

# ANAIS DO V WORKSHOP DE ÁLGEBRA DA UFG-CAC

## O que é segmentação de imagens?

**Daniela de Oliveira Albanez**

*doalbanez@hotmail.com*

Universidade Federal de Goiás - Regional Catalão  
Programa de Pós-Graduação em Modelagem e Otimização

**Marcos Aurélio Batista**

*marcos.batista@pq.cnpq.br*

Universidade Federal de Goiás - Regional Catalão  
Programa de Pós-Graduação em Modelagem e Otimização

**Sérgio Ferreira da Silva**

*sergio@ufg.br*

Universidade Federal de Goiás - Regional Catalão  
Programa de Pós-Graduação em Modelagem e Otimização

### Resumo

Verifica-se a utilização cada vez maior do computador nas tarefas de extração de informações de imagens. Uma dessas tarefas é a segmentação ou subdivisão de uma imagem em suas partes ou objetos constituintes. Este artigo realiza um estudo sobre um algoritmo de segmentação de imagens utilizando Redes Neurais Artificiais (RNA's) em diferentes imagens como elemento classificador de efetivação do processamento das imagens. É nosso objetivo abordar de forma introdutória e simplificada o tema. Ao final os resultados obtidos são apresentados para a validação da segmentação de imagens utilizando-se RNA's.

**Palavras-chave:** Imagem, Segmentação de imagens, Redes Neurais Artificiais.

# 1 Introdução

Inicialmente, as primeiras técnicas de processamento de imagens digitais, inclusive a segmentação de imagens, não obtiveram grande atenção dos estudiosos. Contudo, a partir da década de 1960, essa área começou a ter o seu reconhecimento, isso porque imagens da Lua passaram a ser processadas com a intenção de remover as distorções (Gonzales e Woods 2001). Desde então, essa área de pesquisa evoluiu de forma significativa.

Atualmente, a questão ambiental tornou-se um assunto importante para toda a sociedade. Grande parte da vegetação tem sido devastada para a produção agrícola. Assim, o monitoramento e a mineração do uso da terra se tornam cada vez mais importantes. Pode-se acompanhar esse processo por meio de imagens de satélite de alta resolução que monitoram a superfície da Terra (Albarez, Batista e Silva 2015).

Ao longo deste artigo, propõe-se apresentar a definição matemática de uma imagem, como é realizada a segmentação das imagens através da utilização de RNA's sendo o elemento classificador de efetivação do processamento das imagens. Vale lembrar o grande êxito que essa técnica vem obtendo em trabalhos semelhantes, como os de Haykin (2001), Yin, Zhang e Wu (2012), por exemplo. Essa abordagem é inspirada na definição matemática de um neurônio e no entendimento do funcionamento dessa célula no comportamento humano. Ressalta-se que se optou por utilizar as Redes Neurais para segmentar as imagens porque elas permitem que o conhecimento seja adquirido através de exemplos, tendo este conhecimento a possibilidade de ser aperfeiçoado pela experiência (Haykin 2001).

O procedimento de segmentação de imagem é um processo que divide a imagem em pedaços menores, para depois, tratá-los, simplificando assim o processo de reconhecimento. A partir disso, os algoritmos de segmentação permitem achar diferenças entre duas ou mais regiões, distinguindo-as das outras. Outro procedimento de segmentação é a combinação de pixels e regiões vizinhas de características visuais similares que formam objetos e distribuem rótulo a cada pixel de imagem, identificando-o a qual grupo ele pertence, de acordo com suas características como cor e textura (Gonzales e Woods 2001). Diante disso, é válido lembrar que, neste artigo, investiga-se

métodos de segmentação de imagens por meio das RNA's.

As RNA's têm suas bases em várias disciplinas: neurociência, estatística, ciências da computação, engenharias etc., e tentam imitar a capacidade de reconhecimento do cérebro biológico (Haykin 2001). Elas são utilizadas em muitas áreas como modelagem e análise de séries temporais, reconhecimento, agrupamento e classificação de padrões, processamento de sinais e controle, mas, assim como o cérebro biológico, precisam ser treinadas, no entanto, isso pode consumir muito tempo.

Como as RNA's são desenvolvidas via tecnologia e não podem ser processadas com a mesma agilidade de ação dos neurônios biológicos, existe a necessidade de encontrar um caminho que possa solucionar, da forma mais próxima possível, um problema. Isto é, é preciso criar um modo de desenvolver e implementar RNA's, o que é feito a partir de aplicações próprias, por meio de uma linguagem de programação, buscando sempre a solução do problema.

