

ANÁLISE DAS INCERTEZAS ENVOLVIDAS EM CLASSIFICAÇÃO MULTI-LEGENDAS DA COBERTURA DA TERRA COM SUPORTE DE SIMULAÇÃO MONTE CARLO

*Uncertainty Analysis of Multi-Legend Land Cover Classification with
Monte Carlo Simulation Support*

**Mariane Souza Reis¹, Luciano Vieira Dutra², Sidnei João Siqueira Sant'Anna²
& Maria Isabel Sobral Escada²**

¹Instituto Nacional de Pesquisas Espaciais – INPE

Centro de Ciência do Sistema Terrestre - CCST

Av. dos Astronautas, 1.758 - Jardim da Granja - CEP: 12227-010 - São José dos Campos - SP - Brasil
reis@dpi.inpe.br

²Instituto Nacional de Pesquisas Espaciais – INPE

Divisão de Processamento de Imagens - DPI

Av. dos Astronautas, 1.758 - Jardim da Granja - CEP: 12227-010 - São José dos Campos - SP - Brasil
{dutra, sidnei, isabel}@dpi.inpe.br

Recebido em 21 de Março, 2017/ Aceito em 16 de Dezembro, 2017

Received on March 21, 2017/ Accepted on December 16, 2017

RESUMO

A necessidade de informações acerca das dinâmicas de uso da terra tornou estudos relacionados à classificação de uso e cobertura da terra na região Amazônica relevantes no campo científico, com destaque ao uso de classificadores supervisionados. No entanto, o desempenho de um classificador supervisionado é dependente dos dados de entrada utilizados (imagem a ser classificada, definição das classes e coleta de amostras de treinamento), que em muitos estudos não são propriamente avaliados. Para contribuir com o entendimento de como variações nos dados de entrada afetam os resultados da classificação supervisionada, este estudo analisou os resultados de classificações de cobertura da terra em uma região da Amazônia brasileira, considerando diferentes métodos de classificação baseados em pixel, legendas com distintos níveis de detalhe (número de classes) e a sensibilidade dos classificadores à variação das amostras de treinamento (Incerteza) com o uso de uma imagem ótica de média resolução. Para tanto, foram geradas 100 imagens classificadas para três legendas com diferentes níveis de detalhe e diferentes configurações de quatro algoritmos de classificação supervisionados: *Máxima Verossimilhança (ML)*, *Máquina de Vetores Suporte (SVM)*, *Árvore de Decisão (J48)* e *k-Vizinhos mais Próximos (K-NN)*. No total, foram obtidos 111 (3 níveis de legenda x 37 configurações de classificadores) grupos de 100 imagens classificadas, que foram utilizados para gerar imagens combinadas em que cada pixel recebe o rótulo mais frequente nesses grupos de imagens (moda) e mapas da Incerteza associada. De forma geral, a combinação de imagens retornou uma imagem classificada de igual ou maior exatidão que imagens que a compõem, com diferenças menos expressivas em função dos classificador utilizado que ao se considerar os grupos de 100 imagens classificadas, embora a diferença no valor de exatidão seja pequena. A maioria das imagens classificadas mais acuradas foram obtidas utilizando alguma configuração do algoritmo *K-NN*. No entanto, esse algoritmo apresentou maiores valores de Incerteza quando comparado a *ML* e *SVM*. Essa maior variabilidade (maiores valores de Incerteza),

em compensação, colabora para a obtenção de melhores resultados da operação da moda, pois permite reclassificar adequadamente pixels de classificação instável. O algoritmo *ML* apresentou resultados mais consistentes (variam pouco em relação ao conjunto de amostras de treinamento), adequadamente acurados e possui utilização mais simples, já que a etapa de ajuste de parâmetros não é necessária. Quanto menor o nível de detalhe da legenda, maior a exatidão das imagens classificadas e menor sensibilidade das imagens classificadas à variação das amostras de treinamento (Incerteza). A diminuição do nível de detalhe da legenda resulta também em diferenças menos sutis na exatidão das imagens classificadas por diferentes algoritmos na configuração ótima.

Palavras-chave: Classificação de Cobertura da Terra, Classificação Hierárquica, Incerteza da Classificação, Comparação de Classificadores, Classificação Baseada em Pixel, Amazônia.

ABSTRACT

The need for information about the dynamics of land use highlighted the relevancy of classification of land use and land cover in the Amazon region studies, with special interest to those related to the use of supervised classifiers. However, the performance of a supervised classifier is dependent on the input data used (image to be classified, class definition and sample training), which are not properly evaluated in many studies. In order to contribute to the understanding of how variations in the input data affect supervised classification results, this study analyzed land cover classifications in a region of the Brazilian Amazon, obtained by different pixel based classification methods, legends with distinct levels of detail (number of classes) and the sensitivity of the classifiers to the variation of the training samples (Uncertainty), with the use of a medium resolution optical image. For this, 100 classified images were generated, considering three legends with different levels of detail and varied configurations of four supervised classification algorithms: *Maximum Likelihood (ML)*, *Support Vector Machine (SVM)*, *Decision Tree (J48)* and *k-Nearest Neighbors (K-NN)*. In total, 111 (3 levels of legend x 37 configurations of classifiers) groups of 100 classified images were obtained, which were used to generate combined images in which each pixel receives the most frequent label in a given group of images (mode). Associated Uncertainty maps were also generated from these groups of 100 classified images. In general, combining groups of classified images returned a classified image of equal or greater accuracy than those used to generate it, with less expressive differences related to the used classifier than when considering the groups of 100 classified images. Nevertheless, this difference in accuracy is small. Generally, the most accurate classified images were obtained from some configuration of the *K-NN* algorithm. However, this algorithm presented Uncertainty values higher than either *ML* or *SVM*. Nonetheless, this greater variability (higher Uncertainty values) contributes to obtaining better results from mode operation, since it allows to properly reclassify unstably classified pixels. The *ML* algorithm presented more consistent results (smaller variation in results due to variation of the training samples set), that are adequately accurate and has a simpler use, since the step of adjusting parameters is not necessary. The decrease of the detail level in legends results in more accurate also less influenced by the training samples variation (Uncertainty) classified images. The decrease in legend detail also leads to less subtle differences in the accuracy of the classified images obtained by different algorithms in the optimal configuration.

Keywords: Land Cover Classification, Hierarchic Classification, Classification Uncertainty, Classifier Comparison, Pixel Wise Classification, Amazon.

1. INTRODUÇÃO

A região amazônica trata-se de uma das últimas fronteiras de expansão econômica e territorial de importância mundial, onde numerosos programas de investimento propiciaram condições para mudanças rápidas (MELLO, 2002). A necessidade de informações acerca das dinâmicas de uso da terra tornou estudos sobre uso e cobertura da terra nessa região relevantes no campo científico (ALVES, 2007; LU *et al.*, 2004). Nesse sentido, a classificação de dados de sensoriamento remoto

para fins de mapeamento ou monitoramento de uso e cobertura da terra, seja por interpretação visual ou de forma digital, é uma atividade já reconhecida. Para exemplificar a importância de classificações acuradas na região, pode-se citar diversos programas de caráter técnico-científico focados no estudo e monitoramento Amazônia Legal brasileira, como o Programa de Cálculo do Desflorestamento da Amazônia (PRODES), Mapeamento da Degradação Florestal na Amazônia Brasileira (DEGRAD) (INPE, 2008), Sistema de Detecção de Desmatamentos em Tempo Real (DETER) (ANDERSON *et*

al., 2005; DINIZ *et al.*, 2015), e o projeto Mapeamento do Uso e Cobertura da Terra nas Áreas Desflorestadas da Amazônia Legal (TerraClass) (ALMEIDA *et al.*, 2016),

Segundo Coppin *et al.* (2004), métodos digitais de classificação oferecem resultados consistentes e replicáveis, além de permitir a integração de informações de difícil interpretação visual. Existem diversos métodos de classificação que podem se diferenciar pela representação do objeto de estudo (pixel, contexto, regiões ou objetos, por exemplo) ou pela própria técnica de classificação. Dentre o vasto conjunto de métodos disponíveis, identificar qual a forma mais adequada de classificar os dados pode ser uma tarefa difícil. Existem diferentes trabalhos na literatura dedicados à comparação de algoritmos de classificação, com especial atenção ao uso de algoritmos supervisionados (que necessitam de amostras rotuladas das classes a serem classificadas), dos quais são citados o de Moreira *et al.* (2016), Martins-Bedê *et al.* (2014), Reis (2013), Nery *et al.* (2013), Ferreira *et al.* (2010), Sousa *et al.* (2010) e Lu *et al.* (2004). Em todos esses trabalhos, diferentes classificadores supervisionados foram testados para uma legenda específica, com um único conjunto de amostras de treinamento (de tamanhos variados ou estratificado por classe) e seus resultados avaliados por meio de índices de exatidão derivados de matrizes de confusão, as quais são geradas pela tabulação das classificações com amostras de referência. De forma geral, observa-se que o uso de diferentes classificadores tende a gerar resultados distintos, sendo que um classificador pode ser mais eficiente na discriminação de um conjunto de classes, enquanto outro pode ser melhor para outro conjunto. Os resultados também variam em função da área de estudo e do tipo e data dos dados utilizados.

