

Análise comparativa do desempenho de algoritmos de classificação para o mapeamento de áreas de cultivo de banana

Gabriel de Oliveira ¹
Laurindo Antonio Guasselli ²
Maria do Carmo Lima e Cunha ²
Dejanira Luderitz Saldanha ²

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Divisão de Sensoriamento Remoto - DSR
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
gdo@dsr.inpe.br

² Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia - CEPSRM
Caixa Postal 15.044 - 91501-970 - Porto Alegre - RS, Brasil
{laurindo.guasselli, dejanira.saldanha, maria.cunha}@ufrgs.br

Abstract. This work aims to comparatively analyze four classification algorithms two of each are based on pixel and the other two in region, according to a base map prepared by visual interpretation, in order to detail the use and land cover with emphasis on discrimination in areas of banana plantations in a satellite image SPOT 5 HRG sensor. The algorithms based on pixels, Minimum Euclidean Distance and Maxver showed the highest levels of User accuracy (75.57%, 73.67%) to Class banana, however behaved inappropriately with regard to separation from other classes, which ended up compromising your Kappa Statistic (0.3647, 0.5054) and Global Accuracy (50.11%, 61.78%). With respect to algorithms based on region, Isege had a lot of confusion between areas of banana plantations mainly in areas of Countryside, which meant that it represents the lowest rate of User Accuracy (60.03%) in the class of all algorithms Bananas tested. The algorithm Bhattacharya, although has the third highest rate of User Accuracy (66.81%) to Class Bananas, showed the highest accuracy rate among all classes defined with respect to the base map, obtaining the highest Kappa Statistic (0.5753) and increased Global Accuracy (69.13%). In this sense, analyzing the image generated under the thematic point of view the algorithm Bhattacharya resulted qualitatively and quantitatively in the best value according to the map base, serving appropriately to distinguish the banana-growing areas with the remaining classes linked to its surroundings.

Palavras-chave: classificação digital, HRG – SPOT 5, bananicultura, digital classification, HRG – SPOT 5, banana cultivation.

1. Introdução

Para atender às necessidades do usuário final que, muitas vezes não tem o conhecimento necessário para interpretar uma imagem no seu estado bruto (numérico) faz-se necessário transformá-la numa imagem temática que mostre apenas as informações de seu interesse. O resultado final pode ser obtido, em geral, por dois tipos de classificação: a classificação supervisionada que exige um conhecimento *a priori* da área estudada (amostras para o treinamento) e a classificação não supervisionada que dispensa essas informações iniciais.

A classificação de imagens é importante também para reduzir a dimensionalidade dos dados, de maneira a manter apenas as informações que desejamos (categorias temáticas). Para tanto, muitas teorias matemáticas e estatísticas são estudadas e implementadas nos classificadores para se obter melhor performance ou reduzir o tempo de processamento (Lillesand et al., 2004).

Os algoritmos tradicionalmente usados nos processo de classificação consideram que as classes são linearmente separáveis e utilizam como unidade de medida o pixel. Porém, estudos demonstram que algumas informações acabam não sendo obtidas somente com base na informação contida no pixel, necessitando ser explorados também com relação à vizinhança do pixel e no contexto dos objetos de interesse (Blaschke et al., 2007). Assim, numa abordagem mais abrangente, vem se utilizando algoritmos comumente denominados

classificadores por região, que utilizam, além da informação espectral de cada pixel, a informação espacial que envolve a relação entre os pixels e seus vizinhos (Meinel; Neubert, 2004).

Desta forma, este trabalho tem como objetivo analisar comparativamente quatro algoritmos de classificação, sendo dois baseados em “pixel” e dois em “região”, de acordo com um mapa base elaborado por interpretação visual, visando o detalhamento do uso e cobertura do solo, com ênfase a discriminação de áreas de bananais em uma imagem do satélite SPOT 5, sensor High Resolution Geometric (HRG).

