

# Estimação de controladores de influência das classes em classificadores estatísticos multidimensionais

Orlando Alves Máximo<sup>1,2</sup>  
David Fernandes<sup>2</sup>

<sup>1</sup> Instituto de Estudos Avançados – IEAv/CTA  
Rod Tamoios km 5,5 – 12228-001 – São José dos Campos – SP, Brasil  
oamaximo@ieav.cta.br

<sup>2</sup> Instituto Tecnológico de Aeronáutica – ITA/CTA  
Praça Marechal Eduardo Gomes, 50 – 12228-900 – São José dos Campos - SP, Brasil  
{oamaximo, david}@ita.br

**Abstract.** The Bayesian statistical approach is a well known technique used in computer based image classification, and the Maximum Likelihood Classifier (ML) is one of the most present in literature. The structure of the ML Classifier is such that, in a multidimensional approach, every image used in the classification process has the same effect or contribution, regardless its intrinsic quality. This paper extends the concept of image influence controller in the Modified Global Membership Function (MGMF) to classes reliability factors in order to use class influence controllers instead a single image reliability factor. The classifier that uses the class influence controller was called Class Global Membership Function (CGMF). It is also proposed and evaluated some estimators for the classes reliability factors based on the variance of the classes, the Conditional Kappa coefficient, the Partial Kappa and the Partial Overall Accuracy. Six sets of two SAR (original, and 3x3, 5x5, 7x7, 9x9, 11x11 kernel filtered) images are used to evaluate the estimators and the classification process that take into account the classes' reliability factors. The accuracy was measured using the Kappa Coefficient and the Overall Accuracy. The accuracy of CGMF Classifier was compared with the ML Classifier using a Z Statistic. The results shown that the classes' influence controllers can impact positively in the image classification process, and achieve better results than the ML classifier in general.

**Keywords:** Bayesian classification, image processing, classes influence controllers classificação Bayesiana, processamento de imagens, controladores de influência de classes.

## 1. Introdução

O interesse da comunidade científica internacional no desenvolvimento de técnicas de análise de imagens de sensoriamento remoto tem crescido bastante nas últimas décadas. Contribuiu para isso o caráter interdisciplinar inerente às imagens de sensoriamento remoto, o que as torna atraentes para utilização em várias aplicações tais como: cartografia, hidrologia, planejamento urbano, agricultura, prevenção e monitoramento de catástrofes, preservação e recuperação do meio-ambiente, vigilância territorial e operações de reconhecimento em missões militares. Para uma exploração mais efetiva do potencial destas imagens, uma das técnicas mais utilizadas é a classificação, que consiste em atribuir a cada pixel da imagem uma classe, dentro de um determinado conjunto de classes pré-estabelecido. Dentre as ferramentas matemáticas utilizadas nos processos de classificação, podemos destacar: Teoria das Probabilidades; Lógica Nebulosa e Redes Neurais. A Teoria das Probabilidades, na qual os dados de entrada são modelados num espaço de probabilidades que fornece uma base para medição de incertezas, é uma das mais utilizadas. A classificação, então, é realizada pela minimização dessas incertezas. Neste contexto, a abordagem Bayesiana fornece uma sólida base para a construção de classificadores e para a minimização de erros, mesmo quando o problema de classificação envolve a definição de densidades de probabilidades multidimensionais. Nestas situações, entretanto, os classificadores construídos assumem o pressuposto de que todas as dimensões (ou, simplesmente, as imagens) exercem a mesma influência no resultado final da classificação, independentemente da qualidade das mesmas. Se uma das imagens apresentar características

de baixa qualidade, não há como isolar ou mesmo diminuir a sua influência no processo de classificação e uma perda de precisão é esperada.

Uma maneira de ponderar a influência das diferentes imagens consiste em introduzir “controladores de influência” para cada imagem utilizada na classificação. Exemplos desta abordagem são: a Combinação Linear de Opiniões - LOP (STONE, 1961), a Combinação Logarítmica de Opiniões - LOGP (GENEST, 1984) e a Função de Adesão Modificada - MGMF (BENEDIKTSSON; SWAIN; ERSOY, 1990). O objetivo dos controladores de influência é expressar quantitativamente o grau de participação que cada imagem deve ter no processo de classificação. Desta forma, a influência das imagens consideradas mais relevantes é realçada e a influência das imagens consideradas menos relevantes é minimizada, com o intuito de melhorar o resultado final da classificação (MÁXIMO; FERNANDES, 2002).

