da área correspondente ao tile selecionado (h13v10).	20
Figura 10. Recorte de uma imagem índice de vegetação EVI selecionando apenas a área de interesse.	22

Figura 11. Imagem Google Earth representando a coordenada central e as dimensões do pixel MODIS, em um fragmento de cerradão selecionado.	23
Figura 12. Representação de alguns dos polígonos gerados, em cada classe, ao longo das 23 imagens analisadas.	24
Figura 13. Série temporal EVI, representando uma amostra de treinamento da classe cerradão.	25
Figura 14. Matriz formada (23colunas x 120linhas) e pronta para ser processada como arquivo de treinamento pelas RNA.	26
Figura 15. Arquitetura e codificação utilizada para o treinamento das Redes Neurais. .	27
Figura 16. Mapa temático gerado como resultado da classificação pelas RNA utilizando séries temporais EVI/MODIS.	31
Figura 17. Comparação entre uma série temporal com amplitude de 1 ano e outra de 11 anos, para uma amostra de cerradão (LAF-INPE).	34

EXTRATO

JACON, Aline Daniele. Monografia de graduação. Universidade Federal de Viçosa, setembro de 2013. **ANÁLISE DE SÉRIES TEMPORAIS EVI/MODIS PARA DISCRIMINAÇÃO DE FITOSISIONOMIAS DO CERRADO**. Orientador: José Marinaldo Gleriani.

Objetivou-se com este estudo avaliar a utilização de séries temporais de imagens EVI (*Enhanced Vegetation Index*) do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) para discriminar diferentes fitofisionomias dentro do bioma cerrado. A classificação das imagens foi realizada através de uma Rede Neural Multicamadas (MLP –*MultiLayer Perceptron*) com função de ativação logística sigmoide, cuja camada de entrada recebia um vetor com 23 dados os quais caracterizariam o padrão temporal da fitofisionomia, ou seja, a fitomassa e a variação fenológica. A área estudada teve como base e referência o Inventário Florestal de Minas Gerais, realizado pelo IEF/UFLA em 2008, onde foram identificadas as fisionomias Cerradão, Cerrado Senso Stricto e Campo Cerrado com dados do sensor TM/Landsat-5. Nos resultados obtidos, observou-se que apesar de não ter discriminado as diferentes classes de cerrado de forma satisfatória ($Kappa = 0,10$), a metodologia usada demonstrou ser aplicável no estudo de séries temporais de índice de vegetação analisados através de redes neurais artificiais. A fim de reconhecer as possíveis interferências e obter futuramente melhores resultados nas análises, algumas sugestões foram levantadas, dentre elas: a) Analisar uma amplitude maior das séries temporais EVI (maior número de datas) para melhor caracterizar as fitofisionomias; b) Aumentar o número de amostras para treinamento das redes neurais uma vez que utilizou-se apenas 90 vetores e c) Utilizar outros *softwares* que possam comportar um maior número de dados.

1. INTRODUÇÃO

O conhecimento da dinâmica das diferentes coberturas vegetais sejam elas naturais ou agrícolas; sua distribuição e suas variações fenológicas vêm se tornando um aspecto indispensável para o planejamento de políticas públicas visando o desenvolvimento estratégico de um país. Assim como para a compreensão e avaliação objetiva da convivência de diferentes ecossistemas, sejam naturais, agrícolas ou industriais (CANAVESI, 2005).

Devido à ampla cobertura e repetitiva amostragem, imagens obtidas por sensores remotos possuem um grande potencial para monitorar a vegetação, tanto em escala global como regional (ZHANG et al., 2002). Projetos que visam o reconhecimento e o monitoramento de biomas brasileiros fortemente ameaçados por pressões antrópicas, como o Cerrado e a Amazônia, utilizam dados de diferentes sensores em suas análises. O Projeto PRODES (Projeto de estimativa do desflorestamento bruto da Amazônia) e o sistema DETER (Detecção de desmatamento em tempo real) são exemplos de projetos realizados pelo INPE (Instituto Nacional de Pesquisas Espaciais) que fazem uso de diferentes dados de diferentes sensores remotos no reconhecimento, monitoramento e detecção de desmatamento de biomas brasileiros.

Entre os sensores orbitais utilizados no monitoramento e estudo da vegetação destaca-se o MODIS (*Moderate Resolution Imaging Spectroradiometer*). Este sensor vem sendo largamente usado pela comunidade científica por suas características radiométricas e temporais que, associadas às correções atmosféricas, conferem ao sensor capacidade superior de monitoramento da vegetação (ZHANG et al., 2002)

Sua alta resolução temporal e a disponibilização de seus dados em forma de produtos, como o MOD13 (índices de vegetação NDVI e EVI), fizeram com que análises de diferentes alvos na superfície terrestre passassem a ser realizadas numa escala multitemporal, a exemplo das séries temporais de índice de vegetação. Esse tipo de análise baseia-se no fato de que diferentes coberturas apresentam, além de diferentes respostas espectrais, padrões temporais distintos, podendo ser usadas na caracterização espectro-temporal das mesmas (FERREIRA, 2005).

A utilização de séries temporais de índices de vegetação vem sendo empregada em diferentes trabalhos, entre eles estão: identificação de culturas agrícolas (GLERIANI, 2004), no monitoramento de corredores ecológicos (LACRUZ et al., 2005), como forma de mensurar a intensificação da produção agrícola (BROWN et al., 2007) e identificação de tipos de formações florestais (YU et al., 2004).

Victoria et al. (2009) e Canavesi et al. (2005) mostraram em seus trabalhos que a utilização de séries temporais para discriminar fitofisionomias em diferentes biomas, difere das análises feitas em culturas agrícolas. Estas necessitam de séries temporais de índices de vegetação com pequenas amplitudes, pois na maioria das vezes completam seu ciclo fenológico num pequeno intervalo de tempo, sendo facilmente discriminadas. Já as fisionomias florestais, por apresentarem ciclo fenológicos longos, necessitam de séries temporais que possam captar informações relevantes para que a discriminação possa ser satisfatória, impulsionando assim novos estudos nessa área.

Dentro deste contexto objetivou-se com este estudo avaliar a utilização de séries temporais do índice de vegetação EVI, do sensor MODIS, para a discriminação das diferentes fitofisionomias do bioma Cerrado. Essa análise foi realizada através de Redes Neurais Artificiais.

2. REVISÃO DE LITERATURA

2.1. O Bioma Cerrado

Contido em quase sua totalidade no Brasil, o bioma cerrado representa 9% da área total global das savanas tropicais. Compreende uma área original de 2.039.387 km², abrangendo 10 estados e o Distrito Federal, representando a segunda maior formação vegetal do Brasil (IBGE, 2004).

Sua elevada biodiversidade, atualmente estimada em seis mil espécies vegetais vasculares (MENDONÇA et al., 1998), é favorecida pela presença de três das maiores bacias hidrográficas da América do Sul (Tocantins, São Francisco e Paraná), além de uma extensa diversidade de solos, geologia e queimadas naturais (EITEN, 1972).

As fisionomias do Cerrado formam mosaicos de tipos vegetacionais verticalmente estruturado por espécies herbáceas, arbustivas e arborescentes (Figura 1). Essa riqueza de fisionomias foi descrita por Ribeiro e Walter (1998) e separadas em três formações, divididas em tipos fitofisionômicos gerais, enquadrados em Formações Florestais (ex: Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão), Savânicas (ex: Cerrado Senso Stricto, Parque Cerrado, Palmeiral e Vereda) e Campestres (Ex: Campo Sujo, Campo Rupestre e Campo Limpo).

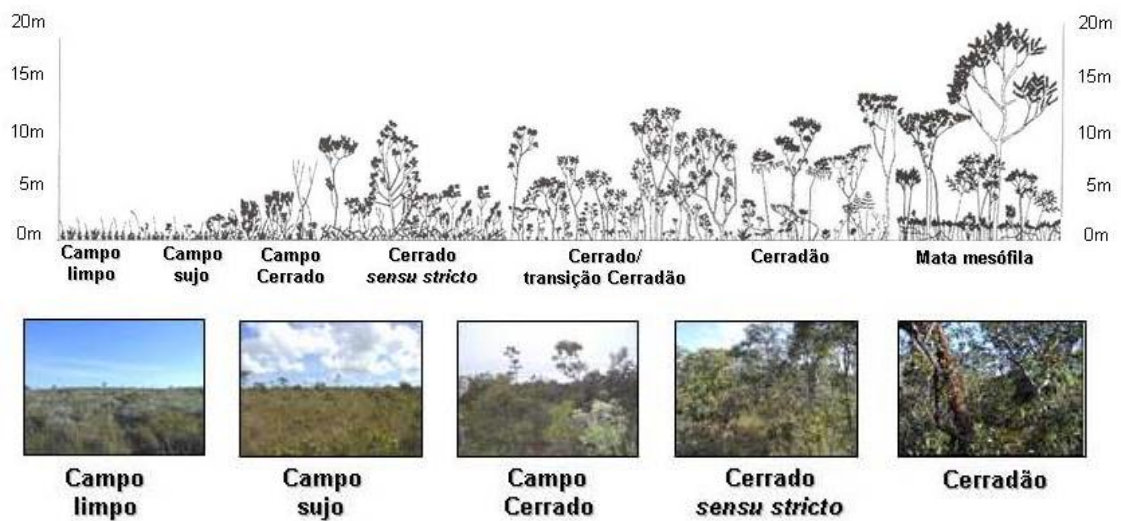


Figura 1. Principais fitofisionomias encontradas no bioma Cerrado.

(Fonte: Bitencourt et al.,1996)

Este gradiente natural é determinado, entre outros fatores, pela disponibilidade de água e nutrientes disponíveis no solo, marcado também pela sazonalidade da estação chuvosa (DIAS, 1992).

