

Mineração de dados geográficos para mapear as fitofisionomias do bioma cerrado

Luciano Teixeira de Oliveira ¹
Luis Marcelo Tavares de Carvalho ¹
Fausto Weimar Acerbi Jr. ^{1,2}

¹ Universidade Federal de Lavras – UFLA/DCF/LEMAF
Caixa Postal 3037 – 37200-000 – Lavras – MG, Brasil
oliveiralt@yahoo.com.br
passarinho@ufla.br
fausto@ufla.br

² Wageningen University and Research Centre – WUR/GRS
P. O. Box 47 – 6700 AA – Wageningen, The Netherlands
fausto.acerbi@wur.nl

Abstract: The main objectives of this work were: (a) to compare image classifiers and (b) to map the physiognomies of the Cerrado biome in the study area. Two levels of detail were considered for mapping the physiognomies of the Cerrado biome, generating classes in the first level and subclasses in the second level. Image from the ETM+ sensor with 30 and 15 m of spatial resolution were classified using univariate and multivariate decision trees, as well as the maximum likelihood algorithm. The input datasets for the classifiers were composed by the spectral bands of multitemporal images, NDVI, Tasseled Cap, spectral unmixing fraction images, Isodata spectral clustering, digital elevation model, and distance from rivers. By comparing Kappa coefficients, it was concluded that ETM+ temporal images with enhanced spatial resolution, plus elevation, distance from rivers, NDVI, Tasseled Cap, fraction images, and Isodata, generate results of excellent quality when input to data mining techniques and used to map cerrados in the centre-west of Minas Gerais.

Palavras-chave: image classification, decision trees, maximum likelihood, classificação de imagens, árvore de decisão, máxima verossimilhança.

1. Introdução

O constante desmatamento do cerrado traz a tona a necessidade de se buscar estratégias para promover o monitoramento e o mapeamento do que restou deste Bioma. O cerrado apresenta uma alta biodiversidade, porém, a intensificação da sua fragmentação pode trazer perdas inestimáveis de exemplares deste bioma, como o que já pode ser observado nos livros vermelhos da fauna (Machado et al., 1998) e da flora (Mendonça & Lins, 2000) de Minas Gerais.

A falta de um mapeamento preciso, não só deste bioma como dos outros existentes no estado de Minas Gerais, faz com que aumente a dificuldade de se ter um plano gerencial com relação ao meio ambiente, gerando uma deficiência no banco de dados e, por conseguinte, em outras áreas do planejamento do estado.

Isto pode ser observado no Norte do estado de Minas Gerais, onde ocorre o bioma cerrado. Nesta região é possível observar áreas com graves problemas sociais, que se intensificam pela falta de planejamento e de monitoramento dos fragmentos existentes, levando a uma elevada exploração clandestina de carvão vegetal, que atualmente é agravada pelo alto valor do deste produto.

Sendo assim, este trabalho tem como objetivos principal desenvolver uma metodologia para o mapeamento das diversas fitofisionomias do bioma cerrado em regiões antropizadas. Os objetivos específicos são:

- Comparar a eficiência entre as imagens ETM+, para o monitoramento do bioma cerrado;
- Comparar a exatidão da Classificação proveniente de imagens com 30 e 15m de resolução;
- Avaliar a precisão de mapeamentos em dois níveis de detalhamento.

2. Material e métodos

2.1. Amostragem das fisionomias no campo

Inicialmente a classificação proposta por Ribeiro & Walter (1998) foi utilizada para proceder à caracterização e escolha do nível de divisão das fitofisionomias do bioma cerrado.

Através de uma análise qualitativa da imagem ETM+ de baixa resolução, período seco e período úmido, foram identificadas áreas representativas de fragmentos florestais e demais componentes da matriz agrária. Foram realizadas campanhas a campo via terrestre e aérea para identificação e distribuição das demais fitofisionomias da região, as quais foram aplicadas na amostragem da verdade terrestre.

