

Classificação por *Pixels* de Imagens de Sensoriamento Remoto empregando Redes Neurais Sem Peso WiSARD

Luneque Silva Junior

Universidade Federal do Rio de Janeiro
Pós-Graduação em Engenharia
de Sistemas e Computação
Rio de Janeiro, Brasil
e-mail: luneque@cos.ufrj.br

Nadia Nedjah

Universidade do Estado do Rio de Janeiro
Pós-Graduação em Engenharia
Eletrônica
Rio de Janeiro, Brasil
e-mail: nadia@eng.uerj.br

Felipe França

Universidade Federal do Rio de Janeiro
Pós-Graduação em Engenharia
de Sistemas e Computação
Rio de Janeiro, Brasil
e-mail: felipe@cos.ufrj.br

Resumo—Este trabalho apresenta um estudo sobre a utilização da rede neural sem peso WiSARD na classificação supervisionada de imagens de satélite. Para uma dada imagem de sensoriamento remoto, é verificado um conjunto de classes distintas, como água, vegetação e área urbana. O método computacional deverá ser capaz de identificar cada uma destas classes após uma etapa de treinamento. Como base de comparação, a mesma metodologia é empregada com outro classificador amplamente usado, a Árvore de Decisão.

I. INTRODUÇÃO

O sensoriamento remoto é uma importante ferramenta no mapeamento, identificação e monitoramento da superfície terrestre, pois possibilita obter informações sobre a cobertura de áreas extensas, de maneira rápida, precisa e econômica. Nas últimas décadas, a tecnologia de sensoriamento remoto evoluiu das fotografias aéreas pancromáticas (tomadas a partir de aeronaves), passando pelas imagens digitais dos primeiros sensores acoplados a plataformas orbitais (ainda com baixa resolução espacial), até as atuais imagens multi e hiper-espectrais de alta resolução espacial provenientes de modernos sensores em nível orbital. Paralelamente, a rápida evolução da engenharia de *hardware* e *softwares* computacionais tem facilitado as pesquisas em sensoriamento remoto, permitindo o desenvolvimento de sofisticados métodos de análise e processamento digital de imagens.

A classificação automática de imagens multi-espectrais permite a extração rápida de informação e definição dos padrões de ocupação da terra. O objetivo principal é a categorização da cobertura da terra distinguindo as composições de diferentes materiais superficiais. Duas abordagens distintas são adotadas na classificação automática de imagens digitais: a classificação supervisionada e a não supervisionada. A classificação supervisionada é baseada num conjunto de amostras utilizadas para treinamento do classificador. Portanto há necessidade de observações de campo na data de passagem do satélite ou conhecimentos de fotointerpretação que permitam o reconhecimento dos padrões de uso da terra. Quando não for possível definir áreas representativas para o treinamento, podem ser utilizados algoritmos baseados em regras estatísticas capazes de fazer o reconhecimento das classes presentes na imagem. Neste caso a classificação é dita não supervisionada.

Diversos aspectos da informação em estudo não podem ser obtidos somente com base na informação contida no *pixel* (*per-pixel classification*), necessitando ser explorados também com relação à vizinhança do *pixel* (*subpixel classification*) e no contexto dos objetos de interesse (*contextual classification*). Assim, numa abordagem mais ampla, os algoritmos comumente denominados *classificadores por região* utilizam, além da informação espectral de cada *pixel*, a informação espacial que envolve a relação entre os *pixels* e seus vizinhos. Na atualidade, muitas abordagens de classificação avançadas, tais como redes neurais artificiais, lógica *fuzzy* e sistemas especialistas, têm sido amplamente aplicados para a classificação de imagens. Para um estudo mais abrangente, o trabalho de Lu e Weng enumera diversas dessas técnicas [1].

Este trabalho apresenta a classificação de imagens com o uso da rede neural artificial WiSARD (*Wilkie, Stonham and Aleksander Recognition Device*) [2]. Esta é uma rede sem peso baseada em RAM. Embora seu uso seja classicamente associado ao reconhecimento de padrões em imagens, neste trabalho a rede é empregada na classificação *per-pixel*, isto é, o padrão de entrada da rede não é uma imagem, mas sim o valor dos canais de cor de cada *pixel*.