Neste estudo, as fisionomias analisadas foram Cerradão, Cerrado Senso Stricto e as fisionomias Campo Cerrado, que alguns autores classificam como uma transição do Cerrado Senso Stricto e as formações campestres. As características das fisionomias mencionadas, segundo Ferreira (2003) e Ribeiro e Walter (1998), estão descritas a seguir:

Cerradão – Formação florestal com aspectos xeromórficos, caracterizado pela presença de espécies que ocorrem no Cerrado Senso Stricto e também por espécies de mata. É mais próximo floristicamente de Cerrado, mas do ponto de vista fisionômico é uma floresta. Apresenta dossel predominantemente contínuo, com altura média do estrato arbóreo variando entre oito e quinze metros, propiciando condições de luminosidade que favorecem a formação de estratos arbustivo e herbáceo diferenciados.

Cerrado Sensu Stricto – Presença de árvores baixas, tortuosas, retorcidas, geralmente com evidências de queimadas. Os arbustos e subarbustos encontram-se espalhados, com algumas espécies apresentando órgãos subterrâneos perenes (xilopódios), que permitem a rebrota após queima ou corte. Na época chuvosa os estratos subarbusivo e herbáceo tornam-se exuberantes devido ao seu rápido crescimento.

Campo Cerrado - Estrato arbóreo pouco definido, com poucas árvores e arbustos bastante espaçados entre si, e com um estrato herbáceo contínuo, com muitas espécies de subarbustos e ervas. Transição entre o Cerrado Sensu Stricto e as formações campestres.

Apesar da elevada biodiversidade, o Cerrado passa, ao longo das últimas décadas, por rápido processo de degradação ambiental, sendo considerado um dos 34 *hotspots* mundiais (MITTERMEIER et al., 2005).

Os investimentos públicos em infra-estrutura, aliado a presença de características naturais favoráveis, propiciaram um ambiente ideal para a intensa ocupação agropastoril que transformou o cerrado na principal fronteira de expansão agrícola brasileira (MIZIARA e FERREIRA, 2008).

Diante desse cenário, o reconhecimento e o monitoramento das diferentes fisionomias do bioma cerrado se tornam estratégicos para conter a expansão agrícola irregular e conservar a alta biodiversidade encontrada nessas formações vegetais.

2.2. Interação da Vegetação com a Radiação Eletromagnética

A energia eletromagnética originada do sol propaga-se pela atmosfera até atingir um alvo que irá refletir ou absorver porções distintas dessa energia. Os sensores passivos necessitam dessa energia para obter dados, em diferentes regiões do espectro eletromagnético, para caracterização espectral de diferentes alvos da superfície terrestre (JENSEN, 2002) (Figura 2).

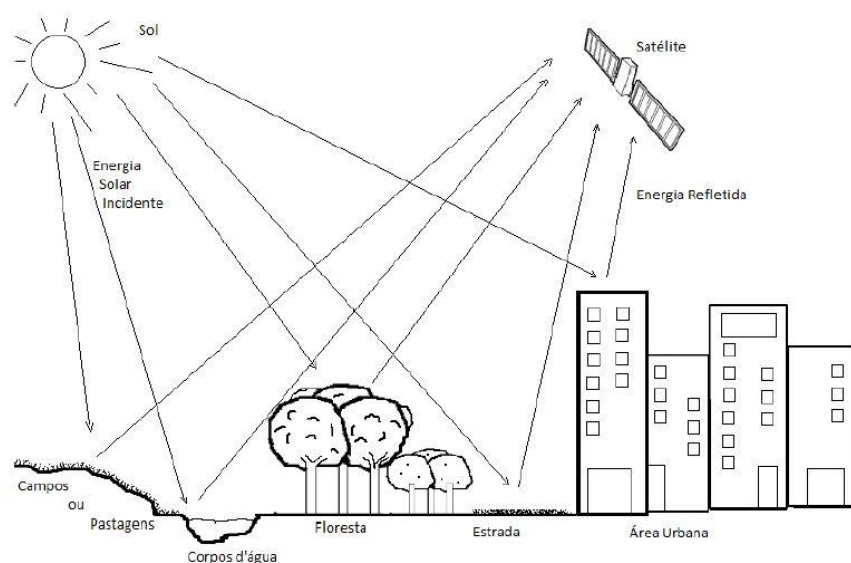


Figura 2. Representação esquemática da interação da radiação eletromagnética com diferentes alvos.

(Fonte: SILVA, 2012)

Parte da radiação solar, antes de alcançar a superfície, interage com partículas suspensas na atmosfera e com moléculas de gases. Os processos que descrevem essa interação são a absorção e espalhamento (JENSEN, 2000). A radiação solar que chega à superfície da Terra interage com a vegetação da seguinte forma: Aproximadamente 50% do total que chega até às plantas é absorvida pelos pigmentos contidos nas folhas no processo de fotossíntese. Outra parte é refletida interagindo novamente com os constituintes da atmosfera, e a parte restante sofre o processo de transmissão, através das camadas de folhas que compõem a copa e daqueles que constituem a folha (MOREIRA, 2003).

Na região do visível (0,4 a 0,7 μm) a resposta espectral das folhas é influenciada, principalmente, pelos pigmentos existentes na planta – pigmentos em geral encontrados nos cloroplastos como, clorofila (65%), carotenos (6%) e xantofilas (29%). Nesta faixa espectral, tanto a reflectância quanto a transmitância das folhas são menores que 15% (MOREIRA, 2003).

Segundo Moreira (2003) ao examinar a resposta espectral de uma folha, nota-se um aumento significativo na reflectância ao passar do espectro visível para o infravermelho próximo (0,7 a 1,3 μm). Nesta região, uma vegetação verde e sadia é caracterizada por alta reflectância, alta transmitância e baixa absorptância quando comparada ao visível. Nesta região, as folhas verdes absorvem pouca energia, apresentando uma alta reflectância causada pelo espalhamento resultante dos diferentes índices de refração das estruturas celulares.

Na faixa do espectro eletromagnético que corresponde ao Infravermelho Médio, a resposta espectral de uma folha verde é caracterizada, notadamente, pelas faixas de grande absorção pela água. Encontram-se dois máximos de absorção pela água em 1,4 μm e 1,9 μm (NOVO, 1989).

Fatores morfológicos como densidade da cobertura vegetal e distribuição horizontal e vertical das folhas, fatores fisiológicos também influenciam na resposta espectral das plantas. Dentre esses fatores estão o déficit hídrico, espessura das folhas e deficiência nutricional (MOREIRA, 2003).

As diferentes fisionomias existentes, sua sazonalidade e seu grau de antropismo, resultam em comportamentos espectrais distintos na absorção, transmissão e reflexão das ondas do espectro eletromagnético. Através do comportamento particular de cada alvo na superfície, se torna possível a discriminação entre eles.

2.3. Sensor MODIS

Com objetivo de monitorar as mudanças ocorridas no Planeta Terra, além do monitoramento global e contínuo da superfície terrestre diariamente, o programa de coleta de dados sobre o planeta Terra denominado “Earth Observing System” (EOS), lançou através da National Aerospace and Space Administration (NASA) os satélites Terra, em dezembro de 1999, e o Aqua, em maio de 2002. Dentre os sensores orbitais

abordo dessas plataformas destaca-se o MODIS (*Moderate Resolution Imaging Spectroradiometer*) (SILVA, 2004).

De acordo com Barker et al.(1992), este sensor foi o principal instrumento desenvolvido para os satélites Terra e Aqua, por apresentar inúmeras características dentre elas:

- Ampla cobertura espacial e espectral;
- Continuidade nas tomadas de medidas nas regiões espectrais, que já estão sendo estimadas por outros satélites, vindo a complementar as informações, já adquiridas por estes. Como exemplo, o conjunto de dados adquiridos pelo AVHRR, usado para a meteorologia e monitoramento da temperatura da superfície do mar, gelo e vegetação; e pelo *Coastal Zone Color Scanne (CZSC)*, usado para monitorar a biomassa oceânica e os seus padrões de circulação;
- Ser a primeira ferramenta dos satélites EOS na condução das pesquisas e mudanças globais.

O sensor MODIS foi projetado para satisfazer os requerimentos de três campos de estudos: atmosfera, oceano e terra, com bandas de resolução espectral e espacial selecionadas para cada objetivo e com uma cobertura global quase diária (JUSTICE et al., 2002). As especificações técnicas deste sensor estão dispostas na Tabela 1.

Tabela 1. Especificações Técnicas do Sensor MODIS.

Especificações Técnicas	
Órbita do satélite Terra	705 Km, síncrona com o Sol, polar; 10:30 a.m descendente
Cobertura de repetição do satélite Terra	Diária, a norte da latitude 30° e a cada dois dias, para latitudes inferiores a 30°
Resolução espacial do sensor MODIS	250 m (2 bandas), 500 m (5 bandas), 1000 m (29 bandas) no nadir
Precisão radiométrica do sensor MODIS	5% Absoluto, <3 mm; 1% Absoluto, >3mm; 2% de reflectância
Alcance espectral do sensor MODIS	0,4 –14,4 mm
Quantização do sensor MODIS	12 bits
Taxa de Dados do satélite Terra	6,2 Mbps (média), 10,8 Mbps (dia), 2,5Mbps (noite)
Força do satélite Terra	162,5 W (média para uma órbita), 168,5W (pico)

(Fonte: Anderson et al., 2003)

Este sensor possui 36 bandas espectrais, sendo 2 com resolução espacial de 250m, 5 com 500m e 29 com 1.000m no nadir, cobrindo uma faixa de 2.330 km de largura. A distribuição das 36 bandas espectrais, ao longo do espectro eletromagnético, permitiu o desenvolvimento de 44 produtos, utilizados para diferentes fins em diversas áreas do conhecimento (HUETE et al., 2002). Alguns desses produtos estão listados na Tabela 2.