2. Material e Métodos

Para realização do estudo foi utilizado um recorte (Figura 1) de 846,66 ha de uma imagem multiespectral advinda do sensor HRG, do satélite SPOT 5, nas quatro bandas espectrais (visível, infravermelho próximo e infravermelho médio), com resolução espacial de 10 metros, referente a órbita ponto 713-409, datada de 27/08/2007. A área cobre parte do município de Três Cachoeiras, situado no Litoral Norte do Estado do Rio Grande do Sul.

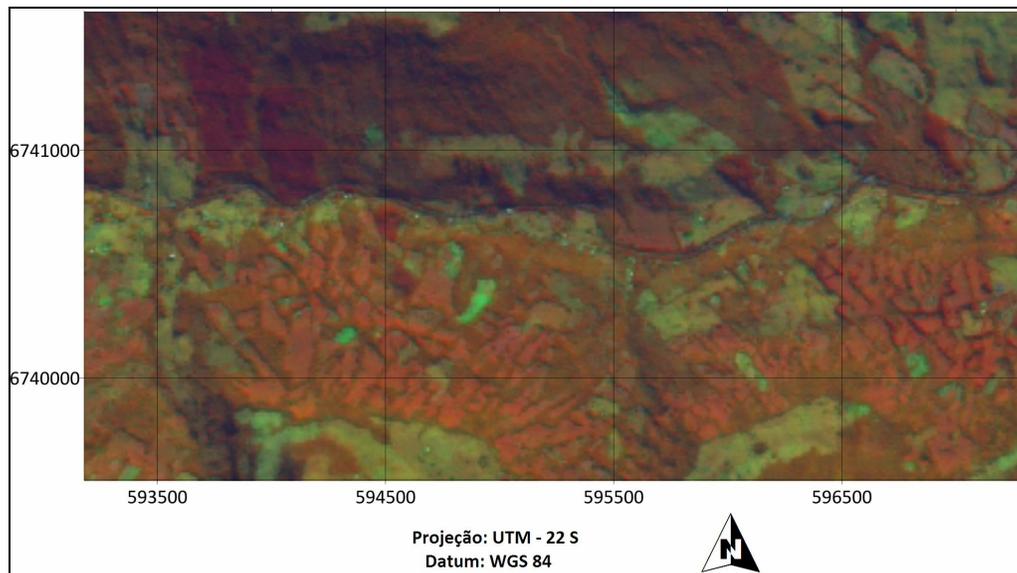


Figura 1. Recorte de imagem HRG-SPOT 5 (R1G4B3), correspondendo a uma área com extensos bananais localizada no vale do rio do Terra, município de Três Cachoeiras, RS.

Por englobar extensos bananais e variadas classes de uso e cobertura da terra, este recorte foi visto como ideal para a realização da classificação visual e posterior validação dos testes com os classificadores digitais automáticos. As classes definidas foram: Floresta Ombrófila Densa, Formação Florestal Secundária, Florestamento, Bananais, Solo Exposto, Campo e Sombra.

2.2 Interpretação Visual x Classificação Digital

A interpretação visual de imagens de satélite é considerada a melhor forma de se adquirir dados de maior acurácia a respeito do uso e cobertura da terra, porém, ela se torna inviável quando aplicada em áreas muito extensas, pela demanda de custo e tempo. Neste sentido, os procedimentos de classificação digital têm sido largamente utilizados, pois podem agilizar todo o processamento das imagens.

No caso da área deste estudo, dada sua extensão, um recorte englobando algumas das classes consideradas foi interpretado visualmente gerando um mapa base. Posteriormente, este

recorte foi submetido á classificação digital com o uso de quatro algoritmos, para avaliar, por índices quantitativos e qualitativos, qual deles melhor correspondia ao mapa base.

A elaboração do mapa base por interpretação visual se deu a partir da digitalização das classes diretamente sobre a imagem. Para tanto, utilizou-se o software ArcGIS 9.1, onde se definiu uma escala de mapeamento de 1:5.000.

Com o propósito de se definir qual o método seria extrapolado para toda área de estudo, foram utilizados os seguintes algoritmos de classificação para geração das imagens temáticas: Máxima Verossimilhança, Distância Euclidiana Mínima, Bhattacharya e Isoseg.

