

# CLASSIFICAÇÃO DE IMAGENS LANDSAT E MUDANÇAS NO USO DO SOLO DE UMA ÁREA DA REPRESA DE FURNAS, ENTRE OS ANOS DE 2004 E 2014 <sup>1</sup>

Cassiano Gustavo Messias<sup>2</sup>; Rafael Lacerda Cobra<sup>3</sup>

**Resumo:** Este trabalho tem como objetivo avaliar o uso do solo do recorte de uma cena do satélite Landsat, em proximidades do lago de Furnas, Minas Gerais, Brasil, considerando os anos de 2004 (TM) e 2014 (OLI). Foram utilizados diferentes algoritmos de classificação supervisionada, sendo que o Máxima Verossimilhança possibilitou a obtenção de melhores resultados para a maioria das classes consideradas. Os resultados obtidos mostram que houve crescimento das classes campos limpos, áreas urbanas e, especialmente, solo exposto. Por outro lado, houve redução das culturas temporárias, culturas perenes, água e vegetação nativa. Os índices *Kappa* e exatidão global para 2004 e 2014 apresentaram valores elevados, considerados excelentes.

**Palavras-Chave:** Sensoriamento remoto, máxima verossimilhança, classificação supervisionada.

## INTRODUÇÃO

O uso e as informações de cobertura da terra têm sido reconhecidos como uma das informações fundamentais para temas relacionados ao planejamento regional, pesquisas em mudanças globais e aplicações de monitoramento ambiental. Ao longo das últimas quatro décadas, os dados de Sensoriamento Remoto têm cada vez mais se tornado a principal fonte de coleta de informações de uso e cobertura da terra (LIU *et al.*, 2014). O avanço na obtenção de dados da superfície, através de sensores orbitais, possibilita a redução dos extensivos trabalhos de campo e permite-nos a obtenção de informações em locais de difícil acesso (ANDRADE *et al.*, 2014).

Embora relativamente recente, uso de imagens de satélite possui potencialidades altamente reconhecidas. A aplicação de técnicas validadas podem proporcionar melhoria e agilidade nos procedimentos de classificação, abertura de novas possibilidades de atuação dentro dos procedimentos tradicionais utilizados nos órgãos ambientais e redução dos custos associados aos programas de monitoramento ambiental (MOREIRA *et al.* 2013).

Entre as técnicas de processamento digital de imagens (PDI) mais difundidas, destaca-se a classificação para a identificação de objetos na superfície. Neste sentido, aplicando-se algoritmos computacionais, podem-se relacionar pixels ou regiões (agrupamento de pixels) a classes de uso do solo (ANDRADE *et al.*, 2014). Isto é possível pois, os produtos de sensores orbitais, permitem-nos distinguir e identificarem as composições dos diferentes materiais na superfície, devido ao comportamento específico de cada um ao longo do espectro eletromagnético (CRÓSTA, 1992).

<sup>1</sup> Trabalho apresentado como parte das atividades da disciplina Geotecnologias II, Programa de Pós-Graduação em Engenharia Agrícola, Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas. Agradecemos ao prof. Dr. Jansle Vieira Rocha por acompanhar o desenvolvimento deste trabalho ao longo da disciplina.

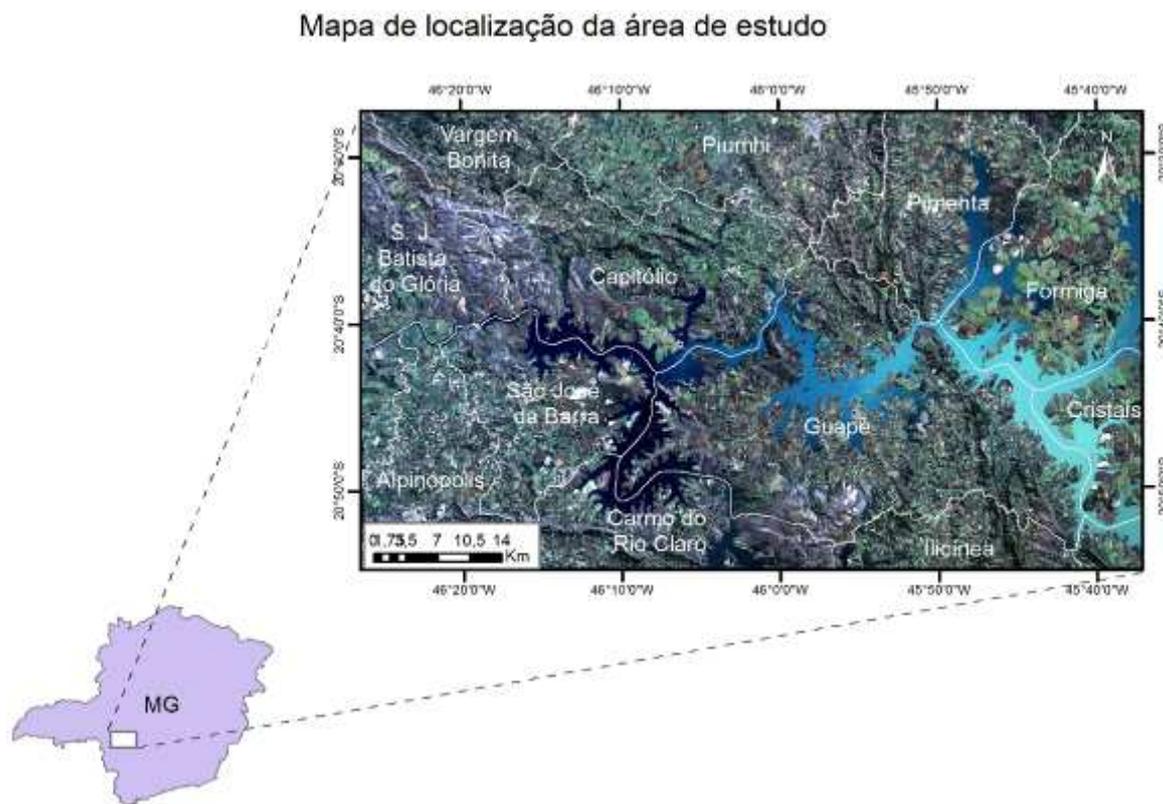
<sup>2</sup> **Mestre**, Instituto de Geociências, Universidade Estadual de Campinas, cassianomessiaslavras@gmail.com