Tabela 2. Produtos da superfície terrestre gerados pelo sensor MODIS.

ESDT	PRODUTOS
PRODUTOS RELACIONADOS AO BALANÇO ENERGÉTICO	
MOD 09	Reflectância de superfície
MOD 11	Temperatura da superfície da Terra e emissividade
MOD 43	BRDF/Albedo
MOD 10 E 29	Cobertura de neve e extensão de gelo na superfície do mar
PRODUTOS VOLTADOS À VEGETAÇÃO	
MOD 13	Grades de índices de vegetação (Máximo NDVI e EVI integrado)
MOD 15	Índice de área foliar (LAI) e FAPAR
MOD 17	Fotossíntese líquida e produtividade primária
PRODUTOS VOLTADOS À COBERTURA TERRESTRE	
MOD 12	Cobertura da terra e mudança na cobertura da terra
MOD 14	Anomalias termais, fogo e queima de biomassa
MOD 44	Conversão da cobertura vegetal

(Fonte: Justice et al.,2002)

Os produtos MODIS estão em uma estrutura de grade o que facilita a correlação entre os dados e a sua localização na Terra. O *Tile* refere-se ao recorte que representa cada cena de uma imagem MODIS, possuindo uma referência horizontal e vertical numérica em uma grade que recobre todo o planeta Terra (FIGURA 3). Cada *tile* possui uma área de 1200 Km x 1200 km, globalmente são 460 *tiles* (ROSENDO, 2005). Esses dados, originalmente na projeção *sinusoidal* (SIN) e no formato *Hierarchical Data Format* (HDF), podem ser reprojatados para uma projeção de interesse do usuário por meio do software *Modis Reprojection Tool* (MRT).




Figura 3. Sistema de referência dos dados MODIS. Em destaque o *tile* de referência horizontal 12, e vertical 09.

(Fonte: ROSENDO, 2005)

Neste trabalho, para alcançar os objetivos propostos e já abordados anteriormente o produto MODIS utilizado foi o MOD13Q1. O “Q” refere-se a *Quarter Km*, ou seja, quarta parte do quilômetro, indicando que os produtos possuem resolução espacial de 250 m (VERMOTE *et al.*, 2002).

As imagens referentes aos Índices de Vegetação (NDVI e EVI) são concebidas dentro do sistema de *compositing* da própria imagem MODIS, no qual imagens de 16 dias são transformadas em Índices de Vegetação. Estas passam por um filtro onde os pixels são avaliados e os que possuem a melhor qualidade vão compor o produto final do MOD13 (SILVA, 2004).

Os produtos MOD13 também dispõem de:

- Dois índices de vegetação o NDVI e o EVI;
- Duas imagens com informações que atestam a qualidade dos produtos Índice de Vegetação - NDVI *Quality* e EVI *Quality*;

- Imagens refletância das bandas Azul, Vermelho, Infravermelho próximo e Infravermelho médio;
- Três imagens referentes à maneira em que estes dados foram adquiridos, ângulo de visada, ângulo zenital solar e azimute.

2.4. Índices de vegetação

Segundo EIPHANIO et al. (1996) os índices de vegetação são transformações lineares de bandas espectrais, geralmente nas faixas do vermelho (V) e infravermelho próximo (IVP) do espectro eletromagnético. Tais índices realçam o comportamento espectral da vegetação e se correlacionam com os parâmetros biofísicos da vegetação, como biomassa, Índice de Área Foliar (IAF), percentagem de cobertura vegetal. Incluem também elevados graus de correlação com o vigor da vegetação verde, percentagem de cobertura do solo, atividade fotossintética e produtividade.

Para minimizar a variabilidade causada por fatores externos, a reflectância espectral tem sido transformada e combinada em vários índices de vegetação (PONZONI, 2001). Os IV são mais sensíveis do que as bandas individuais quando relacionadas com parâmetros biofísicos da vegetação (EIPHANIO et al., 1996). A lógica por trás dos IV baseia-se não somente no fato de que a energia refletida no vermelho e no infravermelho próximo são diretamente relacionadas a atividade fotossintética da vegetação, mas também na suposição de que a utilização de duas ou mais bandas espectrais pode minimizar as principais fontes de “ruídos” que afetam a resposta da vegetação (SILVA, 2004).

O produto MOD13 possui dois índices de vegetação, o NDVI (*Normalized Difference Vegetation Index*) ou índice de vegetação da diferença normalizada, este sensível à clorofila, e o EVI (*Enhanced Vegetation Index*) ou índice de vegetação melhorado (EVI), mais sensível às variações na resposta estrutural do dossel, incluindo o índice de área foliar, a fisionomia da planta e a arquitetura do dossel (HUETE e JUSTICE, 1999).

O NDVI é uma relação entre medidas espectrais (reflectância - ρ) de duas bandas espectrais, a do infravermelho próximo (800-1100nm) e a do vermelho (600-700nm), e visa eliminar diferenças sazonais do ângulo do Sol e minimizar os efeitos da atenuação atmosférica. Os valores obtidos com o NDVI são contidos em uma mesma escala de valores, entre o intervalo de -1 e 1 (COURA, 2006). Este índice pode ser obtido através da utilização da Equação 1:

$$NDVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V} \quad (1)$$

Onde ρ_{IVP} é a reflectância do infravermelho próximo; e ρ_V é a reflectância no vermelho.

Quando existe um aumento da biomassa vegetal o NDVI é rapidamente saturado. Esta peculiaridade atribuída ao índice limita seu uso em vegetações que apresentam alta densidade de biomassa a partir de determinado estágio de desenvolvimento (MOREIRA, 2004).

Segundo Justice et al. (1998) o índice de vegetação melhorado (EVI) foi desenvolvido para otimizar o sinal da vegetação, melhorando a sensibilidade em regiões com maiores densidades de biomassa, além de melhorar o monitoramento da vegetação através de uma ligação do sinal de fundo do dossel e da redução das influências atmosféricas (Equação 2).

$$EVI = 2,5 \left(\frac{\rho_{IVP} - \rho_V}{L + \rho_{IVP} + C1 \cdot \rho_V - C2 \cdot \rho_A} \right) \quad (2)$$

Onde L é fator de ajuste para o solo; C1 e C2 são coeficientes de ajuste para efeito de aerossóis da atmosfera, ρ_V é a reflectância do vermelho e ρ_A é a reflectância do azul.

Os valores dos coeficientes adotados pelo algoritmo do EVI são: $L=1$, $C1=6$, $C2=7,5$ e o fator de ganho $G= 2.5$.

As imagens índices de vegetação, obtidas dos produtos MODIS têm como objetivo fornecer dados consistentes para comparações temporais e espaciais das condições da vegetação, em nível global. O objetivo principal deste produto é monitorar a atividade fotossintética da vegetação visando detectar mudanças no vigor vegetativo e associar estas mudanças às condições biofísicas e fenológicas das mesmas (ANDERSON *et al.*, 2003). Neste estudo o índice de vegetação utilizado foi o EVI, através de comparações temporais ao longo de um ano.

2.5. Classificação de imagens e Redes Neurais Artificiais (RNA)

A classificação de imagens digitais consiste em rotular os pixels de uma cena em classes pré-definidas ou não, chamados de métodos supervisionados e não supervisionados. Os supervisionados são aqueles em que o algoritmo classificador encontra, em meio aos dados, características semelhantes àquelas previamente apresentadas na forma de amostras de treinamento, para cada classe pré-selecionada. Esses são os mais usados na classificação de imagens de sensoriamento remoto (NAVULUR, 2006).

Segundo Schowengerdt (2007), os métodos podem ser ainda agrupados em 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. Já os não paramétricos, como o classificador por Redes Neurais Artificiais (RNA) não fazem suposição alguma sobre a distribuição da probabilidade dos dados e são muitas vezes considerados robustos.

Muitos algoritmos têm sido utilizados para classificação em imagens digitais provenientes de sensores remotos entre eles estão o Máxima Verossimilhança e as RNA. Estas vem chamando a atenção como uma nova ferramenta de classificação de

padrões em imagens de sensores remotos. Além de não serem paramétricas, o treinamento pode ser feito com pequenas amostras e também são tolerantes a dados falhos (KAVZOGLU e MATHER, 2003).

Uma rede neural artificial (RNA) é definida como um processador massivo e paralelamente distribuído, constituído de unidades de processamento simples, que tem a capacidade para armazenar conhecimento experimental e torná-lo disponível para uso. As RNA são modelos simplificados do sistema nervoso central e têm uma grande capacidade de desenvolver atividade e solucionar problemas como de classificação e regressão (HAYKIN, 2001).

Para uma melhor compreensão antes de descrever o funcionamento de transmissão e processamento de um sinal por uma RNA, descreve-se de forma simplificada o funcionamento básico do cérebro humano.

A unidade básica do cérebro é o neurônio (Figura 4), que pode ser dividido em dendritos, axônio e corpo celular. Os dendritos são ramificações que formam uma rede receptora que carrega os sinais elétricos para o corpo da célula. O corpo celular impõe um limiar para execução destes sinais. O axônio é uma fibra longa que leva o sinal processado para o dendrito de um outro neurônio. Entre o axônio e os dendritos existe um ponto de contato chamado sinapse onde não existe contato físico, mas sim uma liberação temporária de neurotransmissores; esta liberação ocorre em função do impulso elétrico disparado. Os neurotransmissores fluem através de fendas quimicamente ativas dos dendritos (neurorreceptores). Com a existência de uma nova diferença de potencial, um novo impulso elétrico é transmitido para o corpo celular sucessivo, dando sequência à propagação (HAGAN et al., 1996).