Os sistemas que utilizam redes neurais costumam explorar sua principal propriedade, a habilidade de aprender a partir de suas experiências e, com isso, extrair conhecimento. Isso é feito através de um processo de treinamento, que consiste num processo iterativo de ajustes, aplicando o algoritmo de treinamento a seus pesos sinápticos.

## 2 Definição de Imagem Digital

A **imagem digital** é uma matriz de pontos  $M \times N$ ,  $M$  linhas e  $N$  colunas, e cada elemento da matriz representa um valor de cor. Segundo Gonzales e Woods (2001), Petrou e Bosdogianni (1999), uma imagem pode ser definida como uma função  $f(x, y)$ , onde o valor das coordenadas espaciais  $x$  e  $y$  são valores inteiros,  $x = 0, 1, 2, \dots, M - 1$  e  $y = 0, 1, 2, \dots, N - 1$  e o valor de  $f$  corresponde ao brilho (intensidade) da imagem na coordenada de entrada ou escala de cinza.

A menor unidade que constitui uma imagem digital é denominada *Picture Element* (pixel). Este, por sua vez, é a representação numérica da luminosidade de um ponto da imagem. A Figura 1 ilustra a representação numérica de uma imagem ampliada de  $10 \times 10$  pixels. Sendo assim, em uma imagem,

quanto mais pixels ela tiver, melhor a sua resolução e qualidade.

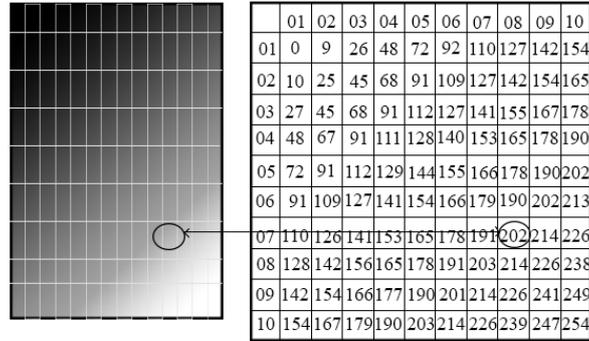


Figura 1: Pixels de uma imagem

Um pixel na coordenada  $(x, y)$  possui quatro pixels vizinhos, dois na posição vertical e dois na posição horizontal, dado pelas coordenadas:

$$(x + 1, y), (x - 1, y), (x, y + 1), (x, y - 1)$$

Esse conjunto de pixels é conhecido como vizinhança-4 do pixel  $p$ . Há ainda quatro vizinhos diagonais que, juntamente com a vizinhança-4, formam a vizinhança-8, dada pelas coordenadas:

$$(x + 1, y + 1), (x + 1, y - 1), (x - 1, y + 1), (x - 1, y - 1)$$

É preciso ressaltar que o conceito de vizinhança é muito utilizado no processamento de imagens, tendo em vista sua importante tarefa para a resolução das imagens.

### 3 Aquisição de Imagens

De acordo com Gonzales e Woods (2001), a primeira etapa no processamento digital de imagens é a aquisição dela, isto é, é preciso ter primeiro uma imagem digital. Para isso é necessário um sensor de imagens e a capacidade para digitalizar o sinal produzido por ele. É preciso dois elementos para a aquisição da imagem, quais sejam: um aparelho físico, que seja sensível à faixa espectral de energia eletromagnética (como raio X, ultravioleta), que produza um sinal elétrico de saída proporcional ao nível de energia sentido; e um digitalizador, que converta o sinal elétrico capturado na sua forma digital.

O aparelho físico pode ser uma câmara de TV monocromática ou colorida, ou qualquer aparelho que permita a leitura do valor do pixel.

## 4 Pré-processamento de Imagens

Depois de adquirida e digitalizada a imagem, o próximo passo é o pré-processamento, que tem como função melhorá-la, com o objetivo de aumentar o sucesso dos próximos passos (Gonzales e Woods 2001).

Conforme Rodrigues (2002), nessa etapa são utilizadas técnicas para aumento de contraste, remoção de ruídos, realce e normalização, buscando converter os padrões para uma forma que possibilite uma simplificação do processo de reconhecimento.

As operações básicas utilizadas no pré-processamento de imagens (Gonzales e Woods 2001) são as seguintes:

- Correção de histograma;
- Correções geométricas e
- Filtragem.