<sup>3</sup> **Mestre**, Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, rafael.ifet@gmail.com

O presente trabalho tem como objetivo mapear o uso do solo do recorte de uma cena do satélite Landsat, nas proximidades do lago de Furnas, região Sul / Sudeste de Minas Gerais, nos anos de 2004 e 2014. Para isto, serão aplicados diferentes algoritmos de classificação de imagens multiespectrais, a fim de se identificarem os melhores resultados para cada classe, gerando-se mapas híbridos de uso do solo. Serão ainda avaliadas a acurácia dos resultados e as mudanças entre as duas datas.

## LOCALIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo está situada a Sul / Sudoeste de Minas Gerais, onde está localizada a barragem do lago de Furnas (Figura 1). O polígono abrange trechos de doze municípios, sendo eles: Vargem Bonita, Piumhi, Pimenta, São João Batista do Glória, Capitólio, Formiga, São José da Barra, Guapé, Cristais, Alpinópolis, Carmo do Rio Claro e Ilicinea.



**Figura 1:** Mapa de localização da área de estudo

## MATERIS E MÉTODOS

### Materiais

Para a produção deste trabalho, foram utilizados produtos de teledetecção e arquivos vetoriais (Tabela 1). Os procedimentos de processamento de imagens e classificação foram executados no *software* ENVI 5.1.

**Tabela 1:** Materiais utilizados na execução do trabalho.

Material	Órbita / ponto	Resolução	Data	Executor
Imagem Landsat 5 / TM	219/74	30m	03/05/2014	NASA
Imagem Landsat 8 / OLI	219/74	30m	15/05/2014	NASA
Imagem Google Earth	-	-	2015	Orbimage / Google
Arquivo vetorial da divisão territorial do estado de SP	-	-	2015	IBGE

## Métodos

Inicialmente foram realizadas etapas de pré-processamento nas imagens Landsat, sensores TM e OLI, a partir do *software* ENVI 5.1. Para os produtos de cada sensor, foram importados os arquivos metadados que contém as informações da imagem e os valores de suas bandas, em níveis de cinza, foram convertidas em radiância. Em seguida, aplicou-se o aplicativo *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH), no qual foram utilizados os seguintes parâmetros: sensibilidade espectral das bandas multiespectrais; visibilidade de 40 km; altitude média da área de 850 m; modelos de atmosfera tropical e de aerossóis rural. Após a aplicação dos procedimentos, foram obtidas bandas multiespectrais com valores de reflectância de superfície, cujo efeito atmosférico foi minimizado.

Posteriormente foram geradas diferentes composições coloridas: falsa-cor R4/G3/B5 (TM) e R4/G5/B3 (TM) e cor-verdadeira R3/G2/B1 (TM), as quais foram utilizadas na análise visual dos produtos Landsat. Após a geração das composições coloridas, realizou-se o registro do produto TM, buscando minimizar distorções espaciais na imagem. Tomou-se como referência a imagem OLI, que é disponibilizada com excelente ajuste geométrico. Para uma melhor análise visual da imagem, aplicou-se a técnica de realce linear 2%.

Após o pré-processamento e realce, foram realizadas classificações não-supervisionadas, onde os pixels da imagem são alocados sem que o usuário tenha conhecimento prévio de sua existência (NOVO, 2008). Este procedimento foi executado com a finalidade de se obter um conhecimento prévio das classes de uso do solo encontradas na área de estudo. Para isto, aplicou-se o método K-média. Além disso, o conhecimento das culturas agrícolas mais expressivas nos municípios foi obtido através de dados disponibilizados pelo Instituto Brasileiro de Geografia e estatísticas – IBGE (2013). Foram definidas 11 principais classes de uso e foram geradas chaves de interpretação para o mapeamento (Quadro 1).

