



UNIVERSIDADE FEDERAL DE GOIÁS – REGIONAL CATALÃO
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA
MESTRADO ACADÊMICO EM MODELAGEM E OTIMIZAÇÃO



Daniela de Oliveira Albanez

**REDES NEURAIS ARTIFICIAIS APLICADAS À SEGMENTAÇÃO DE
IMAGENS**

DISSERTAÇÃO DE MESTRADO

CATALÃO – GO, 2017

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR AS TESES E DISSERTAÇÕES ELETRÔNICAS NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: ☒ **Dissertação** ☐ **Tese**

2. Identificação da Tese ou Dissertação

Nome completo do autor: Daniela de Oliveira Albanez

Título do trabalho: Redes Neurais Artificiais Aplicadas à Segmentação de Imagens

3. Informações de acesso ao documento:

Concorda com a liberação total do documento ☒ SIM ☐ NÃO¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.



Assinatura do (a) autor (a) ²

Data: 24 / 02 / 2017

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

²A assinatura deve ser escaneada.

DANIELA DE OLIVEIRA ALBANEZ

REDES NEURAIAS ARTIFICIAIS APLICADAS À SEGMENTAÇÃO DE
IMAGENS

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre em Modelagem e Otimização pela Universidade Federal de Goiás – Regional Catalão.

Orientador:
Prof. Drº. Marcos Aurélio Batista

CATALÃO – GO

2017

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Albanez, Daniela de Oliveira
Redes Neurais Artificiais Aplicadas à Segmentação de Imagens
[manuscrito] / Daniela de Oliveira Albanez. - 2017.
clii, 152 f.: il.

Orientador: Prof. Dr. Marcos Aurélio Batista.
Dissertação (Mestrado) - Universidade Federal de Goiás, Unidade
Acadêmica Especial de Matemática e Tecnologia, Catalão,
Programa de Pós-Graduação em Modelagem e Otimização, Catalão, 2017.
Bibliografia. Anexos.
Inclui tabelas, algoritmos, lista de figuras, lista de tabelas.

1. Segmentação de Imagens. 2. Redes Neurais Artificiais. 3. Imagens
de Satélite. I. Aurélio Batista, Marcos, orient. II. Título.

CDU 517



Defesa Nº 14

Ata de Defesa Pública – Dissertação de Mestrado

Aos 15 dias do mês de fevereiro do ano de 2017, às 14 h: 19 min, reuniram-se os componentes da banca examinadora, Prof. Dr. Marcos Aurélio Batista (presidente e orientador), Profa. Dra. Célia Aparecida Zorzo Barcelos e Prof. Dr. Sérgio Francisco da Silva para, em sessão pública realizada na sala de reuniões - bl. perq., da Regional Catalão (RC), da Universidade Federal de Goiás (UFG), procederem com a avaliação do trabalho intitulado: “Redes Neurais Artificiais aplicadas à Segmentação de Imagens”, em nível de Mestrado, área de concentração *Modelagem e Otimização*, de autoria de Daniela de Oliveira Albanéz, discente do Programa de Pós-Graduação em Modelagem e Otimização (PPGMO) da UFG/RC. A sessão foi aberta pelo presidente da banca, que fez a apresentação formal dos membros da banca. A seguir, a palavra foi concedida ao discente que, dentro do tempo regulamentar, procedeu a apresentação de seu trabalho. Terminada a apresentação, cada membro da banca arguiu o candidato, tendo-se adotado o sistema de diálogo sequencial. Terminada a fase de arguição, procedeu-se a avaliação do trabalho. Os membros da banca consideraram o trabalho final: (X) **Aprovado** (unanimidade) ou () **Reprovado** (por maioria simples). Cumpridas as formalidades de pauta, às 15 h: 52 min a presidência da mesa encerrou a sessão e para constar, eu, Marcos Aurélio Batista, lavrei a presente Ata que, depois de lida e aprovada, segue assinada pelos membros da banca examinadora e pelo discente e, posteriormente, será homologada pelo Colegiado do PPGMO.

Catalão-GO, 15 de fevereiro de 2017,

Prof. Dr. Marcos Aurélio Batista
Programa de Pós-Graduação em Modelagem e
Otimização, UFG/RC.
(Presidente da Banca)

Profa. Dra. Célia Aparecida Zorzo Barcelos
FAMAT/UFU

Prof. Dr. Sérgio Francisco da Silva
Programa de Pós-Graduação em Modelagem e
Otimização, UFG/RC.

Daniela de Oliveira Albanéz
Programa de Pós-Graduação em Modelagem e
Otimização, UFG/RC.

Dedico este trabalho a toda minha família e amigos que me deram apoio incondicional durante esta caminhada. Em especial, à minha mãe Célia Aparecida de Oliveira Albanez e ao meu pai Romildo Albanez que, sem dúvida nenhuma, formam a base da minha vida.

Agradecimentos

Agradeço primeiramente à Deus, pela vitória conquistada.

Agradeço ao meu orientador, Prof. Drº. Marcos Aurélio Batista, pelas horas dedicadas a me orientar e por ajudar a minha formação profissional e pessoal.

Agradeço ao Prof. Drº. Sérgio F da Silva pela ajuda, na parte de programação e por toda a experiência que me foi transmitida.

Agradeço à banca examinadora pela paciência de ler este extenso documento.

Agradeço à Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) ; à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Tecnológico (CNPq) pelo apoio financeiro durante todo o curso de Mestrado.

Agradeço ao Programa de Pós-Graduação em Modelagem e Otimização (PPGMO), por ter me recebido e criado um ambiente favorável para que esta conquista pudesse se tornar realidade.

Agradeço aos professores do PPGMO, pelo conhecimento transmitido e toda ajuda prestada.

Agradeço aos amigos, colegas e familiares, que me apoiaram nesta caminhada.

Por fim, agradeço à Universidade Federal de Goiás (UFG) - Regional Catalão (RC) , por tantos momentos e tantas oportunidades que me foram proporcionadas.

"O degrau de uma escada não serve simplesmente para que alguém permaneça em cima dele, destina-se a sustentar o pé de um homem pelo tempo suficiente para que ele coloque o outro um pouco mais alto".

Thomas Huxley

RESUMO

ALBANEZ, D. DE O.. *Redes Neurais Artificiais Aplicadas à Segmentação de Imagens*. 2017. 154 f. Dissertação (Mestrado em Modelagem e Otimização) – Unidade Acadêmica Especial de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

Segmentação de imagens é um dos problemas de processamento de imagens que merece especial interesse da comunidade científica, tendo em vista sua real utilidade e aplicação em várias áreas do conhecimento como na medicina, geografia, engenharia, matemática e computação, só para citar algumas. Grande parte do interesse recente sobre segmentação foi motivado pela disponibilidade de imagens de satélite sobre a superfície da Terra, que podem ser transformadas em conhecimento concreto, visando o monitoramento e a mineração do uso da terra. Este trabalho propõe um novo método de segmentação, através de técnicas de Inteligência Artificial, mais especificamente pelas Redes Neurais Artificiais (RNA's), e compara seus resultados de segmentação de imagens de satélite com o método original descrito na literatura. Os resultados binarizados são comparados com o *ground truth* para a validação do método de segmentação proposto. Resultados experimentais, realizados através da análise quantitativa dos resultados de segmentação, indicam que o método de segmentação proposto produz melhores resultados e uma redução média total do desempenho computacional de 36.60% em relação ao método original.

Palavras-chaves: Segmentação de Imagens, Redes Neurais Artificiais, Imagens de Satélite.

ABSTRACT

ALBANEZ, D. DE O.. *Artificial Neural Networks Applied to Image Segmentation*. 2017. 154 f. Master Thesis in Modelling and Optimization – Special Academic Unit of Mathematics and Technology, Federal University of Goiás - Regional Catalão, Catalão - GO.