2.2.1 Máxima Verossimilhança Gaussiana e Distância Euclidiana Mínima

Estes classificadores são ditos supervisionados, pois necessitam da coleta de amostras de treinamento para estimar suas decisões, e são baseados em contexto de pixels. Desta forma, para a classificação da imagem a partir destes algoritmos, no software MultispecW32 foi criado um projeto no qual se inseriu o recorte de imagem e iniciou-se o processo de coleta de amostras.

Foram coletadas cerca de dez amostras para cada classe, com tamanhos e formas variadas, sendo utilizadas as mesmas amostras para o treinamento dos dois algoritmos. Isto impede que os resultados variem por inferência do analista, ao coletar, por exemplo, um maior número de amostras para determinado classificador. Assim, será testada somente a eficácia do algoritmo na estimação de seus dados.

2.2.2 Bhattacharya e Isoseg

Estes algoritmos são baseados em contexto de regiões, sendo necessária, primeiramente, a segmentação da imagem. No caso do recorte da imagem utilizada neste estudo buscou-se testar limiares que permitissem separar da melhor forma as áreas de bananais das classes associadas, que na maioria das vezes correspondiam a Formação Florestal Secundária e Campo. Foram testados os seguintes limiares de segmentação, correspondendo a Similaridade e Área, respectivamente: 8-22; 10-22; 10-24; 10-26 e 12-30.

Após isto, foram iniciados os procedimentos de classificação. Para o algoritmo de Bhattacharya, no software SPRING 5.0.6 inseriu-se o arquivo vetorial correspondente a segmentação 10-26, o recorte da imagem, e posteriormente foram coletadas as amostras, em uma média de dez por classe. Diferentemente dos algoritmos baseados em pixels, estas amostras são selecionadas a partir dos polígonos gerados na segmentação, sendo escolhidos os que melhor correspondem à determinada classe.

Com relação ao algoritmo Isoseg, por se tratar de um classificador não-supervisionado, não há a interferência do analista na coleta das amostras de treinamento, sendo necessário somente definir um limiar de aceitação, descrito em porcentagem, pela Distância de Mahalanobis. Assim, é gerado número de classes que o algoritmo estimar, restando ao analista agrupá-las em quantas achar necessário. Utilizando a ferramenta “*Classificação*” no software SPRING 5.0.6, foi inserido o arquivo correspondente a segmentação 10-26, a imagem e definido um limiar de aceitação de 75%. Foram geradas automaticamente quarenta e quatro classes que foram agrupadas nas sete classes previamente definidas, sendo este processo feito a partir da ferramenta “*Acoplar*” presente no SPRING 5.0.6, onde são sobrepostas a imagem de satélite e a imagem temática resultante.

2.3 Acurácia das Classificações Digitais

A estimação da acurácia das classificações digitais teve por referência o mapa base, elaborado por interpretação visual. Neste contexto, foram geradas as matrizes de confusão; para isso, as imagens temáticas originadas pelos processos de interpretação visual e classificação digital foram importadas para o software Idrisi 32 e cruzadas a partir dos

comandos: “Analysis” → “Database Query” → “CrossTab”. De posse destes dados, foram calculados a Estatística Kappa, Exatidão Global e Acurácia do Usuário.

3. Resultados Discussões

A Figura 2 corresponde à classificação a partir de interpretação visual, mapa base para a avaliação das classificações digitais.

