

Multi-class Segmentation of Satellite Images by Color Mixture and Neural Network

Diego Rafael Moraes and Adilson Gonzaga

Department of Electrical and Computer Engineering

University of São Paulo

São Carlos, Brazil

diego.moraes@usp.br and agonzaga@sc.usp.br

Abstract—The Misturograma-RNA is a recent technique for color image segmentation, based on Color Mixture and Artificial Neural Network, which has been applied only for binary classification. This paper proposes to investigate if this technique can be used for multiclass problems, as well as for any color images. In this paper, we applied this approach for satellite image segmentation, due to be a hard task for segmentation methods and also to the great applicability in rural and urban areas. The goal of this paper was to segment four classes from satellite images: tree, soil, street and water. We also have generated a satellite image database, extracted from Google Earth from 10 cities of different countries, in 4 different scales (500m, 1000m, 1500m and 2000m). Our results show that the Misturograma-RNA is a multiclass classifier technique and surpassed two other classical literature classifiers, the SVM and ANN, reaching over 93% of sensitivity.

Keywords—color image segmentation; multiclass image.

I. INTRODUÇÃO

A segmentação de imagens coloridas é um desafio na Visão Computacional, pois existem menos técnicas na literatura do que as relativas ao processamento em nível de cinza. Entretanto, imagens coloridas possuem mais informações do que imagens em nível de cinza, permitindo investigar novas relações entre os canais de cores.

O Misturograma [1] é uma técnica que se mostrou eficiente para a segmentação de imagens coloridas. Utilizou, para isto, duas combinações: a primeira foi a mistura de cores, semelhante à decomposição das camadas de tintas em telas artísticas; a segunda foi uma ponderação na sua equação, fazendo uma analogia com a retina humana, que possui uma variação na quantidade dos seus cones. O resultado dessa combinação foi um método de quantização de cores em 256 planos ao longo do cubo RGB, adicionado de um classificador gaussiano para a segmentação em nível dos pixels.

Porém, uma limitação do Misturograma é ser apropriado para distinguir amostras de apenas duas classes, ou, mais precisamente, dizer se um pixel é ou não pertencente à classe treinada. Foi estatisticamente superior na segmentação de pele humana frente a outras metodologias [2-5].

Baseado no Misturograma, tanto no seu potencial quanto na sua limitação, foi proposta uma alteração do seu classificador gaussiano por um classificador neural do tipo Perceptron Multi Camadas (PMC), originando, assim, o Misturograma-RNA [6].

Esta nova proposta, também aplicada em imagens de pele humana, mostrou-se mais eficiente na segmentação e classificação do que o uso individual do Misturograma e da Rede Neural Artificial (RNA).

Neste trabalho, o objetivo é investigar se o Misturograma-RNA pode ser utilizado para a segmentação de imagens coloridas de mais de uma classe, ou seja, se pode ser utilizado como classificador multiclasse. Por se tratar de um classificador neural, tem-se a premissa da possibilidade de se prototipar a RNA com mais de uma classe.

Para investigar esta premissa, foram realizados testes em imagens de satélites, devido a sua aplicabilidade no auxílio à resolução de problemas em diversas áreas, sendo um dos seus principais focos o mapeamento geográfico, que busca a localização de objetos específicos em áreas urbanas e rurais.

Nas áreas urbanas, o foco é a identificação de objetos como casas e prédios [7-9], ruas e estradas [10-12] etc. Segundo [13], utilizando-se imagens de satélites, é possível realizar diversas tarefas, como o estudo e planejamento do crescimento urbano, gestão de desastres, vigilância e segurança, sensoriamento remoto, aplicações militares etc.

Em áreas rurais, as aplicações são direcionadas para o monitoramento na agricultura [14], no crescimento de plantações [15], na detecção de pragas, no desmatamento ilegal, no monitoramento de rios, entre outros.

Segundo [16], novos estudos têm sido realizados para a previsão de catástrofes ecológicas, atividades agrícolas, poluição marítima, mudança climática, vigilância em geral, mapeamento das zonas de desastre, planejamento de logística e definição de vias de acesso para as operações de socorro, etc.