**Quadro 1:** Chaves de interpretação utilizadas na identificação de classes de uso do solo, em diferentes composições coloridas geradas por imagens Landsat 5 TM e pelo Google Earth.

Uso do solo	4R/3G/5B	4R/5G/3B	Google Earth
Água com baixo teor de sedimento			
Água com alto teor de sedimento			
Campo limpo			
Cultura temporária recém-plantada			
Cultura temporária em estágio intermediário			

Quadro 1: continuação.

Uso do solo	4R/3G/5B	4R/5G/3B	Google Earth
Cultura temporária em estágio avançado			
Solo pouco úmido			
Solo úmido			
Vegetação nativa			
Cultura perene			

Buscando obter um mapa de uso do solo com o melhor resultado possível, foi realizada a classificação supervisionada utilizando diferentes algoritmos (NOVO, 2008). O processo de seleção de amostras de treinamento foi realizado visualmente sobre as composições coloridas, através da ferramenta *Region of interest* (ROI). Para cada uma das classes foram selecionadas várias amostras, por toda a área de

estudo, as quais totalizaram aproximadamente 1000 pixels. O quadro 2 apresenta a descrição dos algoritmos de classificação supervisionada aplicados.

**Quadro 2:** Descrição dos algoritmos de classificação supervisionada utilizados para o mapeamento do uso do solo na área de estudo.

<i>Técnica</i>	<i>Descrição</i>
Máxima verossimilhança (MaxVer)	“Dentro da abordagem da estatística paramétrica, a MaxVer é um dos métodos mais usados [...]. Este algoritmo estima, em uma abordagem quantitativa, a variância e a covariância dos padrões espectrais das amostras de treinamento” (ANDRADE <i>et. al.</i> , 2014, p. 351).
Mínima distância	“O método da mínima distância atribui cada pixel desconhecido à classe cuja média é mais próxima a ele” (CRÓSTA, 1998, p. 118).
Paralelepípedo	O método considera uma área no espaço de atributos, ao redor do conjunto de treinamentos. Forma-se um paralelepípedo, definido pelo DN máximo e mínimo das amostras. Os pixels situados dentro do paralelepípedo são classificados naquela classe (CRÓSTA, 1998).
Redes Neurais Artificiais (RNA)	As unidades básicas das redes neurais, os neurônios artificiais, simulam as funções dos neurônios naturais e processam todas as informações das RNA (SOUZA <i>et al.</i> , 2010).
<i>Support Vector Machines</i> (SVM)	SVM é uma técnica de aprendizado para reconhecimento de padrão, baseando-se no princípio de separação ótima entre classes em que, retirando-se algumas amostras, são verificadas as mesmas distribuições de probabilidade repetitivamente (HUANG <i>et al.</i> , 2002).

Os produtos obtidos por cada classificador foram avaliados visualmente, comparando-os às composições coloridas e imagens do Google Earth e constatou-se quais classificadores permitiram obter melhores resultados para cada classe de uso. Após esta análise, os melhores resultados foram exportados em diferentes arquivos ROI e, em seguida, estes foram importados de forma conjunta e convertidos em formato de imagem, gerando o mapa final de uso do solo. Foi aplicado o filtro mediana 3x3 para a suavização das classes e remoção de espaços não classificados.

Após serem executados os procedimentos de classificação nas imagens TM do ano de 2004 e OLI de 2014, calculou-se a acurácia dos mapas obtidos. Para isto foram sorteadas amostras aleatórias de 10

pixels para cada classe, através do método de amostragem estratificado desproporcional. Foi construída uma matriz de erro no *software* Excel 2010, comparando-se amostras na imagem classificada e em uma imagem de referência (neste caso, imagens do Google Earth). A matriz de erro é uma maneira de representar a acurácia de cada categoria, tanto nos erros de inclusão (erros de comissão) quanto nos erros de exclusão (erros de omissão) da classificação (SUAREZ E CANDEIAS, 2012). A partir da matriz de erro foram calculados os valores de índices Exatidão Global e *Kappa*. Uma descrição mais detalhada sobre a geração da matriz de erro e cálculos dos índices está disponível em Prina *et al.* (2014).

Ressaltamos que as áreas urbanas não foram classificadas de forma automática. Estas áreas foram delimitadas a partir da ferramenta ROI e extraídas da imagem antes da classificação. Após a classificação, o polígono das áreas urbanas foi inserido sobre o mapa final.