Figura 4. Estrutura de um neurônio biológico.
(Fonte: Hagan et al.,1996)

Em um neurônio artificial as sinapses são representadas pelos pesos sinápticos (W) que podem ser ponderados de maneira excitatórias ou inibitória em um funcionamento análogo ao processo biológico. O processamento de cada neurônio é realizado pela função de ativação, que a partir da soma ponderada dos valores de entrada (X) e seus respectivos pesos (W), fornecem valores de saída (Figura 5) podendo ou não ser usado pelo próximo neurônio (SILVA, 2012).




Figura 5. Modelo de um neurônio Artificial.
(Fonte: SILVA, 2012)

Dentre as funções de ativação mais utilizadas, destacam-se a função limiar, a função sigmoideal e a função tangente hiperbólica. A função sigmoideal permite que as

saídas sejam interpretadas como probabilidades, fornecendo assim mais de uma decisão de classificação, e resultados com grandes potenciais de uso (BISHOP, 1995).

Os neurônios são organizados e ligados em rede, de modo a constituírem camadas como formando as redes neurais (HAYKIN, 2001).

Neste estudo consideram-se as redes formadas por múltiplas camadas de neurônios do tipo perceptron (MLP). Essas redes são constituídas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A alimentação dessas redes é progressiva, onde o sinal é propagado camada por camada (HAYKIN, 2001). Um exemplo de rede MLP é ilustrado na Figura 6. Nela existe uma camada de entrada com quatro neurônios, uma camada oculta com três neurônios e a camada de saída com cinco neurônios, o que resulta numa arquitetura 4-3-5 (BISHOP, 1995).

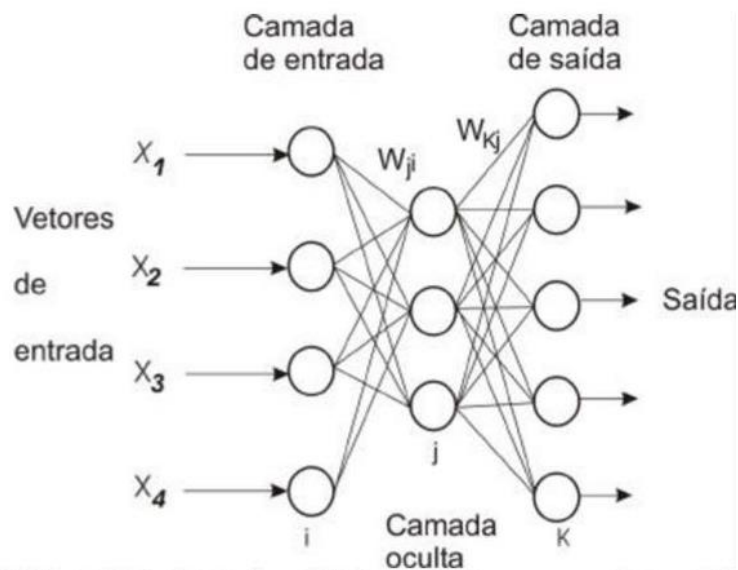


Figura 6. Rede de múltiplas camadas com arquitetura 4-3-5.
(Fonte: Adaptada de Bishop, 1995)

O treinamento das redes MLP é do tipo supervisionado com o algoritmo de retropropagação do erro, baseado na regra de aprendizagem por correção do erro. Nesta regra os sinais de entrada são apresentados a rede que gera uma saída, que é comparada com a saída desejada. Um erro é gerado e este aciona um mecanismo de controle que aplica uma sequencia de ajustes corretivos aos pesos sinápticos, a fim de aproximar a saída do resultado desejado minimizando o erro (HAYKIN, 2001).

3. MATERIAL E MÉTODOS

3.1. Área de estudo

As áreas escolhidas para o desenvolvimento desse estudo tiveram como base o projeto Inventário Florestal de Minas Gerais, realizado pelo Instituto Estadual de Florestas-MG (IEF), em parceria com a Universidade Federal de Lavras (UFLA). Este projeto foi realizado no ano de 2008, com dados do sensor TM/Landsat-5.

O Cerrado, alvo deste estudo, foi um dos biomas inventariados e as três fitofisionomias encontradas foram Cerradão, Cerrado Sensu Stricto e Campo Cerrado (SCOLFORO et al, 2008).

Os fragmentos das três fisionomias do cerrado, inventariados no estado de Minas Gerais, serviram como referência na obtenção de amostras de treinamento para as Redes Neurais e como pontos de referência na avaliação da classificação, obtendo assim deste projeto, a localização através de coordenadas geográficas e o tamanho (em hectare) dos fragmentos de interesse. A figura 7 ilustra a área abrangida por este estudo.




Figura 7. Identificação da área de estudo em vermelho.
(Fonte: Adaptada de COURA, 2006)

A metodologia usada neste estudo foi adaptada de GLERIANI (2004), seguindo as etapas descritas na Figura 8. Nesta Figura, as diferentes etapas desenvolvidas estão indicadas por numerações correspondentes às utilizadas no decorrer deste documento.

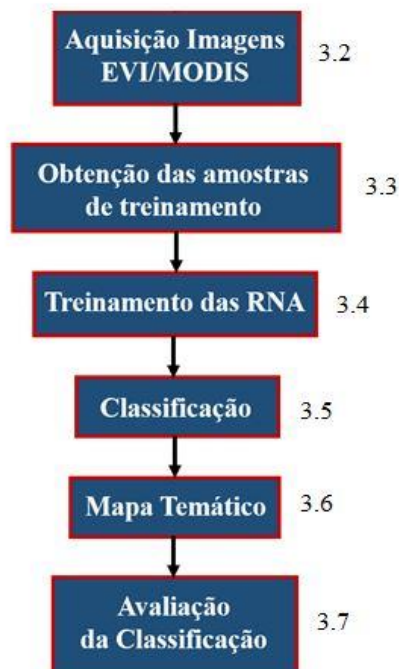


Figura 8. Etapas da metodologia desenvolvida neste estudo.

3.2. Aquisição de imagens EVI/MODIS

Anteriormente a aquisição das imagens MODIS foi necessário definir os seguintes parâmetros: 1) O produto MODIS a ser adquirido: MOD13Q1; 2) *Tile* correspondente a área de interesse: h13v10 (figura 9); 3) Datas de obtenção do produto: ano 2003 com 23 imagens (Tabela 3).

Após a definição das informações que conduziram o processo de obtenção das imagens, estas foram adquiridas gratuitamente através do site <https://lpdaac.usgs.gov/data_access/data_pool/>, escolhendo a opção Download via FTP e MODIS TERRA, <<http://e4ftl01.cr.usgs.gov/MOLT/>>.

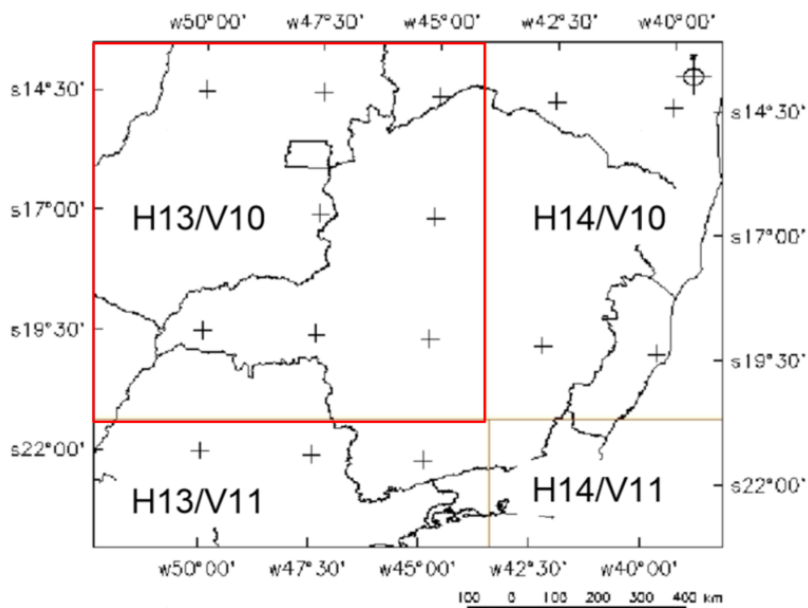


Figura 9. Identificação da área correspondente ao tile selecionado (h13v10).
(Fonte: Adaptada de COURA, 2006).

Tabela 3. Número de imagens selecionadas e as respectivas datas para o ano de 2003.

Imagem	Data	Resolução Espacial
1	01/01/2003	250 m
2	17/01/2003	250m
3	02/02/2003	250m
4	18/02/2003	250m
5	06/03/2003	250m
6	22/03/2003	250m
7	07/04/2003	250m
8	23/04/2003	250m
9	09/05/2203	250m
10	25/05/2003	250m
11	10/06/2203	250m
12	26/06/2003	250m
13	12/07/2003	250m
14	28/07/2003	250m
15	13/08/2003	250m
16	29/08/2003	250m
17	14/09/2003	250m
18	30/09/2003	250m
19	16/10/2003	250m
20	01/11/2003	250m
21	17/11/2003	250m
22	03/12/2003	250m
23	10/12/2003	250m

O produto MOD13Q1 é obtido no formato HDF (*Hierarchy Data Format*) e na projeção Sinusoidal. Devido ao fato do formato HDF não ser um formato usual em Sistemas de Informações Geográficas (SIG`s) foi desenvolvido um software específico para o pré-processamento das imagens, o *Modis Reprojection Tool* (MRT), programa gratuitamente disponibilizado no site <https://lpdaac.usgs.gov/tools/modis_reprojection_tool/>. Com este programa foi possível selecionar apenas o produto de interesse, para este estudo apenas imagens índice de vegetação EVI, converter o formato das imagens para Geotiff e reprojeta-las, com a reamostragem do pixel pelo método vizinho mais próximo, para UTM no Datum WGS84.