Este trabalho concentra-se em imagens coloridas de alta resolução no espectro visível, extraídas do Google Earth, pois são facilmente adquiridas e não possuem custo devido à disponibilidade da nova geração de sensores, tais como: *IKONOS*, *EROS*, *OrbView*, *QuickBird*, *SPOT5*, *WorldView*, *GeoEye*, *Pleiades*, tornando-se essenciais para a detecção automática de objetos geoespaciais [7].

Como objetivo de segmentação, foram escolhidas 4 classes: árvores, solos (gramados e terra), ruas e água (rios e lagos). A maior dificuldade é a complicada diferenciação entre regiões de árvores e solo, principalmente em gramados, dificultando,

assim, o processo de análise das imagens tanto manualmente, a olho nu, como automaticamente, de forma computacional.

Para a realização dos testes, por não ter sido encontrado disponível um banco de imagens de satélite com as classes desejadas, foi construído um banco de dados de imagens reais extraídas do Google Earth, de diferentes localidades do planeta e diversas escalas em relação à altura da aquisição da imagem.

O foco do trabalho não é desenvolver uma técnica para aplicações exclusivamente de satélites, pois, nestes casos, depende muito de cada problema a ser resolvido, tipo de imagem (quantidade de bandas, ruídos), diferentes técnicas etc. As técnicas variam conforme a especialidade e afinidade de cada autor, incluindo, mas não se limitando, a abordagens de cor, forma, texturas, sistemas inteligentes, entropia etc.

Sendo assim, como o objetivo é investigar o desempenho do Misturograma-RNA em aplicações multiclases, os resultados foram comparados com outros dois classificadores consagrados da literatura, uma Rede Neural Artificial (RNA) do tipo Perceptron Multi-Camadas (PMC) e uma Máquina de Vetor Suporte (SVM).

II. METODOLOGIA

Todas as implementações, simulações, testes e análises estatísticas utilizaram a plataforma MATLAB. A Fig. 1 exibe um diagrama das etapas realizadas para o desenvolvimento deste trabalho.




Fig. 1. Sequência das etapas deste trabalho.

A. Construção e disponibilização do banco de dados de imagens de satélite

Este banco de dados foi criado para auxiliar futuras pesquisas com imagens de satélite em visão computacional ou áreas afins. É composto por 120 imagens coloridas de alta resolução no espectro visível, extraídas pela ferramenta do Google Earth, de 10 cidades de diferentes países, a saber: Berlim (Alemanha), Buenos Aires (Argentina), Foz do Iguaçu (Brasil), London (Canadá), Hong Kong (China), Londres (Inglaterra), Veneza (Itália), Varsóvia (Polônia), Nova Iorque (Estados Unidos) e Distrito de Colúmbia (Estados Unidos).

Esta diversificação de lugares é proposital, pois tem-se como premissa que imagens adquiridas de forma bem controlada (mesma região geográfica e mesmo satélite) têm maiores probabilidades de encontrar um padrão e/ou correlação entre as cores e textura das imagens. Portanto, pretende-se investigar a correlação em diferentes regiões geográficas, capturadas por diferentes satélites, o que influencia diretamente a variação da cor e textura das imagens.

Para cada cidade, foram escolhidos 3 pontos para realizar a captura da imagem. Para cada ponto, foram extraídas 4 imagens com altitude variável (500m, 1000m, 1500m e 2000m), permitindo, assim, realizar futuros testes com escalas diferentes.

Cada imagem possui, obrigatoriamente, no mínimo as 4 classes utilizadas neste trabalho (árvore, solo, rua e água), com dimensão de 1280x580 pixels e salvas no formato TIFF, para não sofrerem nenhum tipo de compressão. Um exemplo de imagem é exibido na Fig. 2.



Fig. 2. Imagem extraída de Berlim (Alemanha) com zoom de 500m.

Para cada imagem, será gerada manualmente uma imagem de referência (*ground truth*), com auxílio de um editor de imagens, atribuindo-se cores diferentes para cada classe e preto para o restante. A Fig. 3 exibe um exemplo deste *ground truth*.