Os níveis fisionômicos foram adaptados da classificação original de Ribeiro & Walter (1998), por ser necessário adequar as características dos sensores analisados, que não são capazes de resolver pequenos fragmentos representativos destas fisionomias. Fragmentos de veredas são muito pequenos e muitas vezes estão consorciados com as Matas Ciliares. Fragmentos de campo limpo e campo sujo apresentam-se muito associados entre si, assim como as áreas de campo rupestre e campo limpo hidromórfico. Estas fitofisionomias, individualmente, não seriam captadas pelo sensor por não apresentarem tamanho significativo, já que, teoricamente, o objeto estudado deve ser pelo menos três vezes maior que a resolução do sensor (Molenaar, 1998).

O conjunto de amostras foi estabelecido inicialmente a partir da imagem ETM+ época seca. Nas imagens ETM+ época úmida, foi necessário adaptar o conjunto de amostras, devido a algumas mudanças observadas nas áreas das mesmas, além disso, toda a amostragem teve como base a imagem de baixa resolução para não haver sobreposição de amostras. A imagem de alta resolução foi gerada para as duas épocas utilizando a transformada ondaleta bi-ortogonal não-decimada com filtro de Antonini 7/9 (Oliveira, 2004).

Do conjunto total, para cada classe fisionômica, aleatorizou-se aproximadamente 30% das amostras em cada classe, para treinamento dos algoritmos, acuracidade das classificações e aferição da acuracidade (**Tabelas 1 e 2**), este último utilizado apenas nas árvores de decisão. Desta forma procurou-se seguir um equilíbrio entre a amostragem ao acaso e a estratificada.

TABELA 1. Total de pixels amostrados no Nível – 1.

Amostras	Florestal	Savânica	Campestre	Eucaliptal	Pastagem	Cultura	Solo	Água	Sombra
Amostragem	8237	67251	53956	18710	42396	1814	38487	5635	2104

TABELA 2. Total de pixels amostrados no Nível – 2.

Amostras	MC	FSd	FDe	CerD	CerT	CerRa	CerRu	CaRu	CaLS	EuT1
Amostragem	2945	2050	3242	18928	27027	9963	11333	51783	2173	10463
continuação										
Amostras	EuT2	EuT3	PPuro	PArb	Cult	SoT1	SoT2	SoIm	Água	Somb
Amostragem	5036	3211	37355	5041	1814	33359	4325	803	5635	2104

2.2. Processamento das imagens

Com o intuito de diminuir o ruído acrescentado às imagens resultantes das fusões, devido à influência atmosférica na imagem pancromática tomada pelo sensor ETM+, utilizou-se o Filtro de Lee com uma janela 3x3.

Calculou-se o NDVI para todas as imagens relacionando-se a banda representativa do vermelho com a do infravermelho próximo, correspondentes as bandas 3 e 4 do sensor ETM+.

Já as transformações Tasseled Cap das imagens ETM+, foram realizadas utilizando os coeficientes da **Tabela 3**, os quais foram derivados por Crist & Cicone (1984).

TABELA 3. Coeficientes do Tasseled Cap aplicados às imagens Landsat.

Índices	ETM+ 1	ETM+ 2	ETM+ 3	ETM+ 4	ETM+ 5	ETM+ 7
Brightness	0,3037	0,2793	0,4743	0,5585	0,5082	0,1863
Greenness	-0,2848	-0,2435	-0,5436	0,7243	0,0840	-0,1800
Wetness	0,1509	0,1973	0,3279	0,3406	-0,7112	-0,4572
Fourth	-0,8242	0,0849	0,4392	-0,0580	0,2012	-0,2768
Fifth	-0,3280	0,0549	0,1075	0,1855	-0,4357	0,8085
Sixth	0,1084	-0,9022	0,4120	0,0573	-0,0251	0,0238

As frações de mistura foram obtidas levando-se em consideração a teoria do simplex (Tso & Mather, 2001), obtendo-se os pixels puros dos extremos da distribuição do espaço amostral, Vermelho x infravermelho. O modelo foi aplicado com restrição.

Gerou-se uma imagem de 25 classes, por uma classificação não supervisionada pelo método Isodata, aplicando 10 iterações com um número mínimo de 10 pixels por classe e juntando um número de seis pares isolados na classe.

Utilizando as curvas de nível na forma vetorial do IBGE, gerou-se um modelo digital de terreno. Neste modelo, as altitudes foram re-escaladas para o intervalo de 0 a 255, onde no intervalo de altitude mais baixo foi considerado como 0, aumentando-se proporcionalmente as classes até 255 correspondente a altitude mais elevada da região.