Visando o não sobrecarregamento do software foi feito o recorte das imagens selecionando apenas a área de interesse (Figura 10). Em seguida, as imagens foram importadas para o Sistema de Processamento de Informações Georeferenciadas (SPRING) versão 5.2.3.

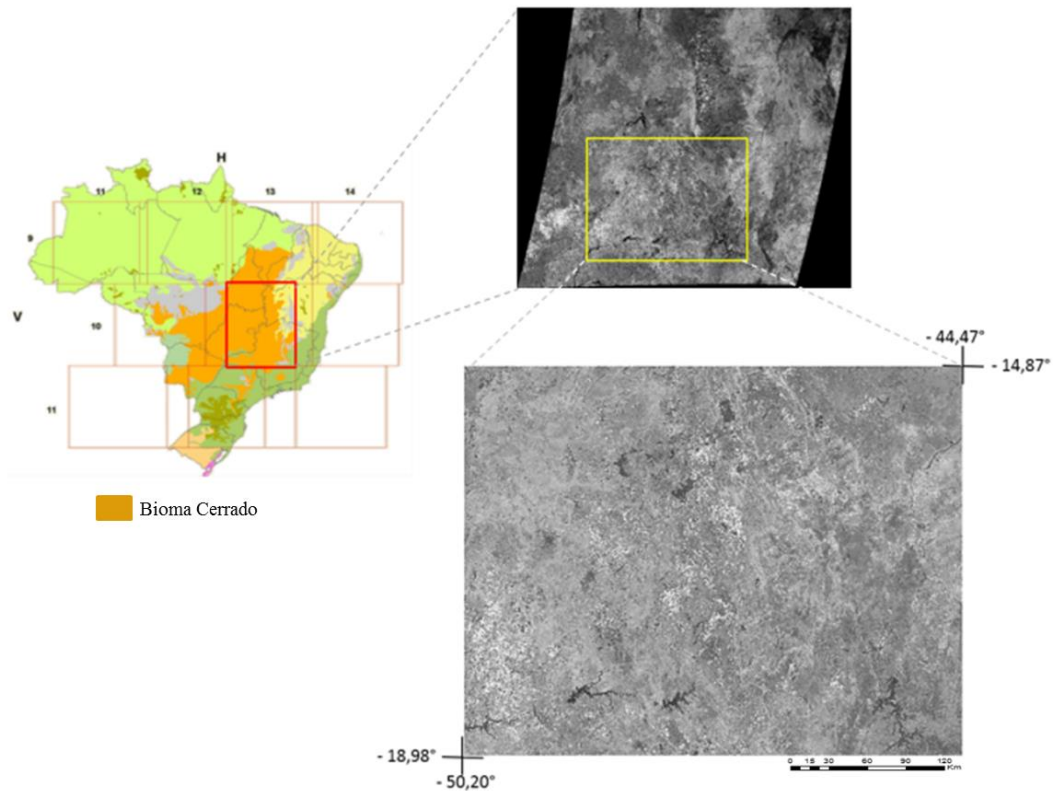


Figura 10. Recorte de uma imagem índice de vegetação EVI selecionando apenas a área de interesse.

3.3. Obtenção das amostras de treinamento

Neste estudo, uma amostra de treinamento foi representada pelo comportamento do índice de vegetação EVI ao longo das 23 imagens em um determinado pixel. Ou seja, cada pixel selecionado para cada classe, teve 23 valores que expressaram o comportamento do índice de vegetação, variando entre 0 e 1, na temporalidade de 23 datas ao longo de um ano. Vale lembrar que cada cena EVI utilizada, vem da

composição de 8 cenas (16 dias), aonde a imagem resultante é um mosaico pixel a pixel, do maior valor EVI em cada posição (x,y).

Para se obter uma amostra de treinamento foi necessário, primeiramente, selecionar fragmentos correspondentes as fitofisionomias analisadas. Estes foram selecionados através do projeto IEF/UFLA-2008, onde pode-se obter suas coordenadas geográficas e consultar suas respectivas dimensões. A confirmação da localização e do tamanho dos fragmentos foi feita com o auxílio de imagens disponíveis no programa Google Earth.

A resolução espacial das imagens EVI/MODIS, 250m, foi determinante para a escolha das amostras, pois estas precisam corresponder ao tamanho do pixel da imagem (Figura 11). Fragmentos menores que 6,25 ha (250m x 250m) não puderam ser selecionados, pois incluiriam características de outra classe na informação do pixel, descaracterizando a amostra. Fragmentos maiores que essas dimensões puderam conter mais de uma amostra, mas sempre considerando as dimensões do pixel MODIS.




Figura 11. Imagem Google Earth representando a coordenada central e as dimensões do pixel MODIS, em um fragmento de cerrado selecionado.

Para cada classe analisada, Cerradão, Cerrado Senso Stricto e Campo Cerrado, foram selecionadas 30 amostras. Uma quarta classe foi criada, também com 30 amostras, para representar tudo que não correspondem às classes anteriores, totalizando 120 amostras ou pontos amostrais.

Como foi obtido apenas o ponto que corresponde a coordenada central da amostra, foi necessário delimitar um polígono correspondente ao tamanho do pixel da imagem MODIS, 250m x 250m. Para isso foi utilizada uma MACRO no Excel, desenvolvida por Gleriani (2004), para que a partir do centro da amostra, coordenada central, fosse gerado um arquivo de cinco coordenadas para serem importadas pelo SPRING. Com os polígonos formados foram feitas as associações com as respectivas classes. Cada polígono correspondem a um pixel da imagem MODIS, e dele foi extraído as informações na temporalidade das 23 imagens (Figura 12).

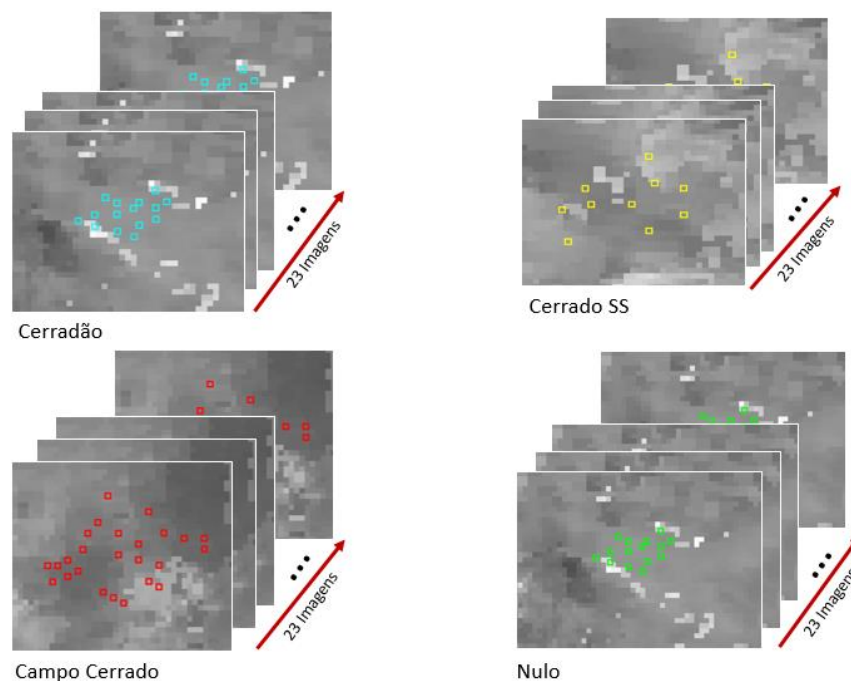


Figura 12. Representação de alguns dos polígonos gerados, em cada classe, ao longo das 23 imagens analisadas.

Para se obter os valores que serviram como amostras de treinamento, foi preciso fazer uso da ferramenta “Estatística por polígono” existente no SPRING. Essa ferramenta gera valores médios de EVI para cada pixel (polígono), em cada uma das

datas analisadas, ou seja, para cada amostra foi gerada uma série temporal de índice de vegetação, com 23 valores de EVI (Figura 13). O aplicativo SNNS trabalha com formato ASCII (*American Standard Code for Information Interchange*), assim cada cena EVI foi transformada de PI (Plano de Informação) Imagem (TIFF) para Numérico (ASCII), através de rotina LEGAL (Linguagem Espacial para Geoprocessamento Algebrico), aonde dividiu-se o PI Imagem por 32767.

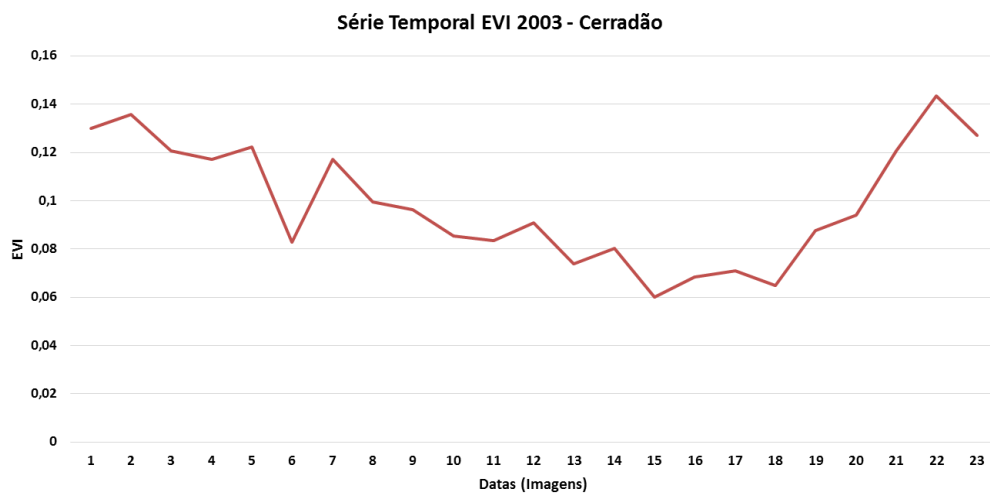


Figura 13. Série temporal EVI, representando uma amostra de treinamento da classe cerradão.