Fig. 3. Imagem *ground truth*: árvore (verde), solo (amarelo), rua (vermelho) e água (azul); em preto são objetos que não são de interesse.

Para todas as imagens adquiridas, foram extraídas regiões de cada classe, com tamanhos variados por meio de recortes manuais, organizadas também pela escala. A Fig. 4 mostra alguns exemplos dessas amostras.




Fig. 4. Amostras na escala de 500m: a) árvore; b) solo; c) rua; d) água.

Para a criação do banco, seguiu-se um protocolo, padronizando-se, assim, desde a aquisição das imagens até a nomenclatura dos arquivos e pastas. Para cada imagem, foi criado um registro com diversas informações, sendo elas: nome da cidade e do país, latitude e longitude (em graus), escala (resolução: pixels/metro), nome do satélite e data de aquisição.

Todos os marcadores utilizados na ferramenta do *Google Earth* foram salvos e estão disponíveis para acesso junto ao banco. A estrutura final do banco pode ser observada na Fig. 5.




Fig. 5. Estrutura de pastas do banco de dados.

O banco está disponível para download em <http://imagem.sel.eesc.usp.br/base/Satellite/Satellite.zip>.

A Tabela I exhibe a quantidade de amostras (pixels individuais), disponíveis para cada classe (Árvore, Solo, Água e Rua), de acordo com a altura que a imagem foi capturada (zoom: 500m, 1000m, 1500m e 2000m).

TABELA I. QUANTIDADE DE PIXELS POR ZOOM E POR CLASSE.

	Árvore	Solo	Água	Asfalto
500m	381.993	467.656	1.304.376	134.659
1000m	179.225	195.032	394.886	53.070
1500m	164.013	120.418	229.808	32.731
2000m	136.597	101.676	162.229	29.005

Na Tabela I, é contabilizado um total de 2.288.684 de amostras (pixels) para o zoom de 500m, 822.213 para 1000m, 546.970 para 1500m e 429.507 para 2000m. Uma observação importante é que, ao variar a altura de aquisição das imagens, quanto mais distante é a altura, menores são os objetos, e isto dificulta a seleção dos pixels correspondentes a cada classe, pois, a olho nu, os objetos ficam tão pequenos que geram dúvidas a qual classe pertencem.

B. Uso do banco de imagens de satélite neste trabalho

As amostras foram agrupadas por zoom, formando, assim, quatro grupos, cada um referente a uma altura de aquisição da imagem. O total de amostras por zoom pode ser encontrado na primeira coluna da Tabela II, identificada como 100%.

TABELA II. QUANTIDADE TOTAL DE AMOSTRAS (PIXELS) POR ZOOM.

	100%	70% Treino	15% Teste	15% Validação
500m	2.288.684	1.602.079	343.303	343.303
1000m	822.213	575.549	123.332	123.332
1500m	546.970	382.879	82.046	82.046
2000m	429.507	300.655	64.426	64.426

Para os experimentos deste trabalho, cada conjunto de 100% foi dividido em 3 novos conjuntos, também apresentados na Tabela II. Um conjunto chamado Treino, com 70% das amostras disponíveis, com a finalidade dessas amostras serem apresentadas no processo de treinamento dos métodos. O conjunto chamado Teste possui 15% das amostras que restaram após serem selecionadas as 70% de Treino, ou seja, essas amostras de teste não fizeram parte do treinamento. Isto permitiu uma análise mais confiável estatisticamente, pois avaliou se realmente os métodos treinados generalizaram o seu conhecimento, sendo capazes de resolver problemas semelhantes.

Por fim, o conjunto chamado Validação, com o restante das amostras que não foram utilizadas no Treino e no Teste, ou seja, os últimos 15% das amostras totais. Este grupo é utilizado por técnicas de RNA, funcionando como critério de parada do treinamento caso o erro comece a subir consecutivamente. Para o SVM, este conjunto de Validação foi somado ao conjunto de Treino, pois, assim como auxiliam o processo de treinamento das RNA's, seria injusto não auxiliarem também o SVM.

Ainda analisando a Tabela II, mesmo considerando o menor quantitativo disponível, ou seja, o grupo do zoom de 2000m, que possui 429.507 amostras, este número mostrou-se suficiente para realizar análises estatísticas confiáveis.