A organização do restante deste trabalho é apresentada a seguir. Na Seção II é feita uma rápida abordagem sobre classificação supervisionada. A Seção III apresenta o multi-discriminador WiSARD. Na Seção IV é realizada a classificação em imagens de teste, seguida de uma breve análise dos resultados. O artigo é concluído na Seção V, onde também são levantados pontos relevantes para trabalhos futuros.

II. CLASSIFICAÇÃO DE IMAGENS

Algoritmos de classificação supervisionada necessitam do conhecimento prévio das classes da área de estudo. Desse modo, amostras pertencentes a cada classe da imagem são usadas no treinamento do classificador. Um número suficiente de amostras de treinamento, bem como sua representatividade, são fatores críticos para classificação de imagens. Quando a imagem de estudo é uma área complexa e heterogênea, a seleção de uma quantidade suficiente de amostras de treinamento torna-se difícil. Este problema pode ser complicado

se forem usados na classificação dados de resolução média ou grossa, pois um grande volume de *pixels* misturados pode ocorrer.

Uma das abordagens mais utilizadas na avaliação da acurácia de um classificador é a *matriz de erros*. Em uma matriz de erros (ou *matriz de confusão*), o valor de cada elemento expressa a quantidade de unidades amostrais associadas a uma dada categoria durante o processo de classificação efetuado e a categoria real a que pertencem essas unidades [3]. Após a geração da matriz de erros, outros elementos de avaliação podem ser derivados, como é o caso do *coeficiente kappa* [4]. O coeficiente ou *índice kappa* é uma medida da concordância real (indicado pelos elementos diagonais da matriz de confusão) menos a concordância por chance (indicado pelo produto total da linha e coluna, que não inclui entradas não reconhecidas), ou seja, é uma medida do quanto a classificação está de acordo com os dados de referência. Assim, kappa pode ser calculado através da Equação 1

$$kappa = \frac{N_x \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N_x^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (1)$$

onde r é o número de linhas da matriz de confusão, x_{ii} é o número de observações na linha i e coluna i , x_{i+} e x_{+i} são os totais marginais na linha i e coluna i , e N_x é o número total de observações [5].

O valor de kappa (Tabela I) permite analisar comparativamente os resultados obtidos por um classificador [6].

Tabela I. QUALIDADE DA CLASSIFICAÇÃO ASSOCIADA AOS VALORES DO COEFICIENTE KAPPA.

Valor de kappa	Qualidade da classificação
0,00 — 0,20	Ruim
0,20 — 0,40	Razoável
0,40 — 0,60	Boa
0,60 — 0,80	Muito Boa
0,80 — 1,00	Excelente

III. REDE NEURAL SEM PESOS WiSARD

O modelo de neurônio definido por McCulloch e Pitts foi o precursor no estudo das redes neurais artificiais [7]. Seu funcionamento imita os neurônios biológicos, com os pesos sinápticos estando associados à informação aprendida pela rede. Por outro lado, em redes baseadas em RAM (*Random Access Memories*), as funções neuronais estão armazenadas em *lookup tables*, não possuindo pesos entre os nós [8]. O aprendizado nestas redes não se dá pelo ajuste dos pesos, mas sim pela atualização dos valores armazenados nas *lookup tables*.

O termo *generalização* diz respeito a capacidade da rede reconhecer corretamente padrões que não fizeram parte da etapa de treinamento. Um único nó RAM produz a saída correta apenas para padrões armazenados durante o treinamento. Contudo, é possível obter generalização em redes formadas por nós RAM.

Um discriminador consiste de um conjunto de k RAMs de N entradas e um somador. Este discriminador recebe um padrão binário de $k \times N$ bits. A RAM e os bits de entrada estão conectados por meio de um mapeamento pseudo-aleatório, conforme visto na Figura 1 (a). Para a etapa de treinamento, inicialmente todas as RAMs têm seu conteúdo armazenado posto em “0”. O conteúdo das RAMs na posição mapeada por um determinado padrão é posto em “1” quando este padrão é apresentado ao discriminador na fase de treinamento.