O desempenho de um classificador supervisionado é dependente da definição das classes a serem utilizadas e da coleta de amostras de treinamento, em termos de qualidade e quantidade (CINGOLANI *et al.*, 2004). Comumente, a legenda (conjunto de classes) a ser utilizada é definida de três formas: 1) a partir de um sistema de classificação, que se trata de um arcabouço lógico que contém o nome das classes, os critérios que as distinguem e como estas se

relacionam (MCCONNELL & MORAN, 2000); 2) em função do objetivo do estudo ou 3) pela capacidade de separar as classes esperada ou observada nos dados de sensoriamento remoto utilizados, sendo que estas duas últimas formas são as mais comuns e por vezes se confundem.

Alguns analistas agrupam diferentes classes de uso e cobertura da terra por esperarem, *a priori*, que estas apresentem confusão, ou não, em determinado tipo de dado. Outros definem essas legendas de forma automática, tendo como base algum critério computacional de separabilidade, como é o caso dos trabalhos de Negri *et al.* (2016) e Pereira *et al.* (2013, 2016). Nesses estudos as legendas geradas são dependentes dos dados de entrada, ou seja, as legendas foram criadas tendo como base a imagem a ser classificada e as amostras rotuladas. No estudo de Pantaleão *et al.* (2012), diferentes agrupamentos de classes, definidos *a priori* pelo analista, e sua relação com os conjuntos de dados de sensoriamento remoto são avaliados em função da exatidão da classificação. Nesse caso, o analista determina quais classes podem ser agrupadas, mas a legenda propriamente dita se baseia nos resultados da classificação, avaliada em função de amostras de referência. A coleta de amostras rotuladas geralmente é feita a partir de dados de campo ou interpretação de imagens de maior resolução espacial (LU & WENG, 2007), o que pode ser um processo subjetivo e não necessariamente resultar no conjunto mais adequado de amostras. Na prática, diferenças nas amostras coletadas podem significar diferenças nas próprias legendas sendo utilizadas se estas forem baseadas nas amostras, ou ainda em resultados não comparáveis ou aparentemente contraditórios em diferentes estudos.

Dessa forma, tem-se que o resultado de uma classificação supervisionada depende não apenas da escolha do classificador adequado, e sim de todo o sistema de análise digital de imagens, definido neste trabalho como os conjuntos de operações computacionais utilizados para gerar uma imagem classificada a partir de uma imagem de sensoriamento remoto. Diversos fatores desse sistema não são propriamente avaliados ao se considerar estudos sobre classificação de imagens de sensoriamento remoto. Visando contribuir para o melhor entendimento desses fatores, o presente estudo

objetiva analisar os resultados de classificações supervisionadas de cobertura da terra em uma região da Amazônia brasileira, considerando diferentes algoritmos de classificação, legendas com diferentes níveis de detalhe (número de classes) e variação de amostras de treinamento e teste. Em particular, inclui-se uma análise da sensibilidade dos classificadores à variação das amostras de treinamento.

Nesta seção foram apresentados o contexto, a motivação e o objetivo desse estudo. Na Seção 2 estão descritos a área de estudo, os dados utilizados e os procedimentos metodológicos para a execução desse estudo. Os resultados obtidos para os diferentes níveis de legenda estão apresentados e discutidos na Seção 3. Considerações gerais e conclusões estão delineadas na Seção 4.

2. MATERIAIS E MÉTODOS

Nesta seção, primeiramente é feita a descrição da área de estudo, das classes de uso e cobertura da terra e das legendas utilizadas. Na sequência, os dados utilizados e a metodologia de classificação e análise dos resultados são apresentados. Ressalta-se que a área de estudo utilizada, os dados de entrada (amostras rotuladas e imagem de sensoriamento remoto) e definição de legendas provém do trabalho de Reis *et al.* (2017), no qual alguns resultados prévios foram publicados.

2.1 Área de estudo e legendas utilizadas

Este estudo foi realizado em uma área de aproximadamente 412 km² localizada ao longo da BR-163 (Rodovia Cuiabá-Santarém) em uma região da Amazônia Brasileira, no município de Belterra, no estado do Pará. Esta área está ilustrada na Figura 1, juntamente com seus limites geográficos. Trata-se de uma região originalmente composta por Floresta Ombrófila Densa, com fisionomia de dossel uniforme ou com árvores emergentes, em que áreas de vegetação secundária, pastagens e áreas agrícolas estão inseridas na matriz florestal. Há também relatos de extração de madeira, bem como da ocorrência de incêndios, causados principalmente pelo uso inadequado do fogo para manejo de pastagens e preparo de áreas agrícolas (ESCADA *et al.*, 2009).




Fig. 1 – Área de estudo em relação a limites naturais e políticos: a) área ampliada; b) em relação à Amazônia Legal brasileira.

Dez classes de cobertura da terra foram definidas para esta área e estão descritas na Tabela 1. Estas classes foram previamente utilizadas por Reis *et al.* (2017) e determinadas a partir dados de campo (setembro de 2009 e 2010), bem como dados do projeto TerraClass (EMBRAPA & INPE, 2008).

As classes definidas foram organizadas em níveis de legenda, considerando a estrutura da vegetação e não os dados utilizados, o que possibilita seu uso em estudos de diferentes escalas. Foram definidos três níveis de legenda: L1, L2 e L3. L1 representa o nível de legenda mais detalhado e é composto pelas dez classes. L2 trata-se de uma legenda de detalhe intermediário, própria para estudos regionais, composta por quatro classes. A legenda L3 possui menor nível de detalhe e separa apenas dois grandes grupos de classes: áreas florestadas e áreas agropastoris. O agrupamento de classes necessário para formar cada legenda está ilustrado na Figura 2.

Tabela 1: Definição de classes de cobertura

Sigla	Classe	Descrição
SE	Solo exposto	Áreas agrícolas recentemente colhidas ou preparadas para o plantio, com predominância de solo exposto (sem cobertura vegetal)
AP	Área em pousio	Áreas agrícolas em pousio, cobertas por gramíneas ou palha
AC	Área cultivada	Área agrícola com cultura de grãos
PL	Pasto limpo	Área de pastagem, coberta predominantemente por gramíneas
PS	Pasto sujo	Área de pastagens, com predominância de gramíneas e espécies invasoras arbustivas
VS1	Vegetação secundária inicial	Áreas de vegetação secundária (crescida após a total retirada da floresta) com predominância de herbáceas e arbustos
VS2	Vegetação secundária intermediária	Áreas de vegetação secundária com presença predominante de arbustos e árvores de pequeno porte
VS3	Vegetação secundária avançada	Áreas de vegetação secundária composta por árvores com altura média de 20 m e presença de árvores emergentes. Pode apresentar herbáceas e arbustos em menor quantidade
FD	Floresta degradada	Áreas florestais modificadas por coleta seletiva ou fogo
FM	Floresta madura	Áreas florestais bem estruturadas, com pouca ou nenhuma evidência de alteração




Fig. 2 - Definição dos níveis de legenda, adaptado de Reis *et al.* (2017). Em que: SE=Solo exposto, AP=Área em pousio, AC=Área cultivada, PL=Pasto limpo, PS=Pasto Sujo, VS1=Vegetação secundária inicial, VS2=Vegetação secundária intermediária, VS3=Vegetação secundária avançada, FD=Floresta degradada e FM=Floresta madura.