Com o total de amostras, foram realizados quatro experimentos quantitativos (um para cada zoom disponível). Para cada experimento, foram testados os três métodos: uma rede neural do tipo PMC, que foi chamada de RNA-PMC; um classificador SVM, e, por fim a proposta de investigação deste trabalho, o Misturograma-RNA.

Uma das dificuldades do trabalho é a classificação dessas amostras, pois, espacialmente, estão muito próximas, mesmo sendo de classes diferentes. A Fig. 6 exhibe a distribuição das amostras com zoom de 500m das quatro classes no cubo RGB.




Fig. 6. Distribuição das amostras com zoom de 500m no cubo RGB. Árvore (verde), solo (amarelo), rua (vermelho) e água (azul).

Analisando-se a Fig. 6, observa-se que as amostras de classes diferentes estão realmente muito próximas umas das outras – em alguns casos, até misturadas e/ou sobrepostas.

Uma das vantagens do Misturograma-RNA frente aos demais classificadores é que, antes de classificar, as amostras são quantizadas em planos, e isto objetiva separar as amostras de classes diferentes que estavam muito próximas no espaço.

C. Misturograma-RNA

O Misturograma-RNA é dividido em duas fases: a primeira fase é responsável pela quantização em planos; a segunda é responsável pela classificação.

Para quantizar em planos, considera-se os valores RGB do pixel em análise, e isso é realizado pela equação 1.

$$m = \frac{4R+2G+B}{7} \quad (1)$$

que retorna um valor de “m” entre 0 e 255, indicando, assim, a qual dos 256 planos aquele pixel em análise deve ser projetado. Um exemplo pode ser visto na Fig. 7.




Fig. 7. Exemplo de uma amostra de Árvore sendo projetada em um plano.

Após todas as amostras disponíveis serem quantizadas, é aplicado uma rede neural em cada um dos planos. Esta é a diferença da proposta do Misturograma-RNA frente ao Misturograma, pois neste é utilizado um único classificador gaussiano ao longo de todo o cubo RGB que contém todas as amostras (Fig. 6).

Na proposta do Misturograma-RNA, aplica-se um classificador neural para cada um dos planos. Isto torna a tarefa de classificação mais eficiente, pois não existe mais o universo todo de amostras para serem classificadas, e sim uma menor região, concentrada em cada plano, conforme pode ser visto na Fig. 8.




Fig. 8. Interseção do plano $m=78$ com as amostras (500m) no cubo RGB. Árvore (verde), solo (amarelo), rua (vermelho) e água (azul).

Para cada um dos 256 planos, foi proposta uma RNA com arquitetura do tipo PMC e aprendizado supervisionado. Cada rede recebe 3 sinais de entrada, sendo, respectivamente, os canais do espaço de cor RGB normalizados e presentes em cada plano. Como saída, foi utilizado o método *One of C-Class*, que consiste em associar cada neurônio da camada de saída diretamente a uma classe – portanto, 4 neurônios.

Como função de ativação, para a camada escondida foi utilizada a função Logística, e, para a camada de saída, a função Linear. Os pesos sinápticos e os limiares de ativação

foram iniciados aleatoriamente com valores entre 0 e 1. Para o treinamento, foi utilizado o algoritmo Backpropagation de Levenberg-Marquardt. O valor para a taxa de aprendizagem foi definido como 0,5, e a precisão requerida foi de 10^{-6} .

Os detalhes da implementação das rotinas de validação cruzada, referentes à escolha da melhor topologia (quantidade de neurônios) de cada rede neural, podem ser encontrados no trabalho original do Misturograma-RNA [6].

D. SVM (Support Vector Machine)

O kernel do classificador SVM foi configurado com uma função de base radial gaussiana, com sigma igual a 1,0. Esta escolha foi embasada em dois fatos: a disposição espacial das amostras não é linearmente separável, como mostra a Fig. 6, e também para investigar o comportamento de um algoritmo de agrupamento das amostras.