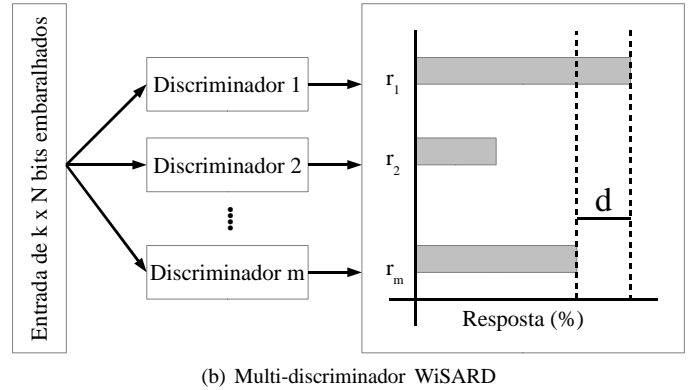
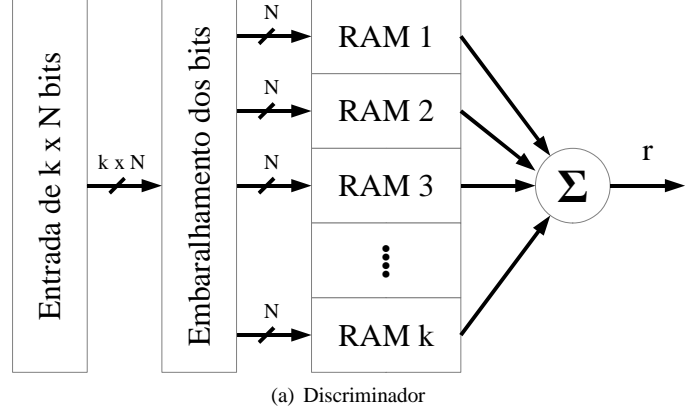


Figura 1. Discriminador com k RAMs de N bits e o multi-discriminador WiSARD de m classes.

Um sistema formado por vários discriminadores é chamado de WiSARD (*Wilkie, Stonham and Aleksander's Recognition Device*) [2]. Cada discriminador é treinado com padrões de uma determinada categoria, com a classificação sendo realizada da seguinte forma. Quando um padrão é dado como entrada, cada discriminador fornece um valor de resposta r a essa entrada. As várias respostas são avaliadas por um algoritmo que compara e calcula a confiança relativa da resposta mais elevada (por exemplo, a diferença d entre a maior resposta e a segunda resposta mais elevada, dividida pela maior resposta). Uma representação do multi-discriminador WiSARD é mostrada na Figura 1 (b).

IV. EXPERIMENTOS E RESULTADOS

Duas bases de dados foram selecionadas para os testes de classificação usando WiSARD. Em ambos os casos, temos uma imagem de satélite e uma imagem que define as classes presentes. As simulações apresentam a qualidade da classificação em relação a diversas configurações da rede WiSARD, bem como a classificação usando Árvore de decisão.

Todos os algoritmos deste artigo foram feitos e executados com o *Matlab* Versão 7.7.0.471 (R2008b). As simulações foram realizadas em PCs com *Intel Core i7 950* 3GHz, 8Gb RAM e o sistema operacional *Microsoft Windows 7 Home Premium*.

A. Imagens

A primeira figura usada para classificação é parte de uma imagem de satélite da cidade de Bilbao, Espanha (NASA WorldWind NLT Landsat7). O fragmento utilizado, no formato de imagem PNG, possui resolução de 600×519 , com três bandas (RGB). A imagem foi classificada visualmente em três classes, sendo elas: “área urbana” (vermelho), “cobertura vegetal” (verde) e “água” (azul).

A imagem original e a classificada visualmente são expostas na Figura 2. A imagem de classificação visual é necessária para a avaliação do classificador, visto que não estão disponíveis dados de *verdade do solo* (*ground truth*) da região analisada.




Figura 2. Imagens da cidade de Bilbao, Espanha.

A segunda imagem foi retirada do projeto T.I Zona Oeste [9][10], que tem por objetivo realizar o mapeamento de uso e ocupação de parte do município do Rio de Janeiro, Brasil (WorldView-2). A região mapeada é uma imagem PNG de 256×256 pixels com 3 bandas de cor (RGB). Esta imagem apresenta três classes: “área urbana” (vermelho), “floresta alterada” (verde) e “campo” (azul).