Este trabalho tem por objetivo apresentar uma extensão do conceito de controladores de influência das imagens para controladores de influência das classes presentes nas mesmas (MÁXIMO; FERNANDES, 2003). Além disso, são apresentadas propostas para estimadores dos controladores de influência das classes e o resultado do seu uso é comparado com o resultado do Classificador em Cascata, que não incorpora o conceito de controladores de influência em sua estrutura.

## 2. Controladores de influência das imagens

O processo de classificação consiste em atribuir a cada pixel da imagem uma classe, dentro de um determinado conjunto de classes pré-estabelecido. Considerando um conjunto de  $N$  observações independentes, cada uma fornece uma medida  $x^{(n)}$ , com  $n = 1, 2, \dots, N$  para um determinado pixel de interesse. Seja  $W = \{w_1, w_2, \dots, w_M\}$  o conjunto pré-definido de classes dentro do qual os pixels deverão ser classificados.

Partindo destas premissas, Lee, Richards e Swain (1987) estabeleceram a Função de Adesão Global (GMF), que associa um vetor de observações  $\check{x} = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$ , a uma classe  $w_m$ , como sendo  $F_m^\circ(\check{x})$ , sendo necessário definir explicitamente esta função.

Ainda sem a introdução dos controladores de influência, uma escolha para a modelagem do relacionamento entre as medições e o conjunto de classes estabelecido é a abordagem Bayesiana. Assim, para observações independentes, a GMF pode ser modelada como:

$$F_m^\circ(\check{x}) = p(w_m)^{1-N} \prod_{n=1}^N p(w_m|x^{(n)}). \quad (1)$$

onde  $p(w_m)$  é a probabilidade *a priori* da classe  $w_m$  e  $p(w_m|\check{x})$  é a probabilidade *a posteriori*.

Uma outra forma de se alocar os controladores de influência foi proposta por Benediktsson e Swain (1989), que analisaram a influência de cada observação isoladamente dentro da GMF. Para isso, calcularam a razão entre a Função de Adesão para as observações  $\{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$  e  $\{x^{(1)}, x^{(2)}, \dots, x^{(N+1)}\}$ , obtendo a influência da observação adicional, dada por:

$$\frac{F_m^\circ(x^{(1)}, x^{(2)}, \dots, x^{(N+1)})}{F_m^\circ(x^{(1)}, x^{(2)}, \dots, x^{(N)})} = \frac{p(w_m)^{-N} \prod_{n=1}^{N+1} p(w_m|x^{(n)})}{p(w_m)^{1-N} \prod_{n=1}^N p(w_m|x^{(n)})} = \frac{p(w_m|x^{(N+1)})}{p(w_m)}. \quad (2)$$

Deste modo:

$$F_m^\circ(x^{(1)}, x^{(2)}, \dots, x^{(N+1)}) = F_m^\circ(x^{(1)}, x^{(2)}, \dots, x^{(N)}) \frac{p(w_m|x^{(N+1)})}{p(w_m)}, \quad (3)$$

e  $p(w_m|x^{(N+1)})/p(w_m)$  representa a contribuição da observação  $X^{(N+1)}$  na Função de Adesão.

A GMF pode então ser reescrita de modo a salientar a influência de cada observação na Função de Adesão da seguinte forma:

$$F_m^\circ(x^{(1)}, x^{(2)}, \dots, x^{(N)}) = p(w_m) \prod_{n=1}^N \frac{p(w_m|x^{(n)})}{p(w_m)}. \quad (4)$$

Assim, para controlar a influência de cada observação dentro do processo de classificação, os controladores de influência  $\alpha_n$  são definidos como expoentes das contribuições individuais de cada observação, criando a Função de Adesão Modificada (*Modified Global Membership Function* - MGMF),  $F_m^*(\check{x})$ , que é dada por:

$$F_m^*(\check{x}) = p(w_m) \prod_{n=1}^N \left[ \frac{p(w_m|x^{(n)})}{p(w_m)} \right]^{\alpha_n}, \quad (5)$$

Desta forma, se uma fonte é totalmente não-confiável, seu controlador de influência é zero ( $\alpha_n = 0$ ) e ela não terá nenhuma influência no resultado final da classificação, independentemente do valor de  $p(w_m|x^{(n)})$ . No extremo oposto, caso a fonte seja totalmente confiável, seu controlador de influência será 1 ( $\alpha_n = 1$ ) e sua influência no resultado final da classificação será totalmente preservada.