E. RNA-PMC (Rede Neural Artificial do tipo PMC)

Para justificar a aplicação de uma rede para cada plano (Misturograma-RNA), foi implementada uma RNA do tipo PMC (RNA-PMC), com as mesmas especificações detalhadas na sessão II-C, mas, com todas as amostras independentes dos planos, ou seja, apenas um classificador neural para todo o cubo RGB.

III. RESULTADOS

Para todas as simulações, independente da metodologia ou zoom, foi calculada e armazenada a matriz de confusão, assim, é possível realizar diversas análises estatísticas.

Baseado nas matrizes de confusão, foi calculada a Sensibilidade de cada classificador, de acordo com cada zoom e cada metodologia. Os resultados são exibidos na Tabela III.

TABELA III. SENSIBILIDADE DE CADA METODOLOGIA PARA CADA ZOOM.

Zoom	Método	Sensibilidade %
500m	Misturograma-RNA	93,69
	SVM	89,82
	RNA-PMC	87,20
1000m	Misturograma-RNA	90,77
	SVM	87,96
	RNA-PMC	85,25
1500m	Misturograma-RNA	91,38
	SVM	88,37
	RNA-PMC	84,94
2000m	Misturograma-RNA	92,60
	SVM	88,72
	RNA-PMC	85,83

A Tabela III mostra por zoom, que o Misturograma-RNA foi mais eficiente do que os outros dois métodos para qualquer altura de aquisição da imagem de satélite, ficando em segundo lugar o SVM, e, por fim, a RNA-PMC.

O Misturograma-RNA atingiu sensibilidade de 93,69% para o zoom de 500m, superando em 4% o SVM e 6% a RNA-PMC. Seu pior desempenho foi no zoom de 1000m, alcançando 90,77%, e, assim, foi superior em 3% ao SVM e 5% comparativamente à RNA-PMC. Mesmo considerando os outros zooms, 1500m e 2000m, o Misturograma-RNA sempre supera os outros métodos, seguido do SVM, e, por fim, da RNA-PMC.

Para visualizar melhor o comportamento de todos os métodos ao se variar a altura de aquisição das imagens, foi gerado o gráfico exibido na Fig. 9.




Fig. 9. Representação gráfica das sensibilidades em cada zoom e método.

Observa-se, na Fig. 9, que, para qualquer zoom, o Misturograma-RNA é mais eficiente, seguido do SVM, e, por fim, da RNA-PMC. A Tabela IV exibe os resultados do cálculo da média de Sensibilidade de todos os zooms para cada método.

TABELA IV. SENSIBILIDADE MÉDIA DE CADA METODOLOGIA.

Método	Sensibilidade Média %
Misturograma-RNA	92,11
SVM	88,72
RNA-PMC	85,81

O Misturograma-RNA superou as demais metodologias, alcançando mais de 92% de sensibilidade, valor este considerado expressivo quando considerada a diversidade das amostras de satélite.

Porém, para saber se realmente se o Misturograma-RNA pode ser considerado um método eficiente para problemas multiclasse, objetivo inicial deste trabalho, faz-se necessário uma análise na matriz de confusão. Para isto, foi selecionada a pior taxa de Sensibilidade, encontrada no zoom de 1000m, onde o Misturograma-RNA alcançou o valor de 90,77%. A Tabela V apresenta esta matriz de confusão.

TABELA V. MATRIZ DE CONFUSÃO: MISTUROGRAMA-RNA PARA 1000M.

MISTUROGRAMA-RNA		Entrada				FPR Falsa Aceitação
		Árvore	Solo	Rua	Água	
Saída	Árvore	21298	2313	265	1209	0,0376
	Solo	3174	25604	641	245	0,0415
	Rua	171	1106	7054	41	0,0113
	Água	1738	456	20	57999	0,0335
FNR Falsa Rejeição		0,1927	0,1314	0,116	0,0251	Sensibilidade=0,9077

A diagonal principal da Tabela V mostra que o número de pixels de cada classe de entrada classificados corretamente em sua correspondente classe de saída é expressivo. Mas, assim como esperado, houve maior confusão entre as classes de árvore e solo, tanto por amostras de árvores que foram classificadas erroneamente como solos, quanto como de solos que foram confundidos com árvores.