Amostras rotuladas das classes definidas pela legenda L1 foram coletadas a partir de dados de campo e agrupadas para formar conjuntos correspondentes às demais legendas. Amostras da legenda L1 estão apresentadas na Figura 3, sobre a banda 5 de uma imagem LANDSAT5/TM de 29 de junho de 2010. A quantidade de amostras para cada classe e grupo, considerando uma resolução espacial de 30 m, está apresentada na Tabela 2.

Tabela 2: Número de amostras rotuladas por classe

Classe	Treinamento	Teste
Solo exposto	1181	1155
Área em pousio	1060	590
Área cultivada	542	570
Pasto limpo	883	400
Pasto sujo	907	929
V.S. inicial	289	227
V.S. intermediária	395	315
V.S. avançada	920	1201
Floresta degradada	2743	3517
Floresta madura	1842	1670

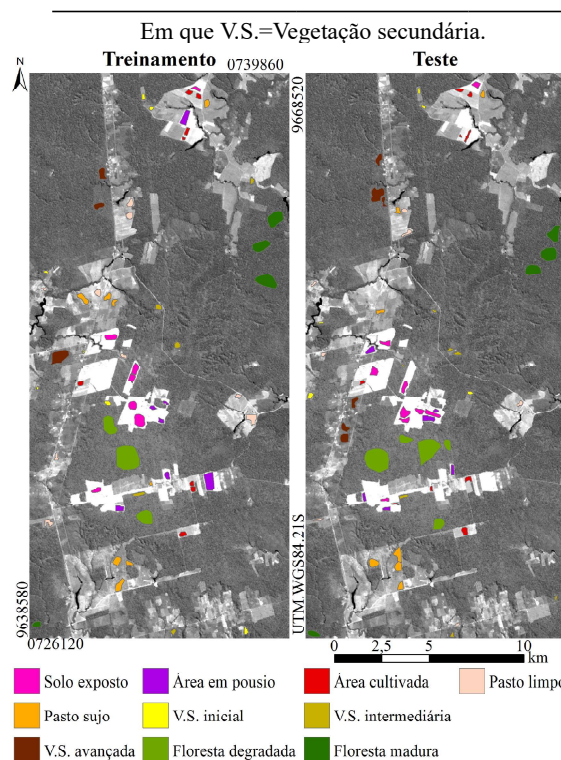


Fig. 3 – Amostras de treinamento e teste sobre banda 5 de imagem LANDSAT5/TM de 29 de junho de 2010. Em que V.S.=Vegetação secundária.

2.2 Imagens

Uma imagem LANDSAT5/TM de órbita/ponto 227/62, de 29 de junho de 2010, foi utilizada nesse trabalho. Esta imagem foi adquirida do catálogo do Instituto Nacional de Pesquisas Espaciais, com correção radiométrica e geométrica de sistema, projetada em UTM, com datum WGS84. Esta imagem possui, originalmente, 7 canais espectrais, resolução espacial de 30 m e resolução radiométrica

de 8 bits. Apenas as bandas 1 a 5 e 7 foram consideradas.

A imagem foi ortoretificada utilizando o modelo *Rational Function (RFM)* presente no software *PCI 13.0*, tendo como modelo digital de elevação dados do *Shuttle Radar Topography Mission*, versão 4 (*SRTM4*). Manteve-se a projeção e resolução do dado original. Não houve processamento adicional de correção radiométrica e a imagem foi utilizada sem alterações de contraste.

Um processo adicional de seleção de atributos foi realizado. Considerando as dez classes determinadas na legenda L1, calculou-se a distância de Jeffries-Matusita (JM) (SCHOWENGERDT, 2006) para todos os possíveis pares de classes, considerando todas as combinações possíveis de b bandas, com b variando de 1 a 6. O conjunto de 3 atributos formado pelas bandas 2, 4 e 5 foi selecionado, por apresentar a maior distância JM mínima entre os pares de classes em conjuntos de 3 atributos, com valor semelhante ao obtido por conjuntos com 4 atributos. A imagem formada pelas bandas selecionadas está apresentada na Figura 4. Estas três bandas selecionadas foram utilizadas para classificação nos três níveis de legenda propostos.

2.3 Classificação e avaliação dos resultados

Para alguns classificadores, como é o caso do *J48* (WITTEN & FRANK, 2005), diferenças no número de amostras de treinamento influenciam fortemente na probabilidade de atribuição das classes para cada pixel sendo classificado. Nesses casos, sortear o mesmo número de amostras do conjunto de treinamento é uma opção viável para manter a mesma probabilidade *a priori* para as classes da legenda sendo usada. Ou seja, sortear as amostras a serem utilizadas é uma prática inerente de muitos processos de classificação. No entanto, não há garantias de que o conjunto de amostras sorteado é o mais adequado para a tarefa. De forma análoga, mesmo que se utilize o conjunto completo de amostras de treinamento, esse pode não ser representativo das classes utilizadas ou conter pixels com informação de classes distintas, o que pode influenciar negativamente no processo de classificação.

Para avaliar essa característica, propõe-

se um sistema de análise digital de imagens, conforme ilustrado na Figura 5, em que grupos de imagens classificadas são gerados utilizando uma estratégia Monte Carlo: realizam-se diversas classificações de uma mesma imagem com um mesmo algoritmo de classificação, mas com diferentes sorteios de amostras de treinamento para observar o resultado mais provável de forma heurística (Produto 1). Uma imagem classificada supostamente menos dependente da escolha particular de um conjunto de treinamento é gerada a partir deste sistema.



Fig. 4 – Imagem LANDSAT5/TM de 29 de junho de 2010, órbita ponto 227/62. Composição colorida 5(R)4(G)2(B).

Do sistema apresentado obtém-se um grupo de imagens classificadas que podem possuir diferentes valores de exatidão. Um exemplo de saída desse sistema está exemplificado na Figura 6. Nessa figura, os valores de um índice de exatidão qualquer foram calculados sobre as imagens classificadas e organizados em um histograma. Uma curva normal com média e variância igual às calculadas a partir dos valores do índice de exatidão está sobreposta ao histograma, em vermelho. Propõe-se neste trabalho que a imagem classificada representante do sistema de análise de imagens (descrito na Figura 5) seja aquela que possui exatidão mais próxima da média dos valores do índice de exatidão adotado, uma vez que pela própria definição de média, esta representa o valor do índice esperado ao se realizar uma classificação com um conjunto de classes e imagem de sensoriamento remoto.

Para cada nível de legenda utilizado, as bandas selecionadas da imagem LANDSAT5/TM foram classificadas utilizando o sistema proposto na Figura 5. Quatro classificadores foram utilizados alternadamente no sistema, todos orientados a pixel. São estes: *Máxima Verossimilhança* (*Maximum Likelihood - ML*), *k-Vizinhos mais Próximos* (*k-Nearest Neighbour - K-NN*), *J48* (implementação do algoritmo baseado em árvore de decisão *C4.5*) e *Máquina de Vetores Suporte* (*Support Vector Machine - SVM*), implementados nos pacotes *Rasclass*, *RWeka* e *e1071*, todos em linguagem *R*. Esses classificadores foram usados em diferentes configurações quando a sintonia de parâmetros se fez necessária. Detalhes sobre os algoritmos podem ser encontrados em Witten e Frank (2005), Theodoridis e Koutroumbas (2006) e Richards e Jia (2006). Os detalhes de cada configuração estão descritos a seguir:

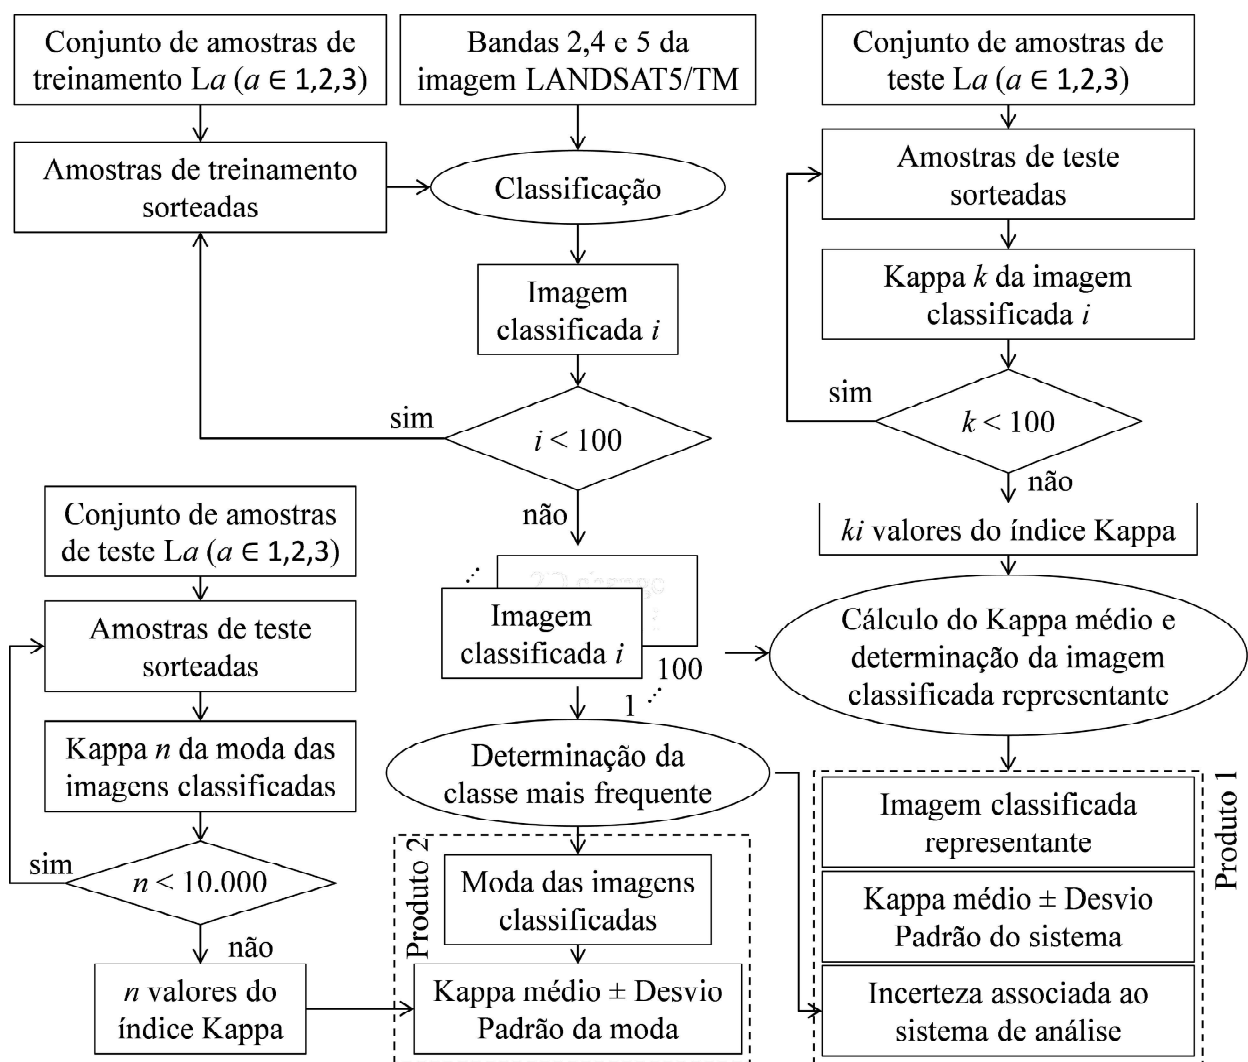


Fig. 5 – Sistema de análise de imagens de sensoriamento remoto proposto. Em que a se refere à legenda utilizada, k é o índice do Kappa calculado para cada imagem classificada i do conjunto I e n se refere ao valor de Kappa calculado para a moda das imagens classificadas.

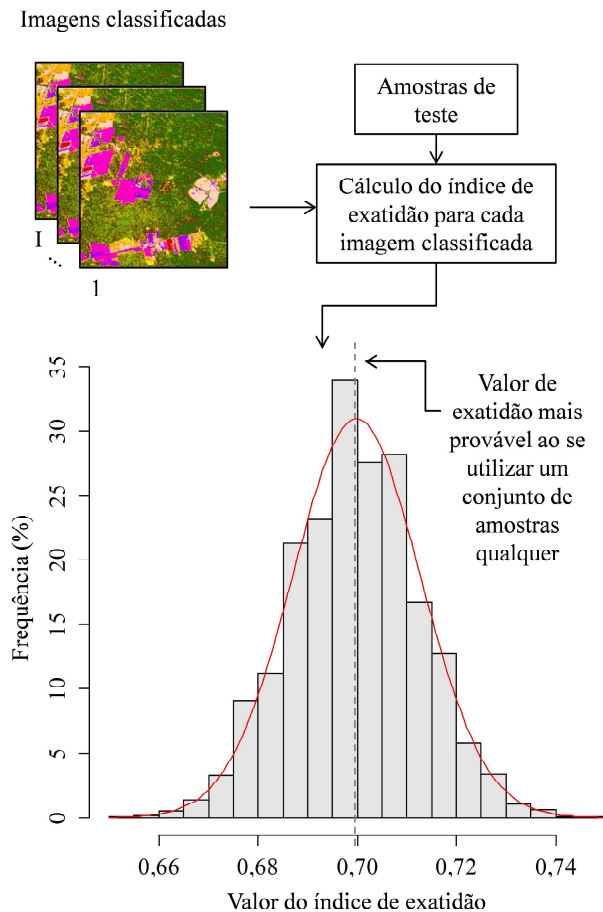


Fig. 6 – Exemplo de saída do sistema de análise de imagens. No presente estudo, considerou-se 100 sorteios de amostras de teste e respectivos valores de índices de exatidão para cada imagem classificada do conjunto I .

- a) *ML*: classificações obtidas por *Máxima Verossimilhança* e distribuição gaussiana. Não há parâmetros a serem ajustados (1 configuração);
- b) *K-NN*: classificações utilizando *K-NN* e v vizinhos mais próximos, sendo que v varia de 1 a 20, em passos de 1 unidade. Resulta em 20 configurações analisadas;
- c) *J48_j*: classificações obtidas pelo algoritmo *J48*, sendo j o número mínimo de instâncias que varia de 2 a 10 em passos de 1 unidade, com demais parâmetros no valor padrão (nível de confiança da poda em 0,25, número de “*folds*” igual a 3 e 1 semente). Resulta em 9 configurações;
- d) *SVM_c*: *SVM* com estratégia de classificação “um contra um” e *kernel* linear. Parâmetro de custo (c) igual a 10^p , com p variando de -2 a 4, em valores unitários (7 configurações).

Foram obtidas 100 imagens classificadas para cada classificador supervisionado (em uma

dada configuração) e nível de legenda, com variação das amostras sorteadas do conjunto de treinamento (300 pixels de cada classe, selecionados de forma aleatória, com reposição). Cada uma dessas imagens classificadas foi avaliada por uma estratégia Monte Carlo, em que 100 pixels por classe do conjunto correspondente de amostra de teste foram sorteados, sem reposição, para calcular uma matriz de confusão e os índices Exatidão Global, Kappa e Exatidão do Produtor e do Usuário (por classe). Esse processo foi realizado 100 vezes por imagem classificada, com variação de amostras de teste, resultando em 10.000 matrizes de confusão e valores dos índices para cada grupo de 100 imagens (mesmo classificador, configuração e legenda). A média dos 10.000 valores de exatidão calculados para um grupo de 100 variações de imagens classificadas foi utilizada como valor de exatidão representativo daquele grupo. A imagem classificada cuja exatidão foi a mais próxima da média foi estabelecida como a imagem classificada representante do sistema e sua incerteza é extraída da própria variabilidade de seus resultados.

Em um segundo momento, uma combinação das imagens classificadas geradas pelo sistema de análise é obtida pela moda dessas imagens classificadas, como apresentado também na Figura 5 (Produto 2). Observe que neste caso a moda se refere aos rótulos (classes) atribuídos a cada pixel das imagens. Nessas imagens combinadas, cada pixel recebe o rótulo mais frequente de um grupo de 100 imagens classificadas (saída de uma rodada do sistema, considerando uma configuração de um classificador e um nível de legenda).

