

Sistema Classificador Parreira: um método de combinação de classificações por pares de classes

Michelle de Oliveira Parreira¹,
Luciano Vieira Dutra¹,
Eliana Pantaleão²,
Sherfis Gibran Ruwer¹,
Dengsheng Lu³

¹Instituto Nacional de Pesquisas Espaciais – INPE, Brasil
12227-010 - São José dos Campos - SP, Brasil
{parreira.michelle, lvdutra}@gmail.com
sherfis@yahoo.com.br

²Universidade Federal de Uberlândia, Centro de Ciências Exatas e Tecnologia,
Faculdade de Ciências da Computação, Brasil
38700103 - Patos de Minas – MG, Brasil
epantaleao@gmail.com

³Michigan State University, Center for Global Change and Earth Observations, EUA
48823 - East Lansing - MI, EUA
ludengsh@msu.edu

Abstract. Traditional procedures for classifying remote sensing images use the concept of competitive classification. It chooses the classification that achieves the best results among the tested metrics. The problem within this procedure is the loss of information for some class when just one classifier is chosen, since each classifier generates different sampling error. This paper presents the first part of the development of a new Classification System, called Parreira. It combines the results of classifiers to analyze the discriminability of class pairs. From an image, a set of classes and their training ROIs, the system generates all possible combinations of classes in pairs. By JM distance, it selects the three attributes that allow greater discriminability between each class pair and performs classification of them. For this paper, just the Maximum Likelihood and Support Vector Machine classifiers were used, in a single hierarchical level. The resulting classification is made by taking classes that were more often identified by the classifier within subsets of class pairs. The class pairs classifications showed better separability when compared to a classification of all classes at the same time. This result shall be studied to prove its validity or if it is due to the inability to correctly classify pixels belonging to classes not involved in pair classification.

Palavras-chave: *remote sensing, image processing, pattern recognition, binary classification, homogeneous classification, sensoriamento remoto, processamento de imagens, reconhecimento de padrões, classificação binária, classificação homogênea.*

1. Introdução

De modo geral, os procedimentos tradicionais de classificação utilizam o conceito de classificação competitiva. Primeiro é selecionado um conjunto de classificadores supervisionados disponíveis. Classificam-se as imagens, utilizando o conjunto de treinamento. Posteriormente, faz-se o uso de métricas de avaliação das imagens classificadas, utilizando o conjunto de validação. Por fim, escolhe-se a classificação que obteve os melhores resultados dentre as métricas avaliadas.

O uso deste procedimento deve-se ao fato de que diferentes classificadores supervisionados geralmente produzem diferentes precisões como resultado para um mesmo conjunto de dados de entrada. O problema em usar classificação competitiva é que optando por apenas um classificador pode-se gerar perda de informação para uma determinada classe, já que classificadores geram erros amostrais diferentes. A utilização

de um único classificador permite usualmente treinar apenas um tipo de característica (atributos/bandas/canais) do dado de entrada.

Na última década vem sendo proposto o uso de combinação de classificadores, que combina as decisões de vários classificadores em apenas um único classificador. Este tipo de classificador resultante é denominado *ensemble* (LEBLANC, 1996; BREIMAN, 2000). Para a construção dos *ensembles* é possível manipular tanto classificadores homogêneos quanto heterogêneos. Utilizar classificadores homogêneos significa usar o mesmo tipo de classificador, ou seja, a mesma técnica de classificação. A combinação neste caso é em nível de dados e características. No nível de dados, pode-se combinar as amostras, enquanto no nível de características pode-se utilizar técnicas de seleção ou extração de atributos. Por sua vez, os classificadores heterogêneos utilizam algoritmos diferentes, mantendo fixos os dados e as características, variando o nível de combinação ou o nível do classificador (KUNCHEVA, 2004).

As tarefas mais comumente utilizadas em classificação supervisionada são: classificação binária, multiclasse e de regressão. A primeira refere-se a duas categorias; a segunda a várias categorias e a última aplica-se quando o valor de saída é um número real. Em um recente trabalho em sensoriamento remoto os autores Pena *et. al.* (2014) abordam essas diferenças de classificações e fazem uso da técnica de combinação de classificação hierárquica, em que no primeiro nível é realizada a classificação binária e no segundo uma classificação multiclasse. Nos dois níveis de classificação o conjunto de dados foi manualmente dividido em pares de classes.