Image segmentation is one of image processing problems that deserve special interest of the scientific community, given its real utility and application in various areas as medicine, geography, engineering, mathematics and computing, just to name a few. Much of the recent interest in segmentation has been motivated by the availability of satellite images on the Earth's surface, which can be transformed into concrete knowledge, aiming at land use monitoring and data mining. This work proposes a new segmentation method, using Artificial Intelligence techniques, more specifically Artificial Neural Networks (ANNs), and compare its results of segmentation of satellite images with the original method. The binarized results are compared with the ground truth for the validation of the proposed segmentation method. Experimental results, quantitative analysis of segmentation results, indicating that the proposed segmentation method generates better results and a decaying of 36.60% in the total average computational time when compared with the original method.

Keywords: Image Segmentation, Artificial Neural Networks, Satellite Images.

RESUMEN

ALBANEZ, D. DE O.. *Redes Neuronales Artificiales Aplicadas a la Segmentación de Imágenes*. 2017. 154 f. Tesis Doctoral en Modelado y Optimización – Unidad Académica Especial de Matemáticas y Tecnología, Universidad Federal de Goiás - Regional Catalão, Catalão - GO.

Image segmentation is one of image processing problems that deserve special interest of the scientific community, given its real utility and application in various areas as medicine, geography, engineering, mathematics and computing, just to name a few. Much of the recent interest in segmentation has been motivated by the availability of satellite images on the Earth's surface, which can be transformed into concrete knowledge, aiming at land use monitoring and data mining. This work proposes a new segmentation method, using Artificial Intelligence techniques, more specifically Artificial Neural Networks (ANNs), and compare its results of segmentation of satellite images with the original method. The binarized results are compared with the ground truth for the validation of the proposed segmentation method. Experimental results, quantitative analysis of segmentation results, indicating that the proposed segmentation method generates better results and a decaying of 36.60% in the total average computational time when compared with the original method.

Palabras Clave: Segmentación de la imagen, Segmentación de la imagen, Segmentación de la imagen.

LISTA DE FIGURAS

Figura 2.1 – Corte horizontal do olho humano.	30
Figura 2.2 – Pixels de uma imagem.	31
Figura 2.3 – Modelo de máscara usada para detecção de pontos isolados.	34
Figura 2.4 – Máscaras de detecção de linhas.	34
Figura 2.5 – Representações dos três tipos de borda que existem. a) Borda em degrau. b) Borda em rampa. c) Borda em telhado.	35
Figura 2.6 – Segmentação de uma imagem com zona problema.	36
Figura 2.7 – <i>Split and Merge</i>	36
Figura 2.8 – Descrição de imagens matriciais por um conjunto de pixels.	38
Figura 2.9 – Representação Vetorial x Representação Matricial.	38
Figura 2.10 – Prisma Óptico.	38
Figura 2.11 – Espectro do comprimento de onda da luz visível.	39
Figura 2.12 – Modelo de Cores RGB.	41
Figura 2.13 – Modelo de Cores HSV.	42
Figura 2.14 – Textura.	43
Figura 3.1 – Neurônio biológico.	49
Figura 3.2 – Representação do neurônio matemático.	50
Figura 3.3 – Função Limiar (Degrau); Função Linear Por Partes e Função Sigmóide.	51
Figura 3.4 – Rede alimentada adiante com uma única camada de neurônio.	57
Figura 3.5 – Rede alimentada adiante totalmente conectada com uma camada oculta.	58
Figura 3.6 – Rede Recorrente.	59
Figura 5.1 – Modelo de PCNN Original.	68
Figura 5.2 – Modelo PCNN Proposto.	71
Figura 6.1 – Imagens originais na primeira coluna e resultados de segmentação obtidos pelos métodos analisados: segunda coluna - <i>ground truth</i> ; terceira coluna - PCNN Original; quarta coluna - PCNN Proposta.	74
Figura 6.2 – Imagens originais na primeira coluna e resultados de segmentação obtidos pelos métodos analisados: segunda coluna - <i>ground truth</i> ; terceira coluna - PCNN Original; quarta coluna - PCNN Proposta.	75

Figura 6.3 – Desempenho computacional das imagens presentes na literatura. 79

Figura 6.4 – Desempenho computacional das imagens de satélite. 79

LISTA DE TABELAS

Tabela 6.1 – Medidas de avaliação quantitativa com relação às imagens presentes na literatura	78
Tabela 6.2 – Medidas de avaliação quantitativa com relação às imagens de satélite . . .	78

LISTA DE ALGORITMOS

Algoritmo 5.1 – Algoritmo para segmentação de imagem com o modelo de PCNN pro-	
posto.	70

SUMÁRIO

1	INTRODUÇÃO	25
1.1	Considerações Iniciais	25
1.2	Motivação	25
1.3	Justificativa	26
1.4	Objetivos	27
1.5	Organização da Dissertação	27
2	PROCESSAMENTO DE IMAGENS	29
2.1	Percepção Visual Humana	29
2.2	Definição de Imagem	30
2.3	Aquisição de Imagens	31
2.4	Pré-Processamento de Imagens	32
2.4.1	Histograma de Cores	32
2.5	Segmentação de Imagens	33
2.5.1	Segmentação por Descontinuidade	33
2.5.1.1	Detecção de Pontos Isolados	33
2.5.1.2	Detecção de Linhas	34
2.5.1.3	Detecção de Bordas	35
2.5.2	Segmentação por Similaridade	35
2.5.2.1	Crescimento de Região	35
2.5.2.2	Divisão e Agrupamento de Região (<i>Split and Merge</i>)	36
2.5.2.3	Limiarização (<i>Thresholding</i>)	36
2.6	Representação de Imagens	37
2.7	Descrição de Cor	38
2.7.0.1	Modelo de Cor	40
2.7.1	Descrição de Textura	42
3	REDES NEURAIS ARTIFICIAIS	45
3.1	Introdução	45
3.2	Redes Neurais	46
3.3	Neurônio Biológico	48
3.4	Sinapses	48

3.5	Neurônio Artificial	49
3.6	Aprendizado da Rede Neural	52
3.6.1	Aprendizado Supervisionado	52
3.6.2	Aprendizado Não-Supervisionado	53
3.6.3	Algoritmos de Aprendizagem	53
3.7	Arquitetura da Rede Neural	56
3.7.1	Redes Alimentadas Adiante com Camada Única (Perceptrons)	56
3.7.2	Redes Alimentadas Adiante com Múltiplas Camadas	57
3.7.3	Redes Recorrentes	58
4	ESTADO DA ARTE	61
5	MÉTODOS	67
5.1	Introdução	67
5.2	Rede Neural de Pulso Acoplado - Modelo Original	68
5.3	Modelo de PCNN Proposto	69
6	RESULTADOS	73
7	CONCLUSÃO	81
REFERÊNCIAS		83
ANEXO A	IMAGE SEGMENTATION BY OTSU METHOD	91
ANEXO B	IMAGE SEGMENTATION BASED IN PULSE COUPLED NEURAL NETWORK	101
ANEXO C	IMAGE SEGMENTATION BASED IN PULSE COUPLED NEURAL NETWORK	113
ANEXO D	SEGMENTAÇÃO DE IMAGENS UTILIZANDO REDES NEURAIS ARTIFICIAIS	117
ANEXO E	APLICAÇÃO DE ALGORITMOS DE OTIMIZAÇÃO A ABSORVEDOR DINÂMICO DE VIBRAÇÃO	123
ANEXO F	SEGMENTAÇÃO DE IMAGENS USANDO REDE NEURAL HOPFIELD	131
ANEXO G	O QUE É SEGMENTAÇÃO DE IMAGENS?	137

Capítulo 1

Introdução

1.1 Considerações Iniciais

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; WOODS, 2001](#)). Desde então, essa área de pesquisa evolui de forma significativa.