## 5 Histograma de Cores

Um **histograma** é um gráfico que representa os valores das tonalidades dos pixels numa imagem com uma determinada luminosidade (Gonzales e Woods 2001), (Petrou e Bosdogianni 1999), ou seja, é a representação da distribuição de cores em uma imagem. Com ele é possível determinar se a imagem está bem contrastada, escura ou muito clara.

O histograma de cores é constituído por pilhas, também conhecidas como *bins*, uma para cada cor presente na imagem, dentro de um espaço de cores. Uma vez formado, o histograma deve ser normalizado, dividindo-se o valor total encontrado em cada *bin* pelo número total de pixels contidos na imagem (Ribeiro 2009).

O histograma de uma imagem digital com  $k$  níveis de cinza é definido por uma função discreta (Gonzales e Woods 2001):

$$p(k) = \frac{n_k}{n} \quad (1)$$

onde:

$k$  é o nível de cinza,

$n_k$  é o número de pixels da imagem com o nível de cinza  $k$

$n$  é o número total de pixels da imagem, ou seja,  $n = M \times N$ .

(E  $k \in \{1, 2, \dots, L\}$ , onde  $L$  é o número total de níveis de cinza que podem estar presentes na imagem.) O histograma da imagem digital é uma ferramenta bastante utilizada na etapa de pré-processamento, pois fornece uma visão estatística sobre a distribuição dos pixels, sobre o contraste da imagem e os níveis de cinza. Além disso, o histograma é bastante utilizado na etapa de segmentação, principalmente em técnicas que se utilizam da similaridade entre os pixels. O histograma também é utilizado na caracterização de imagens.

## 6 Segmentação de Imagens

No que diz respeito ao pré-processamento de imagens, percebe-se que, feito pré-processamento da imagem o passo seguinte é a segmentação que, de forma geral, consiste em subdividir uma imagem de entrada em suas partes constituintes ou objetos. Cada uma dessas partes é uniforme e homogênea com respeito a algumas propriedades da imagem como, por exemplo, cor e textura.

A ideia de segmentação é agrupar pixels ou conjuntos de pixels de mesma propriedade, para isso, é necessário que se faça a segmentação adequada para que não haja erro. Existem diversas técnicas de segmentação de imagens, mas não existe nenhum método único que seja capaz de segmentar todos os tipos de imagem. Globalmente, uma imagem em níveis de cinza pode ser segmentada de duas maneiras: por descontinuidade e por similaridade.

Na primeira categoria, a abordagem é particionar uma imagem baseando-se nas mudanças abruptas nos níveis de cinza. As principais áreas de interesse

dentro dessa categoria são a detecção de pontos isolados, detecção de linhas e detecção de bordas numa imagem através de máscaras de convolução. As principais abordagens da segunda categoria são baseadas em limiarização (*thresholding*), crescimento de regiões (*region growing*), divisão e conquista (*split & merge*) e aglomeração (*clustering*).

## 7 Representação de Imagens

Como a saída do estágio de segmentação geralmente são resultados brutos de pixels, pode ser necessário converter esses dados em uma forma conveniente, possibilitando o processamento. Existem dois tipos de representação que podem ser utilizados: a representação limite, que é aprimorada quando o foco está em característica da forma, e a representação regional, que é aprimorada quando o foco está em propriedades reflectivas, como textura e cor.

As imagens podem ser representadas de duas formas: matricialmente e vetorialmente. Na representação matricial, a imagem é descrita por um conjunto de células em um arranjo espacial bidimensional, ou seja, uma matriz, onde cada célula representa um pixel da imagem (Azevedo e Conci 2003). Essa representação é usada para formar a imagem na memória e nas telas de computador, como é representado na Figura 2:

0	0	0	0	0	1	0	0	0	0	0	0
0	0	0	0	1	1	1	0	0	0	0	0
0	0	0	1	1	1	1	1	0	0	0	0
0	0	1	1	1	1	1	1	0	0	0	0
0	0	1	0	0	0	0	0	1	0	0	0
0	0	1	0	0	0	0	0	1	0	0	0
0	0	1	0	0	0	0	0	1	0	0	0
0	0	1	0	0	0	0	0	1	0	0	0
0	0	1	1	1	1	1	1	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0

memória de imagem

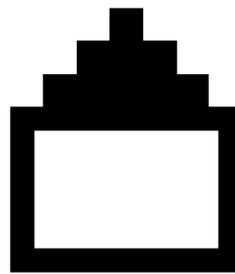


imagem na tela

Figura 2: Descrição de imagens matriciais por um conjunto de pixels

Na representação vetorial são usados, como elementos básicos, os pontos, as linhas e as curvas. Esses elementos são chamados primitivas vetoriais, onde cada primitiva possui um conjunto de atributos que define sua aparência e

um conjunto de dados que define sua geometria (Azevedo e Conci 2003). Na Figura 3 pode-se observar à esquerda a representação vetorial e à direita a representação matricial da imagem.