O objetivo deste trabalho é apresentar um Sistema Classificador, denominado Parreira, que foi desenvolvido para aplicar o método de combinação de resultados de classificadores a fim de analisar a discriminabilidade dos pares de classes. Nesta pesquisa foram utilizados dois classificadores, em único nível hierárquico, para conhecer como os dados comportam-se em uma combinação cooperativa por pares de classes de forma automática. Estão sendo utilizados tanto classificadores homogêneos quanto heterogêneos nesta fase de teste. Aplicar combinação de classificadores permitirá que cada classificador trate um tipo de característica. O objetivo da combinação de classificadores é permitir que ao final os resultados sejam combinados melhorando a discriminabilidade e evitando perda de informação de classes.

2. Metodologia

2.1 Área de estudo e dados utilizados

A área de estudo está localizada a Leste da Floresta Nacional de Tapajós (Figura 1a), sendo uma unidade de conservação federal criada pelo Decreto Nº 73.684 – de 19 de fevereiro de 1974, que abrange uma área aproximada de 600 mil hectares, localizados em terras de quatro municípios: Aveiro, Belterra, Rurópolis e Placas, no Oeste do estado brasileiro do Pará (SEMA, 1974). Esta Mesorregião do Baixo Amazonas localizada entre as coordenadas 55°1'51"W 3°22'51"S e 54°42'16"W 2°56'53"S é caracterizada por ter o clima quente e úmido, com predominância de floresta tropical, mais precisamente por floresta ombrófila densa.

Em virtude da grande expansão agrícola mecanizada nas duas últimas décadas, caracterizada principalmente pela produção de soja e outros grãos, como arroz, milho, sorgo e feijão, existem nestas regiões grandes áreas de floresta degradada, principalmente causada por queimadas (VENTURIERI, 2007). Assim, há florestas em diferentes estágios de regeneração, como resultado das modificações antrópicas nas proximidades da rodovia BR-163 (Santarém/Cuiabá).

Utilizou-se uma cena multiespectral LANDSAT/TM 5 (30m) (Figura 1b), bandas 1, 2, 3, 4, 5 e 7, adquirida em 2009. Da área de estudo foram escolhidas quatro classes para

análise, que foram definidas a partir de trabalhos de campo realizados em datas compatíveis com a aquisição da imagem. As descrições e os tipos de classes utilizadas estão apresentadas na Tabela 1. Foram criadas Regiões de Interesse (ROI's) com 9000 pontos de cada classe para o conjunto de treino e 5000 para o conjunto de validação.

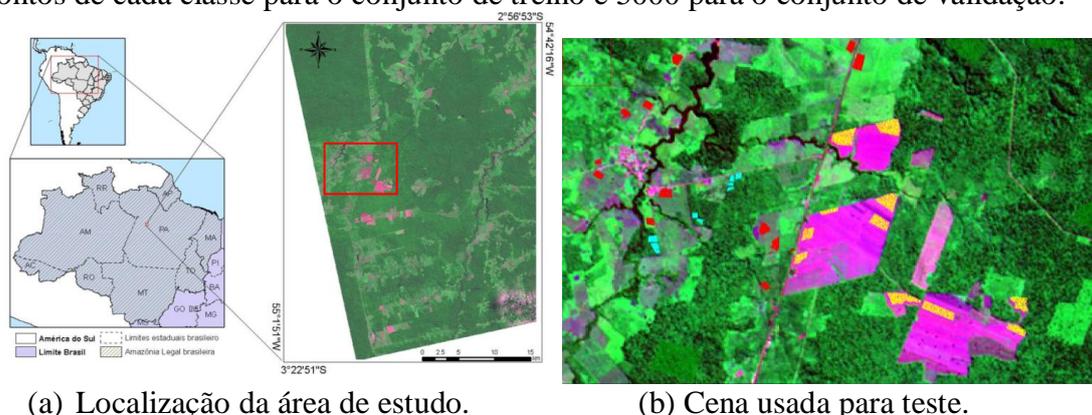


Figura 1 – (a) Composição colorida R3G4B2. A região destacada por um retângulo em vermelho refere-se a (b) cena usada neste trabalho, com apresentação das amostras de treino e validação.