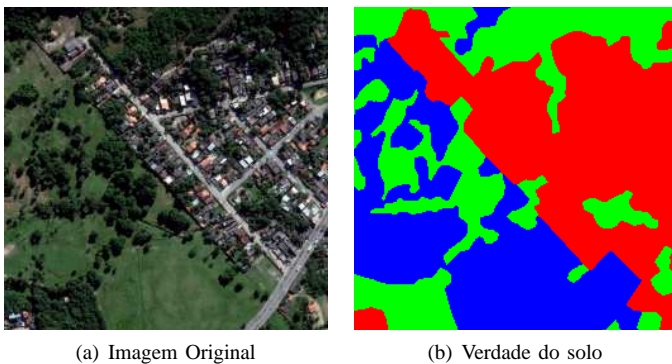



Figura 3. Fragmento de imagem da Zona Oeste do Rio de Janeiro, Brasil.

B. Treinamento

Três abordagens de treinamento foram empregadas neste trabalho: usando apenas o valor do *pixel*, apenas o valor da média dos *pixels* do entorno, e treinando com ambos os

valores. Para definição do conjunto de treinamento por valor de *pixel*, foram selecionadas três regiões da imagem original que mais se assemelhavam visualmente às categorias desejadas. Cada seleção possui o tamanho de 50×50 pixels para a imagem de Bilbao e 30×30 para a imagem da Zona Oeste. Estas três regiões características de cada classe são vistas nos fragmentos apresentados na Figura 4.



(a) Classes da imagem Bilbao



(b) Classes da imagem Zona Oeste

Figura 4. Conjuntos de treinamento por valor de *pixel* para as imagens de teste das cidades de Bilbao e da Zona Oeste do Rio de Janeiro.

Para o treinamento por valor de média, cada elemento do conjunto de treinamento é formado pela média do entorno em quatro direções dos *pixels* do conjunto de treinamento por valor de *pixel*. Assim, para cada conjunto de treinamento, teremos a quantidade de *pixels* definida na Tabela II.

Tabela II. CONJUNTOS DE TREINAMENTO PARA AS IMAGENS DE TESTE.

Treinamento	Por <i>Pixel</i>	Por Média	<i>Pixel</i> e Média
Bilbao	2500 por classe	2500 por classe	5000 por classe
Zona Oeste	900 por classe	900 por classe	2700 por classe

C. Classificação com a rede WiSARD

Na classificação com a WiSARD, é necessário que os padrões estejam em um formato binário para que sejam aplicados à entrada da rede. Embora muitas das aplicações da WiSARD envolvam o uso de imagens binárias (em preto e branco) como padrão de entrada, neste trabalho foi usado apenas valor RGB dos *pixels*. Cada *pixel* é formado por três informações de cor (vermelho, verde e azul) que podem assumir valores inteiros na faixa de 0 à 255. Duas codificações binárias para o valor da informação de cor foram empregadas neste trabalho.

Os valores dos canais de cor foram convertidos em três vetores binários de 8 bits no código Gray. Estes, por sua vez, são concatenados em um único padrão de 24 bits, conforme visto na Figura 5. A codificação Gray é eficiente neste caso (em comparação com a simples conversão para valores na base 2) uma vez que possui uma *distancia de Hamming* de “1” para o código representativo de dois valores consecutivos.




Figura 5. Três valores RGB convertidos em um vetor de 24 bits.

Uma segunda codificação foi usada, com 256 bits empregados na representação dos valores de cada um dos 3 canais, totalizando 768 bits por *pixel*. Nesta representação, o código possui a quantidade de bits postos em “1” igual ao valor decimal representado. O incremento no valor em decimal equivale a mais um bit assumindo o valor “1”.

Antes de ser aplicado a rede, o vetor binário passa ainda por uma etapa de embaralhamento: cada bit é mapeado de forma aleatória a uma determinada entrada da rede. Este mapeamento é mantido tanto no treinamento quanto na utilização da rede.

Uma vez determinado o formato do padrão de entrada, é preciso definir a arquitetura dos discriminadores. Um discriminador é formado por k RAMs de N bits, onde $k \times N$ é o número de bits do padrão de entrada. Como a entrada é fixa (24 e 768 bits para os dois casos) resta definir k e N . Três combinações de valores são possíveis para o caso de 24 bits, como mostrado na Tabela III. Para a codificação com 768 bits, foram escolhidas 3 combinações de valores para k e N . Com o intuito de verificar a variação de desempenho, redes WiSARD com estas diferentes configurações foram usadas.