Para o *buffer* dos rios fez-se necessário à extração de toda a hidrografia, através da análise visual da imagem de alta resolução gerada, a partir do qual gerou-se um *buffer* de 0 a 255. Neste *buffer* considerou os pixels correspondentes à hidrografia com valor 0, aumentado gradativamente este valor à medida que os pixels se distanciassem da hidrografia, valorando-os até um o máximo de 255, correspondente a 255 pixels distantes do pixel da hidrografia.

O modelo digital de terreno, bem como o *buffer* da hidrografia, são bastante relevantes, pois as características da vegetação estão muito relacionadas com a altitude e os cursos d'água.

2.3. Estruturação e mineração dos dados

Com a geração de todas as imagens descritas, obteve-se 3 conjuntos de atributos, (épocas seca, úmida e temporal), dos quais foram extraídas amostras de treinamento e aferição. Tais amostras foram utilizadas para gerar e selecionar as melhores árvores de decisão, pertencentes ao nível – 1 e ao nível – 2, produzidas no programa Cart 5.0 com o algoritmo Gini.

Procedeu-se à classificação supervisionada pelo método da máxima verossimilhança no programa Envi 4.0. Foram utilizadas as amostras de treinamento, correspondentes a, aproximadamente, 30% dos valores totais descritos nas **Tabelas 1 e 2**. Na máxima verossimilhança considerou-se que todos os pixels possuíam a mesma probabilidade de pertencer a uma determinada classe.

Utilizou-se o mesmo conjunto de amostras de treinamento da máxima verossimilhança na árvore de decisão, com a finalidade de gerar as árvores univariadas e multivariadas. Para a aferição destas árvores extraiu-se um novo conjunto de amostras dos valores iniciais descritos nas **Tabelas 1** e **2**, sendo que este conjunto de amostras possuía o mesmo número de pixels das amostras de treinamento.

2.4. Determinação e comparação do grau de acuracidade das imagens geradas

Para verificar a acurácia dos classificadores, utilizou-se as amostras de acuracidade, extraídas da **Tabelas 1** e **2** da mesma forma que as de treinamento e aferição. Com o uso das amostras de acuracidades foi gerada uma matriz de confusão, extraindo-se desta o coeficiente Kappa (Colganton & Green, 1999; Tso & Mather, 2001) e sua variância.

Para comparar a melhor classificação utilizou-se o teste z sobre os coeficientes Kappa (Lillessand & Kiefer, 1999). Utilizando um nível de significância de 95%, equivalente a $z = 1,9599$.

Também se verificou a acuracidade de cada classe em separado pelo método utilizado por Carvalho (2001), o qual leva em consideração os erros de comissão e omissão de cada classe.

3. Resultados e discussão

3.1. Mineração dos dados, classificação das imagens, geração e análises das matrizes.

Com a utilização das amostras de treinamento nas árvores de decisão uni e multivariada, para o nível 1 e para o nível 2, selecionou-se as árvores de decisão com o menor custo relativo, as quais possuem uma menor mistura de classes nas folhas terminais (Breiman et al., 1984).

Com a prévia seleção das árvores, geraram-se as suas respectivas matrizes, com a utilização das amostras de acurácia. Obteve-se também as matrizes referentes à classificação por máxima verossimilhança, que teve sua apresentação limitada a seleção do melhor Coeficiente Kappa.

No conjunto de atributos de época úmida constatou um melhor desempenho das árvores multivariadas em relação aos demais classificadores (**Tabela 4**), tendo apenas um caso que a univariada se mostrou melhor, porém com uma diferença muito pequena.

TABELA 4. Resultado do Coeficiente Kappa para as matrizes do conjunto de atributos Landsat época úmida.