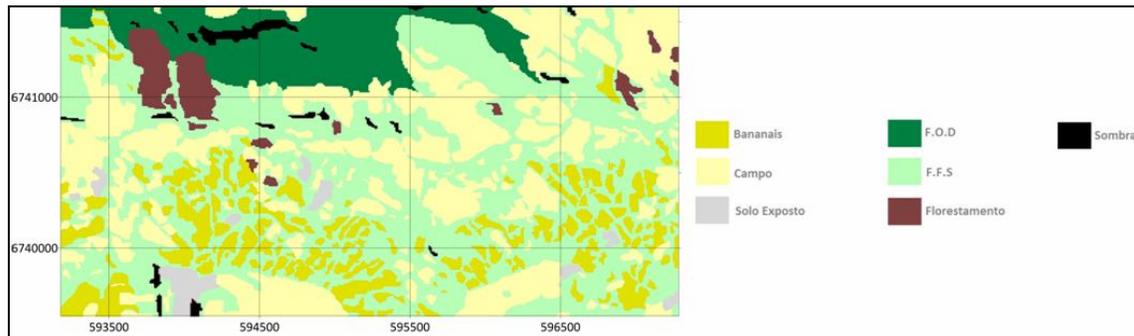


Figura 2. Imagem classificada a partir de interpretação visual.

A Figura 3 corresponde a imagem classificada pelo algoritmo de Máxima Verossimilhança Gaussiana, e a Tabela 1 apresenta a respectiva matriz de confusão.

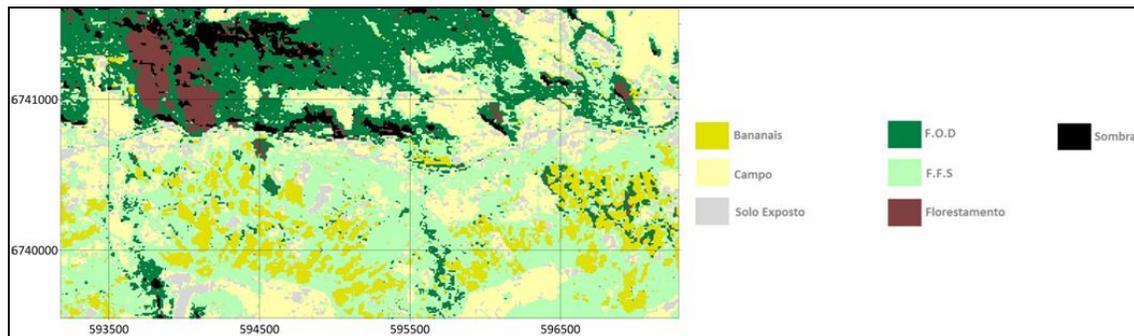


Figura 3. Imagem classificada pelo algoritmo de Máxima Verossimilhança Gaussiana.

Tabela 1. Matriz de confusão para a comparação da classificação visual (colunas) com a classificação digital pelo algoritmo de Máxima Verossimilhança Gaussiana (linhas).

Classe	Bananais	Solo Exposto	Campo	F.O.D	F.F.S	Florestamento	Sombra	Σ Linha	Acurácia do Usuário
Bananais	6674	2	374	21	1949	39	0	9059	73,67%
Solo Exposto	227	775	3324	5	802	2	0	5135	15,09%
Campo	143	471	14910	71	1728	33	10	17366	85,85%
F.O.D	399	10	611	6963	8600	487	157	17227	40,41%
F.F.S	3033	221	5741	472	20345	95	34	29941	67,95%
Florestamento	16	0	6	595	511	1836	47	3011	60,97%
Sombra	0	0	74	1193	646	205	809	2927	27,63%
Σ Coluna	10492	1479	25040	9320	34581	2697	1057	84666	-

A classificação pelo algoritmo de Máxima Verossimilhança Gaussiana apresentou os terceiros maiores valores de Estatística Kappa (0,5054) e Exatidão Global (61,78%) entre os algoritmos testados.

Analisando a matriz de confusão, destaca-se uma subestimação de área para a classe Bananais com relação a interpretação visual. Do total de 9059 pixels estimados para esta classe pelo algoritmo, 6674 estão em conformidade com o mapa base, sendo que 1949 foram classificados em área de Formação Florestal Secundária.