Atualmente, a questão ambiental tornou-se um assunto importante para toda a sociedade, dada a grande devastação, dentre outros fatores, em virtude da produção agrícola. Nesse contexto, o monitoramento e a mineração do uso da terra se tornam cada vez mais importantes, já que se pode acompanhar esse processo por meio de imagens de satélite.

Ao longo deste trabalho, propõe-se apresentar como é realizada a segmentação das imagens utilizando Redes Neurais Artificiais (RNA's). 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. As RNA's são inspiradas na definição matemática de um neurônio e no entendimento do funcionamento dessa célula no comportamento humano. Ressalta-se que se optou por utilizar as RNA's 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](#)).

1.2 Motivação

O cérebro possui incrível capacidade de processamento. Com sua estrutura altamente complexa, não linear e paralela, permite executar alguns tipos de tarefas mais rapidamente do que qualquer computador, embora seja superado pelas máquinas atuais na execução de operações matemáticas e repetitivas. Para exemplificar a incrível capacidade do cérebro humano, o sistema visual precisa criar uma representação do ambiente e extrair

toda informação necessária para sua interação com o mesmo em uma fração de segundos. Esse exemplo está entre as tarefas rotineiras de reconhecimento perceptivo do cérebro humano, que são feitas em pouco mais de 100ms, enquanto um computador pode levar horas, ou até dias para fazer o mesmo procedimento (HAYKIN, 2001).

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.

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.

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. 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. É válido lembrar que, neste trabalho, investigaremos métodos de segmentação de imagens por meio das RNA's.

1.3 Justificativa

O desmatamento e as atividades agrícolas são os principais fatores da grande devastação ambiental, com isso, tornou-se necessária a utilização de técnicas capazes de monitorar a superfície terrestre. Com o monitoramento e a mineração do uso da terra, juntamente com as imagens de satélite disponíveis gratuitamente pelo INPE (Instituto Nacional de Pesquisas Espaciais), o Brasil se transformou em um exemplo mundial na busca pela conservação da natureza.

De acordo com dados divulgados em setembro de 2016 pelo INPE, a Amazônia já perdeu 20% de sua cobertura vegetal original. No ano de 2015 o desmatamento na Amazônia cresceu 24% em relação ao ano anterior, mas ainda é a quarta menor taxa de desmatamento desde 1988 e corresponde a 68,5% de redução. O Cerrado já perdeu cerca de 50% da vegetação original no Brasil. Dados preliminares de 2015, proveniente do Projeto TerraClass, realizado pelo INPE e EMBRAPA, indicam uma crescente taxa de desmatamento no Cerrado, o estado de Goiás possui apenas 43% de sua vegetação natural e, além disso, o referido es-

tado contribui com 21% de área desmatada acumulada no total no Brasil.

Diante disso, o problema clássico de processamento de imagens é determinar se a imagem contém ou não um dado objeto ou atividade. A partir daí, o problema concentra-se no desenvolvimento de uma Rede Neural capaz de segmentar objetos na imagem e posteriormente, analisá-la com base em uma métrica confiável.

1.4 Objetivos

A presente dissertação propõe fazer um levantamento bibliográfico de alguns métodos de segmentação de imagens por redes neurais e, além disso, fazer uma comparação de dois métodos de segmentação de imagens via utilização da inteligência artificial, mais especificamente, Redes Neurais. O primeiro método é o método original da Rede Neural de Pulso Acoplado, cujo termo em inglês é *Pulse Coupled Neural Network (PCNN)*, o segundo método é uma proposta mais direta para a PCNN original. A partir dos resultados obtidos por ambas as redes será realizado uma análise quantitativa para avaliar qual rede teve o melhor desempenho no processo de segmentação. Para isso, as RNAs irão atuar como uma abstração matemática, inspirada no cérebro humano, para adquirir conhecimento através da experiência, o que, por sua vez, será feito por meio do treinamento da rede. Após realizado esse treinamento com imagens presentes na literatura, os pesos estarão prontos para serem usados em imagens de satélite.

1.5 Organização da Dissertação

Esta dissertação se desenvolve ao longo de 7 capítulos. No Capítulo 1, faz-se a introdução do contexto ao que se insere este trabalho, a justificativa e motivação para seu desenvolvimento e dos objetivos a serem alcançados.

No Capítulo 2, ressalta-se os conceitos iniciais sobre o Processamento de Imagens, incluindo a percepção visual humana.

No Capítulo 3 são introduzidos conceitos sobre neurônio biológico, ou seja, é o capítulo que teoriza e dá base à explicação das Redes Neurais Artificiais. Ainda nesse capítulo, apresentam-se conceitos necessários para o entendimento das Redes Neurais Artificiais, bem com o aprendizado e as arquiteturas.

No Capítulo 4, explana-se o estado da arte relacionado à Segmentação de Imagens usando Redes Neurais Artificiais.

No Capítulo 5, descreve-se um método de segmentação de imagens, usando redes neurais juntamente com o método proposto.

Os resultados obtidos e discussões estão presentes no Capítulo 6.

Finalmente, as considerações finais e proposta de trabalhos futuros são apresentadas no Capítulo 7. Em seguida, são listadas as referências bibliográficas e, ainda são apresentados todos os artigos publicados durante o decorrer do mestrado (Anexos).

Capítulo 2

Processamento de Imagens

2.1 Percepção Visual Humana


O ser humano é dotado de cinco sentidos, todos importantes. A visão, devido a sua complexidade e importância do sistema visual, é o sentido mais estudado e o menos entendido entre os sistemas sensórios, conforme diz Kovács (1997). O sistema visual do ser humano é composto, principalmente, por dois olhos e pelo córtex visual. Um olho humano mede, aproximadamente, 20 milímetros de diâmetro e é o responsável por captar a luz refletida pelos objetos à sua volta e transmitir tal informação ao córtex visual no cérebro (GONZALES; WOODS, 2001).

Além disso, o olho humano é envolvido por três membranas: a córnea e a cobertura externa da esclerótica, a coróide e a retina. Na Figura 2.1, é apresentado um desenho que representa um corte horizontal do olho humano. À frente do olho está a córnea, um tecido resistente e transparente, que tem por função principal refratar a luz e atua como a lente de uma câmera, se fizermos a analogia com um objeto técnico.

A esclerótica, contínua à córnea, é uma membrana opaca que envolve o restante do olho. A coróide, situada abaixo da esclerótica, contém uma rede de vasos sanguíneos que servem como principal fonte de nutrição do olho. Na extremidade anterior, a coróide é dividida em corpo ciliar e íris, que contrai e expande de forma a controlar a quantidade de luz que entra no olho. A abertura central da íris, responsável por esse controle de luz, chama-se pupila.

Atrás da íris está o cristalino, que é formado por camadas de células fibrosas. A função principal do cristalino é permitir a visão nítida em todas as distâncias. Quando se olha para perto, o cristalino torna-se convergente, aumentando o seu poder de refração e, quando se olha para longe, o cristalino torna-se menos convergente, diminuindo seu poder dióptrico. Esse processo feito pelo cristalino é conhecido por acomodação, o que faz com que a visão seja nítida em todas as distâncias. A acomodação, por sua vez, é controlada pelo corpo ciliar,

Figura 2.1 – Corte horizontal do olho humano.



Fonte: (RIBEIRO, 2009).

composto por um grupo de músculos que cercam o cristalino.

Por trás do cristalino, encontra-se o humor vítreo, que tem a função de sustentar a forma do olho e, ainda antes dele, por trás, está a retina, onde a luz de um objeto fora do olho se torna uma imagem. A retina possui receptores discretos de luz espalhados por sua superfície, os quais são chamados: cones e bastonetes. Os cones são responsáveis pela visão colorida e os bastonetes permitem a visão noturna. Quando a energia luminosa atinge os cones e bastonetes, a luz converte-se em impulsos elétricos que são transmitidos ao cérebro.