Tabela 1. Classes, descrição e cores utilizadas para classificação.

Classes	Descrição	Cor
Floresta Primária (FP)	Floresta intacta, que não foi modificada pela atividade humana.	Verde
Regeneração Intermediária (RI)	Florestas Secundárias de 8 a 20 anos de reflorestamento.	Ciano
Agricultura Pousio (AP)	Área de culturas agrícolas em pousio.	Amarelo
Pasto Limpo (PL)	Terras usadas para pastagens, pouca presença de árvores, arbustos e espécies invasoras.	Vermelho

2.2 Classificadores Supervisionados Utilizados

Classificação supervisionada é uma atividade preditiva que consiste na generalização de amostras a partir de respostas conhecidas utilizadas para classificar novos exemplos. A partir de um conjunto de treinamento constrói-se um modelo para cada classe baseado nas características dos dados.

As amostras obtidas em trabalho de campo, na região do Amazonas, foram utilizadas como conjunto de treinamento para as classificações supervisionadas por Máxima Verossimilhança (*Maximum Likelihood* - ML) com *Iterated Conditional Modes* (ICM) (contextual) e Máquinas de Vetores Suporte (*Support Vector Machine* - SVM) (pontual).

2.2.1 Máxima Verossimilhança (*Maximum Likelihood* - ML)

A classificação por Máxima Verossimilhança (ML) é uma técnica de classificação supervisionada pontual, sendo uma das mais utilizadas para dados de sensoriamento remoto (RICHARDS, JIA, 2006). No processo de classificação ML é extraído um vetor de atributos e calculada a probabilidade de um pixel r pertencer a cada uma das classes ω_i definidas na fase de treinamento (Equação 1). Em seguida, associam-se os pixels da imagem à classe que apresentar a maior probabilidade de pertencer, obedecendo ao seguinte critério de decisão (RICHARDS, JIA, 2006).

$$r \in \omega_i \text{ se } g_i(r) > g_j(r) \text{ para qualquer } j \neq i \quad (1)$$

Onde, $g_i(r)$ é chamada de função discriminante. Admitindo uma distribuição normal para cada uma das classes, a função discriminante pode ser calculada pela Equação 2.

$$g_i(r) = \ln[p(\omega_i)] - \frac{1}{2} \ln \left| \sum_i i \right| - \frac{1}{2} (r - m_i)^t \sum_i^{-1} (r - m_j) \quad (2)$$

Onde, m_i e \sum^i são vetor média e a matriz de covariância dos dados da classe da classe ω_i ; e $[p(\omega_i)]$ é a probabilidade a priori de x pertencer à classe ω_i .

Para melhorar o resultado da classificação foi utilizada uma combinação dos classificadores ML e *Iterated Conditional Modes* (ICM). O classificador ML-ICM, possui características semelhantes às do classificador ML, porém associa à classificação a informação contextual e espacial da imagem, reprocessando os resultados anteriores (GABOARDI, 2002).

2.2.2 Support Vector Machine (SVM)

O classificador *Support Vector Machine* (SVM) possui boa capacidade de generalização e é independente da distribuição dos dados. Este método consiste em encontrar o hiperplano de separação entre amostras de treinamento que possua maior margem. O hiperplano de separação é uma função dada pela Equação 3 (THEODORIDIS, KOUTROUMBAS, 2008).

$$f(x) = w^T \cdot \phi(x) + b \quad (3)$$

Onde w^T representa o transposto do vetor ortogonal ao hiperplano de separação, $b/\|w\|$ é a distância do hiperplano à origem e $\phi(x)$ é uma função adotada, caso necessário, para remapear os vetores em um novo espaço (THEODORIDIS, KOUTROUMBAS, 2008).

Os parâmetros utilizados no ENVI para o classificador SVM são: Kernel Type: Radial Basic Function; Gamma in Kernel Funcion: 0.5; Penalty Parameter: 100; Pyramid Levels: 0; Classification Probability Threshold: 0.