Também se destaca uma grande dificuldade na separação dos tipos de floresta, onde se verifica, por exemplo, que dos 17227 pixels estimados pelo algoritmo na classe Floresta Ombrófila Densa, apenas 6963 estão em conformidade com o mapa base, e 8600 foram classificados em áreas que deveriam pertencer a classe Formação Florestal Secundária. Isto pode ser verificado na imagem (Figura 3) em sua porção norte, onde há uma superestimação das áreas de Floresta Ombrófila Densa.

Outro problema está relacionado às classes Solo Exposto e Campo. O algoritmo superestimou as áreas de solo exposto, definindo 5135 pixels para esta classe, enquanto na interpretação visual ela corresponde a apenas 1479 pixels. Destes 5135 pixels, apenas 775 foram classificados corretamente, sendo que 3324 foram classificados equivocadamente em áreas que deveriam pertencer à classe Campo. Isto pode ser verificado pelo baixo valor de Acurácia do Usuário (15,09%) nesta classe.

A Figura 4 corresponde a imagem classificada pelo algoritmo de Distância Euclidiana Mínima, e a Tabela 2 apresenta sua respectiva matriz de confusão.

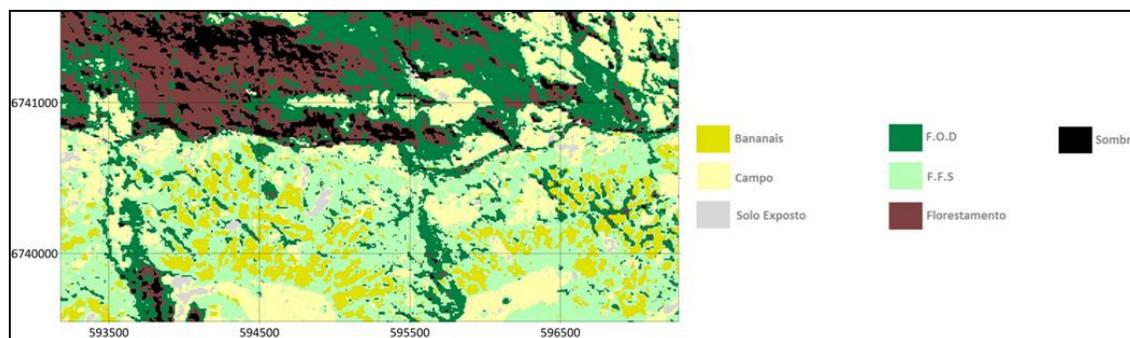


Figura 4. Imagem classificada pelo algoritmo de Distância Euclidiana Mínima.

Tabela 2. Matriz de confusão para a comparação da classificação visual (colunas) com a classificação digital pelo algoritmo de Distância Euclidiana Mínima (linhas).

Classe	Bananais	Solo Exposto	Campo	F.O.D	F.F.S	Florestamento	Sombra	Σ Linha	Acurácia do Usuário
Bananais	6129	3	300	0	1673	5	0	8110	75,57%
Solo Exposto	0	545	549	0	26	0	0	1120	48,66%
Campo	179	615	14144	7	1047	6	0	15998	88,41%
F.O.D	637	122	4359	3203	10581	417	24	19343	16,55%
F.F.S	3518	180	4712	97	15630	84	0	24221	64,50%
Florestamento	25	6	381	4207	3913	1883	135	10550	17,84%
Sombra	4	8	595	1806	1711	302	898	5324	16,86%
Σ Coluna	10492	1479	25040	9320	34581	2697	1057	84666	-

A classificação pelo algoritmo de Distância Euclidiana Mínima não se mostrou eficiente no mapeamento de diversas classes, evidenciado pelos baixos valores de Acurácia do Usuário, o que acabou por comprometê-lo com os piores valores de Estatística Kappa (0,3647) e Exatidão Global (50,11%) entre todos os algoritmos.

Ao analisar a matriz de confusão com relação a classe Bananais, verifica-se que houve uma subestimação de área se comparada à interpretação visual. Pelo algoritmo Distância Euclidiana Mínima foram definidos 8110 pixels frente aos 10492 definidos pela interpretação visual, destes 8110 pixels, 6129 estão em conformidade com o mapa base.