2.2 Definição de Imagem

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 2.2 ilustra a representação numérica de uma imagem ampliada de 4×4 pixels. Sendo assim, em uma imagem, quanto mais pixels ela tiver, melhor a sua resolução e qualidade.

Figura 2.2 – Pixels de uma imagem.



Fonte: o autor.

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 dados pelas coordenadas abaixo, que juntamente com a vizinhança-4, formam a vizinhança-8.

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

É preciso ressaltar que o conceito de vizinhança é muito utilizado no processamento de imagens, tendo em vista sua importância para tarefas de processamento local.

2.3 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.

2.4 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; 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; WOODS, 2001) são as seguintes:

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

2.4.1 Histograma de Cores

Um histograma é uma função discreta que pode ser representado pela Equação 2.1 (GONZALES; WOODS, 2001; PETROU; BOSDOGIANNI, 1999), ou seja, é a representação da distribuição de cores em uma imagem. Com o histograma é possível determinar se a imagem está bem contratada, escura ou muito clara.

O histograma de cores é constituído por *bins*, uma para cada cor presente na imagem, dentro de um espaço de cores. Inicialmente representa a quantidade de ocorrências de uma determinada cor. Em seguida, 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; WOODS, 2001):

$$p(k) = \frac{n_k}{n} \quad (2.1)$$

onde:

k é o nível de cinza, $k \in \{1, 2, \dots, L\}$, onde L é o número total de níveis de cinza que podem estar presentes na imagem.

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, $n = M \times N$.

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.

2.5 Segmentação de Imagens

No que diz respeito ao processamento de imagens, percebe-se que, feito o 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. O assunto tem sido estudado nas diversas áreas de análise de imagens. Segundo [Gonzales e Woods \(2001\)](#) "os algoritmos para segmentação são usualmente baseados em duas propriedades das imagens: *i*) descontinuidade e *ii*) similaridade".

Na descontinuidade, o particionamento da imagem é baseado no subconjunto de pontos de um objeto que o separa do restante da imagem, ou seja, são representadas por mudanças bruscas feitas nos tons de cinza, cores e texturas. Na similaridade, a segmentação é baseada nas técnicas de limiarização, crescimento por regiões, divisão e agrupamento de regiões, ou seja, baseiam-se nos aspectos em comum dos diversos pixels ([GONZALES; WOODS, 2001](#)).

2.5.1 Segmentação por Descontinuidade

Essa abordagem consiste em particionar a imagem com base em mudanças nos níveis de cinza, utilizando a detecção de pontos isolados, linhas ou bordas.

2.5.1.1 Detecção de Pontos Isolados

Para se detectar pontos isolados são usadas máscaras que possuem coeficientes cuja soma é sempre zero, conforme visto na Figura 2.3. Um ponto, denotado pelo valor 1, é detectado no local (x, y) , onde a máscara esta centrada, caso o módulo do valor de resposta da convolução da máscara neste ponto exceda o limiar estabelecido; caso contrário não é detectado ponto no local (x, y) , que receberá o valor 0. Esse método é dado pela seguinte

equação:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T, \\ 0 & \text{caso contrário.} \end{cases} \quad (2.2)$$

onde:

- $f(x, y)$ é a imagem de entrada,
- T é o limiar
- $g(x, y)$ é a imagem de saída.

Figura 2.3 – Modelo de máscara usada para detecção de pontos isolados.

1	1	1
1	-8	1
1	1	1

Fonte: o autor.

2.5.1.2 Detecção de Linhas

A detecção de linhas se assemelha ao método anterior, podendo-se utilizar a mesma máscara da Figura 2.3. Esse método pode ser orientado a reconhecer linhas em direções específicas da imagem. Para este tipo de detecção são usados pesos maiores nos coeficientes da máscara na direção em que se deseja encontrar as linhas. A soma dos coeficientes da máscara continua sendo 0. A Figura 2.4 mostra os ângulos em relação ao sistema de eixos.

Figura 2.4 – Máscaras de detecção de linhas.

-1	-1	-1
2	2	2
-1	-1	-1

Horizontal

-1	-1	2
-1	2	-1
2	-1	-1

+45°

-1	2	-1
-1	2	-1
-1	2	-1

Vertical

2	-1	-1
-1	2	-1
-1	-1	2


-45°

Fonte: o autor.

2.5.1.3 Detecção de Bordas

De acordo com [Gonzales e Woods \(2001\)](#), na abordagem de descontinuidade, o método de detecção de bordas é o procedimento mais comum para a segmentação de imagens. Para [Schoenmakers, Wilkinson e Schoauten \(1991\)](#), esse método é o processo pelo qual os fragmentos de bordas são definidos e, posteriormente, compostos em uma estrutura mais elaborada, representando uma fronteira de classe homogênea. A borda pode ser classificada de três maneiras: borda em degrau, rampa ou telhado, conforme visto na Figura 2.5.

Figura 2.5 – Representações dos três tipos de borda que existem. a) Borda em degrau. b) Borda em rampa. c) Borda em telhado.



Fonte: o autor.

2.5.2 Segmentação por Similaridade

As principais abordagens desse tipo de segmentação se baseiam em limiarização e crescimento de regiões. Essa segmentação particiona a imagem em regiões constituintes, seguindo algum critério pré-estabelecido, baseando-se na análise dos objetos. Essa abordagem se divide em: *i*) crescimento de região, *ii*) divisão e agrupamento de região (*Split and Merge*) e *iii*) limiarização.


2.5.2.1 Crescimento de Região

O crescimento de região é um processo pelo qual os pixels com características semelhantes em uma vizinhança são agrupados em regiões maiores, partindo-se de um pixel denominado a "semente" da região. [Gonzales e Woods \(2001\)](#) propõe que para a segmentação de imagens monocromáticas, admi-se uma propriedade P , que é utilizada para classificar um pixel de uma determinada região (ou seja, o valor absoluto da diferença entre o nível de cinza de um pixel e o nível de cinza tomado como "semente"), todo pixel de uma vizinhança que possuir uma diferença menor que um limite T do pixel semente será enquadrado na região desse pixel. Esse método se diferencia do método de limiarização apenas pelo fato de levar em consideração a informação do ponto da vizinhança.

De acordo com [Schoenmakers, Wilkinson e Schoauten \(1991\)](#), esta abordagem procura por pixels com características similares aos segmentos adjacentes. Se a similaridade for satisfatória, ela os ligam a estes segmentos. O crescimento de regiões continua até que

encontre uma zona problema, isto é, características que não satisfazem aos critérios fornecidos, como visto na Figura 2.6.

Figura 2.6 – Segmentação de uma imagem com zona problema.




Fonte: o autor.

2.5.2.2 Divisão e Agrupamento de Região (*Split and Merge*)

O processo que acabamos de discutir, cresce regiões a partir de um conjunto de pontos de sementes. A operação *split* divide uma determinada região em quatro novas regiões, cada uma corresponde a um quadrante da região original, enquanto que a operação *merge* agrupa regiões adjacentes que satisfaçam os critérios de homogeneidade. O método *Split and Merge* é a combinação da divisão com agrupamento de regiões, utilizando simultaneamente as vantagens das duas operações.

Esse método utiliza uma estrutura de dados chamada *quadtree* (*quadtree* é uma árvore em que cada nó possui quatro descendentes), como visto na Figura 2.7.

Figura 2.7 – *Split and Merge*.



Fonte: o autor.