2.3 Sistema Classificador Parreira (Sistema CP)

A Figura 2 apresenta o método utilizado pelo Sistema Classificador Parreira, que foi desenvolvido na linguagem *Interactive Data Language* (IDL), para combinação de classificações por pares de classes. Inicialmente, o sistema classificador Parreira carrega uma imagem, com B bandas, suas ROI's de treino e N classes. Posteriormente, gera todas as possíveis combinações entre as classes, em pares (w_{ij}) , onde $i, j \in \{1, 2, \dots, N\}$ são os índices das classes, com $i \neq j$. Por exemplo, dado $N = 4$ classes de entrada produz-se $C_{4,2} = 6$ combinações de pares de classes, indicadas por $W = \{w_{12}, w_{13}, w_{14}, w_{23}, w_{24}, w_{34}\}$.

Uma das maneiras de medir a distância entre classes (separabilidade) no espaço de atributos é por distância de Bhattacharyya (DUTRA; HUBER, 1999). Outra medida, a distância Jeffreys-Matusita (JM), é derivada da distância de Bhattacharyya, e mede a diferença entre funções densidade de duas classes (DUTRA; HUBER, 1999). Esta última foi utilizada neste trabalho por apresentar escala com limites finitos. Conforme a Figura 2, para cada par de classes w_{ij} o sistema irá calcular a distância JM entre as classes i, j usando cada subconjunto de três bandas $r, s, t \in \{1, 2, \dots, B\}, r \neq s \neq t$, e então selecionará os três atributos que produzam a maior distância JM. Assim, o conjunto de bandas r, s, t da imagem, que permite maior separabilidade entre as classes i, j , são identificados junto com as classes do par em w_{ij-rst} , atualizando os elementos do conjunto W . Desta forma, selecionam-se atributos pelo modelo de filtro, um processo de escolha do subconjunto de atributos anterior ao processo de aprendizado e que possui como vantagens a independência do classificador além da rapidez de execução.