## RESULTADOS E DISCUSSÃO

### Uso do solo em 2004

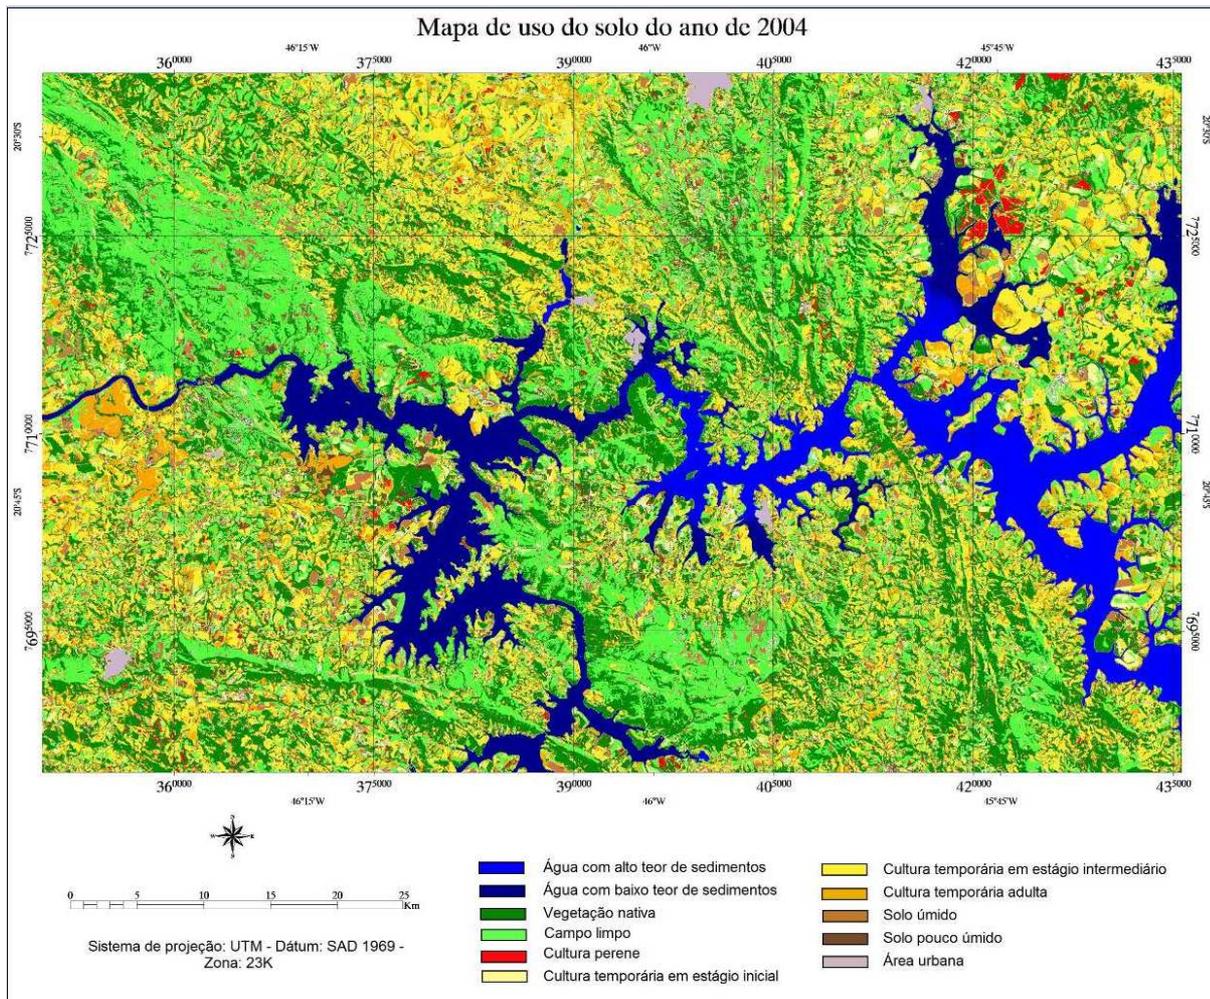
Os algoritmos de classificação geraram diferentes resultados e, por este motivo, foram avaliados, classe por classe, quais os melhores resultados de classificação obtidos, a fim de uni-los e gerar o melhor mapa de uso possível. A tabela 2 relaciona os classificadores utilizados para cada classe na geração do mapa híbrido de uso do solo.

**Tabela 2:** Classificadores utilizados para cada classe na geração do mapa final do ano de 2004

Classe de uso do solo	Classificador de melhor resultado
Água com baixo teor de sedimento	Máxima verossimilhança
Água com alto teor de sedimento	Máxima verossimilhança
Campo limpos	Máxima verossimilhança
Cultura temporária recém-plantada	Máxima verossimilhança
Cultura temporária em estágio	Máxima verossimilhança
Cultura temporária adulta	Máxima verossimilhança
Solo pouco úmido	Redes Neurais Artificiais
Solo úmido	<i>Support Vector Machines</i>
Vegetação nativa	Redes Neurais Artificiais
Cultura perene	Máxima verossimilhança

Para o mapa de uso do solo do ano de 2004 (Figura 2, quadro 3), foi obtido o índice de exatidão global no valor de 0,86, que mostra que 86% da classificação é correta, conforme as amostras utilizadas na geração da matriz de confusão. Além disso, atingiu-se índice *Kappa* de 0,84, valor considerado como excelente na visão de Landis e Koch (1977).