2.5.2.3 Limiarização (*Thresholding*)

O método de limiarização foi adotado, primeiramente, para segmentação de imagens em tons de cinza e, posteriormente, para imagens multicromáticas. A limiarização serve

para determinar para qual faixa de intensidade o pixel vai pertencer à região e qual faixa fará parte do fundo. Basicamente, faz-se uma varredura na imagem, pixel a pixel, determinando um valor binário em função de um limiar pré-estabelecido. Assim, para intensidades maiores que o limiar T , o pixel é considerado da região, caso contrário, é considerado como fundo. O pixel pertencente à região recebe valor 1 e o pixel do fundo recebe valor 0. Então, qualquer ponto (x, y) em que $f(x, y) > T$, é chamado um ponto de objeto, caso contrário, o ponto é chamado de ponto de fundo. O processo de limiarização é descrito pela Equação 2.3:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T, \\ 0 & \text{se } f(x, y) \leq T. \end{cases} \quad (2.3)$$

2.6 Representação de Imagens


Como a saída do estágio de segmentação geralmente são resultados brutos de pixels, podem ser necessário converter esses dados em uma forma conveniente, possibilitando o processamento. Existem dois tipos de representação que podem ser utilizados: a representação para fronteiras ou bordas, que é adequada quando o foco está em características externas, como a forma, e a representação por regiões, que é adequada quando o foco está em características internas, como textura e cor.

Contudo, escolher a representação é apenas parte da solução para a transformação de dados brutos em uma forma conveniente para o processamento computacional. A descrição, portanto, nada mais é do que a extração de características que diferenciam uma classe de objetos de outra (GONZALES; WOODS, 2001).

As imagens podem ser representadas de duas formas: matricialmente e vetorialmente. Na representação matricial, a imagem é descrita por um conjunto de células de grade, ou seja, uma matriz, onde cada célula representa um pixel da imagem (AZEVEDO; CONCI, 2003). Essa representação é usada para formar a imagem na memória e nas telas de computador, como é representado na Figura 2.8:


Por definição, vetores são elementos de dados que permitem descrever posição e direção. Na representação vetorial são usados elementos básicos como, pontos, linhas e curvas. Cada um desses elementos possuem um conjunto de atributos que define sua aparência e um conjunto de dados que define sua geometria (AZEVEDO; CONCI, 2003). Na Figura 2.9 pode-se observar à esquerda a representação vetorial e à direita a representação matricial da imagem.

Figura 2.8 – Descrição de imagens matriciais por um conjunto de pixels.



Fonte: o autor.

Figura 2.9 – Representação Vetorial x Representação Matricial.




Fonte: o autor.

2.7 Descrição de Cor

As cores que percebemos são determinadas pela natureza da luz refletida. De acordo com [Gonzales e Woods \(2001\)](#) em 1666, Isaac Newton descobriu que um feixe de luz solar é decomposto ao passar no prisma, como visto na Figura 2.10. O fato do prisma decompor a luz branca comprova a natureza ondulatória da radiação, visto que essa se deve à variação do índice de refração do prisma nos diferentes comprimentos de onda.


Figura 2.10 – Prisma Óptico.



Fonte: (GONZALES; WOODS, 2001).

As cores que conhecemos, denominadas de luz visível, é uma pequena parcela do espectro eletromagnético. Como consta na Figura 2.11, a gama de cor que percebemos em luz visível representa uma porção muito pequena do espectro electromagnético de 400nm a 700nm aproximadamente. Desde 1931 aceita-se os valores 435.8nm, 546.1nm e 700nm como sendo as três cores primárias: azul, verde e vermelho, respectivamente. De acordo com a CIE ("*Commission Internationale del'Eclairage*") (SOUTO, 2000), esse sistema é conhecido com RGB (Red (vermelho), Green (verde) e Blue (azul)).

Figura 2.11 – Espectro do comprimento de onda da luz visível.



Fonte: (RIBEIRO, 2009).

A luz visível, também chamada de luz cromática, é descrita por três valores (GONZALES; WOODS, 2001):

- Radiância: quantidade total de energia que flui de uma fonte de luz, medida em watt;
- Luminância: quantidade de energia que o observador percebe da fonte de luz, medida em lúmen;
- Brilho: descritor subjetivo, praticamente impossível de ser medido. Incorpora a noção acromática (sem cores) de intensidade.

As características usadas para distinguir uma cor da outra são brilho, matiz e saturação (GONZALES; WOODS, 2001):

- Matiz: atributo associado ao comprimento de onda dominante em uma mistura de ondas de luz, ou seja, o matiz representa a cor dominante.
- Saturação: refere-se a pureza relativa, ou, quantidade de luz branca misturada com o matiz.

As cores preta, branca e cinza possuem saturação uniforme em todos os comprimentos de onda, sendo diferenciadas apenas pelo brilho.

A cor C de cada pixel da imagem pode ser representada, matematicamente, por:

$$C = r * R + g * G + b * B \quad (2.4)$$

onde R , G e B são as três cores primárias e r , g e b são os coeficiente de mistura correspondentes a cada uma das três bandas espectrais que compõe a imagem. Dessa forma, a cor C de cada pixel da imagem pode ser plotada no espaço de cores RGB usando-se os coeficiente de mistura (r, g, b) como coordenadas.

2.7.0.1 Modelo de Cor

Existem vários modelos de cores, os mais conhecidos são: RGB (red, green, blue) e HSV (hue, saturation, value), mas, existem ainda HLS, CMY, YIK e YcbCr. Todos esses modelos podem ser derivados dos dois primeiros.

No modelo de cores desenvolvido pela CIE, as cores são especificadas pela combinação das cores primárias X , Y e Z . As quantidades das cores primárias presentes em uma cor são chamadas de coeficientes tricromáticos, dadas por (GONZALES; WOODS, 2001):

$$x = \frac{X}{X + Y + Z} \quad (2.5)$$

$$y = \frac{Y}{x + Y + Z} \quad (2.6)$$

$$z = \frac{Z}{X + Y + Z} \quad (2.7)$$


A soma dos três coeficientes tricromáticos reduz o espaço de cores tridimensional a um plano bidimensional que satisfaz a restrição:

$$X + Y + Z = 1 \quad (2.8)$$

O objetivo do modelo de cor é facilitar a especificação das cores em algum padrão. Dos modelos de cores existentes o sistema de cores RGB é o mais comum, sendo formado pelas cores primárias: vermelho (R), verde (G) e azul (B). As demais cores descritas por esse modelo se dão pela adição das três primárias, variando cada uma delas entre 0 e 1. O valor 0 corresponde à intensidade mínima em que a cor é representada e o valor 1 à intensidade máxima. A cor branca é o resultado da soma das três cores no seu valor máximo, e a cor preta é o resultado da soma das cores no seu valor mínimo (HARDEBERG, 2000).

Através das três cores primárias e das suas intensidades, o espaço de cor RGB é constituído criando um espaço tridimensional com três direções ortogonais onde $0 \leq R \leq 1$, $0 \leq G \leq 1$ e $0 \leq B \leq 1$, caracterizando assim, um cubo de aresta unitária em que as coordenadas (0,0,0) representam a cor preta e as coordenadas (1,1,1) representam a cor branca, como representado na Figura 2.12. Também é comum usar valores entre 0 e 255 para representar o grau de cada componente de cor.

Figura 2.12 – Modelo de Cores RGB.




Fonte: (RIBEIRO, 2009).

No modelo de cores HSV temos as três componentes definidas como: matiz (H), saturação (S) e brilho (V). A matiz determina a cor ou tonalidade medida em graus de 0 a 359; o brilho determina a intensidade percebida, variando entre 0 e 1; e a saturação determina a profundidade ou "pureza" da cor. Esse modelo pode ser representado a partir do cubo RGB, a partir do qual pode-se obter uma projeção de um sólido com base hexagonal com a cor branca ocupando o centro, rodeado de todas as cores do espaço HSV e um ponto representando a cor preta. A Figura 2.13 representa o modelo de cores HSV.