Os mapas de incerteza associados às imagens representantes do sistema (Produto 1) também foram obtidos a partir dos grupos de 100 imagens classificadas. A Incerteza (U) de cada ponto da imagem é calculada por:

$$U = 1 - m/t \quad (1)$$

em que m é o número de vezes em que a classe mais frequente foi computada e t é o total de classificações (100 nesse caso). Salienta-se aqui que a Incerteza refere-se à proporção das classificações em que a classe majoritária foi

classificada, não havendo nenhuma consideração se esta classe foi corretamente atribuída ou não.

A operação de combinação de imagens classificadas gera apenas uma moda, que é menos dependente dos dados de treinamento. A avaliação é efetuada com base nas amostras de teste apenas, também por uma estratégia Monte Carlo. Foram aleatoriamente sorteadas 100 amostras por classe do conjunto de teste e gerada uma matriz de confusão e calculados os índices anteriormente citados. Esse processo foi repetido 10.000 vezes, variando-se o sorteio das amostras. Os valores médios dos índices de exatidão das modas das imagens classificadas, bem como os valores das médias dos índices calculados para grupos de 100 imagens classificadas (que representam o próprio sistema de análise para um dado classificador, configuração e legenda), foram comparados por meio do teste de hipótese T, com 1% de nível de significância.

3. RESULTADOS E DISCUSSÃO

Os resultados obtidos são apresentados e discutidos nesta seção, separados por nível de legenda. Para cada nível de legenda, as configurações que resultam nas imagens moda (aquelas obtidas pela combinação de 100 imagens classificadas) com maior valor de Kappa Global foram selecionadas como a que possui os parâmetros mais adequados para determinado classificador. Essas configurações foram então selecionadas como representantes daquele classificador e discutidas nessa seção. As configurações selecionadas estão apresentadas na Tabela 3.

Tabela 3: Configurações selecionadas para os classificadores, por nível de legenda

Classificador	Parâmetro ajustado	Nível de legenda		
		L1	L2	L3
<i>ML</i>	Não possui	-	-	-
<i>K-NN</i>	Número de vizinhos	20	16	4
<i>J48</i>	Número mínimo de instâncias	6	4	3
<i>SVM</i>	Custo	10	1	10

3.1 Legenda com maior nível de detalhe

Na Tabela 4 são apresentados os valores de Kappa esperado (valor referente à média dos 10.000 valores de Kappa Global calculados) do sistema de análise (conjuntos de 100 imagens

classificadas para cada algoritmo de classificação, configuração e legenda), juntamente com o valor de desvio padrão (após Kappa esperado e sinal de \pm) e de Incerteza média associada. Nesta tabela, também estão apresentados os sistemas de análise que obtiveram Kappa esperado estatisticamente semelhante àquele sendo analisado, considerando um nível de significância de 1%.

Tabela 4: Valores de Kappa esperado e de Incerteza média dos sistemas de análise, considerando a legenda

Classificador	Kappa esperado	Estatisticamente igual a	Incerteza média (%)
<i>ML</i>	0,700 \pm 0,013	-	4,9
<i>K-NN</i>	0,692 \pm 0,014	-	18,4
<i>J48</i>	0,674 \pm 0,017	-	12,4
<i>SVM</i>	0,698 \pm 0,014	-	4,9

Observa-se que todos os classificadores obtiveram valores de Kappa esperado estatisticamente diferentes entre si, a 1% de significância. Os resultados mais acurados para este nível de legenda foram obtidos pelo classificador *ML*, que também trata-se do algoritmo de utilização mais simples por não necessitar da etapa de sintonia de parâmetros.

É comum que se prefira utilizar o classificador que retorna resultados mais acurados para uma determinada análise. No entanto, também é importante que o classificador seja robusto no sentido de prover resultados satisfatórios para diferentes configurações de dados de entrada. No presente estudo, a medida de Incerteza (*U*) foi utilizada para avaliar o quanto cada classificador é afetado por variações nos conjuntos de amostras de treinamento. Neste sentido, tem-se que os classificadores *SVM* (em qualquer configuração adotada) e *ML* apresentaram valores menores de incerteza que *K-NN* ou *J48*.

Os valores de Kappa Global médio e desvio padrão calculados sobre as imagens moda de cada classificador estão apresentados na Tabela 5. Nesta tabela, também estão apresentados os resultados do teste estatístico comparando os valores médios de Kappa Global das imagens moda entre si. Todos os valores médios de Kappa Global apresentaram-se estatisticamente distintos dos Kappas esperados dos sistemas de análise a 1% de significância, neste e nos demais níveis de legenda. Dessa forma, esta

coluna foi omitida das tabelas correspondentes.

Observa-se que combinações de imagens mais acuradas da legenda L1 são provenientes dos algoritmos *J48* e *K-NN* e que estas combinações apresentam valor médio de Kappa Global estatisticamente iguais entre si e superiores que os de Kappa esperado apresentados na Tabela 4. Apenas para *ML* combinar as imagens classificadas obtidas resultou em uma redução na exatidão, sendo que os valores apresentados diferem em apenas 0,001. Adicionalmente, observa-se a diferença entre os valores de Kappa Global das imagens moda é menor que a diferença entre os valores de Kappa esperado dos sistemas de análise de imagens.

Tabela 5: Kappa Global médio das imagens moda da legenda L1

Imagem moda	Kappa Global	Estatisticamente igual a
<i>ML</i>	0,699 ± 0,013	-
<i>K-NN</i>	0,702 ± 0,013	<i>J48</i>
<i>J48</i>	0,702 ± 0,013	<i>K-NN</i>
<i>SVM</i>	0,701 ± 0,013	-

Considerando as melhorias globais observadas ao se combinar imagens classificadas, estes resultados foram utilizados para uma análise estratificada por classe de cobertura. Os valores médios de Exatidão do Usuário (EU) e de Exatidão do Produtor (EP) para cada classe da legenda L1 nas imagens moda estão apresentados na Tabela 6. Apesar de haver diferenças estatisticamente significativas entre vários valores médios dos índices, observa-se que a diferença em si é pequena, ou seja, os classificadores tendem a retornar resultados similares na combinação das imagens classificadas, em termos de exatidão por classe e global.

Apesar de as imagens moda, no geral, apresentarem exatidão superior à dos conjuntos que as compõem, a diferença nos valores é pequena e pode não justificar o uso do sistema de análise de imagens proposto. No entanto, o sistema oferece a vantagem de proporcionar os mapas de Incerteza. Embora os resultados de classificação tenham valores de exatidão próximos, *SVM* e *ML* apresentaram resultados mais estáveis, com o melhor compromisso entre exatidão e incerteza obtido por *SVM*. No entanto, por ser mais estável, a imagem moda pouco difere da imagem

representativa, logo os valores de exatidão da imagem moda e do sistema de análise são parecidos. Esses resultados endossam o conhecimento de que os classificadores não paramétricos *J48* e o *K-NN* são mais dependentes dos dados de treinamento que *SVM* e *ML* (que são paramétricos), mesmo que esse fato não seja sempre transcrito em resultados mais acurados. Nesse sentido, ressalta-se que a operação da moda permite reclassificar adequadamente pixels de classificação instável (aqueles espectralmente semelhantes a mais de uma classe, cujo rótulo atribuído varia com a variação das amostras de treinamento), o que é potencializado em classificadores que apresentaram maiores valores de Incerteza.

Para efeito de ilustração, recortes das imagens classificadas (representativa e moda) e dos mapas de Incerteza estão apresentados na Figura 7. Observa-se que os resultados de classificação foram semelhantes entre si, independente do classificador utilizado, e que os maiores e mais frequentes valores de Incerteza ocorrem em áreas de vegetação mais desenvolvida (Vegetação secundária e florestas).