**Figura 2:** Mapa de uso do solo da área de estudo no ano de 2004.



**Quadro 3:** Matriz de confusão da classificação do ano de 2004.

		Amostras de referência											
		Água pura	Água c/ sedim.	Solo seco	Solo úmido	Cultura temp. 1	Cultura temp. 2	Cultura temp. 3	Cultura perm.	Mata	Campo	Soma	Inclusão
Mapa classificado	Água pura	10	0	0	0	0	0	0	0	0	0	10	0,00
	Água c/ sedimento	0	10	0	0	0	0	0	0	0	0	10	0,00
	Solo seco	0	0	10	0	0	0	0	0	0	0	10	0,00
	Solo úmido	0	0	2	8	0	0	0	0	0	0	10	0,20
	Cultura temp. 1	0	0	0	0	7	0	0	0	0	3	10	0,30
	Cultura temp. 2	0	0	0	0	0	10	0	0	0	0	10	0,00
	Cultura temp. 3	0	0	0	0	0	4	6	0	0	0	10	0,40
	Cultura permanente	0	0	0	0	0	0	0	7	3	0	10	0,30
	Mata	0	0	0	0	0	0	0	0	10	0	10	0,00
	Campo	0	0	0	0	0	2	0	0	0	8	10	0,20
	Soma	10	10	12	8	7	16	6	7	13	11	100	
<b>Omissão</b>		0,00	0,00	0,17	0,00	0,00	0,38	0,00	0,00	0,23	0,27		
<b>Exatidão global</b>		0,86		<b>Kappa</b>		0,84							

A classe mais expressiva se relaciona aos campos limpos, tendo sido identificada em 24,75% da área estudada (Tabela 3). Os campos limpos são fitofisionomia do cerrado, que foram descritas por Couto Junior *et al.* (2010) como vegetação herbácea de poucos arbustos, ausência de árvores e não fotossinteticamente ativa nos meses de seca. Esta classe engloba também as áreas de pastagem, utilizadas pela pecuária para alimentar o gado. Os campos limpos ocorrem geralmente em maiores altitudes e são

utilizados como pastagem em áreas menos elevadas. Houve confusão por parte do classificador utilizado (MaxVer), ao classificar algumas áreas de campo limpo como cultura temporária em estágio intermediário.

**Tabela 3:** Áreas ocupadas para as classes de uso no ano de 2004

Classe	Área (%)
Água com baixo teor de sedimento	6,12
Água com alto teor de sedimento	4,99
Campos limpos e pastagem	24,75
Cultura temporária recém-plantada	1,26
Cultura temporária em estágio intermediário	17,66
Cultura temporária adulta	15,19
Solo pouco úmido	3,94
Solo úmido	2,33
Vegetação nativa	21,96
Cultura perene	1,38
Área urbana	0,37

A segunda classe de maior expressividade representa as áreas de vegetação nativa (21,96%), associada aos remanescentes de fitofisionomias arbóreas do cerrado ou matas ciliares que acompanham os cursos d'água. O classificador RNA obteve um bom desempenho, visto que não foram observados erros de inclusão nas áreas amostradas.

Foi possível diferenciar duas classes de água, de acordo com a quantidade de materiais em suspensão. Foi verificada uma classe água com maior teor de sedimentos, a leste da região estudada, que ocupa 4,99%. Foi possível diferenciá-la devido à alta reflectância destes sedimentos no comprimento de onda do vermelho (0.630 - 0.680  $\mu\text{m}$ ). Por sua vez, água com baixo teor de sedimentos abrange 6,12% da área. Deve-se ressaltar que não houve erros de inclusão e omissão destas classes na matriz de confusão de ambas as classes.

Além disso, diferenciaram-se dois tipos de solo exposto. O solo exposto pouco úmido, que ocupa 3,94% da área, possui tonalidade mais clara na composição colorida, está geralmente associado a áreas já colhidas, muitas vezes com a palha da cana-de-açúcar cobrindo-o. Já o solo úmido (2,33%) apresenta tonalidade mais escura na composição colorida, devido à redução da reflectância na banda do infravermelho médio (1.560 - 1.660  $\mu\text{m}$ ) pela umidade e pode estar associado ao processo de irrigação. O classificador RNA teve bom desempenho ao identificar solo seco, enquanto solo úmido teve alguns erros de omissão com a classe solo seco pelo SVM.

Os municípios que abrangem a área de estudo apresentam grandes áreas agrícolas, sendo que as principais culturas temporárias são cana-de-açúcar, milho e feijão (IBGE, 2013). Foram mapeados três estágios de culturas temporárias. No primeiro, cultura temporária recém-plantada (1,26%), verifica-se reflectância de solo e cobertura vegetação apresenta baixa biomassa. As culturas temporárias em estágio

intermediário (17,66%) apresentam baixa reflectância de solo, mostrando textura lisa e maior teor de biomassa que o estágio anterior. Já as culturas temporárias adultas (15,19%) possuem alta biomassa, por isso apresentam alta reflectância na região do infravermelho próximo (0.845 - 0.885  $\mu\text{m}$ ). Houve confusão entre cultura recém-plantada e campo, assim como algumas áreas de cultura temporária adulta foram mapeadas como cultura temporária em estágio intermediário.