A saturação S mede a pureza da matiz. Quando o valor for 1, representa uma cor de pureza total, quando o valor for 0 a cor será a totalmente branca, sendo H insignificante. A matiz e a saturação, quando tomadas juntas, são chamadas de cromaticidade. Portanto, uma cor pode ser caracterizada pelo seu brilho e cromaticidade.

Independente do modelo de cor é importante ressaltar que "é a presença ou a ausência de luz que nos dá a sensação de cor. A luz é um fenômeno físico, mas a cor depende da interação da luz com o sistema visual, sendo, portanto, um fenômeno psicofísico" (GOMES; VELHO, 1994).

Figura 2.13 – Modelo de Cores HSV.



Fonte: o autor.

2.7.1 Descrição de Textura

A textura está presente na maioria das imagens digitais, "não é um atributo fácil de se extrair computacionalmente" (BOTELHO, 2007) e é de fácil percepção visual, como consta na Figura 2.14. Contudo, não existe uma definição precisa para textura. Ela não pode ser definida com base na informação de um pixel, mas sim através de uma região ou um conjunto de características capazes de descrever cada região de uma imagem (PREDINI; R.SCHWARTZ, 2007).

Tendo em vista a não compatibilidade de aceções para textura, muitos pesquisadores trazem sua própria definição para o termo. Por exemplo, Tamura, Mori e Yamawaki (1978) definem textura como algo que constitui uma região macroscópica, com uma estrutura atribuída aos padrões em que os elementos ou primitivas são organizados com uma regra de localização. Já para Zucker e kant (1981), textura tem uma noção paradoxal. De um lado, ela é usada no pré-processamento com o objetivo de classificar uma imagem. Por outro lado, não se obteve sucesso em produzir uma definição aceita para textura. A resposta a esse paradoxo, de acordo com Zucker e kant (1981), irá depender de um modelo mais rico e melhor desenvolvido sobre o pré-processamento de informação visual. No trabalho de Rocha *et al.* (2007) definem textura como um arranjo repetitivo de padrões sobre uma área, com o objetivo de medir a sua aspereza, observando fatores como as dependências de níveis de cinza, autocorrelação, entre outros. Por sua vez, Gonzales e Woods (2001) definem textura como sendo medidas que quantificam suas propriedades de suavidade, rugosidade e

regularidade. Segundo [Gonzales e Woods \(2001\)](#), existem três principais abordagens usadas na descrição de textura, quais sejam: a estatística, a estrutural e a espectral.

De acordo com a abordagem estatística, a textura é um conjunto de medidas extraídas do padrão, ou seja, descreve a textura através de grandezas que caracterizam a imagem como suave, granular, áspera, etc.

Na abordagem estrutural, a textura é formada por regras pré-definidas de repetição de padrões, como o próprio nome diz. Tal abordagem lida com conceitos estruturais que se repetem numa área da imagem. Já na abordagem espectral, ela se baseia nas propriedades do espectro de Fourier e na identificação de picos de alta energia das frequências espaciais.

Figura 2.14 – Textura.



Fonte: [\(RIBEIRO, 2009\)](#).

Capítulo 3

Redes Neurais Artificiais

3.1 Introdução

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. 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.

Haykin (2001) descreve que McCullough e Pitts, em 1943, sugeriram a construção de uma máquina baseada ou inspirada no cérebro humano, estabelecendo as bases da neurocomputação, com modelos matemáticos. Em 1951, o primeiro neurocomputador denominado Snark foi construído. Essa máquina desenvolvida por um cientista chamado Marvin Minsky, operava com êxito de acordo com um ponto de partida técnico, adaptando seus pesos de forma automática. Apesar desse neurocomputador não convir para efetuar qualquer função de processamento de informação interessante, ele serviu de inspiração para as ideias de estruturas que o sucederam (HAYKIN, 2001; LUGER, 2004).

Em 1956 nasceram os dois ramos da Inteligência Artificial, a simbólica e a conexionista. A Inteligência Artificial Simbólica tenta simular o comportamento inteligente humano, desconsiderando os mecanismos responsáveis por tal. Já a Inteligência Artificial Conexionista acredita que construindo um sistema que simule a estrutura do cérebro, ele será capaz de aprender, assimilar, errar e aprender com seus erros.

Então, em 1957, foi apresentado o que hoje se considera o primeiro neurocomputador de sucesso. Chamada de Mark I Perceptron, essa máquina foi construída por Charles

Wightman e Frank Rosenblatt, que devido à sagacidade de seus estudos, suas colaborações técnicas e de seu caráter moderno de pensar, é considerado como o criador da neurocomputação moderna. Seu objetivo inicial para a concepção do Perceptron era o reconhecimento de padrões (RUSSEL; NORVIG, 2004). Enquanto Rosenblatt trabalhava no Perceptron, Bernard Widrow desenvolveu uma nova rede neural chamada Adaline, que se destaca pela sua poderosa lei de aprendizagem (HAYKIN, 2001; LUGER, 2004).

Os anos seguintes foram tomados por um ânimo desenfreado de vários pesquisadores, os quais começaram a publicar artigos e livros com anseios audaciosos através de prescrições inseguras para a época, dissertando sobre instrumentos tão poderosos quanto o cérebro humano que surgiriam em um curto espaço de tempo. Isso tirou quase toda a qualidade dos estudos deste campo e ocasionou uma repulsão por parte dos técnicos de outras áreas (HAYKIN, 2001). Contudo, no início da década de 80, John Hopfield, físico e biólogo conhecido mundialmente, interessou-se pela neurocomputação, produzindo vários artigos sobre as RNA's e levando cientistas a se unirem nessa nova área (HAYKIN, 2001).

Em 1986, o campo de pesquisa sobre neurocomputação chega ao seu patamar máximo, quando David E. Rumelhart e James L. McClelland publicam o livro *Parallel Distributed Processing: explorations in the microstructure of cognition (vol.1: Foundations, vol.2: Psychological and Biological Models)*. Nesse livro, eles criticam o perceptron e apresentam um novo modelo de rede neural que propicia o treinamento supervisionado, surgindo assim o algoritmo *backpropagation* (HAYKIN, 2001; LUGER, 2004).

Em 1987, ocorreu a primeira conferência de redes neurais, chamada IEEE- *International Conference on Neural Network*. Também foi formada a primeira associação de estudiosos em redes neurais, chamada Sociedade Internacional de Redes Neurais (*International Neural Network Society - INNS*) juntamente com o *INNS Journal*, em 1989, acompanhado do *Neural Computing* e do *IEEE Transactionson on Neural Networks*, em 1990 (HAYKIN, 2001; LUGER, 2004). Desde então, inúmeras universidades desenvolveram grupos de pesquisas e programas de educação em neurocomputação.

3.2 Redes Neurais

As RNA's são modelos computacionais inspirados no sistema nervoso biológico. Para Emaruchi *et al.* (1994), a rede neural artificial 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 rede neural 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 RNAs, 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 e 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 elementos 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.

Ainda em relação às redes neurais, [Haykin \(2001\)](#) afirma que essas possuem algumas propriedades, são elas:

- não-linearidade;
- mapeamento de entrada-saída;
- adaptabilidade;
- tolerância a falhas;

- uniformidade de análise e projeto.

Diante do exposto, vê-se que, basicamente, as redes neurais são constituídas por um conjunto de elementos de entrada, interligados a outros elementos que fazem o processamento, chamados neurônios artificiais. Dessa forma, uma rede neural consiste num conjunto de neurônios conectados por sinapses.

3.3 Neurônio Biológico

O sistema nervoso, mais precisamente o cérebro humano, é formado por diferentes regiões, cada uma responsável por uma determinada função. Ele é constituído por um conjunto extremamente complexo de células nervosas, denominadas neurônios que, por sua vez, são compostos por um corpo celular, um axônio e várias ramificações. Essas ramificações são conhecidas como dendritos, como é possível observar na Figura 3.1. Existem, aproximadamente, 15 bilhões de neurônios que são responsáveis por todas as funções do sistema nervoso. O neurônio destaca-se das outras células por ser capaz de processar informações.