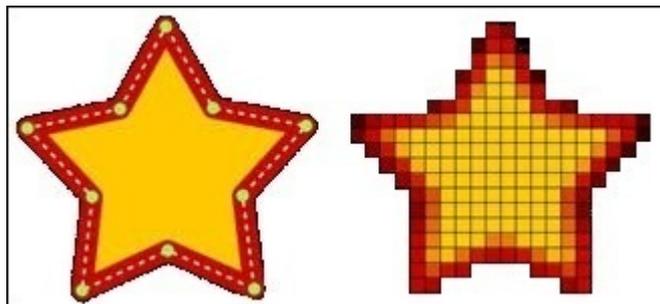


Figura 3: Representação Vetorial x Representação Matricial

## 8 Redes Neurais Artificiais

A complexidade do ser humano é tão grande que tem sido, ao longo de muitos anos, estudada por vários pesquisadores que buscam modelar, computacionalmente, a reprodução do sistema humano em todos os seus aspectos. Uma dessas áreas de estudo diz respeito ao sistema nervoso, cujas pesquisas são realizadas com base em redes neurais. Diante disso, perceberam que o circuito neural cerebral possui várias conexões entre seus neurônios, células e sinapses que interagem entre si. A partir dessa ideia e com pesquisas mais avançadas, surgiu o comportamento inteligente (transportar para a máquina aquilo que o cérebro humano é capaz de fazer). É nesse momento que surgem as redes neurais artificiais, inspiradas no neurônio biológico, tal inspiração faz com que a rede neural seja capaz de adquirir e manter o conhecimento através de informações (Wasserman 1989), assim como o sistema nervoso humano.

Para Emaruch *et al.*(1994), a RNA procura resolver problemas a partir da imitação do cérebro humano, utilizando-se de um grande número de neurônios interligados, afim de processarem os sinais de entrada.

Segundo Haykin (2001), uma RNA é um processador maciço e paralelamente distribuído, constituído de unidades de processamento simples (neurônios), que têm a propensão natural para armazenar conhecimento adquirido

através de um processo de aprendizagem que leva a melhores resultados, tornando-o disponível para uso. Dessa forma, a RNA inspira-se no cérebro em dois aspectos:

1. o conhecimento é adquirido pela rede, a partir de seu ambiente, através de um processo de treinamento;
2. forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Em relação à formação das RNA's, as teorias não são tão divergentes, como pode-se perceber ao analisar as obras de alguns cientistas. Para Selli e Seleglim (2007), a RNA é como um mapeamento não linear de um vetor de espaço de entrada para um vetor de espaço de saída, onde as coordenadas de entrada são somadas conforme o valor de seus pesos e bias, produzindo uma saída simples.

Segundo Guyon (1991), a RNA é como uma estrutura lógico-matemática inspirada na forma, comportamento e funções de um neurônio biológico. De acordo com Emaruchi *et al.* (1994), a RNA é um método que procura resolver problemas através da imitação do cérebro humano utilizando-se de um grande número de neurônios interligados para processar os sinais de entrada.

As redes neurais também possuem características importantes, das quais podem se destacar três, de acordo com Silva, Spatti e Flauzino (2010). São elas: habilidade de adaptação por experiência objetivando aperfeiçoar seu desempenho e possibilitando a aquisição de conhecimento por experimentação; capacidade de aprendizado por intermédio de um algoritmo de treinamento; habilidade de generalização, isto é, após o treinamento da rede, essa é capaz de generalizar o conhecimento, podendo estimar soluções até então desconhecidas.

Segundo Liporace (1994), as redes neurais se caracterizam por grande quantidade de elementos de processamento simples, baseados no neurônio; grande número de conexões entre os elemento de processamento; controle paralelo e distribuído; capacidade de aprendizagem através da observação; robustez e manutenção do desempenho na presença de ruído e capacidade de lidar com dados incompletos.

Existem várias técnicas de segmentação de imagens sendo utilizadas na literatura. Nesta seção, veremos uma técnica baseada em RNA's para segmentação de imagens de satélite. A técnica que discutiremos é a Rede Neural de Pulso Acoplado, cujo termo em inglês é *Pulse Coupled Neural Network*(PCNN).