Foram mapeadas também culturas perenes (1,38%), sendo elas silvicultura de eucalipto e café, das quais houve confusão em certos locais com áreas de vegetação nativa. Por fim, as áreas urbanas, delimitação visualmente, ocupam 0,37% da área de estudo.

### Uso do solo em 2014

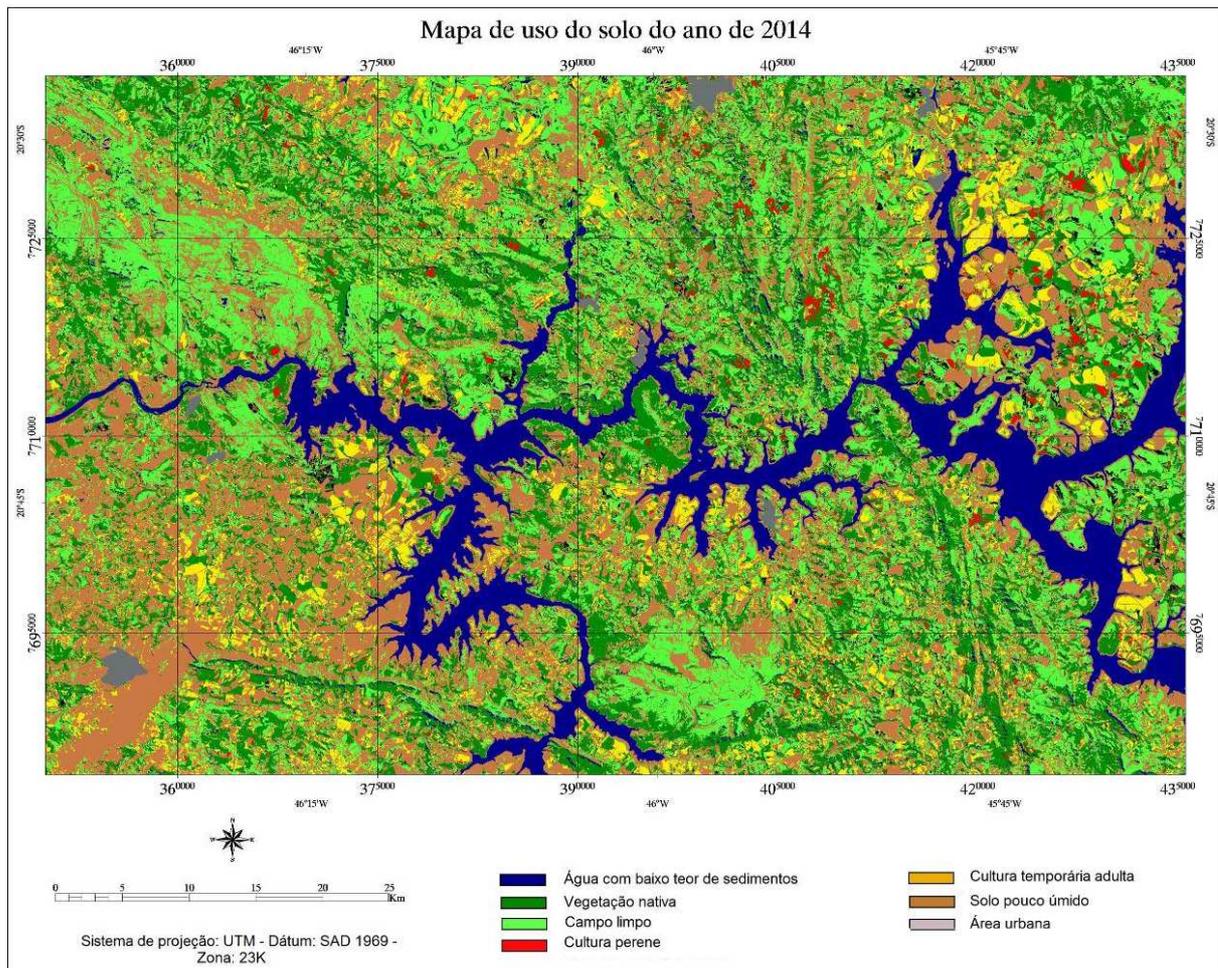
Da mesma forma que o constatado no ano de 2004, os algoritmos de classificação geraram diferentes resultados para 2014. Sendo assim, os melhores classificadores para cada uso e cobertura do solo estão destacados na tabela 4. Os resultados destes classificadores foram utilizados para a geração do mapa híbrido de uso do solo para 2014. Deve-se destacar que, para o ano de 2014, houve menor variabilidade de usos e estágios de desenvolvimentos de culturas agrícolas. Por este motivo, foi identificado menor número de classes que em 2004.

**Tabela 4:** Classificadores utilizados para cada classe na geração do mapa final do ano de 2014.

Classe de uso do solo	Classificador de melhor resultado
Água	Mínima distância
Campo limpos	Máxima verossimilhança
Cultura temporária	Máxima verossimilhança
Solo exposto	Máxima verossimilhança
Vegetação nativa	Máxima verossimilhança
Cultura perene	Redes neurais

O mapa de uso do solo do ano de 2014 (Figura 3) apresenta índice de exatidão global no valor de 0,83, que mostra que 83% da classificação foi correta, conforme as amostras utilizadas na geração da matriz de confusão (Quadro 4). Por sua vez, o índice *Kappa* obtido foi de 0,8, considerado excelente.