Uma surpresa foi a confusão entre as amostras de árvore e água, representando praticamente a metade da confusão entre árvores com solos. Isto aconteceu pois, nas imagens originais, as regiões de água (rios e lagos), quando adquiridas por

satélites, acabam ficando de certa forma “esverdeadas”, e não azuis e/ou transparentes como se esperava, exemplo visto na Fig. 4d.

Outra confusão bastante constante foi entre ruas e solos, que pode ser justificada pelo fato de que nas imagens do banco, quase sempre ao lado de uma rua existia um gramado ou canteiro, correspondente ao solo.

Estas confusões elevaram o número de Falsa Rejeição (razão de uma classe não classificada como ela mesma) a valores de 20% para árvore, 13% para solo e 11% para ruas.

Para finalizar os resultados, foram contabilizados os tempos dos treinamentos de todas as simulações, sendo utilizado, para isto, um mesmo computador, com processador Core i7 de 2.5 GHz, 24 GB memória RAM e sistema operacional Ubuntu de 64-bits. A Tabela VI mostra os tempos computados.

TABELA VI. TEMPO APROXIMADO DE CADA METODOLOGIA POR ZOOM.

Zoom	Método	Tempo ~
500m	Misturograma-RNA	47 horas
	SVM	15 horas
	RNA-PMC	92 dias
1000m	Misturograma-RNA	53 horas
	SVM	9 horas
	RNA-PMC	125 horas
1500m	Misturograma-RNA	45 horas
	SVM	4 horas
	RNA-PMC	193 horas
2000m	Misturograma-RNA	127 horas
	SVM	8 horas
	RNA-PMC	98 horas

Na Tabela VI, pode ser visto que, para qualquer zoom, o SVM mostra-se mais rápido do que os demais métodos. Isto é porque os classificadores neurais exigem a descoberta da melhor topologia (quantidade de neurônios), executando rotinas de validação cruzada.

No entanto, o Misturograma-RNA foi mais rápido que a RNA-PMC, principalmente para um maior número de amostras, que é o caso do zoom de 500m. A justificativa é que, apesar do Misturograma ter que ajustar a topologia de 256 redes neurais, uma para cada plano que foi quantizado, a quantidade de amostras por plano é muito menor do que se considerado o cubo RGB.

Em contrapartida, a RNA-PMC, por não fazer a quantização, se sobrecarrega no processo de treinamento, pois precisa ajustar seus pesos para atender as mais de 1,6 milhão de amostras de treinamento para o zoom de 500m, que levou para isto, 92 dias de treinamento, valor muito superior às 47 horas consumidas pelo Misturograma-RNA.

IV. CONCLUSÃO

Neste trabalho, foi avaliada a aplicação da técnica denominada de Misturograma-RNA, publicada anteriormente para classificação binária de imagens coloridas e especificamente para pixels de pele humana, como um segmentador multiclasse em imagens de satélite.

A classificação deste tipo de pixel de imagem tem aplicabilidade em áreas urbanas e rurais, com o objetivo de segmentar quatro classes: árvore, solo, rua e água.

Neste trabalho, foi criado e disponibilizado um banco de dados de imagens de satélites, imagens estas extraídas do Google Earth, de 10 cidades de diferentes países, sendo armazenadas 3 imagens para cada uma das cidades, e cada imagem foram adquiridas em 4 escalas diferentes (500m, 1000m, 1500m e 2000m), totalizando, assim, 120 imagens.

O resultado da classificação dos pixels com o Misturograma-RNA foi comparado com os resultados de outros dois métodos, um classificador SVM e uma RNA do tipo PMC, pois são utilizados em diversas aplicações, com excelentes resultados.

Analisando os resultados estatisticamente, para os quatro experimentos realizados, um para cada zoom, o Misturograma-RNA foi mais eficiente na Sensibilidade que os outros dois métodos. Superou, em média, o SVM em mais de 3% e a RNA-PMC em mais de 6%, alcançando valor máximo de 93,69% para o zoom de 500m e valor mínimo de 90,77% para 1000m.