Esse procedimento foi realizado para cada classe (Cerrado, Cerrado Senso Stricto, Campo Cerrado e Nulo). As informações geradas no SPRING foram armazenadas no Access e posteriormente exportadas para o Excel para manipulação e união dos dados de cada classe em um único arquivo. Através de programa em linguagem C esses arquivos foram organizados, formando assim uma matriz com 23 colunas e 120 linhas, pronta para ser processada como arquivo de treinamento pelas RNA (Figura 14).

EVIs – 23 imagens/ 2003

Amostras por Classe		→																						
Cerradão	1	0.130039364	0.13574633	0.120609149	0.117099524	...	0.143467516	0.127109587																
	2	0.087374493	0.120303966	0.112491228	0.099642932	...	0.166234314	0.192419201																
	3	0.071626939	0.113406785	0.103030488	0.099368267	...	0.149998471	0.13788262																
	30	0.134586632	0.145603806	0.159825429	0.129978329	...	0.126468703	0.100070193																
Cerrado SS	1	0.099917598	0.108920559	0.097109899	0.103061005	...	0.106875822	0.15045625																
	2	0.104190193	0.135227516	0.136387214	0.111484118	...	0.106875822	0.15045625																
	3	0.098849453	0.118747517	0.107455671	0.097842343	...	0.12524797	0.114108704																
	30	0.109958187	0.142521441	0.12524797	0.114108704	...	0.142887667	0.117221594																
Campo Cerrado	1	0.080813013	0.132816553	0.116763815	0.107486188	...	0.082399979	0.111789301																
	2	0.086794645	0.132511362	0.158726767	0.116824858	...	0.818177853	0.917439324																
	3	0.079561755	0.106173895	0.09866634	0.09219642	...	0.082399979	0.111789301																
	30	0.087527089	0.098788418	0.089327678	0.091982789	...	0.074617758	0.131656855																
Nulo (Classe Variada)	1	0.236390284	0.316018863	0.10953933	0.939363083	...	0.353928574	0.233955947																
	2	0.115805421	0.428092635	0.502532916	0.489883813	...	0.026090258	0.298245451																
	3	0.260625824	0.240966699	0.893391873	0.515011765	...	0.48083287	0.591282485																
	30	0.169458494	0.230526477	0.149493861	0.271964009	...	0.648473363	0.569312398																

Figura 14. Matriz formada (23colunas x 120linhas) e pronta para ser processada como arquivo de treinamento pelas RNA.

3.4. Treinamento das Redes Neurais

Para realizar o processamento com RNA o programa escolhido foi o Stuttgart Neural Network Simulator (SNNS) (Zell et al., 1998). Este pacote foi desenvolvido pelos pesquisadores da Universidade de Stuttgart e Tübingen e está disponível no portal <http://www-ra.informatik.uni-tuebingen.de/SNNS/>.

O programa SNNS trabalha com arquivos de entrada e saída em formato ASCII e as configurações de rede armazenam a arquitetura, funções de ativação e pesos de treinamento. Assim, uma rede treinada pode ser salva e usada para uma classificação futura. O treinamento foi feito com a função “shuffle” ativada, o que permitia uma entrada aleatória das amostras, evitando tendenciosidades durante o treinamento (GLERIANI, 2004).

Foi utilizada a rede *Multi Layers Perceptrons* (MLP), com função de ativação sigmoide logística, treinada utilizando o algoritmo “Std_Backpropagation”, com o parâmetro da taxa de aprendizagem (η) de 0,2. A diferença máxima ($d_j = I_j - o_j$) entre os valores de entrada (I_j) e saída (o_j), foi ajustada para 0,1. O critério de parada adotado para o treinamento foi o da validação cruzada.

O número de neurônios da camada de entrada foi definido segundo o número de datas que compõem a série temporal (23), sendo que cada data possui 120 valores de EVI correspondentes as 30 amostras de treinamento para cada uma das quatro classes analisadas.

O número de neurônios da camada de saída foi definido segundo o número de classes a serem reconhecidas (4). Sendo elas Cerradão, Cerrado Senso Stricto (SS), Campo Cerrado e Nulo. Foi utilizada apenas uma camada oculta, com 11 neurônios.

A codificação utilizada para treinamento foi: 1 0 0 0 para a classe Cerradão, 0 1 0 0 para a classe Cerrado Senso Stricto, 0 0 1 0 para a classe Campo Cerrado e 0 0 0 1 para a classe Nulo (Figura 15).

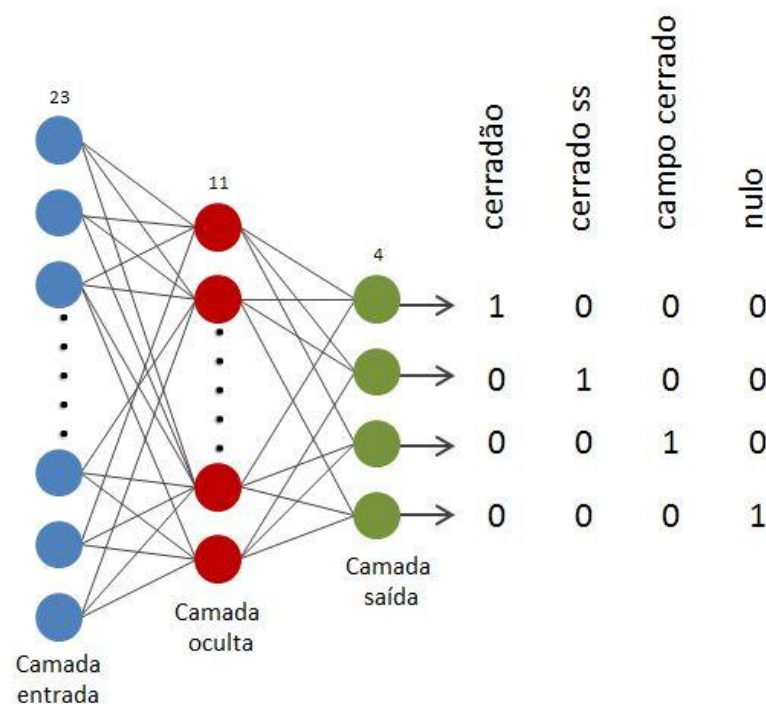


Figura 15. Arquitetura e codificação utilizada para o treinamento das Redes Neurais.

3.5. Classificação

Os dados de classificação tiveram que ser organizados para que a rede neural “entendesse” que certo conjunto de dados representava uma única posição (x,y) da imagem, ou seja, entender a temporalidade de 23 datas do EVI, pixel a pixel. Dessa maneira, uma rede com 23 neurônios de entrada, por exemplo, terá que ler 23 números correspondentes à mesma posição x,y, formando assim um padrão (GLERIANI, 2004).

Um programa em linguagem C organizou os 23 arquivos de EVI, cada um com 1.850 linhas e 2.468 colunas (dimensões da imagem), obtidos a partir do SPRING, em um único arquivo usado para classificação, que manteve o número de linhas (1.850) e teve o número de colunas multiplicadas pela quantidade de imagens analisadas (23). Considerando sempre a ordem das imagens que compõe a série temporal este arquivo resultou em uma matriz de dados com 1.850 linhas por 56.764 colunas (2.468x23), pronta para ser lida e classificada pelas redes neurais.

3.6. Mapa Temático

Após a classificação, utilizou-se um outro programa em linguagem C para transformar os arquivos de saída SNNS em matrizes numéricas, gerando uma matriz com as dimensões da imagem MODIS 1.850 x 2.468, a partir da lista de linhas de saída do SNNS. Posteriormente foi importada para o SPRING onde foi executado um fatiamento em programa LEGAL, para a geração do Mapa Temático.

3.7. Avaliação da classificação

Os pontos de referência, usados para compor a avaliação da classificação, foram obtidos a partir do Projeto IEF/UFLA. Para cada classe foram escolhidos aleatoriamente

30 pontos, totalizando 120 amostras de referência. As amostras também tiveram que ser analisadas quanto ao seu tamanho, para que fragmentos com dimensões menores que o pixel MODIS (250mx250m) não fossem erroneamente selecionadas.

Esses pontos foram importados para um Plano de Informação (PI) temático no SPRING e foram associados a suas respectivas classes. Posteriormente, esse PI temático foi transformado em PI matricial com resolução de 250 m.

Para avaliar a classificação foi feito o uso da ferramenta do SPRING “Validação” que gerou uma matriz de confusão ou matriz de erros (Tabela 4), comparando os resultados de classificação com os pontos referência, podendo então calcular os parâmetro avaliativos como a Exatidão ou Acurácia Global (Equação 3), do Usuário e do Produtor e o Índice Kappa (Equação 4).

Tabela 4. Matriz de confusão genérica para a avaliação da classificação.

	j = colunas (referência)			total linha n_{i+}	
	1	2	K		
i = linhas classificação	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	K	n_{k1}	n_{k2}	n_{kk}	n_{k+}
	total coluna n_{+j}	n_{+1}	n_{+2}	n_{+k}	N

(Fonte: Congalton e Green, 1999)

$$EG = \frac{\sum_{i=1}^k x_{ii}}{x} \quad (3)$$

onde:

x_{ii} = número de observações na linha i e coluna i (na diagonal principal);

x = número total de observações.

$$\hat{k} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{i+} \cdot n_{+i})}{n^2 - \sum_{i=1}^k (n_{i+} \cdot n_{+i})} \quad (4)$$

onde:

k = Número de linhas da matriz de confusão.

n = número total de observações da matriz.

n_{ii} = número de observações na linha i e coluna i (na diagonal principal)

n_{i+} = total de observações da linha i ;

n_{+i} = total de observações na coluna i .