Tabela 6: Valores médios de exatidão das imagens moda da legenda L1

	Imagem moda							
	<i>ML</i>		<i>K-NN</i>		<i>J48</i>		<i>SVM</i>	
	EU	EP	EU	EP	EU	EP	EU	EP
SE	0,88	0,89	0,85	0,88	0,86	0,91	0,81	0,93
AP	0,89	0,88	0,88	0,84	0,90	0,80	0,91	0,78
AC	0,83	0,93	0,86	0,91	0,85	0,91	0,86	0,90
PL	0,95	0,65	0,92	0,69	0,86	0,70	0,92	0,69
PS	0,72	0,94	0,73	0,92	0,74	0,93	0,73	0,94
VS1	0,88	0,78	0,88	0,81	0,91	0,80	0,89	0,79
VS2	0,49	0,44	0,49	0,53	0,48	0,49	0,50	0,51
VS3	0,46	0,47	0,46	0,46	0,46	0,49	0,47	0,46
FD	0,48	0,46	0,53	0,42	0,54	0,42	0,51	0,45
FM	0,75	0,87	0,76	0,87	0,75	0,87	0,76	0,86
Kappa Global	0,70 ± 0,01		0,70 ± 0,01		0,70 ± 0,01		0,70 ± 0,01	
Exatidão Global	0,73 ± 0,01		0,73 ± 0,01		0,73 ± 0,01		0,73 ± 0,01	

em que: SE=Solo exposto, AP=Área em pousio, AC=Área cultivada, PL=Pasto limpo, PS=Pasto Sujo, VS1=Vegetação secundária inicial, VS2=Vegetação secundária intermediária, VS3=Vegetação secundária avançada, FD=Floresta degradada, FM=Floresta madura, EU=Exatidão do Usuário e EP=Exatidão do Produtor.




Fig. 7 – Recorte das imagens selecionadas na legenda L1 e Incerteza associada. Em que V.S.=Vegetação secundária.

3.2 Legenda com nível de detalhe intermediário

Os valores de Kappa esperado dos sistemas de análise que utilizaram a legenda L2 estão apresentados na Tabela 7. O valores de Kappa Global médio e desvio padrão calculados sobre as imagens moda de cada classificador e mesma legenda estão apresentados na Tabela 8, juntamente com resultados do teste estatístico, considerando 1% de significância. Os valores médios de exatidão por classe e global das imagens moda da legenda L2 estão apresentados na Tabela 9.

De forma análoga ao que ocorreu no nível de legenda de maior detalhe (L1), observa-se

que na legenda L2 as imagens combinadas pela moda dos rótulos apresentam valores de exatidão maiores que as imagens das quais foram gerados, mas as melhorias se traduzem em valores pequenos (ganho de 2,7 % no valor de Kappa).

Tabela 7: Valores de Kappa esperado e de Incerteza média dos sistemas de análise, considerando a legenda L2

Conjunto	Kappa esperado	Estatisticamente igual a	Incerteza média (%)
<i>ML</i>	0,791 ± 0,023	-	2,5
<i>K-NN</i>	0,785 ± 0,024	-	7,1
<i>J48</i>	0,775 ± 0,026	-	8,3
<i>SVM</i>	0,776 ± 0,024	-	2,2

Tabela 8: Kappa Global médio das imagens moda da legenda L2

Imagem moda	Kappa Global	Estatisticamente igual a
<i>ML</i>	0,797 ± 0,021	<i>J48</i>
<i>K-NN</i>	0,803 ± 0,022	-
<i>J48</i>	0,796 ± 0,021	<i>ML</i>
<i>SVM</i>	0,781 ± 0,023	-

Tabela 9: Valores médios de exatidão das imagens moda da legenda L2

	Imagem moda							
	<i>ML</i>		<i>K-NN</i>		<i>J48</i>		<i>SVM</i>	
	EU	EP	EU	EP	EU	EP	EU	EP
SE+AP+AC	0.94	0.97	0.96	0.96	0.97	0.95	0.94	0.93
PL+PS	0.92	0.90	0.92	0.92	0.90	0.96	0.88	0.89
VS1+VS2	0.78	0.66	0.75	0.73	0.77	0.67	0.75	0.72
VS3+FD+FM	0.75	0.86	0.78	0.79	0.74	0.82	0.77	0.81
Kappa Global	0,80 ± 0,02		0,80 ± 0,02		0,80 ± 0,02		0,78 ± 0,02	
Exatidão Global	0,85 ± 0,02		0,85 ± 0,02		0,85 ± 0,02		0,84 ± 0,02	

em que: SE=Solo exposto, AP=Area em pousio, AC=Área cultivada, PL=Pasto limpo, PS=Pasto Sujo, VS1=Vegetação secundária inicial, VS2=Vegetação secundária intermediária, VS3=Vegetação secundária avançada, FD=Floresta degradada, FM=Floresta madura, EU=Exatidão do Usuário e EP=Exatidão do Produtor.

Agrupar classes para gerar legendas mais generalizadas e com menor número de classes resultou em maiores valores de Kappa esperado (relativos ao sistema de análise) e de Kappa Global médio (calculado sobre a imagem moda), bem como em menores valores de Incerteza,

quando comparados com a legenda L1. Para a legenda L2, o melhor compromisso entre exatidão e Incerteza foi atingido pelo classificador *ML*, muito embora as diferenças nos valores de exatidão obtidos pelos diferentes classificadores seja pequena. Analogamente ao ocorrido ao se utilizar a legenda L1, para a legenda L2 todas as configurações de SVM analisadas e o classificador *ML* apresentaram incerteza média menor que as configurações de *K-NN* e *J48*.

s3.3 Legenda com menor nível de detalhe

Os valores de Kappa esperado dos sistemas de análise com a legenda L3, juntamente com o valor de desvio padrão, de Incerteza média associada e resultados do teste estatístico estão apresentados na Tabela 10. O Kappa Global médio, desvio padrão do Kappa Global e resultados do teste estatístico das imagens moda estão apresentados na Tabela 11.

Tabela 10: Valores de Kappa esperado e de Incerteza média dos sistemas de análise, considerando a legenda L3

Conjunto	Kappa Global	Estatisticamente igual a	Incerteza Média (%)
<i>ML</i>	0,979 ± 0,015	-	0,5
<i>K-NN</i>	0,980 ± 0,014	-	0,8
<i>J48</i>	0,971 ± 0,021	-	1,1
<i>SVM</i>	0,978 ± 0,015	-	0,8

Tabela 11: Kappa Global médio das imagens moda da legenda L3

Imagem moda	Kappa Global	Estatisticamente igual a
<i>ML</i>	0,980 ± 0,014	-
<i>K-NN</i>	0,985 ± 0,012	-
<i>J48</i>	0,987 ± 0,011	-
<i>SVM</i>	0,982 ± 0,013	-

Também para a legenda L3 as imagens moda são mais acuradas que as imagens classificadas que as compõem, mas essa diferença é pequena. No que se refere aos diferentes classificadores, nota-se que apesar de haver diferenças estatisticamente significativas nos valores de Kappa, essas diferenças também são pequenas. Nesse nível de legenda todos os valores de Kappa são superiores a 0,97, como esperado ao se considerar uma legenda com apenas duas classes.




Fig. 8 – Recorte das imagens selecionadas na legenda L2 e Incerteza associada. Em que: SE=Solo exposto, AP=Área em pousio, AC=Área cultivada, PL=Pasto limpo, PS=Pasto Sujo, VS1=Vegetação secundária inicial, VS2=Vegetação secundária intermediária, VS3=Vegetação secundária avançada, FD = Floresta degradada, FM=Floresta madura.

Algumas configurações de *K-NN* (configurados para computar mais de 5 vizinhos) apresentaram valores de Incerteza média associada menores que algumas configurações de *SVM* (custo maior que 10), sendo que *J48* (em todas as configurações) apresentam valores de Incerteza maiores que *ML* e *SVM*, bem como as configurações de *K-NN* com pelo menos 2 vizinhos. No entanto, a maior Incerteza média

encontrada nesse nível de legenda foi de 1,5% (J48 com mínimo de 8 instâncias) que trata-se de um valor relativamente baixo. Pela análise dos valores médios de exatidão global e por classe das imagens moda, apresentados na Tabela 12, observa-se que os diferentes classificadores apresentam altos valores de exatidão, bastante semelhantes entre si. Recortes das imagens classificadas e mapas de incerteza da legenda L3 estão apresentados na Figura 9. Nota-se que os maiores valores de incerteza ocorrem em áreas de pastagens.