	Classificação	Árvore Univariada		Árvore Multivariada		Maxiver	
		Kappa	Varição	Kappa	Varição	Kappa	Varição
Alta Resolução	Nível – 1	0,8976	-0.00052	0,8975	-0.00052	0,8282	-7.7E-07
	Nível – 2	0,8289	-7.4E-07	0,8306	-1.1E-06	0,7681	-0.00014
Baixa Resolução	Nível – 1	0,9074	-0.00048	0,9166	-0.00043	0,8155	-4.3E-07
	Nível – 2	0,8478	-1.3E-06	0,8540	-3.8E-07	0,8010	-0.00012

Já no conjunto de imagens época seca, evidenciou-se uma melhor avaliação do Kappa (**Tabela 5**), quando comparado com as da época úmida (**Tabela 4**). Isto indica que a época seca deve ser o melhor período para avaliação das fisionomias do Bioma Cerrado, quando utilizada apenas uma data de imagem.

TABELA 5. Resultado do Coeficiente Kappa para as matrizes do conjunto de atributos Landsat época seca.

	Classificação	Árvore Univariada		Árvore Multivariada		Maxiver	
		Kappa	Varição	Kappa	Varição	Kappa	Varição
Alta Resolução	Nível – 1	0,9563	-0.00023	0,9550	-0.00024	0,8981	-1E-06
	Nível – 2	0,9314	-9E-07	0,9296	-8.4E-07	0,8961	-7.3E-05
Baixa Resolução	Nível – 1	0,9527	-0.00025	0,9483	-0.00028	0,8915	-8.7E-07
	Nível – 2	0,9157	-1.3E-06	0,9160	-1.1E-06	0,895	-7.2E-05

Observou-se neste conjunto de dados um melhor desempenho das árvores univariadas, do nível 1 de classificação e das imagens geradas com alta resolução espacial.

O conjunto de imagens temporais obteve um melhor resultado em relação aos demais conjuntos, por este conseguir captar melhor a variação da deciduidade da vegetação (**Tabela 6**).

TABELA 6. Resultado do Coeficiente Kappa para as matrizes do conjunto de atributos Landsat Temporal

	Classificação	Árvore Univariada		Árvore Multivariada		Maxiver	
		Kappa	Varição	Kappa	Varição	Kappa	Varição
Alta Resolução	Nível – 1	0,9639	-0.00021	0,9671	-0.00018	0,9284	-7.9E-07
	Nível – 2	0,9375	-8.8E-07	0,9410	-8.3E-07	0,9083	-6.8E-05
Baixa Resolução	Nível – 1	0,9569	-0.00024	0,9574	-0.00024	0,9160	-8E-07
	Nível – 2	0,9215	-9.8E-07	0,9271	-9.3E-07	0,9044	-6.9E-05

Aplicando a avaliação de Landis & Koch (1977), todas as classificações foram definidas como Excelente, salvo as de alta resolução espacial no nível 2 de classificação da época úmida, , que teve sua avaliação como Muito Boa.

Tendo a avaliação de todas as classificações como excelente segundo Landis & Koch (1977).

3.2 Comparação dos procedimentos

Com a aplicação do “z” tabelado a 95% de probabilidade foi possível constatar a significância dos melhores resultados dos conjuntos analisados (Lillessand & Kiefer, 1999).

a) Época seca x Época úmida.

Analisando a **Tabela 7** pode-se inferir, que as imagens do ETM+ época seca conseguem resolver melhor a distinção das fisionomias do que as imagens ETM+ captadas na época úmida, principalmente quando se almeja um maior detalhamento, obtendo-se melhores resultados quando melhorada a resolução espacial destas. Observou-se também um melhor desempenho das árvores univariadas sobre as demais, porém, constatou-se que esta é significativamente diferente apenas das classificações por máxima verossimilhança, tendo como base o melhor resultado do índice Kappa. Já nas diferentes resoluções analisadas, houve uma diferença significativa apenas nas imagens geradas com alta resolução espacial relativas à época úmida, o que pode ser explicado pelo baixo valor do coeficiente Kappa das imagens desta época.

TABELA 7. Significância dos resultados observados no Coeficiente Kappa a 95% de probabilidade para todos os níveis de classificação, no confronto de resultados Landsat época úmida com os de época seca.