O resultado do índice Kappa pode enquadrar a classificação em 5 classes de conceitos de desempenho conforme mostra a Tabela 5 .

Tabela 5. Valor do índice Kappa e seus conceitos de desempenho da classificação.

Valor do Kappa		Concordância
<	0,20	Pobre
0,21	0,40	Fraca
0,41	0,60	Moderada
0,61	0,80	Boa
0,81	1,0	Muito Boa

(Fonte: Galparsoro e Fernández, 2001).

4. RESULTADOS E DISCUSSÃO

A partir do mapa temático (Figura 16), gerado no SPRING, é possível verificar que ocorreram muitos erros na classificação, dentre eles a ausência da classe campo cerrado e a fragmentação e dispersão em toda a imagem da classe cerrado.




Figura 16. Mapa temático gerado como resultado da classificação pelas RNA utilizando séries temporais EVI/MODIS.

A dinâmica do mapeamento das classes e a confusão entre as mesmas pode ser melhor compreendida através da análise da Tabelas 6, que mostra a matriz de confusão ou matriz de erros, que faz a comparação entre os pontos de referência, obtidos através do projeto IEF/UFLA-2008, e a imagem classificada, gerando assim os parâmetros avaliativos como a exatidão global, a acurácia do produtor e do usuário e o índice Kappa.

Tabela 6. Matriz de confusão entre a classificação por RNA e as amostras de referência IEF/UFLA, com os parâmetros avaliativos, Exatidão Global, índice Kappa e Acurácia do Produtor e do Usuário para cada classe.

		Referência				Total	Acurácia Usuário
		Cerradão	Cerrado SS	Campo Cerrado	Nulo		
Classificação	Cerradão	1	0	6	1	8	0,13
	Cerrado SS	15	15	4	6	40	0,38
	Campo Cerrado	0	0	0	0	0	0,00
	Nulo	14	15	20	23	72	0,32
	Total	30	30	30	30	120	
	Acurácia Produtor	0,03	0,50	0,0	0,77		
	Exatidão Global						0,33
Índice Kappa						0,10	

Com uma exatidão global de 33% e um índice Kappa de 10% a classificação foi considerada não satisfatória, não sendo possível a discriminação entre as fitofisionomias analisadas.

A classe cerradão foi as de maior confusão. Para esta classe foi classificado corretamente apenas um pixel de 30 amostrados (referência), resultando em uma acurácia do produtor de apenas 0,03 ou aproximadamente 3% de acerto. A classe campo cerrado não existiu na classificação, então todos os 30 pixels amostrados não foram corretamente classificados, resultando em uma acurácia do produtor de 0%.

Dentre as fitofisionomias amostradas, a que apresentou maior desempenho na classificação foi a classe Cerrado sensu stricto. Dos 30 pixels amostrados 15 foram classificados corretamente, apresentando 50% de acerto. Ocorreu confusão de 15 pixels, dos 40 classificados, desta classe com a classe cerrado, resultando em 38% de confusão da classe Cerrado ss com a Cerrado.

A classe nula, que incluiu tudo que não pertence às outras classes, obteve o melhor desempenho, com 77% de acerto. Teve 28% dos pixels classificados confundidos com a classe Cerrado ss, ou seja, 20 pixels, dos 72 classificados como nulo, foram confundidos com Cerrado ss.

Apesar de não ter discriminado as diferentes classes de cerrado de forma satisfatória, a metodologia usada demonstrou ser promissora no estudo de séries temporais de índice de vegetação, analisados através de redes neurais artificiais. Em busca de detectar possíveis erros e melhorar o desempenho da classificação, surgiram alguns questionamentos do que possa ter influenciado esse resultado.

O primeiro deles é com relação ao intervalo que constitui a série temporal analisada, apenas um ano. Estudos que visam a discriminação de culturas agrícolas (BENEDETTI e ROSSINI, 1993; XIN et al., 2002; GLERIANI, 2004) através de análises de séries temporais de índice de vegetação, conseguem obter resultados altamente satisfatórios em suas classificações, mesmo com séries de apenas um ano, ou menores. Dentre as explicações existentes para esses bons resultados está o fato de que a maioria das culturas agrícolas completam seu ciclo fenológico (brotação, crescimento, floração, frutificação) em um curto espaço de tempo, caracterizando bem cada cultura e facilitando a discriminação entre elas (CANAVESI et al., 2005).

Já o comportamento espectral da vegetação, a exemplo do Cerrado, é bastante semelhante para a maior parte das suas diversas fitofisionomias. Aliado a este fator, considera-se, ainda, a grande sazonalidade envolvida na sua resposta espectral (COURA, 2006).

Estudos em outros biomas brasileiros, como o Pantanal (VICTORIA et al., 2009), também obtiveram resultados não satisfatórios em suas classificações ao objetivar a discriminação de formações vegetais.

Diante desses fatos, para se obter melhores resultados visando a discriminação entre fitofisionomias, deve-se considerar a amplitude da séries temporais que possam melhor caracterizar suas variáveis fenológicas, a fim de obter uma classificação mais satisfatória.

A figura 17 representa o comportamento do índice de vegetação EVI2 (JIANG et al., 2008) de uma amostra de cerradão, ao longo de uma série temporal de apenas um ano comparada a outra de 11 anos. Estas foram obtidas a partir do projeto desenvolvido pelo Laboratório de Sensoriamento Remoto aplicado a Agricultura e Floresta (LAF-INPE), que possibilita a visualização instantânea de séries temporais de índice de vegetação EVI2/ MODIS para qualquer coordenada geográfica da América Sul (FREITAS et al., 2011).



Figura 17. Comparação entre uma série temporal com amplitude de 1 ano e outra de 11 anos, para uma amostra de cerradão (LAF-INPE).

Essa comparação possibilita a percepção da representatividade de séries temporais com maior amplitude para a caracterização de fisionomias vegetais.

Neste estudo foi analisado apenas 23 imagens de índice de vegetação EVI, que corresponderam a uma série de um único ano. Essa decisão foi tomada, pois o software SNNS possui limitações quanto ao número total de colunas a serem analisadas. No caso de aumentar a amplitude da série temporal, resultando em um maior número de imagens e conseqüentemente maior número de colunas, outros softwares precisam ser utilizados para suportar esse tipo de análise. A exemplo pode-se citar os softwares ENVI e IDRISI.

Outro questionamento que possa levar a melhores resultados na classificação é com relação ao número de amostras de treinamento usadas neste estudo. Estas foram de apenas 30 para cada classe, num total de 120 amostras. Não há um número ideal a ser amostrado pela literatura, porém este assunto já foi alvo de estudo de diversos autores como Zhuang et al. (1994). Estes sugerem uma amostragem de 5 a 10% dos pixels da imagem.

Para as imagens MODIS analisadas (1851 x 2468 pixels), se a amostragem fosse de 5%, aproximadamente 230 mil pixels deveriam ser amostrados. Por causa das dimensões do pixel do sensor MODIS, 250 m, e da grande fragmentação dos remanescentes de cerrado analisados, houve uma grande dificuldade na obtenção de amostras de treinamento na área delimitada para o estudo. Uma alternativa seria analisar todo o estado de Minas gerais, que corresponderia a quatro *tiles* do sensor MODIS, e não apenas um como foi utilizado nesse estudo. Com uma área mais ampla, existiria maior possibilidade de localizar outros fragmentos com maiores dimensões, e consecutivamente aumentaria a quantidade de amostras de treinamento.

5. CONCLUSÕES

Apesar da classificação não ter sido satisfatória, apresentando parâmetros avaliativos com valores baixos, a metodologia já vem sendo empregada, segundo a literatura, e demonstra ser promissora no estudo de series temporal de índices de vegetação através de Redes Neurais Artificiais.

Os resultados obtidos neste estudo, e outros existentes na literatura, indicam a importância da análise de séries temporais em intervalos de tempo que reflitam as características fenológicas das diferentes coberturas vegetais, para que possa haver a satisfatória discriminação entre elas.

Para obter melhores resultados na classificação este estudo sugere, através das observações discutidas, que o uso de séries temporais com maiores amplitudes e o aumento do número de amostras de treinamento, possam apresentar informações mais representativas às redes neurais, e gerar assim uma classificação mais satisfatória.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ANDERSON, L.O; LATORRE, M. L. ; SHIMABUKURO, Y. E.; ARAI, E.; CARVALHO-JUNIOR, O.A. **Sensor MODIS : uma abordagem geral**. São José dos Campos -SP: Instituto Nacional de Pesquisas Espaciais -INPE, 86 p. (RPQ / 752). 2003.

BARKER, J.L.; HARDEN, M.K.; ANUTA, E.A.; SMID, J. E HOUGT, D. **MODIS spectral sensivity study: requirements and characterization**. Washington: Nasa, 84p.Oct, 1992.

BENEDETTI, R.; ROSSINI, P. **On the use of NDVI profiles as a tool for agricultural statistics: the case study of Emilia Romagna**. Remote Sensing of Environment, v.45, n.3, p. 311-326, 1993.

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

BITENCOURT, M. D.; MESQUITA JR., H. N.; MANTOVANI, W.; BATALHA, M. A.; PIVELLO, V. R. Identificação de fisionomias de Cerrado com imagem índice de vegetação. In: Contribuição ao conhecimento ecológico do Cerrado, 1, 1997, Brasília. **Anais...** Brasília: Universidade de Brasília, Dep. de Ecologia, p. 316-320. 1997.

BROWN, J. Multitemporal, Moderate-Spatial-Resolution Remote Sensing of Modern Agricultural Production and Land Modification in the Brazilian Amazon. **GIScience & Remote Sensing**, v. 44, n. 2, p. 117-148, June 1, 2007.

CANAVESI, V.; COURA, S. M. C.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; QUIRINO, V. F. **Dinâmica espectro-temporal MODIS em região de Cerrados e intenso uso agropecuário**. XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 2005. Anais..., INPE, p. 1435-1442.