A regra de decisão para a alocação de uma classe ao pixel com vetor de atributos  $\check{x}$  fica:

$$\check{x} \in w_m \Leftrightarrow F_m^*(\check{x}) = \max_k F_k^*(\check{x}). \quad (6)$$

A Função de Adesão Modificada (MGMF), definida em (5), pode ser escrita em função da probabilidade condicional  $p_X(x^{(n)}|w_m)$  como:

$$F_k^*(\check{x}) = p(w_m) \prod_{n=1}^N \left[ \frac{p_X(x^{(n)}|w_m)}{p_X(x^{(n)})} \right]^{\alpha_n} \quad (7)$$

Num processo de classificação, como  $\prod p_X(x^{(n)})^{-\alpha_n}$  é comum a todas as classes, não tem influência no processo. A Função de Adesão Modificada, reescrita em função de  $p_X(x^{(n)}|w_m)$  fica:

$$F_m^\star(\check{x}) = p(w_m) \prod_{n=1}^N p_X(x^{(n)}|w_m)^{\alpha_n} \quad (8)$$

E a regra de decisão:

$$\check{x} \in w_m \Leftrightarrow F_m^\star(\check{x}) = \max_k F_k^\star(\check{x}). \quad (9)$$

### 3. Controladores de Influência Aplicados às Classes

Os controladores de influência, tal como apresentado na Seção 2, atuam nas observações utilizadas no processo de classificação e afetam do mesmo modo todas as classes presentes nestas observações. O conceito de controladores de influência para as imagens pode ser estendido definindo-se um controlador de influência específico para cada classe em cada imagem.

Assim, incorporando o controlador de influência das classes, a MGMF, definida pela Equação (5), passa a ser definida, Função de Adesão Global para as Classes (CGMF), que

pode ser reescrita como:

$$F_m^{*c}(\check{x}) = p(w_m) \prod_{n=1}^N \left[ \frac{p(w_m | x^{(n)})}{p(w_m)} \right]^{\alpha_{nm}} \quad (10)$$

onde  $\alpha_{nm}$  é o controlador de influência da classe  $m$  presente na observação  $n$ .

A regra de decisão fica:

$$\check{x} \in w_m \Leftrightarrow F_m^{*c}(\check{x}) = \max_k F_k^{*c}(\check{x}). \quad (11)$$

$F_m^{*c}(\check{x})$  em função das probabilidades condicionais  $p_X(x^{(n)} | w_m)$  é expressa como:

$$F_m^{\star c}(\check{x}) = p(w_m) \prod_{n=1}^N \left[ \frac{p_X(x^{(n)} | w_m)}{p_X(x^{(n)})} \right]^{\alpha_{nm}} \quad (12)$$

E a regra de decisão fica:

$$\check{x} \in w_m \Leftrightarrow F_m^{\star c}(\check{x}) = \max_k F_k^{\star c}(\check{x}). \quad (13)$$

#### 4. Estimação dos controladores de influência das classes presentes nas imagens

Uma vez que a estrutura do classificador que incorpora em sua estrutura os controladores de influência das classes presentes nas imagens está definida, resta agora definir como estimar os valores destes controladores. O ponto central desta estimação consiste em quantificar a influência que uma determinada classe deve ter no processo de classificação com o intuito de aumentar a precisão do processo como um todo.

##### 4.1. Variância da Classe

Baseando-se no fato de que quanto menor a variância, maior a homogeneidade de uma classe, o que leva a se esperar uma maior precisão na modelagem da mesma, podemos utilizar estas variâncias para determinar os controladores de influência de cada uma delas, através de uma relação inversa de proporcionalidade:

$$\alpha_i^{(n)} = \beta \frac{1}{\sigma_{w_i}^2} \quad (14)$$

onde a constante arbitrária  $\beta$  foi definida como  $\beta = 0,9 \min_k \sigma_{w_k}^2$ , sendo  $w_k^{(n)}$  a classe  $k$  presente na  $n$ -ésima observação.