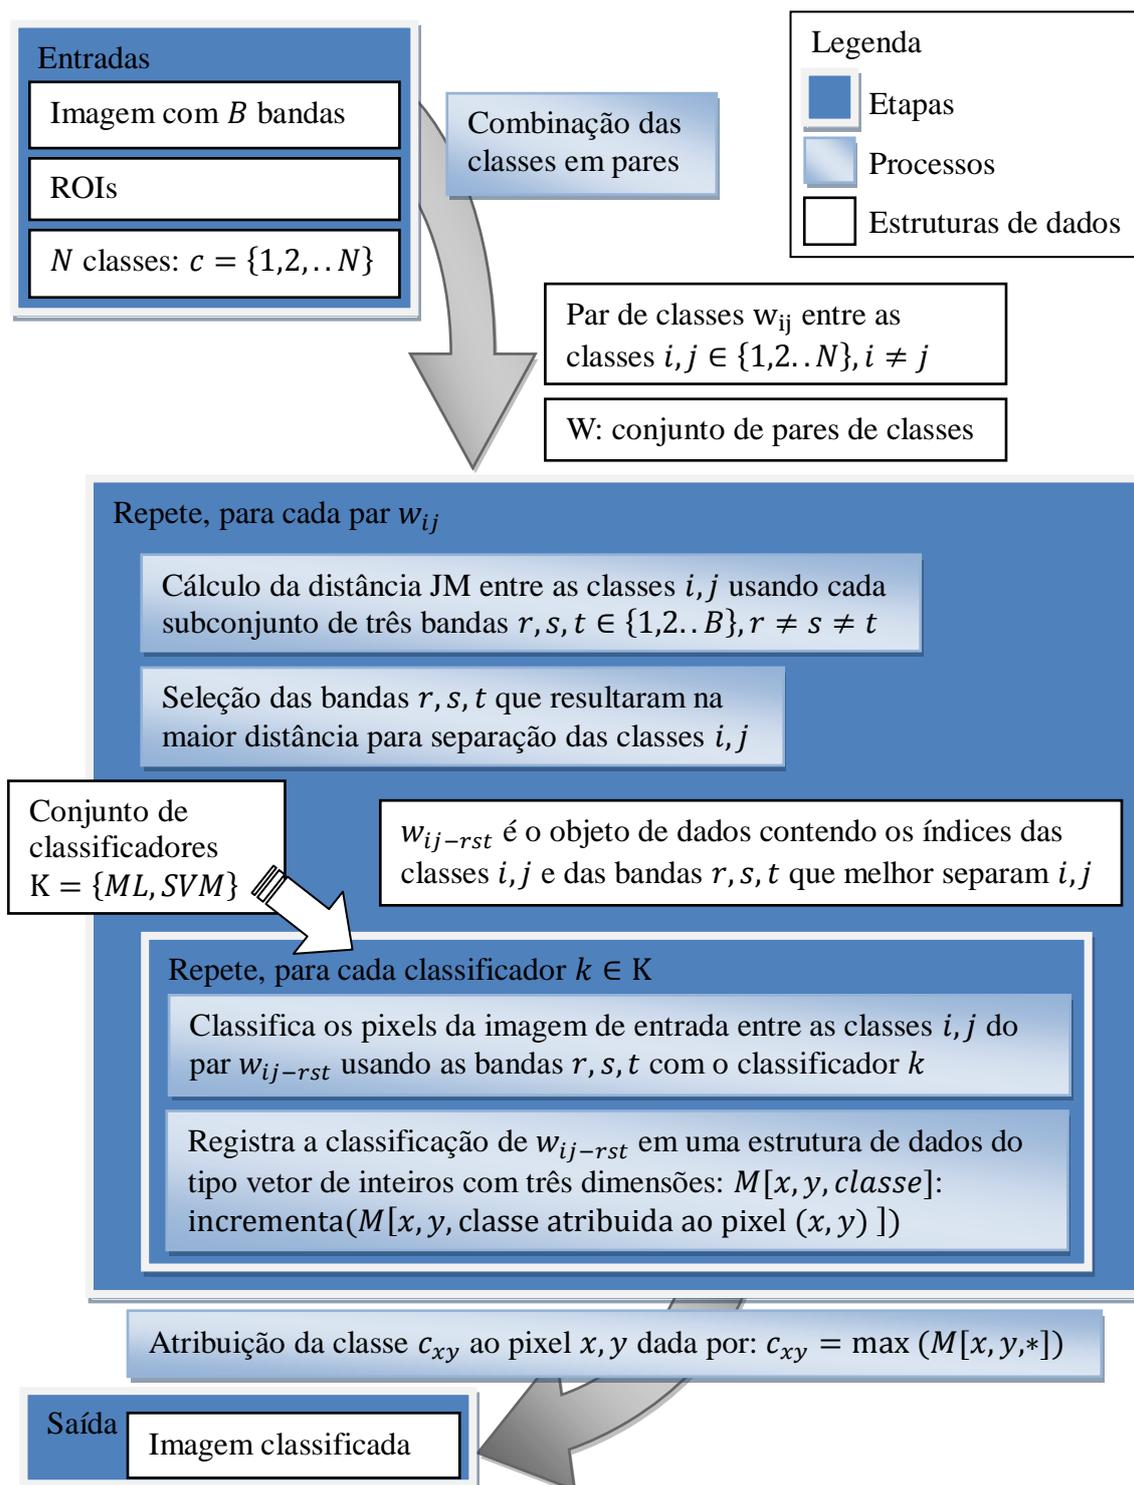


Figura 2. Fluxograma do Sistema Classificador Parreira.

O processo seguinte é a execução dos classificadores sobre os pares de classes. Dado um conjunto de L classificadores, $K = \{k_1, k_2, \dots, k_L\}$, o qual neste trabalho foi utilizado $K = \{ML, SVM\}$, o processo de classificação é executado por cada $k \in K$ sobre cada par de classes $w_{ij-rst} \in W$, utilizando apenas as bandas r, s, t para reduzir tempo computacional, resultando em $R = C_{N,2} \cdot L$ **classificações por pares de classes**. Esses resultados são o foco principal de estudo, avaliação e conclusões apresentadas a seguir. Cada resultado de classificação é registrado em uma estrutura de dados do tipo

vetor de inteiros com três dimensões: $M[\#x, \#y, N]$, em que $\#x$ e $\#y$ são respectivamente a largura e a altura da imagem em número de pixels e N o número de classes de entrada. Esse registro é feito incrementando o inteiro correspondente à classe atribuída pelo classificador k ao pixel localizado em (x, y) , conforme a seguinte instrução: $\text{incrementa}(M[x, y, \text{classe atribuída ao pixel } (x, y)])$.