Diversos pesquisadores têm buscado criar um modelo computacional que represente as funcionalidades do cérebro humano, tais como pensar e memorizar de uma maneira simples. A estrutura do modelo computacional consiste no corpo do neurônio (soma), constituído de núcleo, que dá suporte metabólico a toda célula. O axônio (fibra nervosa) é um prolongamento único e grande que aparece no soma, sendo responsável pela condução do impulso nervoso para o próximo neurônio. Ainda nessa estrutura, existem os dendritos, que são prolongamentos menores em forma de ramificações que emergem do soma e do final do axônio, sendo, na maioria das vezes, responsáveis pela comunicação entre os neurônios (VILELA, 2015). As extremidades do axônio são conectadas com os dendritos de outros neurônios caracterizando a sinapse.

3.4 Sinapses

Silva, Spatti e Flauzino (2010) diz que os estímulos entram nos neurônios através das sinapses, que conectam os dendritos (ramificações de entrada) de um neurônio com os axônios de outros neurônios. As sinapses regulam as quantidades de informações que passam dos dendritos para o neurônio. Os sinais são passados para o corpo celular, que os adiciona e os aplica a um sensor de limiar, que determina o nível de entrada acima do qual o neurônio dispara uma carga elétrica.

Se a soma dos sinais for maior que o limiar, o neurônio envia energia através do axônio, de onde a energia é transmitida para outras sinapses ou também pode realimentar a

Figura 3.1 – Neurônio biológico.



Fonte: (RIBEIRO, 2009).

sinapse original. Contudo, se a soma for menor que o limiar, nada ocorre. As sinapses têm papel fundamental na memorização, tendo em vista que são nelas que são armazenadas as informações.

LUDEIG e Canpolim (2010) enfatiza que

inúmeras pesquisas comprovam que uma vida intelectual ativa é fundamental para manter a cabeça funcionando. (...) Toda vez que algo chama a atenção - uma visão, um som, uma ideia - um grupo de neurônios é ativado e deflagra milhares de impulsos elétricos nas brechas existentes entre eles, as chamadas sinapses, transformando essa elaborada rede em uma tempestade de atividades sinalizadoras. A memória humana trabalha com esse gigantesco número de informações distribuídas por todo o cérebro e está em contínua mudança (...) (LUDEIG; CANPOLIM, 2010).


3.5 Neurônio Artificial

Assim como o sistema nervoso é composto por vários neurônios biológicos, a rede neural artificial é também formada por unidades que nada mais são que pequenos módulos que simulam o funcionamento de um neurônio. Como foi dito anteriormente, o neurônio artificial é uma estrutura lógico-matemática e que pode ser entendida como uma unidade de processamento matematicamente simples, a qual recebe uma ou mais entradas, que transformam-se em saídas, como representado na Figura 3.2. Os dendritos do neurônio j são representadas por n entradas, cujas ligações com o corpo celular artificial é dado por elementos denominados pesos sinápticos, que simulam as sinapses. Cada sinal (x_i) na entrada da sinapse i conectado ao neurônio j é multiplicado pelo peso sináptico (w_{ij}).

Essas sinapses nervosas podem ser representadas por um peso sináptico excitatório (valor positivo) ou inibitório (valor negativo). O axônio é representado pela saída (y_j), que

é o resultado da aplicação da função de ativação sobre a soma entre o somatório dos sinais de entradas ponderadas pelos seus respectivos pesos sinápticos (w_j) e a polarização externa (bias) b_j que, por sua vez, pode aumentar ou diminuir a polarização na função de ativação. Podemos formular um modelo matemático do neurônio artificial descrito pelas Equações 3.1, 3.2 e 3.3:

Figura 3.2 – Representação do neurônio matemático.



Fonte: o autor.

$$u_j = \sum_{i=1}^n x_i w_{ij} \quad (3.1)$$

$$v_j = u_j + b_j \quad (3.2)$$


$$y_j = \sigma(v_j) \quad (3.3)$$

onde $x_1, x_2, \dots, x_n$ representam os sinais de entrada, $w_{1j}, w_{2j}, \dots, w_{nj}$ correspondem aos pesos sinápticos do neurônio j , u_j é a saída do combinador linear devido aos sinais de entrada, e y_j é o sinal de saída do neurônio. O termo b_j corresponde ao bias aplicado externamente e tem o efeito de aumentar ou diminuir a entrada da função de ativação, dependendo se ele é positivo ou negativo. De acordo com o bias b_j positivo ou negativo, a relação entre o potencial de ativação v_j do neurônio j e a saída do combinador linear u_j é modificado.

A função $\sigma(\cdot)$ corresponde à função de ativação do neurônio, geralmente não linear, responsável pela ativação da saída ou resposta do elemento processador. O elemento de

saída tem um limiar, cujo objetivo é reproduzir o estado ativo ou inativo do neurônio biológico. Os tipos de funções de ativação podem ser: função limiar (degrau), função linear por partes, função logística ou sigmóide (HAYKIN, 2001), como mostra a Figura 3.3.

Figura 3.3 – Função Limiar (Degrau); Função Linear Por Partes e Função Sigmóide.



Fonte: o autor.

A função limiar, utilizada no modelo McCulloch e Pitts, limita a saída do neurônio a apenas dois valores (binário: 0 ou 1, ou bipolar: -1 ou 1). Representada pela Eq. 3.4, normalmente, a função limiar é utilizada para criar neurônios que tomem decisões binárias.

$$\sigma(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.4)$$

A função linear por partes possui a seguinte equação (HAYKIN, 2001):

$$\sigma(v) = \begin{cases} 1, & \text{se } v \geq \frac{1}{2} \\ v + \frac{1}{2}, & \text{se } -\frac{1}{2} < v < \frac{1}{2} \\ 0, & \text{se } v < -\frac{1}{2} \end{cases} \quad (3.5)$$

A função sigmóide, geralmente adotada em redes neurais, por ser contínua, monotônica, não-linear e facilmente derivável em qualquer ponto, possui a seguinte equação:

$$\sigma(v) = \frac{1}{1 + e^{-av}} \quad (3.6)$$

onde a é o "parâmetro de achatamento" (HAYKIN, 2001).

De forma sucinta, segundo Liporace (1994), o processamento dos neurônios artificiais consiste na aplicação de uma função de ativação não linear, sob o somatório dos sinais de entrada que chegam a esse elemento, gerando um resultado de saída.

3.6 Aprendizado da Rede Neural

Uma das características mais importantes das RNA's é a capacidade de aprender por meio da experiência, da mesma forma que uma criança aprende as primeiras coisas como andar, comer e falar, partindo de exemplos dados ou na prática. O mesmo acontece com a RNA, pois, primeiramente, escolhe-se a representação para os dados do problema, monta-se um conjunto de treinamento e, depois, através desse treinamento, a rede "aprende". Segundo Braga, Carvalho e Ludermir (2007), as RNA's armazenam conhecimento através da aprendizagem, que consiste na fase em que a rede neural absorve dados e, a partir desses dados, modifica seus parâmetros.

O aprendizado permite ajustar o conjunto de pesos sinápticos de modo que a rede consiga executar uma tarefa desejada. Para que isso ocorra, é necessário conhecer as informações disponíveis à rede e como os pesos sinápticos serão atualizados. As abordagens de aprendizado podem ser divididas em (GONZALES; WOODS, 2001; SILVA; SPATTI; FLAUZINO, 2010; BRAGA; CARVALHO; LUDERMIR, 2007): aprendizado supervisionado e não-supervisionado.