Baseado nos resultados obtidos, conclui-se que o método do Misturograma-RNA pode ser utilizado para segmentação de imagens coloridas multiclasse, assim como para quaisquer outras aplicações multiclasse com imagens coloridas.

Como trabalho futuro, o objetivo é investigar se o Misturograma-RNA é invariante a escala. Esta hipótese é sustentada se considerarmos que não houve alterações significativas no comportamento da Sensibilidade ao se variar o zoom.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da FAPESP, processo #2015/20812-5, para a realização deste trabalho.

REFERENCES

- [1] O. Severino and A. Gonzaga, "A new approach for color image segmentation based on color mixture," *Machine Vision and Applications*, vol. 24, no. 3, pp. 607–618, 2013.
- [2] P. Peer and F. Solina, "An automatic human face detection method," in *4th Computer Vision Winter Workshop*, 1999, pp. 122–130.
- [3] D. Forsyth and M. Fleck, "Automatic detection of human nudes," *International Journal of Computer Vision*, vol. 32, no. 1, pp. 63–77, 1999.
- [4] J. Brand and J. S. Mason, "A comparative assessment of three approaches to pixel-level human skin-detection," in *Pattern Recognition, 2000. Proceedings. 15th International Conference on*, vol. 1, 2000, pp. 1056–1059.
- [5] N. Bourbakis, P. Kakumanu, S. Makrogiannis, R. Bryll, and S. Panchanathan, "Neural network approach for image chromatic adaptation for skin color detection," *International Journal of Neural Systems*, vol. 17, no. 01, pp. 1–12, 2007.
- [6] D. R. Moraes, J. P. B. Casati and A. Gonzaga, "Human skin segmentation based on Color Mixture and Artificial Neural Networks," in *XII Workshop de Visão Computacional*, 2016.
- [7] J. Wang et al., "An efficient approach for automatic rectangular building extraction from very high resolution optical satellite imagery," *IEEE Geoscience and Remote Sensing Letters*, v. 12, n. 3, p. 487–491, March 2015.
- [8] M. Wang, S. Yuan and J. Pan, "Building detection in high resolution satellite urban image using segmentation, corner detection combined with adaptive windowed Hough Transform," in *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2013, Melbourne. Proceedings... Melbourne: IEEE, p. 508–511, 2013.
- [9] S. Freire et al., "Introducing mapping standards in the quality assessment of buildings extracted from very high resolution satellite imagery," *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 90, p. 1–9, April 2014.
- [10] L. Abraham and M. Sasikumar, "A fuzzy based road network extraction from degraded satellite images," in *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2013, Mysore. Proceedings... Mysore: IEEE, 2013, p. 2032–2036, 2013.
- [11] O. Besbes and A. Benazza-Benyahia, "Joint road network extraction from a set of high resolution satellite images," in *22ND European Signal Processing Conference (EUSIPCO)*, 2014, Lisbon. Proceedings... Lisbon: IEEE, p. 2190–2194, 2014.
- [12] R. Gaetano et al., "Morphological road segmentation in urban areas from high resolution satellite images," in *17TH International Conference On Digital Signal Processing (DSP)*, 2011, Corfu. Proceedings... Corfu: IEEE, p. 1–8, 2011.
- [13] H. Iftikhar and K. Khurshid, "Fusion of Gabor filter and morphological operators for the detection of settlement zones in Google Earth satellite images," in *IEEE International Conference On Signal And Image Processing Applications (ICSIPA)*, 2011, Kuala Lumpur. Proceedings... Kuala Lumpur: IEEE, p. 232–237, 2011.
- [14] S. Jamali et al., "Detecting changes in vegetation trends using time series segmentation," *Remote Sensing of Environment*, v. 156, p. 182–195, January 2015.
- [15] S. Aksoy, I. Z. Yalniz and K. Tasdemir, "Automatic detection and segmentation of orchards using very high resolution imagery," *IEEE Transactions on Geoscience and Remote Sensing*, v. 50, n. 8, p. 3117–3131, August 2012.
- [16] A. L. Barbieri et al., "An entropy-based approach to automatic image segmentation of satellite images," *Physica A: Statistical Mechanics and its Applications*, v. 390, n. 3, p. 512–518, 2011.