Tabela III. CONFIGURAÇÕES DAS RAMS PARA *pixels* COM 24 E 768 bits

k	N	# posições
12	2	$12 \times 2^2 = 48$
8	3	$8 \times 2^3 = 64$
6	4	$6 \times 2^4 = 96$
256	3	$256 \times 2^3 = 2048$
128	6	$128 \times 2^6 = 8192$
64	12	$64 \times 2^{12} = 262144$

A quantidade de posições nas RAMs do discriminador de cada uma das três classes é pequena em relação aos conjuntos de treinamento. Assim, é possível que ocorra uma rápida saturação dos discriminadores. A fim de evitar este problema, duas abordagens foram empregadas. Primeiramente, adotou-se valores inteiros como conteúdo das RAMs. Quando um padrão de treinamento é apresentado à rede, a posição endereçada pela entrada não é apenas posta em “1”, mas sim incrementada. Dessa forma, é possível saber quais subconjuntos são mais treinados que outros dentro de um mesmo discriminador. Diferente do discriminador binário, em que r indicava a quantidade de posições ativadas para uma dada entrada, a resposta de um discriminador inteiro é a soma do conteúdo destas posições. A segunda abordagem diz respeito ao uso da técnica de *bleaching* [11]. Nesta situação, uma posição só é ativada se seu conteúdo inteiro ultrapassar um determinado valor de limiar. A resposta r é a quantidade de posições ativadas. Neste trabalho, o *bleaching* só foi empregado na WiSARD com entrada de 24 bits cuja configuração obteve

a melhor avaliação na classificação, no caso a rede 6-4 ($k = 6$ e $N = 4$).

D. Classificação com Árvore de Decisão

Para fins de comparação, as imagens foram usadas com outro classificador supervisionado amplamente usado: a *Árvore de Decisão* [12]. Uma *Árvore de Decisão* é definida como um procedimento de classificação que particiona recursivamente um conjunto de dados em subdivisões menores com base em testes definidos em cada ramificação. A árvore é composta por um nó raiz (formado por todos os dados), um conjunto de nós intermediários (as divisões) e um conjunto de nós terminais (folhas). Nesta técnica, um conjunto de dados é classificado ao ser sequencialmente subdividido de acordo com a estrutura definida pela árvore até alcançar uma folha. Uma categoria é definida a cada valor observado com base na classe associada a cada folha.

Assim como na classificação com a WiSARD, a classificação com *Árvore de Decisão* também se baseou nos três critérios de treinamento: *pixel*, média e ambos os valores. A Figura 6 apresenta a estrutura da árvore classificadora para o treinamento por *pixel* e média.




Figura 6. Fragmento da árvore classificadora. Treinamento com o valor do *pixel* e a média do entorno.

E. Resultados

Para a primeira imagem (Bilbao), diversas classificações foram realizadas, todas usando os três padrões de treinamento:

- WiSARD com discriminadores 12-2, 8-3 e 6-4
- WiSARD com discriminadores 256-3, 128-6 e 64-12
- WiSARD 6-4 com *bleaching*
- *Árvore de Decisão*

A imagem de teste (Bilbao) dividida em 3 classes é apresentada na Figura 7 para a classificação por *Árvore de Decisão*, WiSARD 6-4 (entrada de 24 bits) e WiSARD 64-12 (entrada de 768 bits).

Com base na classificação visual da Figura 2 (b) e no resultado de cara classificação, foi possível obter o coeficiente




Figura 7. Imagem de teste (Bilbao) em três classificadores distintos. Vermelho: área urbana, verde: cobertura vegetal, azul: águas.

kappa de cada uma dos cenários apresentados, como sumariado no gráfico da Figura 8. Como descrito na Tabela I, quanto maior o valor de kappa, melhor a resposta do classificador.

Alguns comentários podem ser feitos com base nos valores obtidos. Primeiramente, é visível que os resultados para classificação usando WiSARD com a codificação de 768 bits foram superiores aos demais, estando próximos a 0,8. Isto é esperado, tendo em vista a maior quantidade de dados usados na classificação.