A classificação final é construída a partir dos resultados das classificações por pares de classes armazenadas em M . Cada pixel (x, y) da imagem de entrada é classificado como da classe c dada por: $c_{xy} = \max(M[x, y, *])$, em que $[*]$ indica todos os elementos da respectiva dimensão do vetor. Como resultado é apresentada uma imagem classificada composta pelas classes c_{xy} de atribuída a cada pixel.

3. Resultados

As Figuras 3.a, 3.b, 3.c, 3.d, 3.e e 3.f apresentam respectivamente as classificações de cada par de classes: PL-AP, PL-RI, PL-FP, RI-AP, AP-FP, RI-FP. Para cada figura é apresentado o resultado da classificação por ML (lado esquerdo) e SVM (lado direito), atributos/canais selecionados, taxa de acerto e acurácia global apresentados pela matriz de confusão, além do índice *kappa*. Nota-se que os canais mais comumente utilizados nas classificações foram os canais 2, 3, 4 e 5.

Na Figura 3.a, classificação entre PL-AP, a classe PL apresenta uma taxa de acerto de **97,62%** utilizando o classificador ML, enquanto para o classificador SVM o valor foi de 94,32%. Já para a classe AP o melhor acerto está para SVM com **97,18%** contra 95,34% do ML. Na Figura 3.b, classificação entre PL-RI, a classe PL apresenta uma taxa de acerto de **99,64%** utilizando o classificador ML, enquanto para o classificador SVM o valor foi de 99,56%. Já para a classe RI o melhor acerto está para SVM com **98,54%** contra 96,76% do ML. Na Figura 3.c, classificação entre PL-FP, a classe PL apresenta uma taxa de acerto de **100%** utilizando o classificador ML, enquanto para o classificador SVM o valor foi de 99,92%. Já para a classe FP, tanto SVM quanto ML tiveram a mesma taxa, **100%**. Na Figura 3.d, classificação entre RI-AP, a classe RI apresenta uma taxa de acerto de 97,84% utilizando o classificador ML, enquanto para o classificador SVM o valor foi de **98,14%**. Já para a classe AP o melhor acerto está para SVM com **100%** contra 99,58% do ML. Na Figura 3.e, classificação entre AP-FP, a classe AP apresenta uma taxa de acerto de **98,50%** utilizando o classificador SVM, enquanto para o classificador ML o valor foi de 98,16%. Já para a classe FP, tanto SVM quanto ML tiveram a mesma taxa, **100%**. Na Figura 3.f, classificação entre RI-FP, a classe RI apresenta uma taxa de acerto de **78,88%** utilizando o classificador SVM, enquanto para o classificador ML o valor foi de 71,58%. Já para a classe FP o melhor acerto está para ML com **63,62%** contra 58,74% do SVM.

As classes PL e AP possuem boa discriminabilidade quando comparadas com quaisquer outras classes analisadas. Essas duas classes apresentaram taxas de acerto acima de 90% para as amostras de validação. Para AP e RI o melhor classificador foi SVM, enquanto para PL foi ML. Todos os pares em que FP ou RI foram combinados com PL ou AP, a classificação do par obteve 100% de acerto. Porém, a classificação do par FP-RI produz grande confusão e, portanto, baixa discriminabilidade. A consequência desta confusão é a baixa acurácia resultante no processo global de classificação, tanto nos métodos convencionais do software ENVI como no Sistema Classificador Parreira, como pode ser visualizada na Figura 4. A classe PL obtém melhor resultado com o Sistema CP utilizando o classificador ML (**97,26%**). A classe AP utilizando o software Envi-SVM (**98,10%**). RI com o Sistema CP-SVM (**77,42%**) e FP com Envi-ML (**72,56%**). Como melhor classificação final, utilizando todas as classes, o resultado foi com Envi-SVM (**84,15%**).