Tabela 12: Valores médios de exatidão das imagens moda da legenda L3

	Imagem moda							
	J48_3		K-NN_4		SVM_10		ML	
	EU	EP	EU	EP	EU	EP	EU	EP
SE+AP+AC+PL+PS	0,99	1,00	0,99	0,99	0,99	0,99	0,98	1,00
VS1+VS2+VS3+FD+FM	1,00	0,99	0,99	0,99	0,99	0,99	1,00	0,98
Kappa Global	0,99 ± 0,01		0,99 ± 0,01		0,98 ± 0,01		0,98 ± 0,01	
Exatidão Global	0,99 ± 0,01		0,99 ± 0,01		0,99 ± 0,01		0,99 ± 0,01	

em que: SE=Solo exposto, AP=Área em pousio, AC=Área cultivada, PL=Pasto limpo, PS=Pasto Sujo, VS1=Vegetação secundária inicial, VS2=Vegetação secundária intermediária, VS3=Vegetação secundária avançada, FD=Floresta degradada, FM=Floresta madura, EU=Exatidão do Usuário e EP=Exatidão do Produtor.

3.4 Tempo computacional

Nas seções anteriores, verificou-se que o sistema de análise de imagens proposto apresenta as vantagens de possibilitar o cálculo de um mapa de incertezas associado e em uma segunda etapa calcular uma imagem moda das imagens classificadas. No entanto, deve-se salientar que o uso desse sistema, dependendo do tamanho da imagem, número de classes na legenda, classificador e quantidade de repetições (número de classificações), pode demandar um tempo computacional consideravelmente maior para execução que a classificação de uma imagem sem a variação de amostras de treinamento.




Fig. 9 – Recorte das imagens selecionadas na legenda L3 e incerteza associada. Em que: SE=Solo exposto, AP=Área em pousio, AC=Área cultivada, PL=Pasto limpo, PS=Pasto Sujo, VS1=Vegetação secundária inicial, VS2=Vegetação secundária intermediária, VS3=Vegetação secundária avançada, FD=Floresta degradada, FM=Floresta madura.

No presente trabalho, classificou-se uma imagem de 998 por 456 pixels, em legendas de 10 (L1), 4 (L2) e 2 (L3) classes. Considerando um computador com sistema operacional *Windows 10*, processador *Intel® Core™ i7-6700* (3,40 GHz) e 16 GB de memória instalada, o tempo computacional gasto para gerar as 100 imagens classificadas dos quatro classificadores (na melhor configuração) e em cada nível de legenda estão apresentados na Tabela 13. Ressalta-se que estas classificações foram

realizadas com auxílio do *RStudio* e que os quatro conjuntos de cada legenda foram processados em paralelo. Ressalta-se também que não foram feitas alterações nos algoritmos presentes nos pacotes utilizados, logo o tempo computacional apresentado compreende transformações nos dados necessárias para utilizar cada pacote, bem como a execução inerente de tarefas das funções utilizadas, ainda que essas não sejam necessárias para a classificação, como por exemplo, os algoritmos que calculam automaticamente matrizes de confusão a partir das amostras de treinamento, não utilizadas nesse estudo.

Tabela 13: Tempo computacional para gerar os conjuntos de 100 imagens classificadas para cada classificador na configuração ótima

Classificador	Tempo computacional aproximado (min)		
	L1	L2	L3
<i>ML</i>	87,59	39,22	23,59
<i>K-NN</i>	87,33	39,23	18,32
<i>J48</i>	2,62	2,01	1,86
<i>SVM</i>	21,18	6,40	2,28

Calcular e escrever a moda das imagens classificadas, em geral, demorou menos de 1 minuto, enquanto a geração do mapa de Incerteza demorou entre 1 e 2 minutos. No *R*, a leitura da imagem e das amostras, uma única classificação sem sorteio de amostras e a exportação da imagem classificada em formato TIFF (*Tagged Image File Format*) não durou mais de 1 minuto para nenhuma classificação.

Pela análise da Tabela 13, observa-se que quanto menor o número de classes também menor é o tempo computacional necessário para a geração de 100 imagens classificadas. Além disso, os classificadores apresentaram tempos computacionais distintos. Para o classificador *J48*, o que demandou menor tempo computacional, a diferença entre o tempo gasto para gerar 1 imagem classificada ou 100 é pequena para todos os níveis de legenda utilizados, o que somado às melhoras na exatidão observadas nas modas das imagens classificadas incentivam o uso desse classificador no sistema de análise proposto. No entanto, salienta-se que imagens maiores (maior número de pixels) e de número de classes da legenda utilizada pode levar a tempos computacionais consideravelmente mais extensos. Além disso, dos classificadores

testados nesse estudo, o *J48* é o que possui o maior número de parâmetros ajustáveis, o que pode levar a uma etapa de sintonia de parâmetros mais extensa.

3.5 Comparação entre níveis de legenda

Para a área de estudo, dados utilizados e legendas consideradas, têm-se que a diminuição do nível de detalhe da legenda resulta em classificações mais acuradas e com menor Incerteza associada. Adicionalmente, quanto menor o nível de detalhe da legenda, menor a diferença entre os valores de Kappa esperado computados para os sistemas de análise e os valores de Kappa Global médios calculados sobre as imagens moda. Há também diferenças menos expressivas no valor entre esses índices considerando diferentes classificadores. Ou seja, quanto menor o nível de detalhe da legenda utilizada, menor também o impacto da escolha do classificador no resultado obtido e menor o impacto de se gerar uma imagem classificada ou um conjunto de imagens e combiná-las pelo rótulo mais frequente. Esses resultados indicam que a escolha das amostras de treinamento é menos importante para legendas com menor nível de detalhe do que para aquelas mais detalhadas. Para todas as legendas, destaca-se que é possível gerar imagens classificadas similarmente acuradas a partir de diferentes classificadores. Observa-se também que a operação da moda é mais eficiente em classificadores mais instáveis (maior Incerteza).

4. CONCLUSÕES

Os resultados de classificações supervisionadas de cobertura da terra em uma região da Amazônia brasileira foram analisados neste estudo. Foram considerados diferentes métodos de classificação baseados em pixel, legendas com diferentes níveis de detalhe e a sensibilidade dos classificadores à variação das amostras de treinamento (Incerteza).

Para as três legendas avaliadas e os classificadores com resultados mais acurados, gerar um conjunto de 100 imagens classificadas a partir de diferentes sorteios de amostras de treinamento e gerar uma imagem combinada em que cada pixel recebe o rótulo mais frequente dessas classificações (moda) retornou uma imagem classificada de maior exatidão que o

conjunto que a compõem, embora os ganhos no valor de exatidão sejam pequenos. Apesar de determinados processamentos permitirem a variação do conjunto de treinamento durante o processo de classificação/análise de imagens de forma automática, como é o caso das classificações realizadas no ambiente *R*, ainda trata-se de uma etapa que acrescenta custos computacionais consideráveis ao processo e os ganhos nos valores de exatidão, apenas, não parecem justificar a existência dessa etapa. No entanto, essa variação apresenta a vantagem de fornecer um segundo parâmetro de avaliação, que é o mapa de Incerteza. A operação da moda também permite reclassificar corretamente pixels de classificação instável, sendo que esta característica é mais evidente em classificadores que apresentaram maiores valores de Incerteza.

Foram testados quatro classificadores em diferentes configurações. Considerando-se apenas a configuração de cada algoritmo que retornou resultados com maior Kappa Global médio para cada imagem moda, tem-se que diferentes classificadores alcançaram os melhores resultados para cada nível de legenda. No entanto, observa-se que a operação de moda tende a tornar o resultado da classificação menos dependente do classificador escolhido, i.e os valores de exatidão das imagens moda são mais parecidos entre si que os provenientes dos sistemas de análise de imagens.

De forma geral, as imagens classificadas (conjunto de imagens gerado pelo sistema de análise ou da moda destas) mais acuradas foram obtidas usando *K-NN*, enquanto *ML* e *SVM* se mostraram os classificadores menos sensíveis à variação de amostras de treinamento. Nesse sentido, os classificadores que mais se beneficiaram da operação da moda foram *J48* e *K-NN*, uma vez que essa operação permite resolver problemas de pixels de classificação instável. Note que devido à baixa variabilidade dos resultados dos classificadores *SVM* e *ML*, pixels espectralmente semelhantes são classificados correta ou erroneamente de forma sistemática, então a operação da moda tende a não corrigir erros de classificação. O classificador *ML* apresentou resultados mais consistentes (variam pouco em relação ao conjunto de amostras de treinamento), adequadamente acurados e possui utilização mais simples, já que a etapa de sintonia

de parâmetros não é necessária. Ressalta-se, no entanto, que este classificador é paramétrico e foi utilizado considerando distribuição gaussiana multivariada, ou seja, pode não ser indicado para outros tipos de dados de entrada, que sigam outras distribuições estatísticas.