A classe Florestamento foi superestimada, pois o algoritmo definiu 10550 pixels, enquanto na interpretação visual ela corresponde a 2697 pixels. Isto pode ser observado na porção norte da imagem (Figura 4), onde uma extensa área que corresponderia às classes de Floresta Ombrófila Densa e Formação Florestal Secundária foi classificada como Florestamento. Destes 10550 pixels estimados, apenas 1883 foram classificados corretamente, determinando o baixo valor de Acurácia do Usuário (17,84%).

A classe Formação Florestal Secundária, estimada em 24221 pixels pelo algoritmo, apresentou 15630 pixels em concordância com o mapa base, 3518 em áreas que deveriam pertencer à classe Bananais, 180 em áreas que deveriam pertencer à classe Solo Exposto, 4712 em áreas que deveriam pertencer à classe Campo, 97 em áreas que deveriam pertencer à classe Floresta Ombrófila Densa e 84 pixels em áreas que deveriam pertencer à classe Florestamento.

Na classe Campo, apesar do algoritmo subestimar em valores de área se comparado com a interpretação visual, houve uma boa relação com o mapa base, pois dos 15998 pixels estimados, 14144 estão em concordância.

Com relação aos algoritmos classificadores baseados em regiões (Bhattacharya e Ioseg), fez-se necessária a segmentação da imagem. Este processo é em geral ajustável aos diferentes tipos de imagens, com limiares definidos face à complexidade dos alvos investigados. Para a definição destes limiares, é possível trabalhar com abordagens quantitativas e qualitativas, pois os dois métodos são aceitos. Neste estudo optou-se por uma definição baseada em critérios qualitativos.

Desta forma, a avaliação da qualidade da segmentação se deu de forma empírica, sendo obtida pela comparação visual dos polígonos gerados, sobrepostos ao recorte da imagem HRG-SPOT 5. Após alguns testes foram definidos limiares de 10 para a Similaridade e de 26 para Área.

Optou-se por escolher os limiares de segmentação que apresentassem uma melhor definição das bordas das classes de interesse, principalmente das áreas de bananais e que servissem adequadamente para o processo de coleta das amostras.

A Figura 5 corresponde a imagem classificada pelo algoritmo de Bhattacharya, e a Tabela 3 sua matriz de confusão.

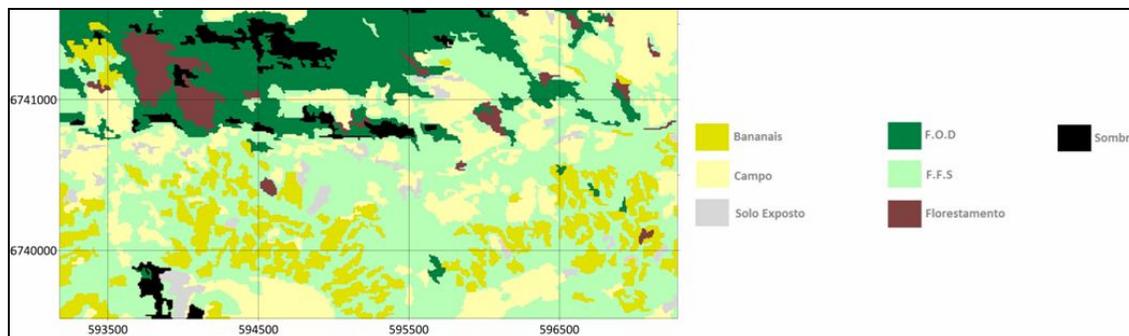


Figura 1. Imagem classificada pelo algoritmo de Bhatthacharya.

Tabela 3. Matriz de confusão para a comparação da classificação visual (colunas) com a classificação digital pelo algoritmo de Bhattacharya (linhas).