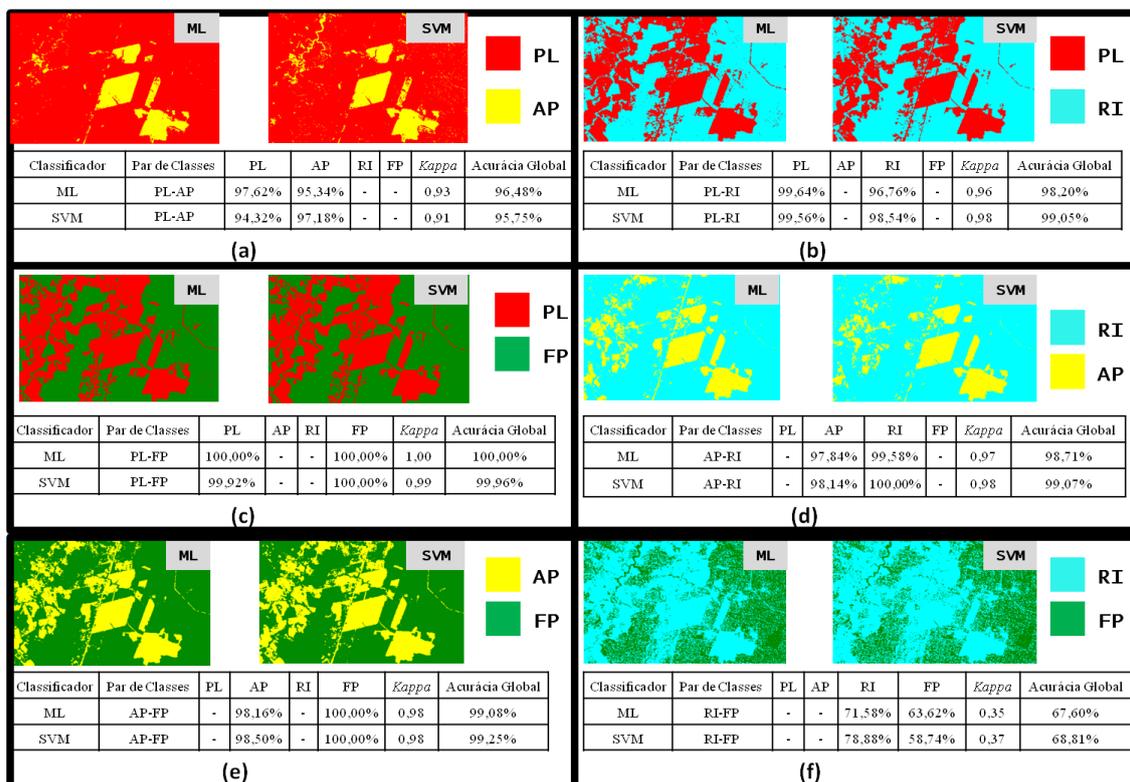


Figura 3 – Classificações por par de classes (canais). Sistema CP: a) PL e AP (3/4/7). b) PL-RI (2/3/5). c) PL-FP (2/3/5). d) RI-AP (2/4/5). e) AP-FP (2/4/5). f) RI-FP (2/4/5).