	Classificação	Árvore Univariada	Árvore Multivariada	Maxiver
Nível – 1 Ép.Úmida	Alta Resolução	2,138525*	2,135854*	8,370535*
	Baixa Resolução	1,823676	1,539116	9,205675*
Nível – 1 Ép. Seca	Alta Resolução	0	0,058384	3,801879*
	Baixa Resolução	0,163323	0,354396	4,232065*
Nível – 2 Ép.Úmida	Alta Resolução	8,327384*	8,210829*	9,697031*
	Baixa Resolução	7,08394*	6,688916*	8,226858*
Nível – 2 Ép. Seca	Alta Resolução	1,624826	1,742231	3,441529*
	Baixa Resolução	2,645513*	2,630752*	3,507871*

* Valores significativos ao nível de 95% de probabilidade.

b) Época Seca x Época úmida x Temporal

A premissa de que o conjunto de imagens temporais proporcionaria um melhor resultado foi observada, já que este conjunto de imagens temporais conseguiu captar a deciduidade da vegetação. Isto é constado na análise das **Tabelas 4, 5 e 6**, no nível 2 de classificação, onde a floresta decídua é

fortemente evidenciada devido a sua modificação no conjunto de imagens de época seca e época úmida.

Sendo assim, ao analisar-se a **Tabela 8**, observa-se que a combinação dos conjuntos de imagens de época seca e época úmida geraram uma melhoria no resultado para separação detalhada das fisionomias do Bioma Cerrado, quando utilizados as árvores multivariadas. E que as imagens de época seca podem ser utilizadas para separar as fisionomias deste bioma, com um bom desempenho quando aplicadas as árvores univariadas já que não se observou diferença significativa desta na **Tabela 5**, com as imagens temporais multivariadas quando exigido um menor detalhamento.

O conjunto de imagens de época úmida gerou os piores resultados e diferença significativa nos dois níveis de classificação. Porém, as imagens de época úmida são de grande valia, quando consorciadas com as imagens de época seca.

TABELA 8. Significância dos resultados observados no Coeficiente Kappa a 95% de probabilidade entre os níveis de classificação, no confronto de resultados Landsat época úmida, época seca e Temporal.

	Classificação	Árvore Univariada	Árvore Multivariada	Maxiver
Nível – 1	Alta Resolução	2,619917*	2,614888*	10,2282*
Ép.Úmida	Baixa Resolução	2,307658*	2,035482*	11,17227*
Nível – 1	Alta Resolução	0,527982	0,584755	5,0779*
Ép. Seca	Baixa Resolução	0,689861	0,87592*	5,563431*
Nível – 1	Alta Resolução	0,159321	0	2,84736*
Temporal	Baixa Resolução	0,491597	0,468264	3,760474*
Nível – 2	Alta Resolução	10,17984*	10,04614*	11,0069*
Ép.Úmida	Baixa Resolução	8,774667*	8,335458*	9,481929*
Nível – 2	Alta Resolução	2,624961*	2,757448*	4,43394*
Ép. Seca	Baixa Resolução	3,773699*	3,757888*	4,509052*
Nível – 2	Alta Resolução	2,180245*	1,919157*	3,7056*
Temporal	Baixa Resolução	3,35365*	2,942558*	3,941825*

* Valores significativos ao nível de 95% de probabilidade.

Já o ganho de exatidão, quando se trabalha no nível 1 de classificação, deve ser avaliado com cautela, pois ao se trabalhar no nível 2 apesar de piorar a exatidão, obtém-se um ganho a nível de detalhamento da região estudada, cabendo esta escolha ser feita em função dos objetivos do projeto avaliado.

Sendo assim, gerou-se a classificação por árvore multivariada do conjunto ETM+ Temporal, em alta resolução no nível – 2 e para o nível – 1 pelo mesmo procedimento (**Figura 1a e 1b**). O mesmo foi feito para a imagem época seca (**Figura 1c**), que se portou melhor na classificação quando utilizada individualmente, obtendo-se as matrizes finais nas **Tabelas 9, 10, 11**.

TABELA 9. Matriz de confusão para Imagem Landsat Época Seca com 96,31% de acuracidade e 0,9555 de Coeficiente Kappa.