**Figura 3:** Mapa de uso do solo da área de estudo no ano de 2014.



**Quadro 4:** Matriz de confusão da classificação do ano de 2014

		Amostras de referência							
		Água	Solo exposto	Cultua perene	Cultura Temporária	Vegetação nativa	Campo limpo	Soma	
Mapa classificado	Água	10	0	0	0	0	0	10	0,00
	Solo exposto	0	6	0	2	0	0	10	0,40
	Cultua perene	0	0	10	0	0	0	10	0,00
	Cultura Temporária	0	0	3	7	0	0	10	0,30
	Vegetação nativa	0	0	0	0	9	1	10	0,10
	Campo limpo	0	2	0	0	0	8	10	0,80
	Soma	10	8	13	9	9	11	60	0,18
Omissão	0,00	0,25	0,23	0,22	1,00	0,73			
Exatidão global	0,83		Kappa	0,8					

As classes predominantes no mapa são campo limpo (que englobam pastagens) e solo exposto, que juntas correspondem a 61,25% da área total. Em seguida, a vegetação nativa representa 20,87% da área (Tabela 5). As classes de cultura temporária e perene correspondem juntas a 8,5%, sendo a cultura temporária a que ocupa maior área entre as duas (7,29%). A partir da matriz de confusão, pode-se constatar que os algoritmos obtiveram bons resultados na classificação de água e vegetação nativa, mas

os resultados foram inferiores ao diferenciarem campo limpo e cultura perene da classe cultura temporária.

**Tabela 5:** Áreas ocupadas para as classes de uso no ano de 2014

Classe	Área (%)
Água	8,86
Campos limpos	32,31
Cultura temporária	7,29
Solo exposto	28,94
Vegetação nativa	20,87
Cultura perene	1,27
Área urbana	0,42

### Análise comparativa dos mapas gerados para os anos de 2004 e 2014

Comparativamente, podemos dizer que 38,81% da área total permanecem com o mesmo uso após 10 anos (2004 a 2014). Sendo assim, ocorreram mudanças em 61,19% da área de estudo (Quadro 5). Avaliando tais mudanças, comprovou-se que a área ocupada pela represa de Furnas reduziu consideravelmente de 2004 para 2014 (Figura 4) e, em consequência disto, houve um aumento das áreas de solo exposto, ou seja, 18,83% da área ocupada por água se tornou solo exposto em 2014.

**Quadro 5:** Concordância global do uso do solo nos anos de 2004 e 2014

		Uso do solo do ano de 2004								
		Não class.	Mata	Cult. Temp.	Solo exposto	Água	Cidades	Cultura Perene	Campo	Total
Uso do solo de 2014	Não class.	6,44	1,16	2,42	2,67	0,15	0,22	0,64	3,35	2,75
	Mata	17,29	66,02	3,7	5,26	0,41	1,24	28,37	9,86	21,72
	Cult. Temp.	12,07	8,87	10,7	7,79	0,27	0,36	45,46	5,03	8,37
	Solo exposto	37,69	11,7	38,52	60,91	18,83	9,78	16,53	42,58	31,74
	Água	0,3	2,89	0	0,1	79,46	0,2	0,1	0,4	10,18
	Cidades	0,25	0,11	0,15	1,04	0	87,27	0,14	0,19	0,49
	Cultura Perene	1,3	1,1	1	1,59	0	0,15	6,17	0,94	1,05
	Campo	24,66	8,15	43,5	20,63	0,87	0,78	2,69	37,64	23,7
	Total	100	100	100	100	100	100	100	100	100

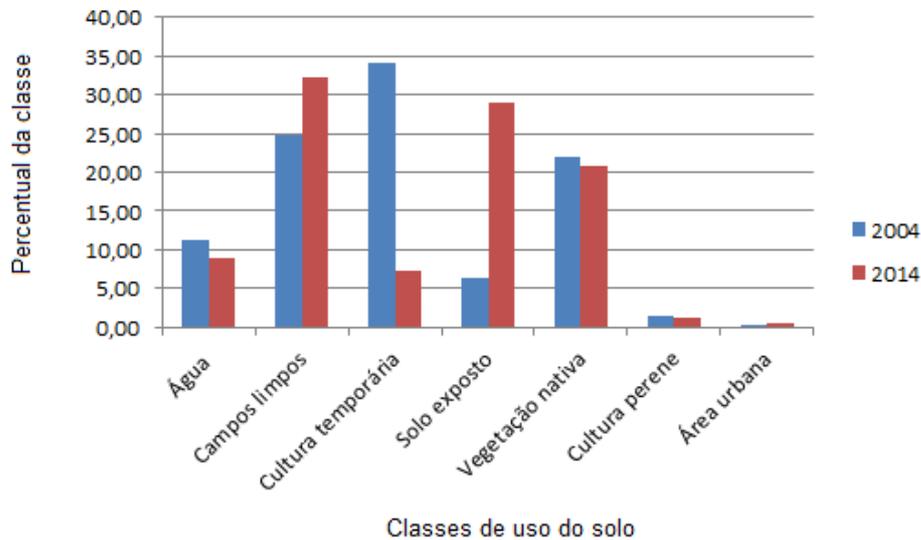
Concordância global: 38,81%

Áreas de campo limpo (incluindo pastagens) aumentaram cerca de 6,0% e passaram a ocupar locais onde ocorriam outros tipos de uso. A vegetação nativa foi suprimida de 2004 para 2014, tendo sido transformadas em áreas de solo exposto, provavelmente utilizadas na agricultura.