Classe	Bananais	Solo Exposto	Campo	F.O.D	F.F.S	Florestamento	Sombra	Σ Linha	Acurácia do Usuário
Bananais	7325	5	729	8	2860	36	0	10963	66,81%
Solo Exposto	2	895	831	0	85	0	0	1813	49,36%
Campo	78	257	15704	47	1106	21	0	17213	91,23%
F.O.D	52	0	723	8019	4954	490	200	14438	55,54%
F.F.S	3025	293	6717	216	24037	258	18	34564	69,54%
Florestamento	10	0	321	124	618	1753	34	2860	61,29%
Sombra	0	29	15	906	921	139	805	2815	28,59%
Σ Coluna	10492	1479	25040	9320	34581	2697	1057	84666	-

A classificação pelo algoritmo de Bhattacharya apresentou os maiores índices de acerto entre a maioria das classes definidas com relação ao mapa-base, obtendo o maior valor de Estatística Kappa (0,5953) e a maior Exatidão Global (69,13%),

Analisando a matriz de confusão, com relação à classe Bananais, denota-se que houve uma pequena superestimação de área pelo algoritmo classificador, de 472 pixels. Dos 10963 pixels definidos pelo algoritmo, 7325 estão em concordância com o mapa base, 5 foram classificados em áreas que deveriam pertencer à classe Solo Exposto, 729 em áreas que deveriam pertencer à classe Campo, 8 em áreas que deveriam pertencer à classe Floresta Ombrófila Densa, 2860 em áreas que deveriam pertencer à classe Formação Florestal Secundária e 36 em áreas que deveriam pertencer à classe Florestamento. Esta inclusão da classe de Bananais em áreas de Formação Florestal Secundária pode ser visualizada na porção noroeste da imagem, ao lado de uma área de florestamento.

Na classe Floresta Ombrófila Densa houve uma superestimação de área, para o qual o algoritmo estimou 14438 pixels, frente a 9320 pixels definidos na interpretação visual. Destes 14438 pixels, 8019 foram classificados corretamente, porém, 4954 foram classificados em áreas que deveriam pertencer à classe Formação Florestal Secundária. Esta confusão de classes pode ser observada na porção centro-norte da imagem gerada.

Na classe Campo, obteve-se o melhor índice de Acurácia do Usuário entre todas as classes e todos os algoritmos. Foram estimados 17213 pixels pelo classificador e 25040 pixels pela interpretação visual. Destes, 15704 pixels estão em concordância e apenas 1509 pixels foram classificados em áreas que deveriam pertencer a outras classes.

A Figura 6 corresponde a uma imagem classificada pelo algoritmo de Isoseg, e a Tabela 4 apresenta sua matriz de confusão.

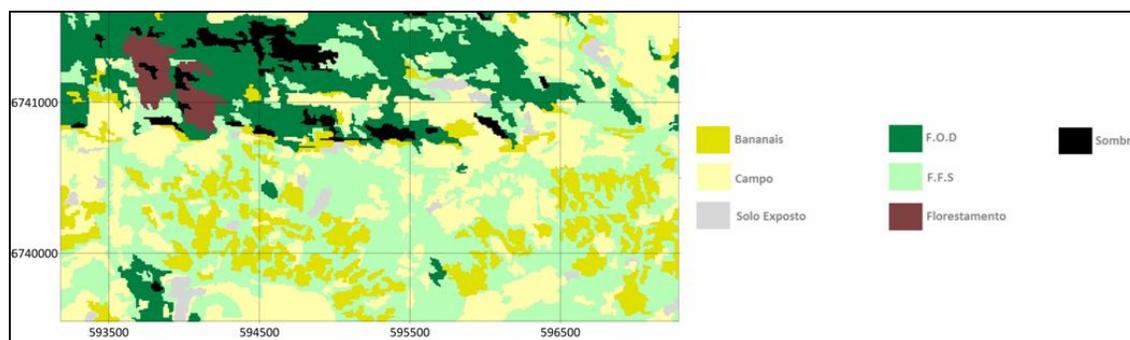


Figura 6. Imagem classificada pelo algoritmo de Isoseg.

Tabela 4. Matriz de confusão para a comparação da classificação visual (colunas) com a classificação digital pelo algoritmo de Isoseg (linhas).