## 9 Rede Neural de Pulso Acoplado

A rede neural de pulso acoplado começou a ser estudada na década de 80 e 90. Pesquisando os fenômenos de pulso síncrono no córtex visual do gato, Eckhorn introduziu um campo de ligação na rede e descobriu que o cérebro, de uma forma oscilante, criava imagens binárias que poderia extrair diferentes características da impressão visual (Eckhorn *et al.* 1990). Com essa descoberta, o pesquisador desenvolveu uma rede neural chamada rede de Eckhorn, para simular esse comportamento em que os neurônios com entradas semelhantes geram pulsos simultaneamente. No entanto, de acordo com (Kuntimad e Ranganath 1999), a rede de Eckhorn sua performance depende da seleção adequada dos parâmetros quando usada para processamento de imagens.

Ao longo dos anos, pesquisadores estudaram modelos de neurônios para tornar a PCNN adequada para o processamento de imagens. Como resultado, aplicações baseadas em PCNN são discutidas (Kuntimad e Ranganath 1999), (Caufield e Kinser 1999), (Zhang, Dong e Shi 2005) e (Ranganath e Kuntimad 1996) modificaram o modelo de Eckhorn para aplicações de processamento de imagem, incluindo segmentação de imagem, suavização e detecção de objetos.

A PCNN é um modelo de rede neural de uma só camada e na sua utilização, para processamento de imagem, um neurônio corresponde a um pixel. O objetivo é aplicar uma PCNN em imagens de satélite do Estado de Goiás, a fim de verificar a eficácia desse modelo por meio de experimentos.

O modelo de PCNN desenvolvido por Eckhorn (Eckhorn *et al.* 1990) é uma rede simples construída através da simulação das atividades dos neurônios do córtex visual do gato, a PCNN consiste em três partes principais (Lindblad e kinser 2005): o campo de entrada, o campo de modulação e o gerador de pulso, conforme Figura 4. A PCNN produz um pulso de saída

quando estimulada, gerando imagens binárias. O modelo matemático da PCNN pode ser descrito pelas Equações (2-6) (Song, Xiao-Hui e Liu 2010), (Wang *et al.* 2010):

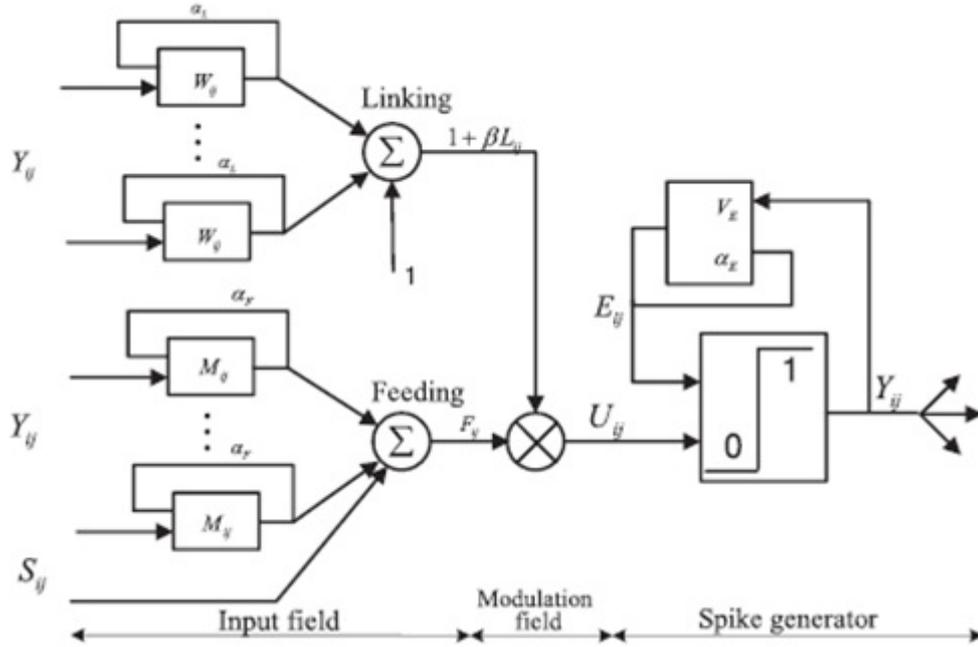


Figura 4: Modelo de PCNN Original (Gao, Zhou e Guo 2013)