Da disponibilidade de um sistema de análise de imagens que considere diferentes sorteios de amostras de treinamento, recomenda-se o uso de classificadores não paramétricos e cálculo da imagem moda, para melhorar a classificação de pixels de classificação instável. No caso de se desejar realizar apenas uma classificação, recomenda-se o uso de classificadores mais estáveis, como o *ML* e o *SVM*. No entanto, ressalta-se que mesmo para esses classificadores, podem existir pares de conjuntos de amostras (de treinamento e teste) que resultem em valores de índices de exatidão muito abaixo ou muito acima da média, o que pode comprometer a análise e comparação desses resultados, quando não há variação de amostras.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (processos #312753/2015-2, #401528/2012-0 e #309135/2015-0) pela concessão de bolsas. Agradecem também ao projeto Monitoramento Ambiental por Satélite no Bioma Amazônia, processo #1022114003005-MSA-BNDES e ao Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) pelas autorizações #48186-4, #48186-2 e #38157-2.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, C.A.; COUTINHO, A.C.; ESQUERDO, J.C.D.M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C.G.; DESSAY, N.; DURIEUX, L.; GOMES, A.R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amazonica*, v. 46, pp. 291–302, 2016.

ANDERSON, L.O.; SHIMABUKURO, Y.E.; DEFRIES, R.S.; MORTON, D. Assessment of deforestation in near real time over the Brazilian Amazon using multitemporal fraction images

- derived from Terra MODIS. **IEEE Geoscience and Remote Sensing Letters**, v.2, pp. 315-318, 2005.
- ALVES, D. A. Science and technology and sustainable development in Brazilian Amazon. In: TSCHARNTKE, T.; LEUSCHNER, C.; ZELLER, M.; GUHARDJA, E.; BIDIN, A. (Ed.). **Stability of Tropical Rainforest Margins**. Springer Berlin Heidelberg, 2007, (Environmental Science and Engineering). p. 491–510.
- CINGOLANI, A.M.; RENISON, D.; ZAK, M.R.; CABIDO, M.R. Mapping vegetation in a heterogeneous mountain rangeland using Landsat data: an alternative method to define and classify land-cover units. **Remote Sensing of Environment**, 92, pp. 84–97, 2004.
- COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, v. 25, n. 9, p. 1565–1596, 2004.
- DINIZ, C.G.; SOUZA, A.A.A.; SANTOS, D.C.; DIAS, M.C.; LUZ, N.C.; MORAES, D.R.V.; MAIA, J.S.; GOMES, A.R.; NARVAES, I.S.; VALERIANO, D.M.; MAURANO, L.E.P.; ADAMI, M. DETER-B: the New Amazon Near Real-Time Deforestation Detection System. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.8, pp. 3619-3628, 2015
- ESCADA, M.I.S.; AMARAL, S.; RENNÓ, C.D.; PINHEIRO, T.F. **Levantamento do uso e cobertura da terra e da rede de infraestrutura no distrito florestal da BR-163**. São José dos Campos: [s.n.], 2009. 52 p. Disponível em: <http://www.dpi.inpe.br/arquivos_pime/RPQ_PIME_20090422.pdf>. Acesso em: 25 fev. 2017.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA); INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **TerraClass: Levantamento de informações de uso e cobertura da terra na Amazônia- Sumário Executivo**. São José dos Campos: INPE, 2008. Disponível em: http://www.inpe.br/cra/projetos_pesquisas/sumario_executivo_terraclass_2008.pdf. Acesso em: 25 fev. 2017.
- FERREIRA, M.V.; RIEDEL, P.S.; MARQUES, M.L.; TINÓS, T.M. Comparação entre técnicas de classificação digital de imagens para detecção de mudanças do uso e cobertura da terra. **Revista Brasileira de Cartografia**, n. 62 (4), pp. 613-627, 2010.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Monitoramento da cobertura florestal da Amazônia por satélites – Sistemas PRODES, DETER, DEGRAD e Queimadas 2007-2008**. São José dos Campos:INPE, 2008. 47 p. Disponível em: <http://www.obt.inpe.br/prodes/Relatorio_Prodes2008.pdf>. Acesso em: 08 out. 2017
- LU, D., MAUSEL, P., BATISTELLA, M., MORAN, E. Comparison of land-cover classification methods in the Brazilian Amazon Basin. **Photogrammetric Engineering & Remote Sensing**, v.70, n.6, p. 723-731, 2004.
- LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, n. 5, p.823-870, 2007.
- MARTINS-BEDÊ, F. T.; REIS, M. S.; PANTALEÃO, E.; DUTRA, L. V.; SANDRI, S. A. An application of multiple space nearest neighbor classifier in land cover classification. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, (IGARSS 2014)., 2014, Quebec City. **Proceedings...** 2014. p. 1713-17. DVD. ISBN 9781479957750.
- MCCONNELL, W.; MORAN, E. Meeting in the middle: The challenge of meso-level integration. **LUCC report series**, n. 5. 62p, LUCC:Itália, 2000.
- MELLO, N.A. **Políticas públicas territoriais na Amazônia brasileira: conflitos entre conservação ambiental e desenvolvimento (1970-2000)**. 2002. Tese (Doutorado) - Departamento de Geografia da Universidade de São Paulo, São Paulo, São Paulo, Brasil, 2002. 568p.
- MOREIRA, E. F.; SANTOS, R. L.S.; FRANÇA-ROCHA, W. J. S.; BOSCOLO, D.; PIGOZZO, C. M.. Comparação e desempenho dos algoritmos

- paramétricos na classificação supervisionada de áreas naturalmente heterogêneas e dinâmicas. **Revista Brasileira de Cartografia**, n. 68 (3) Edição Especial Aplicações dos SIG, p.581-594, 2016.
- NEGRI, R.G.; DUTRA, L.V.; FREITAS, C.C.; LU, D.
- Exploring the Capability of ALOS PALSAR L-Band Fully Polarimetric Data for Land Cover Classification in Tropical Environments. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 12, p. 5369-5384, 2016.
- NERY, C.V.M.; FERNANDES, F.H.S.; MOREIRA, A.A.; BRAGA, F.L.B. Avaliação das Técnicas de Classificação MAXVER, MAXVER – ICM e Distância Mínima Euclidiana de acordo com Índice Kappa. **Revista Brasileira de Geografia Física**, v.6, n. 2, p. 11-219, 2013.
- PANTALEÃO, E.; DUTRA, L. V.; SANDRI, S. A. Scenario analysis for image classification using multi-objective optimization. **InfoComp**, v. 11, n. 3, p. 15-22, set.-dez. 2012.
- PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, S. J. S.; LU, D.; MORAN, E. F. Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon. **Giscience & Remote Sensing**, v. 50, n. 3, p. 301-321, 2013.
- PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, S. J. S.; REIS, M.S ALOS/ PALSAR Data Evaluation for Land Use and Land Cover Mapping in the Amazon Region. . **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 12, p. 5413-5423, 2016.
- REIS, M. S. Comparação entre os Classificadores Máxima Verossimilhança, SVM e Rede Neural MLP para Uso e Cobertura da Terra em Parcela da FLONA Tapajós e Arredores. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR), 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 2377-2383. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD).
- REIS, M.S.; DUTRA, L.V.; SANT'ANNA, S.J.S.; ESCADA, M.I.S. Examining Multi-Legend Change Detection in Amazon with Pixel and Region Based Methods. **Remote Sensing**, v.9, n. 1, artigo 77, 2017.
- RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 4. ed. Germany: Springer, 2006. 223 p.
- SCHOWENGERDT, R. **Remote Sensing: Models and methods for image processing**. 3. ed. USA: Academic Press, 2006. 560 p.
- SOUSA, B.F.S.; TEIXEIRA, A.S.; SILVA, F.A.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, edição especial 2, p.385-399, 2010.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 3. ed. San Diego: Academic Press, 2006. 984p.
- WITTEN, I.H.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. ed. São Francisco: Morgan Kaufmann, 2005. 560p.