COURA, S. M. C. **Mapeamento de vegetação do estado de Minas Gerais utilizando dados MODIS**. Dissertação de Mestrado - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 150 p. 2006.

DIAS, B. F. S. **Cerrados: uma caracterização**. In: DIAS, B. F. S. (Org.). **Alternativas de desenvolvimento dos Cerrados: manejo e conservação dos recursos naturais renováveis**. Brasília: Fundação Pró-Natureza, p. 11-25. 1992.

EITEN, G. The Cerrado vegetation of Brazil. **The Botanical Review**, New York, v. 38, n. 2, p. 201-341, 1972.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. **Índices de vegetação no sensoriamento remoto da cultura do feijão**. Pesquisa agropecuária brasileira, Brasília, v. 31, n. 6, p. 445-454, 1996.

FERREIRA, I. M. **O afogar das Veredas** : uma análise comparativa espacial e temporal das Veredas do Chapadão de catalão (GO). 2003. 242 f. Tese (Doutorado em Geografia) –Instituto de Geociências e Ciências exatas, Universidade Estadual Paulista, Rio Claro.

FREITAS, R.M.; ARAI, E.; ADAMI, M.; SOUZA, A.F.; SATO, F.Y.; SHIMABUKURO, Y.E.; ROSA, R.R.; ANDERSON, L.O.; RUDORFF, B.F.T. **Virtual laboratory of remote sensing series: visualization of MODIS EVI2 data set over South America**. **Journal of Computational Interdisciplinary Sciences**, 2:57-64. 2011. <http://www.epacis.net/jcis> Acesso em: 22 de jul. de 2013.

GALPARSORO, L. U.; FERNÁNDEZ, S. P. **Medidas de concordancia: el índice Kappa**. 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em: 20 jul. 2013.

GLERIANI, J. M. **Redes neurais artificiais para classificação de espectro-temporal de culturas agrícolas**. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 211p. 2004.

HAYKIN, S. **Redes Neurais: princípios e práticas**. 2ed. Porto Alegre, Brasil, Bookman, 900p, 2001.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. **G.Overview of the radiometric and biophysical performance of the MODIS vegetation indices**. Remote Sensing of Environment, v.83, p. 195-213, 2002.

HUETE, A; JUSTICE, C. **MODIS VEGETATION INDEX (MOD13) Algorithm Theoretical Basis Document**. n. Version 3, p. 120, abr. 1999 Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/land_atbd.php>. Acesso em: 02 jun 2013.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATISTICA (IBGE). 2004. **Mapas interativos (Mapa de Biomassas)** 2004.. Disponível em: <<http://www.ibge.gov.br/mapas/>>. Acesso em 03 agosto 2013.

JAKUBAUSKS, M. E.; LEGATES, D. R.; KASTENS, J. H. Crop identification using harmonic analysis of time-series Avhrrndvi data. **Computers and Electronics in Agriculture**, v. 37, p. 127-139, 2002.

JENSEN, J. **Remote sensing of the environment : an earth resource perspective**. New York: Prantice Hall, 544 p. 2000.

JIANG Z. , HUETE A. R., DIDAN K., MIURA T. **Development of a two-band Enhanced Vegetation Index without a blue band**, Remote Sensing of Environment, 112(10), p 3833-3845. 2008.

JUSTICE, C. O.; TOWNSHEND, J.R.G.; VERMOTE, E.F., MASUOKA, E., WOLFE, R.E., SALEOUS, N., ROY, D.P., MORISETTE, J.T. An overview of MODIS Land

data processing and product status. **Remote Sensing of Environment**, v. 83, n.1-2, Nov. p 3 –15, 2002a.

KAVZOGLU, T.; MATHER, P.M. The use of backpropagation artificial neural networks in land cover classification. **International Journal of Remote Sensing**, v.24, n.13, p. 4907-4938, Dec. 2003.

LATORRE, M. L. ANDERSON, L.O.; SHIMABUKURO, Y.E.; JUNIOR, O.A.C. Sensor Modis: características gerais e aplicações. **Espaço & Geografia**. v. 6, n. 1, p. 97 – 126, 2003.

LACRUZ, M. P.; SANTOS, J. R.; CONFORTE, J. C. **Utilização de séries temporais de imagens MODIS/TERRA e análise harmônica para o monitoramento de corredores ecológicos**. 12º Simpósio Brasileiro de Sensoriamento Remoto, Goiania. **Anais...** São José dos Campos: INPE, p. 3223-3228. 2005.

MENDONÇA, R. C.; FELFILI, J. M.; WALTER, B. M. T.; SILVA, M. C.; REZENDE, A. V.; FILGUEIRAS, T. S.; NOGUEIRA, P. E. Flora vascular do Cerrado. In: Sano, S.M.; ALMEIDA, S.P. (Ed.). **Cerrado: ambiente e flora**. Planaltina, DF: Embrapa Cerrados, p. 289-556. 1998.

MITTERMEIER, R.A.; ROBLES, P.; HOFFMAN, M.; PILGRIM, J.; BROOKS, T.; MITTERMEIER, C.G.;LAMOREUX, J. & FONSECA, G.B. **Hotspots revisited. Conservação Internacional/CI, Agrupación Sierra Madre**. Pp. 15-96. 2005.

MIZIARA, F. E FERREIRA, N. C. **Expansão da fronteira agrícola e evolução da ocupação e uso do espaço no Estado de Goiás: subsídios à política ambiental**. In: FERREIRA, L Jr.. (Org.). *A encruzilhada socioambiental: biodiversidade, economia e sustentabilidade no Cerrado*. 1 ed. Goiânia: UFGv. 1, p. 107-125. 2008.

MOREIRA, M. A; **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Viçosa - MG: UFV, 2003. 307 p.

MOREIRA, M. A; SHIMABUKURO, Y.E. Cálculo do Índice de Vegetação a Partir do Sensor AVHRR. In: Ferreira, N.J. **Aplicações Ambientais Brasileiras dos Satélites NOAA e TIROS-N**. São Paulo-SP: Oficina de Textos, 2004. Cap. 4, p. 271.

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

NOVO, E. M. L. de M. **Sensoriamento Remoto. Princípios e Aplicações.** São Paulo – Edgar Blucher LTDA. 1989.

PONZONI, F. J. Comportamento Espectral da Vegetação. In: MENESES, P. R., NETTO, J. S. M. (org) Sensoriamento remoto, reflectância dos alvos naturais. Brasília – DF: Editora Universidade de Brasília - UNB, Embrapa Cerrados, p 157-199, 2001.

ROSENDO, J. S. **Índices de vegetação e monitoramento do uso do solo e cobertura vegetal na Bacia do Rio Araguari – MG – utilizando dados do sensor MODIS.** Dissertação (Mestrado em Geografia) – Universidade Federal de Uberlândia, Uberlândia. 130p. 2005.

RIBEIRO, J. F; WALTER, B. M. T. **Fitofisionomias do Bioma Cerrado.** In: SANO, S. M.; ALMEIDA, S. P. **Cerrado: ambiente e flora.** Planaltina: EMBRAPA, p. 89-166. 1998.

SCOLFORO, J. R.; MELLO, J. M.; OLIVEIRA, A. D.(Ed.). **Inventário Florestal de Minas Gerais: Cerrado - Florística, Estrutura, Similaridade, Distribuição Diamétrica e de Altura, Volumetria, Tendências de Crescimento e Áreas Aptas para Manejo Florestal.** Lavras: UFLA, cap. 1, p.1-76. 2008.

SILVA, A. A. **Uso de dados MODIS para o monitoramento ambiental nos cerrados: Um estudo a partir de dados MOD13Q1 realçados através de um modelo de mistura espectral.** Dissertação de Mestrado, Goiânia, 2004.

SILVA, P. R. **Uso de redes neurais artificiais e objetos geográficos na classificação digital de imagens de sensoriamento remoto.** Dissertação de mestrado- Universidade Federal de Lavras, Lavras, 106p. 2012.

VICTORIA, D. C.; ANDRADE, R. G.; PAZ, A. R. **Série temporal de imagens EVI/MODIS para discriminação de formações vegetais do Pantanal.** 2º Simpósio de Geotecnologias no Pantanal, Corumbá – MS, 2009. Anais..., Embrapa Informática Agropecuária/INPE, p. 1018-1025.

VERMOTE, E.; EL SALEOUS, N.; JUSTICE, C. Atmospheric correction of the MODIS data in the visible to middle infrared: first results. **Remote Sensing of Environment**, v. 83, p. 97-111, 2002.

XIN, J.; YU, Z.; VAN LEEUWEN, L.; DRIESSEN, P.M. **Mapping crop key phenological stages in the North China Plain using NOAA time series images**. International Journal of Applied Earth Observation and Geoinformation, v.4, n.2, p.109-117, Nov. 2002.

ZHANG, X.; ENGEL, B.A.; LOZANO-GARCIA, D.F.; FERNÁNDEZ, R.N.; JOHANNSEN, C.J. Optimization of training data required for neuro-classification. **International Journal of Remote Sensing**, v.15, n.16, p.3271-3277, Nov. 1994.

ZHANG, X.; SOHLBERG, R.A.; TOWNSHEND, J.R.G.; DIMICELI, C.; CARROLL M.L.; EASTMAN, J.C.; HANSEN, M.C.; DEFRIES, R.S. Detection of land cover changes using MODIS 250 m data. **Remote Sensing of Environment**, v. 83, p. 336-350, 2002.

YU, X.; ZHUANG, D.; CHEN, H.; HOU, X. Forest classification based on MODIS time series and vegetation phenology. Geoscience and Remote Sensing Symposium, 2004. **IGARSS '04. Proceedings**. vol.4, pp. 2369- 2372, set. 2004.