Considerando as áreas ocupadas por cultura em 2004, um total de 89,3% da área de cultura temporárias deixou de aparecer no mapa de uso após os 10 anos. Esta alteração não deve ser associada a uma real redução na produção agrícola, mas ao fato de que na imagem de 2014 as culturas ainda não haviam sido plantadas (motivo também pelo qual houve crescimento de solo exposto). As culturas

perenes tiveram pouca modificação em seu percentual, mas grande parte delas passou a ocupar outros locais.

**Figura 4:** Gráfico comparativo (%) das classes de uso do solo nos anos de 2004 e 2014



Entre 2004 e 2014 houve crescimento das áreas urbanas, avançando sobre as áreas como mata, cultura temporária, solo exposto, cultura perene e campo limpo. O único uso que não foi afetado pelo avanço das cidades foi o reservatório de Furnas ou áreas ocupadas por água.

## CONSIDERAÇÕES FINAIS

Os produtos Landsat são excelentes para a geração de mapas de uso do solo em média resolução. Para as classificações geradas na área de estudo, os algoritmos classificadores geram diferentes resultados, os quais foram avaliados. Contudo, de maneira geral, o classificador MaxVer apresentou resultados superiores aos outros na maioria das classes.

Podemos concluir, a partir dos resultados apresentados, que após 10 anos, a área de estudo alterou em 61,19% seu uso do solo. As áreas de cultura temporárias tiveram redução considerável e, por outro lado, houve o crescimento das áreas de solo exposto. Houve redução também das culturas permanentes, porém em menor intensidade. A área ocupada pela represa de Furnas e de vegetação nativa também reduziu.

As técnicas de classificação automática são excelentes ferramentas para o mapeamento de uso do solo, podendo ser executadas a partir de imagens e *softwares* gratuitos, reduzindo-se o tempo e os custos do trabalho. No entanto, o usuário deve ter cuidado na etapa de seleção de amostras de treinamento, garantindo maior proximidade dos resultados com a verdade terrestre, além de realizar validação dos resultados, comprovando assim a confiabilidade dos resultados obtidos.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE, A. C.; FRANCISCO, C. N.; ALMEIDA, C. M. Desempenho De Classificadores Paramétricos E Não Paramétricos Na Classificação Da Fisionomia Vegetal. *Revista Brasileira de Cartografia*, n° 66/2, p. 349-363, 2014.
- CRÓSTA, A. P. Processamento digital de imagens de sensoriamento remoto. Campinas: IG/UNICAMP, 1992.
- IBGE. IBGE cidades. Disponível em: <<https://cidades.ibge.gov.br/>>. Acesso em: 01 jul. 2018.
- HUANG, C.; DAVIS, L.S.; TOWNSHEND, J.R.G. An assessment of support vector machines for land classification. *International Journal of Remote Sensing*, v. 23, n. 4, p. 725-749, 2002.
- LIU, Q.; GUO, Y.; LIU, G.; ZHAO, J. Classification of Landsat 8 OLI Image Using Support Vector Machine With Tasseled Cap Transformation. *In: Anais da 10th International Conference on Natural Computation*, Xiamen, China, IEEE, p. 665-669, 2014.
- NOVO, E. M. L. M. Sensoriamento remoto: princípios e aplicações – 3ª ed. São Paulo: Blucher, 2008. 362 p.
- MOREIRA, G. F.; FERNANDES, R. B. A.; FERNANDES FILHO, E. I.; VIEIRA, C. A. O.; SANTOS, K. A. Classificação Automatizada do Uso e Cobertura do Solo Usando Imagens Landsat. *Revista Brasileira de Geografia Física*, v. 6, n. 1, p. 58-65, 2013.
- PRINA, B. Z.; TRENTIN, R.; BENEDETTI, A. C. P. AVACIM - Avaliador de Classificação de Imagens. *In: XXVI Congresso Brasileiro de Cartografia*, Gramado, 2014.
- SOUZA, B. F. S.; TEIXEIRA, A. S.; SILVA, F. S. T. F.; ANDRADE, E. M.; BRAGA, A. P. S. Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma caatinga. *Revista Brasileira de Cartografia*, n. 62, ed. especial 2, p. 385-399, 2010.
- SUAREZ, A. F.; CANDEIAS, A. N. B. Avaliação de acurácia da classificação de dados de sensoriamento remoto para o município de Maragogipe. *In: Anais do IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação*, Recife, 2012.