##### 4.2. Precisoões Marginais ou Parciais

Uma das formas mais comuns de se avaliar a precisão de um processo de classificação assistida por computador é o cálculo de índices a partir da matriz de erro. Alguns destes índices mais utilizados são a Precisão Global e o Coeficiente Kappa, definidos respectivamente por:

$$PG(\mathbf{E}_n) = \frac{1}{e_{++}} \sum_{i=1}^{M_n} e_{ii} \quad (15)$$

$$\hat{k}(\mathbf{E}_n) = \frac{e_{++} \sum_{i=1}^{M_n} e_{ii} - \sum_{i=1}^{M_n} (e_{i+} e_{+i})}{e_{++}^2 - \sum_{i=1}^{M_n} (e_{i+} e_{+i})} \quad (16)$$

onde  $M_n$  é o número de classes na  $n$ -ésima observação e  $\mathbf{E}_n$  é a matriz de erro da imagem  $n$  com elementos  $e_{ij}$ ;  $e_{i+}$  corresponde ao somatório na linha  $i$  e  $e_{+i}$  corresponde ao somatório na coluna  $i$ .

A partir da matriz de erro também podem ser obtidos índices marginais que avaliam a conformidade de cada uma das classes presentes na imagem com o conjunto de classes de referência. Um destes índices é o Coeficiente Kappa Condicional, que é derivado da estrutura do Coeficiente Kappa. O estimador de máxima verossimilhança para o Kappa Condicional referente à classe  $w_i^{(n)}$ , com  $i = 1, 2, \dots, M_n$ , é dado por (CONGALTON; GREEN, 1999):

$$\hat{k}_i(\mathbf{E}_n | w_i^{(n)}) = \left( \frac{e_{ii}}{e_{i+}} - \frac{e_{+i}}{e_{++}} \right) \frac{e_{++}}{e_{++} - e_{+i}} \quad (17)$$

A participação de cada classe na composição do Coeficiente Kappa (denominado Kappa Parcial), pode ser obtida decompondo-se a expressão (16) de tal modo que:

$$\hat{k}_i^p(\mathbf{E}_n | w_i^{(n)}) = \frac{e_{++} e_{ii} - (e_{i+} e_{+i})}{e_{++}^2 - (e_{i+} e_{+i})} \quad (18)$$

O mesmo ocorre com a Precisão Global, onde a participação de cada classe na composição do índice geral pode ser obtida por:

$$PG_i^p(\mathbf{E}_n | w_i^{(n)}) = \frac{e_{ii}}{e_{++}} \quad (19)$$

Estes três índices de precisão podem ser utilizados para estimar os controladores de influência de cada classe no processo de classificação.

## 5. Descrição do experimento e Resultados

Para a avaliação do desempenho dos estimadores propostos na Seção 4, foi conduzido um experimento utilizando duas imagens do sensor SAR-580, com 512x512 pixels, nas Bandas X e L. A verdade terrestre foi obtida utilizando analistas de imagens, mapas e informação contextual. Foram definidas quatro classes de referência: Floresta, Área Cultivada, Resto de Cultura e Solo Exposto. Além do conjunto de imagens originais, foram utilizados mais cinco conjuntos de imagens filtradas com filtro da média com janelas 3x3, 5x5, 7x7, 9x9 e 11x11.

As classes de referência foram modeladas com uma função densidade de probabilidade gaussiana e os controladores de influência das classes foram calculados a partir das Equações (14); (17); (18) e (19). Estes índices utilizaram a matriz de erro obtida pela aplicação do Classificador MaxVer em cada imagem individualmente. A Tabela 1 apresenta os valores obtidos com cada estimador, para os conjuntos de imagens originais e filtrados com filtro da média e janelas de filtragem 3x3 e 5x5.

Foram implementados os Classificadores CGMF utilizando todos os conjuntos de imagens e os controladores de influência definidos na Seção 4. Para avaliar o desempenho dos classificadores foram calculados o Coeficiente Kappa e a Precisão Global para cada processo de classificação.