$$F_{ij}(n) = e^{\alpha_F} F_{ij}[n-1] + V_F \sum_{k,l} M_{i,j,k,l} Y_{ij}[n-1] + S_{ij} \quad (2)$$

$$L_{ij}(n) = e^{\alpha_L} L_{ij}[n-1] + V_L \sum_{k,l} W_{i,j,k,l} Y_{ij}[n-1] \quad (3)$$

$$U_{ij}(n) = F_{ij}(n)[1 + \beta L_{ij}(n)] \quad (4)$$

$$Y_{ij} = \begin{cases} 1 & \text{se } U_{ij}(n) > E_{ij}(n), \\ 0 & \text{caso contrário.} \end{cases} \quad (5)$$

$$E_{ij}(n) = e^{\alpha_E} E_{ij}(n-1) + V_E Y_{ij}(n) \quad (6)$$

O campo de entrada contém duas partes: o campo receptivo *feeding*  $F_{ij}(n)$  e campo receptivo *linking*  $L_{ij}(n)$ . O campo receptivo *feeding* é alimentado

pela intensidade dos pixels da imagem  $(i, j)$ .  $S_{ij}$  é um estímulo externo. O campo receptivo *linking* é a entrada que comunica com os neurônios vizinhos através da matriz peso  $W$ .  $M$  e  $W$  referem-se à distância Gaussiana. Cada pixel da imagem é ligado a um único neurônio e cada neurônio é conectado com os neurônios vizinhos através de sinapses ligadas ao campo receptivo *linking*. A entrada  $F$  do neurônio recebe o estímulo de entrada  $S$ , que corresponde à intensidade do pixel.

A atividade interna do neurônio  $U_{ij}(n)$  é dada combinando as entradas do campo receptivo *feeding* e do campo receptivo *linking* no campo de modulação, onde  $\beta$  é o coeficiente de ligação. Se a atividade interna é grande, então, o neurônio irá gerar um pulso.  $V_F$  e  $V_L$  são constantes de amplitude e  $\alpha_F$  e  $\alpha_L$  são constante de decaimento do tempo.

O pulso gerador é composto da variável limiar e do gerador de pulsos.  $E_{ij}(n)$  é o limiar dinâmico, onde  $\alpha_E$  é a constante limiar de decaimento do tempo e  $V_E$  é a constante amplitude do limiar, que a PCNN pode trabalhar, meticulosamente, se  $\alpha_E$  for pequeno, mas esse processo vai demorar muito tempo para terminar, enquanto, se  $\alpha_E$  for maior o tempo de processamento decresce (Wang *et al.* 2010).

Quando o limiar  $E_{ij}(n)$  ultrapassa a atividade interna  $U_{ij}(n)$ , o pulso gerador é desligado e o limiar começa a diminuir exponencialmente (Yang 2009). Se  $U_{ij}(n) > E_{ij}(n)$ , o neurônio emite um pulso causando disparo do neurônio, enquanto a saída do neurônio correspondente  $Y_{ij}(n) = 1$ , este disparo alcançará os neurônios adjacentes, se estes tiverem a intensidade semelhante. A saída do neurônio é, em seguida, realimentada com um atraso de uma única interação. A saída do neurônio é, conseqüentemente,  $Y_{ij}(n) = 0$ , quando o limiar é maior do que a atividade interna.

## 10 Experimentos

Nesta seção o objetivo é aplicar uma PCNN em imagens de satélite do Estado de Goiás, a fim de verificar a eficácia desse modelo por meio de experimentos. A modelagem matemática da rede PCNN é descrita pelas Equações (2-6) acima. É apresentado na Figura 5 os resultado da segmentação de imagens de satélite utilizando a rede neural PCNN. Na primeira coluna tem-se as

imagens originais e na segunda coluna as imagens segmentadas.

Quando a PCNN é usada na segmentação de imagens, o número de neurônios na rede é igual ao número de pixels na imagem de entrada. A equação (2) indica que a intensidade de cada pixel é embutida no canal  $F_{ij}$  do neurônio, que é ligado a ele. Enquanto isso, cada neurônio está conectado com neurônios pelo canal  $L_{ij}$  em seu campo de 8 vizinhos, a equação (3). A saída de cada neurônio tem dois estados, 1 (dispara) ou 0 (não dispara). Em (5),  $Y_{ij}$  é a saída do neurônio, neste momento a rede retorna como resultado uma imagem binarizada, ou seja, tem-se a conversão de uma imagem preto e branco em uma matriz formada por números zeros e uns.