Quanto aos conjuntos de treinamento, é possível notar que o uso dos diferentes padrões pouco afeta a capacidade de classificação da WiSARD (em ambos os tipos de codificação de dados). Por outro lado, a Árvore de Decisão possui uma resposta inferior quando treinada apenas com o valor da média do entorno dos *pixels*.

Para as diferentes implementações da WiSARD com entrada de 24 bits, a que obteve melhores resultados foi a com configuração 6-4. Isto foi esperado, uma vez que o desempenho do discriminador depende de k [13]. Quanto maior a quantidade de RAMs, mais especializada é a resposta da rede. Reduzindo sua quantidade, maior será a capacidade de generalização. Por fim, selecionando a WiSARD 6-4 e aplicando a técnica de *bleaching*, são obtidos valores ainda maiores de kappa. Para a WiSARD 6-4 com e sem *bleaching*, os valores de kappa estão no intervalo entre 0,6 e 0,7, o que segundo a Tabela I indica que a classificação é *muito boa*.

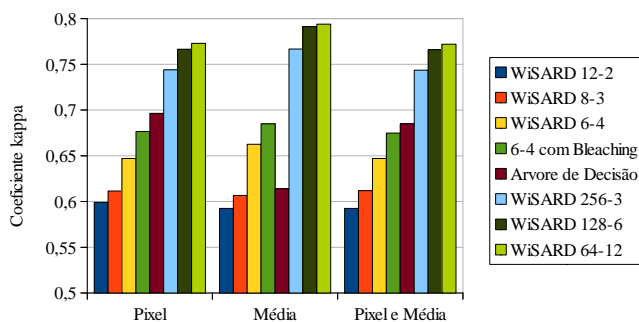


Figura 8. Coeficiente kappa para as diversos classificadores.

Para a imagem do repositório T.I. Zona Oeste, a classificação foi realizada usando-se Árvore de Decisão e WiSARD com entradas de 24 e 768 bits.

- WiSARD com discriminadores 12-2, 8-3 e 6-4
- WiSARD com discriminadores 256-3, 128-6 e 64-12
- Árvore de Decisão

Para todos estes classificadores, empregou-se os três conjuntos tipos de treinamento previamente citados. Os valores de kappa obtidos podem ser vistos na Figura 9. Mais uma vez, o treinamento escolhido pouco influenciou na qualidade da classificação.




Figura 9. Coeficiente kappa para as diversas classificadores.

Nos testes com a imagem da Zona Oeste, a classificação por Árvore de Decisão mostrou-se melhor que o empregando WiSARD. Isto pode ser visto através dos valores obtidos de kappa. Uma possível explicação para tais resultados pode ser inferida a partir da análise das imagens classificadas, mostradas na Figura 10, e da imagem de verdade do solo - Figura 3 (b). Nota-se no mapa de classes fornecido pelo repositório que a região com a classe “área urbana” é praticamente contínua. Em outras palavras, no mapa de *ground truth*, generalizou-se que toda a região construída (habitações e vias públicas) pertencem à uma mesma classe, mesmo que eventualmente também existam *pixels* de outras classes. Este tipo de consideração foi obedecida na classificação com Árvore de Decisão, onde apenas algumas regiões das classes “floresta alterada” e “campo” aparecem em meio a área vermelha. Por




Figura 10. Imagem de teste (Zona Oeste) com dois classificadores. Vermelho: área urbana, verde: floresta alterada, azul: campo.

outro lado, na classificação com WiSARD, a rede focou-se em detalhes bem específicos para a classe "área urbana". Isto é notório na Figura 10 (b), onde a região vermelha delimita apenas áreas asfaltadas e casas.

V. CONCLUSÕES

Este trabalho apresentou um estudo inicial do uso da rede neural sem peso WiSARD na classificação de imagens. A identificação de classes em imagens de sensoriamento remoto é de grande importância, pois permite uma rápida verificação não só da composição geográfica de uma determinada região, mas também de sua parcela de utilização do solo. Nos exemplos mostrados, imagens foram classificadas em três categorias bem distintas.