O desempenho dos Classificadores CGMF foi comparado com o desempenho do

Tabela 1: Controladores de influência das classes presentes nas imagens

Variância das Classes						
Classe	Imagem Original		Janela 3x3		Janela 5x5	
	Banda X	Banda L	Banda X	Banda L	Banda X	Banda L
Floresta	0,108	0,151	0,108	0,155	0,108	0,156
Área Cultivada	0,090	0,260	0,106	0,257	0,135	0,267
Resto de Cultura	0,182	0,425	0,198	0,407	0,212	0,381
Solo Exposto	0,900	0,900	0,900	0,900	0,900	0,900
Kappa Condicional						
Classe	Imagem Original		Janela 3x3		Janela 5x5	
	Banda X	Banda L	Banda X	Banda L	Banda X	Banda L
Floresta	0,237	0,686	0,406	0,784	0,271	0,851
Área Cultivada	0,084	0,082	0,066	0,052	0,115	0,108
Resto de Cultura	0,098	0,039	0,082	0,100	0,131	0,297
Solo Exposto	0,297	0,192	0,427	0,433	0,756	0,556
Kappa Parcial						
Classe	Imagem Original		Janela 3x3		Janela 5x5	
	Banda X	Banda L	Banda X	Banda L	Banda X	Banda L
Floresta	0,008	0,526	0,050	0,663	0,053	0,811
Área Cultivada	0,054	0,062	0,054	0,056	0,099	0,124
Resto de Cultura	0,139	0,035	0,178	0,100	0,260	0,276
Solo Exposto	0,515	0,376	0,697	0,550	0,861	0,601
Precisão Global Parcial						
Classe	Imagem Original		Janela 3x3		Janela 5x5	
	Banda X	Banda L	Banda X	Banda L	Banda X	Banda L
Floresta	0,032	0,855	0,116	1,034	0,179	1,214
Área Cultivada	0,074	0,074	0,074	0,084	0,116	0,137
Resto de Cultura	0,412	0,179	0,517	0,253	0,591	0,369
Solo Exposto	0,897	0,718	0,918	0,707	0,971	0,697

Classificador MaxVer em cada conjunto de imagens. Para esta comparação foi utilizado o teste de significância:

$$Z = \frac{C_1 - C_2}{\sqrt{\sigma_1^2 + \sigma_2^2}} \quad (20)$$

onde  $C_1$  representa o Coeficiente Kappa ou a Precisão Global do Classificador MaxVer;  $C_2$  representa o Coeficiente Kappa ou a Precisão Global do Classificador CGMF.  $\sigma_1^2$  e  $\sigma_2^2$  representam suas variâncias.

A Tabela 2 apresenta os resultados obtidos para o Coeficiente Kappa e a Tabela 3 apresenta os resultados obtidos para a Precisão Global. Nestas tabelas, “probabilidade de  $Z > 0$ ” representa a probabilidade da Precisão Global ou do Coeficiente Kappa do Classificador CGMF ser maior que a Precisão Global ou o Coeficiente Kappa do Classificador MaxVer. O índice do Classificador CGMF indica o estimador do controlador de influência das classes:  $KC$ , para o Kappa Condicional;  $KP$ , para o Kappa Parcial;  $GP$ , para a Precisão Global Parcial e  $MV$ , para a variância das classes.

Medindo-se o desempenho pela Precisão Global, os Classificadores CGMF obtiveram melhores resultados que o Classificador MaxVer, apresentando probabilidades de melhor resultado acima de 50% em todos os conjuntos de imagens exceto para o conjunto de imagens filtradas com filtro de janela 11x11. Os melhores resultados foram obtidos com os conjuntos de imagens filtrados com filtro da média de janelas 3x3 e 5x5. Destaque para o Classificador CGMF $_{KP}$ , que obteve probabilidade de melhora de 98,4% no conjunto de imagens filtradas com janela 3x3. Outro destaque é o desempenho do Classificador CGMF $_{MV}$ , que obteve uma probabilidade de melhora de 94,8% para o conjunto de imagens originais.

De maneira geral, o comportamento se mantém quando medimos o desempenho pelo Coeficiente Kappa, porém com uma diminuição nas probabilidades de melhora. Destaque novamente para o Classificador CGMF $_{KP}$ , que apresentou probabilidade de melhora de 94,6%

Tabela 2: Classificação comparativa entre os Classificadores CGMF e o Classificador MaxVer. Desempenho medido pela Precisão Global.