Na Figura 5 apresenta-se diferentes imagens de satélite do Estado de Goiás, na imagem 5.1 tem-se um reservatório de água entre os municípios de Três Ranchos e Cascvalho Rico. Na imagem 5.2 observa-se parte do Rio Paranaíba que corta o Estado de Goiás. Já nas imagens 5.3 e 5.4 encontra-se áreas reservadas para o plantio de culturas. Com isso, percebe-se que os resultados gerados pela rede neural PCNN se mostrou eficiente na segmentação de imagens de satélite tanto na segmentação de água, quanto na segmentação de solo que apresenta áreas destinadas a agricultura.

## 11 Conclusões

Neste artigo discute-se conceitos básicos e introdutórias de processamento de imagens. Lembrando que na prática o processamento de imagens é uma técnica extremamente dependente do problema ao qual se quer resolver. Existem várias técnicas utilizadas na segmentação de imagens e, normalmente as técnicas de processamento de imagens estão baseadas em métodos matemáticos que permitem descrever quantitativamente imagens das mais diversas origens.

Conhecendo estes conceitos básicos é possível realizar diversas operações na imagem desejada. Além disso, é conveniente ter uma base matemática que permita uma referência exata da composição da imagem, pois isto permite uma manipulação também exata, permitindo obter-se o resultado esperado após a manipulação.

É importante ressaltar que neste artigo utilizou-se uma RNA conhecida

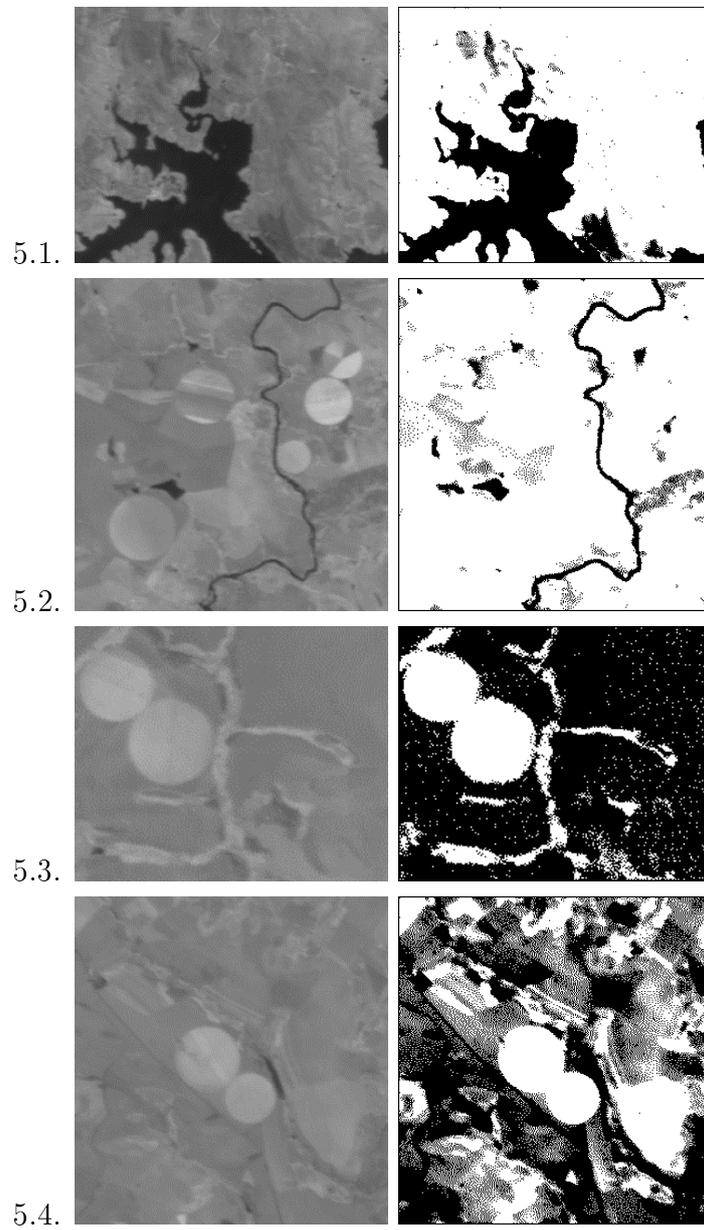


Figura 5: Resultados de segmentação com imagens de satélite usando rede neural PCNN

como rede neural de pulso acoplado - PCNN, como método de segmentação e que os resultados foram satisfatórios para a pesquisa e que o estudo das redes neurais é um dos ramos da Inteligência Artificial que mais se desenvolve, atraindo pessoas de diversas áreas do conhecimento. Todas as informações aqui expostas levam a crer que o campo de RNA's é acima de tudo extremamente vasto e promissor.