Classe	Bananais	Outros Usos	Campo	F.O.D	F.F.S	Florestamento	Sombra	Σ Linha	Acurácia do Usuário
Bananais	6783	5	1456	21	2973	60	0	11298	60,03%
Outros Usos	2	762	834	0	74	0	0	1672	45,57%
Campo	1291	381	17528	91	3582	42	0	22915	76,49%
F.O.D	238	29	1034	6810	6707	475	310	15603	43,64%
F.F.S	2178	302	4137	1388	20438	432	59	28934	70,63%
Florestamento	0	0	0	104	164	1461	0	1729	84,49%
Sombra	0	0	51	906	643	227	688	2515	27,35%
Σ Coluna	10492	1479	25040	9320	34581	2697	1057	84666	-

A classificação pelo algoritmo de Isoseg apresentou os segundos maiores valores de Estatística Kappa (0,5194) e Exatidão Global (64,33%) entre todos os algoritmos.

Na classe Bananais houve uma superestimação de área pelo algoritmo, o qual definiu 11298 pixels, enquanto o mapa base definiu 10492 pixels. Destes, 6783 pixels foram corretamente classificados, sendo que 1456 pixels foram classificados em áreas que deveriam pertencer à classe Campo e 2973 pixels em áreas que deveriam pertencer à classe Formação Florestal Secundária.

Na classe Formação Florestal Secundária, dos 28934 pixels estimados pelo algoritmo, 20438 pixels estão em concordância com o mapa base, destacando-se que 4137 pixels foram classificados em áreas que deveriam pertencer à classe campo, e 2178 pixels em áreas que deveriam pertencer à classe Bananais.

Com relação à classe Floresta Ombrófila Densa, foram estimados 15603 pixels pelo algoritmo, destacando-se que 6810 estão em concordância com o mapa base, e que 6707 foram classificados em áreas que deveriam pertencer à classe Formação Florestal Secundária.

4. Conclusões

A realização de testes com diferentes algoritmos de classificação foi extremamente importante, pois possibilitou averiguar as potencialidades e deficiências de cada classificador de forma a se analisar qual destes melhor se adaptava as características presentes na área de estudo. De modo geral, em todos os classificadores testados, as maiores dificuldades de discriminação se concentraram entre as classes: Floresta Ombrófila Densa e Formação Florestal Secundária; Bananais e Formação Florestal Secundária; Campo e Formação Florestal Secundária.

As imagens classificadas pelos algoritmos baseados em pixels (Máxima Verossimilhança Gaussiana e Distância Mínima Euclidiana), por não considerarem a textura da imagem quando comparam o valor nominal de um pixel com a estatística de um grupo pré-selecionado (amostras de treinamento), apresentaram pontos de pixels “pulverizados” dentro das classes. Já as classificações geradas pelos algoritmos de classificação que necessitam da segmentação das imagens antes de classificá-las (Bhattacharya e Iseseg), eliminando os pixels isolados, geraram imagens temáticas com qualidades visuais muito superiores.

Por fim, baseando-se na qualidade visual da imagem gerada e nos valores estatísticos obtidos, dentre os classificadores testados neste recorte definido, o algoritmo Bhattacharya foi o que apresentou melhor desempenho, servindo adequadamente para a distinção entre áreas de cultivo de banana e as demais classes associadas ao seu entorno.

Referências bibliográficas

Blaschke, T.; Burnett, C.; Pekkarinen, A. **Image segmentation methods for object-based analysis and classification**. In: De Jong, S. M. & Der Meer, F. D. (eds). Remote sensing image analysis – including the spatial domain. Dordrecht, The Netherlands, Springer. pp. 211-236. 2007.

Lillesand, T. M.; Kiefer, R. W.; Chipman, J. W. **Remote sensing and image interpretation**. 5 ed. New York: John Wiley & Sons, 2004.

Meinel, G.; Neubert, M.: A Comparison of segmentation programs for high resolution remote sensing data. **Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences**. XXXV-B4, pp. 1097-1102. 2004.