Precisão Global					
	MaxVer	CGMF <sub>KC</sub>	CGMF <sub>KP</sub>	CGMF <sub>GP</sub>	CGMF <sub>MV</sub>
Imagem Original	0,559	0,580	0,607	0,596	0,617
Janela 3x3	0,699	0,755	0,768	0,734	0,747
Janela 5x5	0,792	0,815	0,828	0,823	0,815
Janela 7x7	0,839	0,847	0,852	0,855	0,858
Janela 9x9	0,871	0,879	0,873	0,870	0,881
Janela 11x11	0,889	0,881	0,881	0,881	0,897
Probabilidade de $Z > 0$					
		CGMF <sub>KC</sub>	CGMF <sub>KP</sub>	CGMF <sub>GP</sub>	CGMF <sub>MV</sub>
Imagem Original		0,721	0,908	0,849	0,948
Janela 3x3		0,957	0,984	0,853	0,928
Janela 5x5		0,795	0,903	0,866	0,795
Janela 7x7		0,618	0,692	0,728	0,761
Janela 9x9		0,629	0,543	0,629	0,670
Janela 11x11		0,366	0,366	0,366	0,639

Tabela 3: Classificação comparativa entre os Classificadores CGMF e o Classificador MaxVer. Desempenho medido pelo Coeficiente Kappa.

Coeficiente Kappa					
	MaxVer	CGMF <sub>KC</sub>	CGMF <sub>KP</sub>	CGMF <sub>GP</sub>	CGMF <sub>MV</sub>
Imagem Original	0,370	0,371	0,404	0,393	0,381
Janela 3x3	0,565	0,617	0,638	0,595	0,604
Janela 5x5	0,694	0,712	0,733	0,727	0,708
Janela 7x7	0,761	0,763	0,772	0,778	0,777
Janela 9x9	0,807	0,813	0,806	0,815	0,816
Janela 11x11	0,832	0,818	0,819	0,820	0,841
Probabilidade de $Z > 0$					
		CGMF <sub>KC</sub>	CGMF <sub>KP</sub>	CGMF <sub>GP</sub>	CGMF <sub>MV</sub>
Imagem Original		0,505	0,771	0,686	0,596
Janela 3x3		0,874	0,946	0,744	0,796
Janela 5x5		0,668	0,830	0,791	0,630
Janela 7x7		0,525	0,616	0,675	0,661
Janela 9x9		0,571	0,491	0,587	0,600
Janela 11x11		0,343	0,354	0,360	0,605

no conjunto de imagens filtradas com janela 3x3.

A Figura 1 apresenta as imagens originais e alguns resultados do processo de classificação.

## 6. Conclusão

O uso de controladores de influência para as classes presentes nas imagens pode impactar positivamente o desempenho de classificadores multidimensionais. Pode ser observada uma melhoria de desempenho em relação ao Classificador MaxVer em todos os conjuntos de imagens estudados, com exceção do conjunto filtrado com o filtro da média com janela 11x11, utilizando tanto o Coeficiente Kappa quanto a Precisão Global para estimar a precisão do processo de classificação.

## Referências

BENEDIKTSSON, J. A.; SWAIN, P. H. A method of statistical multisource classification with a mechanism to weight the influence of the data sources. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM - IGARSS89. *Proceedings...* Vancouver: IEEE, 1989. p. 517–520. (CD-ROM).