O classificador WiSARD obteve bons resultados (tendo como métrica o valor do coeficiente kappa) na classificação da imagem de teste Bilbao. Contudo, para a imagem retirada do repositório T.I Zona Oeste, o valor de kappa obtido com outro classificador supervisionado, Árvore de Decisão, superou todas as implementações de classificador WiSARD. Assim, existe a necessidade de um maior estudo sobre como usar a rede WiSARD como um classificador mais genérico para imagens de sensoriamento remoto.

Uma série de etapas ainda podem ser realizadas neste estudo. A primeira delas é a utilização de um maior número de imagens de teste, cada uma com um diferente número de classes. Tais imagens podem também possuir um maior número de bandas de informação, além de apenas os 3 canais de cor. É possível usar, por exemplo, a informação da imagem capturada em Infravermelho. Também é de interesse a comparação de resultados com outros tipos de classificadores, como redes neurais artificiais Multilayer Perceptron [14]. Por fim, uma possível melhoria seria a utilização da classificação não supervisionada com uma rede Auto-WiSARD [15], onde novas classes são criadas a medida que os padrões de treinamento são apresentados à rede.

AGRADECIMENTOS

Agradecemos à FAPERJ (*Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro*, www.faperj.br), ao CNPq (*Conselho Nacional de Desenvolvimento Científico e Tecnológico*,

www.cnpq.br) e à CAPES (*Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior*, www.capes.gov.br) por seu contínuo apoio financeiro.

REFERÊNCIAS

- [1] D. Lu and Q. Weng, "A survey of image classification methods and techniques for improving classification performance," *International Journal of Remote Sensing*, vol. 28, no. 5, pp. 823–870, 2007.
- [2] I. Aleksander, W. Thomas, and P. Bowden, "Wisard - a radical step forward in image recognition," *Sensor review*, vol. 4, no. 3, pp. 120–124, 1984.
- [3] G. Rosenfield and K. Fitzpatrick-Lins, "A coefficient of agreement as a measure of thematic classification accuracy," *Photogrammetric Engineering and Remote Sensing*, vol. 52, pp. 223–227, 1986.
- [4] J. Cohen, "A coefficient of agreement for nominal scales," *Educational and psychological measurement*, vol. 20, no. 1, pp. 37–46, 1960.
- [5] Y. Bishop, S. Fienberg, and P. Holland, *Discrete multivariate analysis: theory and practice*. Springer, 2007.
- [6] J. Landis and G. Koch, "The measurement of observer agreement for categorical data," *Biometrics*, vol. 33, no. 1, pp. 159–174, 1977.
- [7] W. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bulletin of mathematical biology*, vol. 5, no. 4, pp. 115–133, 1943.
- [8] I. Aleksander, M. De Gregorio, F. França, P. Lima, and H. Morton, "A brief introduction to weightless neural systems," in *Proceedings of the 17th European Symposium on Artificial Neural Networks, ESANN, 2009*, pp. 22–24.
- [9] G. Ribeiro, M. Pereira, and M. Moraes, "SIG apoiado por imagens WorldView destinado à análise de cenários urbanos e cobertura vegetal da Zona Oeste do Rio de Janeiro," *IV SIMGEO*, 2012.
- [10] G. Ribeiro, *Projeto T.I Zona Oeste*, 2013 (acessado em 01/05/2013). [Online]. Available: <http://globalgeosig.com.br/tizo/>
- [11] B. Grieco, P. Lima, M. De Gregorio, and F. França, "Producing pattern examples from "mental" images," *Neurocomputing*, vol. 73, no. 7, pp. 1057–1064, 2010.
- [12] M. Friedl and C. Brodley, "Decision tree classification of land cover from remotely sensed data," *Remote sensing of environment*, vol. 61, no. 3, pp. 399–409, 1997.
- [13] I. Aleksander and H. Morton, *An introduction to neural computing*. Chapman and Hall London, 1990, vol. 240.
- [14] F. Rosenblatt, "Principles of neurodynamics: Perceptrons and the theory of brain mechanisms," DTIC Document, Tech. Rep., 1961.
- [15] I. Wickert and F. M. Franca, "Validating an unsupervised weightless perceptron," in *Neural Information Processing, 2002. ICONIP'02. Proceedings of the 9th International Conference on*, vol. 2. IEEE, 2002, pp. 537–541.