## Referências

- ALBANEZ, D. O.; BATISTA, M. A. e SILVA, S. F. (2015) Image Segmentation Based in Pulse Coupled Neural Network. *III ERIGO 2015 - Escola Regional de Informática de Goiás, Goiânia.*
- AZEVEDO, E.; CONCI, A. (2003) Computação Gráfica: geração de imagem. *Campus, Rio de Janeiro.*
- CAUFIELD, H. J.; KINSER, J. M. (1999) Finding shortest path in the shortest time using pcnn's. *IEEE Transactions on Neural Networks, X, n. 3, p. 604 – 606.*
- ECKHORN, R. *et al.* (1990) Feature linking via synchronization among distributed assemblies: Simulations of results from cat visual cortex. *Neural Computation, II, n. 3, p. 293 – 307.*
- EMARUCHI, B. *et al.* (1994) Land cover mapping using an artificial neural networks. *ISPRS mapping and geographic information systems, XXX, p. 84-89.*
- GAO, C.; ZHOU, D.; GUO, Y. (2013) Automatic iterative algorithm for image segmentation using a modified pulse-coupled neural network. *Neurocomputing, CXIX, p. 332 – 338.*
- GUYON, I. (1991) Neural networks and applications tutorial. *Physics Reports, XVII, n. 3, p. 215 – 259.*
- Haykin, S. (2001) Redes Neurais: princípios e prática. *Bookman, Porto Alegre.*
- KUNTIMAD, G.; RANGANATH, H. (1999) Perfect image segmentation

- using pulse coupled neural network. *IEEE Transactions on Neural Networks*, X, n. 3, p. 591 – 597.
- LINDBLAD, T.; KINSER, J. M.(2005) Image processing using pulse-coupled neural networks. *Springer*.
- LIPORACE, F. dos S. (2012) Um sistema neural para o monitoramento do desflorestamento na região Amazônica utilizando imagens do landsat. *Dissertação de Mestrado — Universidade Federal do Rio de Janeiro, Rio de Janeiro*.
- Yin, L.; Zhang, G.; Wu., Z. (2012) A scale-synthesis method for high resolution remote sensing image segmentation. *IEEE Transaction on Geoscience and Remote Sensing*, L, n.10, p.1–9.
- Gonzales, R. C.; Woods, R. E. (2001) Digital Image Processing. *Prentice Hall, New Jersey*.
- Petrou, M.; Bosdogianni, P. (1999) Image Processing: The Fundamentals 2 nd., *Wiley*.
- RANGANATH, H. S.; KUNTIMAD, G. (1996) Iterative segmentation using pulse-coupled neural networks. *SPIE*, n.2760, p. 543 – 554.
- RIBEIRO, E. F. (2009) Caracterização de Imagens Utilizando Redes Neurais. *Dissertação de Mestrado — Universidade Federal de Uberlândia, Uberlândia - MG*.
- SELLI, M. F.; SELEGHIM, P. J. (2007) On-line identification of horizontal two-phase flow regimes through gabor transform and neural network processing. *Heat Transfer Engineering*, VIII, n. 6, p. 541 – 548.
- SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. (2010) Redes Neurais Artificiais para Engenharia e Ciências Aplicadas *Atliber Editora Ltda, São Paulo*.
- SONG, Y.M.; XIAO-HUI, Z.; LIU, G. L. (2010) One segmentation algorithm of multi-target image based on improved pcnn. *Intelligent Systems and Applications (ISA), 2nd International Workshop on*, p. 1 – 4.
- ZHANG, J.; DONG, J.; SHI, M. (2005) An adaptive method for image

- filtering with pulse-coupled neural networks. *IEEE Int. Conf. on Image Processing, II*, n. 5-6, p. 133 –136.
- WANG, Z. *et al.* (2010) Image and vision computation. *Image and Vision Computation, XXVIII*, n. 1.
- WASSERMAN, P. D. (1989) Neural Computing Theory and Praticce. *Van Nostrand Reinhold, New York*.
- YANG, B. (2009) Search in two-way pulse coupled neural network and image segmentation. *J. Automation Technology and Application, XXVIII*, n. 5, p. 332 – 338.