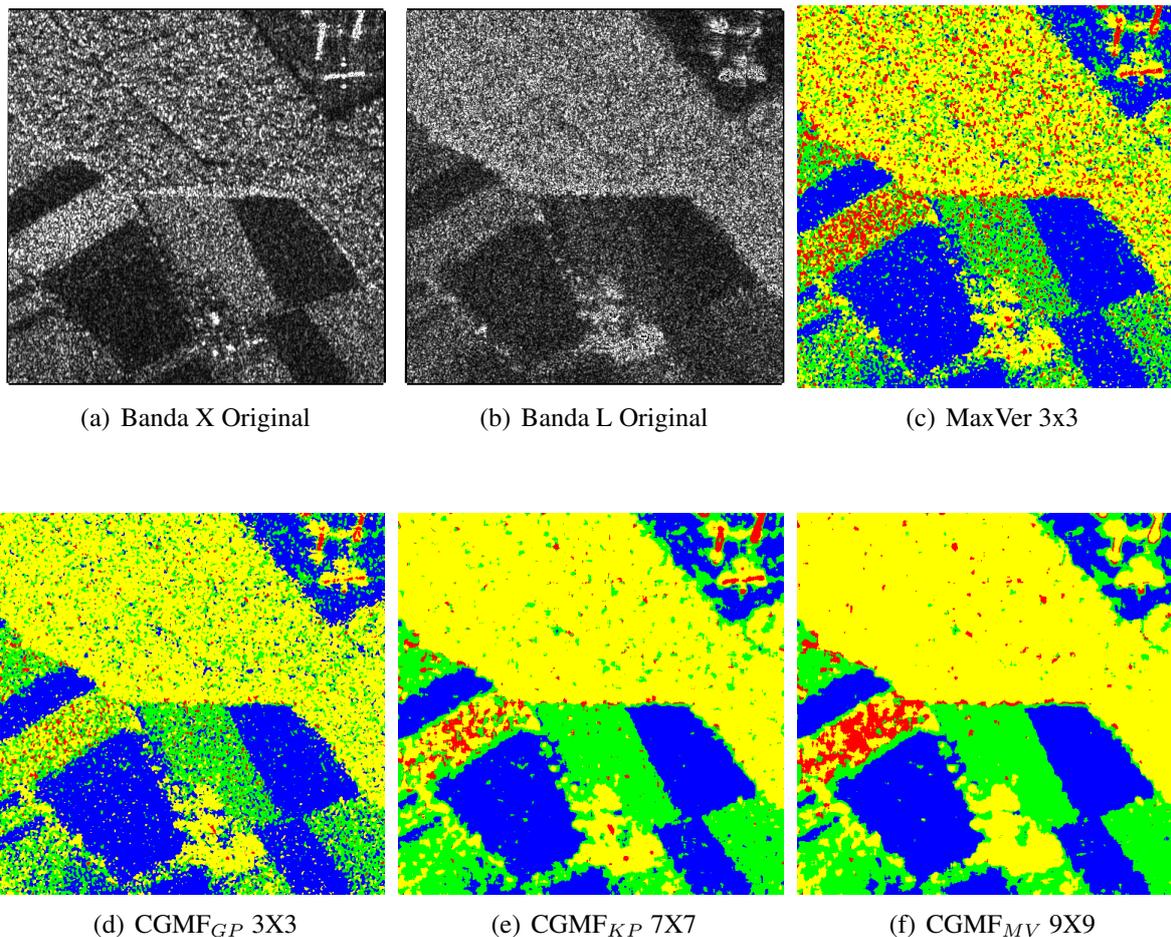


Figura 1: Imagens originais e classificadas com diversos estimadores e filtros

BENEDIKTSSON, J. A.; SWAIN, P. H.; ERSOY, O. K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. *IEEE Transactions on Geoscience and remote sensing*, v. 28, n. 4, p. 540–552, july 1990.

CONGALTON, R.; GREEN, K. *Assessing the accuracy of remotely sensed data: principles and practices*. Boca Raton: Lewis Publishers, 1999. 137 p.

GENEST, C. A. A characterization theorem for externally bayesian groups. *The annals of statistics*, v. 12, n. 3, p. 1100–1105, 1984.

LEE, T.; RICHARDS, J.; SWAIN, P. H. Probabilistic and evidential approaches for multisource data analysis. *IEEE Transactions on Geoscience and remote sensing*, GE-25, n. 3, p. 283–293, may 1987.

MÁXIMO, O. A.; FERNANDES, D. The use of data set reliability factors in a multidimensional bayesian classifier. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. *Proceedings...* Toronto: IEEE, 2002. 1CD.

MÁXIMO, O. A.; FERNANDES, D. Uso de graus de confiança das classes em classificadores bayesianos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO. *Anais ...* Belo Horizonte: INPE, 2003. p. 2083–2090. 1CD.

STONE, M. The opinion pool. *Annals of mathematical statistics*, v. 32, p. 1339–1342, 1961.