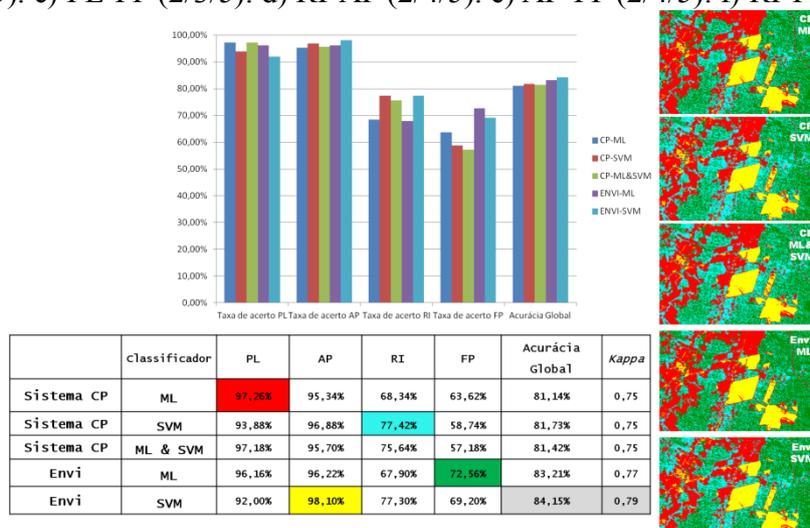


Figura 4. Resultados das classificações realizadas.

4. Conclusões

Nota-se que as classes PL e AP tiveram bons resultados em todas as vezes que estiveram presentes no par de classes classificado, inclusive todos os valores foram melhores que do método tradicional. Porém quando ocorre a junção dos mapas de classificação no Sistema Classificador Parreira, o resultado da classificação final é pior que todas as contribuições das classificações onde a classe aparece.

Percebe-se que cada classificação por par de classes apresenta um melhor resultado de separabilidade em relação a uma classificação com todas as classes ao mesmo tempo. Porém, ainda está sendo estudado se este resultado é efetivamente válido ou representa a impossibilidade de classificar corretamente os pixels pertencentes às classes não envolvidas no par da classificação.

Um aspecto que deverá contribuir para eficácia global do Classificador Parreira são alternativas de junções dos mapas de classificações por par de classes. Entretanto, avaliando que os resultados globais permeiam os menores valores de acurácia das classificações por pares de classes, a melhor estratégia para a continuidade do desenvolvimento é a criação de um algoritmo que foque na classificação do par de classes com pior resultado. Assim, o estudo mostrou não uma melhor alternativa para classificação geral da imagem, mas a determinação dos elementos que necessitam de atenção para que o resultado geral da classificação seja melhorado.

Agradecimentos

Os autores agradecem aos órgãos financiadores CAPES e CNPq.

Referências Bibliográficas

Breiman, L. **Some In_nity Theory for Predictor Ensemble**. University of California: Berkeley, 2000.

Dutra, L. V.; Huber, R. Feature extraction and selection for ers 1/2 insar classification. **Int. J. Remote Sensing**, v. 20, n. 5, p. 993-1016, 1999.

Fujisawa, H. The maximum likelihood estimators in a multivariate normal distribution with ar(1) covariance structure for monotone data. **Ann. Inst. Statist. Math.**, v. 48, n. 3, p. 423-428, 1996.

Gaboardi, C. **Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós**. 2002. 139 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São Jose dos Campos, 2002.

Kuncheva, L. I. **Combining Pattern Classifiers: Methods and Algorithms**. [S.l.]: Wiley-Interscience, 2004.

Leblanc, M.; Tibshirani, R. Combining estimates in regression and classification. **Journal of the American Statistical Association**, v. 91, n. 436, p. 1641, 1996.

Pena, J. M.; Gutierrez, P. A.; *et al.* Object-Based Image Classification of Summer Crops with Machine Learning Methods. **Int. J. Remote Sensing**, n. 6, p. 5019-5041, 2014.

Richards, J. A.; Jia, X. **Remote sensing digital image analysis: an introduction**. Berlin: Springer-Verlag, 2006.

Secretaria de Estado de Meio Ambiente (SEMA). Decreto n. 73.684 - **Decreto de criação da FLONA do Tapajós** - 19/02/1974. 1974. Disponível em: <http://www.sema.pa.gov.br/interna.php?idconteudocoluna=2018&idcoluna=9&titulo_onteudocoluna=73684>. Acesso em: Dezembro de 2011.

Theodoridis, S.; Koutroumbas, K. **Pattern Recognition**. [S.l.]: Academic Press, 2008.

Venturieri, A. Zoneamento ecológico-econômico da área de influência da rodovia BR-163 (Cuiabá-Santarém): diagnóstico do meio socioeconômico, jurídico e arqueologia. **Embrapa Amazônia Oriental**, p. 229-252, 2007.