Classes	Água	Cultura	Solo	Sombra	Pastagem	Eucaliptal	Savanica	Campest.	Florestal	Total
Água	1475	0	0	1	0	0	0	0	5	1481
Cultura	0	410	3	0	0	8	0	0	0	421
Solo	4	0	3024	0	36	6	5	18	0	3093
Sombra	5	0	0	493	0	0	0	5	1	504
Pastagem	0	2	33	0	3287	0	17	8	0	3347
Eucaliptal	5	8	2	0	0	4187	77	0	29	4308
Savanica	1	0	1	0	19	42	7613	41	39	7756
Campest.	0	0	46	1	8	3	103	2393	39	2593
Florestal	10	0	1	5	0	74	85	165	2207	2547
Total	1500	420	3110	500	3350	4320	7900	2630	2320	26050
%	97,9	95,1	95,1	96,5	96,4	94,3	94,7	84,6	83,9	

TABELA 10. Matriz de confusão para Imagem Landsat Temporal com 97,27% de acuracidade e 0,9671 de Coeficiente Kappa.

Class	Água	Cultura	Solo	Sombra	Pastagem	Eucaliptal	Savanica	Campest.	Florestal	Total
Água	1486	0	0	5	0	3	1	6	4	1505
Cultura	0	412	3	0	0	4	0	0	0	419
Solo	2	2	3025	0	47	2	6	21	3	3108
Sombra	2	0	0	490	0	0	0	1	1	494
Pastagem	0	0	30	0	3291	0	3	3	1	3328
Eucaliptal	0	3	1	0	0	4228	30	1	56	4319
Savanica	0	0	10	0	12	35	7712	55	48	7872
Campest.	4	0	31	2	0	3	49	2502	13	2604
Florestal	6	3	10	3	0	45	99	41	2194	2401
Total	1500	420	3110	500	3350	4320	7900	2630	2320	26050
%	97,8	96,5	94,7	97,2	97,2	95,9	95,7	91,6	86,8	

TABELA 11. Matriz de confusão para Imagem Landsat Temporal, Nível – 2 de classificação com 94,21% de acuracidade e 0,9383 de Coeficiente Kappa e precisão por classe.

Class	Água	CerT	Cult	SoT1	SoT2	Solm	Somb	PPuro	PArb	EuT1	EuT2	EuT3	CerD	MC	CaLS	FDe	FSd	CeRa	CaRu	CeRu	Total
Água	1467	0	0	0	0	0	7	0	0	0	0	0	0	2	0	0	0	0	0	0	1476
CerT	2	1802	0	0	0	0	0	1	0	3	13	124	2	0	1	1	25	8	10	0	1992
Cult	0	0	418	0	2	0	0	0	2	0	0	0	0	0	0	1	0	0	0	0	423
SoT1	0	0	0	1967	12	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	1981
SoT2	3	0	0	20	739	4	0	34	5	0	0	0	0	0	0	0	0	0	0	0	805
Solm	7	0	1	0	7	290	0	4	0	0	1	0	0	6	4	0	1	7	1	0	329
Somb	2	0	0	0	0	0	485	0	0	0	0	0	0	0	1	1	0	3	0	0	492
PPuro	7	0	0	9	18	0	0	1891	47	0	0	0	0	3	0	1	2	0	0	0	1978
PArb	0	0	0	0	14	6	0	70	1274	0	0	0	0	0	3	10	0	0	3	0	1380
EuT1	0	0	1	0	0	0	0	0	0	1853	75	5	1	3	0	4	1	0	0	0	1943
EuT2	1	1	0	0	0	0	0	0	0	137	1260	9	5	11	1	18	0	2	0	0	1445
EuT3	0	15	0	0	0	0	0	0	2	10	866	19	1	0	0	4	1	0	1	0	919
CerD	0	105	0	0	0	0	0	0	1	7	2	1751	8	0	4	22	0	4	1	0	1905
MC	3	4	0	0	0	0	0	0	3	12	5	14	753	0	0	18	0	0	0	0	812
CaLS	2	0	0	4	2	5	0	0	0	0	0	0	0	617	0	0	1	0	5	0	636
FDe	3	0	0	0	0	0	4	1	0	0	0	2	0	0	936	2	1	26	0	0	975
FSd	1	10	0	0	0	0	0	0	2	33	17	80	20	0	4	484	0	17	3	0	671
CeRa	0	35	0	0	0	1	0	3	10	0	0	0	0	1	0	0	1953	2	6	0	2011
CaRu	2	8	0	0	6	4	4	0	3	0	0	1	0	1	9	0	4	1892	26	0	1960
CeRu	0	20	0	0	0	0	0	6	0	0	2	3	0	1	0	1	1	39	1844	0	1917
Total	1500	2000	420	2000	800	310	500	2000	1350	2000	1400	920	2000	800	630	960	560	2000	2000	1900	26050
%	97,2	82,3	98,4	97,7	85,3	83,1	95,7	90,6	87,5	88,7	79,5	89,0	81,3	87,7	95,1	93,7	64,8	94,9	91,5	93,5	




FIGURA 1. Resultado da Classificação Nível – 2, por (a) Árvore de Decisão Multivariada Temporal, e classificação Nível – 1 (b) árvore de decisão multivariada Temporal; (c) árvore de decisão univariada Época Seca e (d) árvore de decisão multivariada época úmida.

4. Conclusões

Com base nos resultados obtidos pode se concluir que:

-As imagens produzidas de alta resolução espacial apresentaram-se melhores para o mapeamento das fisionomias do bioma Cerrado que as de baixa resolução;

-A imagem Landsat coletada na época seca é mais eficiente que as imagens em épocas úmidas na distinção de fisionomias do Bioma Cerrado;

-As imagens Landsat época úmida e época seca quando unidas em um conjunto temporal geram classificações mais eficientes no detalhamento do bioma cerrado;

-É possível gerar classificações de excelente qualidade usando os níveis 1 e 2 de classificação do Bioma cerrado, quando combinado o conjunto de atributos trabalhados na dissertação, para o Centro-Oeste Mineiro.

-As árvores multivariadas são mais eficientes quando aplicadas ao conjunto de atributos temporais.

-As árvores univariadas foram mais eficientes que as multivariadas, quando aplicadas a um conjunto de atributos de uma mesma data (época seca).

-O procedimento não paramétrico por árvore de decisão se mostrou mais eficiente que o procedimento paramétrico por máxima verossimilhança.

Referências

Breiman, L., Friedman, J. H., Olshen, R. A. **Classification and regression trees**. Belmont: Chapman & Hall, 1984. 358 p.

Carvalho, L. M. T. **Mapping and monitoring forest remnants: a multi-scale analysis of spatio-temporal data**. 2001. 140 p. Thesis (Doctor) - Wageningen University, Wageningen.2001.

Colgaton, R. G., Green, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 137 p.

Crist, E. P., Cicone, R. C. A physically – based transformation of thematic mapper data – the TM Tasseled Cap. **IEEE Transactions on Geoscience and Remote Sensing**, Los Alamitos, v. 22. n. 3, p. 256-262, 1984.

Landis, J. R., Koch, C. H. **The measurement of observer agreement for categorical data**. **Biometrics**, Washington, v. 33, n. 3, p. 159-174, 1977.

Lillesand, T. M., Kiefer, R. W. **Remote sensing and image interpretation**. 4. ed. USA: John Wiley, 1999. 724 p.

Machado, A. B. M., Fonseca, G. A. B., Machado, R. B., Aguiar, L. M. S., Lins, L. V. **Livro vermelho das espécies ameaçadas de extinção da fauna de Minas Gerais**. Belo Horizonte: Fundação Biodiversitas, 1998. 608 p.

Mendonça, M. P., Lins, L. V. **Lista vermelha das espécies ameaçadas de extinção da flora de Minas Gerais**. Belo Horizonte: Fundação Biodiversitas/Fundação Zôo-Botânica de Belo Horizonte, 2000. 160 p.

Molenaar, M. **An introduction to theory of Spatial object modelling for GIS**. Enschede, The Netherlands: Taylor & Francis, 1998. 246 p.

Oliveira, L. T. **Fusão de imagens de sensoriamento remoto e mineração de dados geográficos para o mapeamento das fitofisionomias do bioma cerrado**. 2004. 131 p. (DCF-UFLA). Dissertação (Mestrado em Manejo Ambiental) – Universidade Federal de Lavras, Lavras. 2004.

Ribeiro, J. F., Walter, B. M. T. Fitofisionomias do bioma Cerrado. In: Sano, S., Almeida, S. P. (Ed.) **Cerrado: ambiente e flora**. Planaltina: EMBRAPA-CPAC, 1998. p. 89-169.

Tso, B., Mather, P. M. **Classification Methods for remotely sensed data**. New York: Taylor & Francis, 2001. 332 p.