Entre as questões práticas e fundamentais a respeito da aprendizagem, podem-se destacar a capacidade de armazenamento da rede e o limite de decisões que ela deve tomar. Há uma complexidade em relação aos possíveis exemplos que determinam o número de padrões de treinamento necessários para que a rede "aprenda" e qual será o tempo computacional gasto para que isso ocorra.

3.6.1 Aprendizado Supervisionado

No aprendizado supervisionado, como o próprio nome já sugere, existe um supervisor, que é responsável por estimular as entradas da rede por meio de padrões específicos e observar se a saída calculada pela rede é compatível com a saída desejada. Com esse tipo de aprendizagem, as redes neurais devem ser treinadas antes de serem usadas e o treinamento consiste na apresentação de sinais de entrada e saída da rede para ajustar os pesos sinápticos.

O aprendizado ocorre quando a saída esperada é gerada pela rede a partir dos cálculos efetuados com a entrada e os pesos sinápticos. Se a saída não for a desejada, o algoritmo de

aprendizagem ajusta os pesos sinápticos da rede de forma a minimizar o erro, que está na diferença entre a saída obtida pela rede e a desejada. O erro é calculado passo a passo e esse processo é repetido até que atinja uma saída satisfatória. Isso faz com que o conhecimento seja transferido para a rede, gradualmente, por meio do treinamento.

O aprendizado supervisionado, de acordo com a teoria proposta por [Silva, Spatti e Flauzino \(2010\)](#), [Braga, Carvalho e Ludermir \(2007\)](#), utiliza um mapeamento dos conjuntos de pares (entrada - saída), onde, para cada entrada é especificada uma saída (resposta desejada). Os algoritmos mais conhecidos para essa abordagem são a Regra Delta e o Algoritmo *Backpropagation*.

Sucintamente, quando um padrão é inicialmente apresentado à rede neural, ela produz uma saída. Após medir a distância entre a resposta atual e a desejada, são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir esta distância. Este procedimento é conhecido como Regra Delta.

No Algoritmo *Backpropagation*, a rede neural opera em dois passos distintos. Primeiramente, um padrão é apresentado à camada de entrada da rede neural. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, então o erro da rede é calculado e os pesos são atualizados.

3.6.2 Aprendizado Não-Supervisionado

Diferentemente da abordagem anterior, no aprendizado não-supervisionado não há um supervisor para acompanhar a aprendizagem. Neste caso utiliza-se no treinamento da rede apenas valores de entrada. A rede trabalha essas entradas e se organiza de modo a agrupá-las mediante algum critério de semelhança.

Esse tipo de rede utiliza os neurônios como classificadores e os dados de entrada são os elementos de classificação. Sendo assim, a regularidade de semelhança nas entradas são características essenciais no aprendizado não-supervisionado. Para [Silva, Spatti e Flauzino \(2010\)](#), [Braga, Carvalho e Ludermir \(2007\)](#) o aprendizado não-supervisionado visa identificar agrupamentos (*clusters*) ou classes.

Segundo [Osório e Vieira \(1999\)](#), esse tipo de rede desenvolve a habilidade de extrair características relevantes a partir das entradas fornecidas e formar representações internas que codifiquem essas características, criando novas classes automaticamente.

3.6.3 Algoritmos de Aprendizagem

Algoritmos de aprendizagem são um conjunto de regras definidas para resolver algum problema de aprendizagem. Embora o homem esteja longe de descobrir como ocorre o

processamento biológico, existem diferentes tipos de algoritmos de aprendizagem que se distinguem pela maneira como é feito o ajuste do peso sináptico de um neurônio (HAYKIN, 2001). Esses podem ser divididos em:

- Aprendizagem por correção de erro: esse tipo de algoritmo ajusta-se aos pesos sinápticos de maneira a obter um erro mínimo. O erro (e_j) é então definido com sendo a diferença do valor da saída obtida (y_j) pela rede e a saída desejada (d_j), apresentado na Equação 3.7.

$$e_j(m) = d_j(m) - y_j(m) \quad (3.7)$$

A fim de minimizar o erro da rede, define-se um índice de desempenho $E(m)$ baseado na função erro, definida por:

$$E(m) = \frac{1}{2} e_j^2(m) \quad (3.8)$$

A minimização do índice de desempenho, $E(m)$, resulta na regra delta, a qual determina o ajuste dos pesos sinápticos ($\Delta w_{ij}(m)$). Esse ajuste, aplicado ao peso w_{ij} do neurônio j , excitado pela entrada x_i no tempo m , m é o tempo discreto, ou seja, o passo de tempo de processo iterativo envolvido no ajuste dos pesos sinápticos do neurônio j , pode ser descrito por (HAYKIN, 2001):

$$\Delta w_{ij}(m) = \eta e_j(m) x_i(m) \quad (3.9)$$

onde η é uma constante positiva que determina a taxa de aprendizado de um passo a outro no processo de aprendizado. A escolha adequada do parâmetro η é muito importante para assegurar a estabilidade da convergência do processo de aprendizado iterativo. Após calcular o ajuste, o novo peso sináptico w_{ij} será:

$$w_{ij}(m+1) = w_{ij}(m) + \Delta w_{ij}(m) \quad (3.10)$$

- Aprendizagem Hebbiana: baseada na teoria de Hebb e defendida também pelos estudos de Luger (2004), o qual afirma que, quando um neurônio contribui para o disparo de outro, sua conexão é reforçada. A aplicação desse algoritmo de aprendizagem pode ser descrita da seguinte forma – se dois neurônios, um de cada lado de uma sinapse, são ativados, os pesos sinápticos da conexão entre os dois neurônios são alterados, logo, a força da sinapse entre eles aumentará. O ajuste $\Delta w_{ij}(m)$ dos pesos sinápticos do neurônio j aplicado ao peso w_{ij} no tempo m é definido por (HAYKIN, 2001):

$$\Delta w_{ij}(m) = \eta y_j(m) x_i(m) \quad (3.11)$$

onde η é uma constante positiva que determina a taxa de aprendizado, x_i é o sinal pré-sináptico do neurônio j e y_j é o sinal pós-sináptico do neurônio j .

- **Aprendizagem Boltzmann:** tem suas origens na teoria da computação, além de contar com algumas considerações da teoria da termodinâmica. As redes neurais que utilizam esse algoritmo possuem neurônios que funcionam em apenas dois estados, $(+1)$ ligados ou (-1) desligados e que são caracterizadas por uma função de energia cujo valor é determinado pelos estados dos neurônios. O ajuste $(\Delta w_{ij}(m))$ dos pesos sinápticos aplicado ao peso w_{ij} do neurônio j para o neurônio i é determinado pela equação seguinte (HAYKIN, 2001):

$$\Delta w_{ij} = \eta(\rho_{ij}^+ - \rho_{ij}^-), i \neq j \quad (3.12)$$

onde η é a taxa de aprendizagem, ρ_{ij}^+ é a correlação dos estados dos neurônios i e j no estado bloqueado e ρ_{ij}^- é a correlação dos estados dos neurônios i e j no estado livre. Note que tanto ρ_{ij}^+ como ρ_{ij}^- assumem valores no intervalo entre -1 e $+1$.

- **Aprendizagem competitiva:** nesse tipo de algoritmo, os neurônios de saída da rede são projetados de tal forma que somente um deles está ativo após a computação de determinada tarefa. O neurônio vencedor leva tudo. De acordo com a regra de aprendizagem competitiva padrão, o ajuste Δw_{ij} aplicado ao peso w_{ij} é definido por (HAYKIN, 2001):

$$\Delta w_{ij} = \begin{cases} \eta(x_i - w_{ij}), & \text{se o neurônio } j \text{ vencer a competição} \\ 0, & \text{caso contrário} \end{cases} \quad (3.13)$$

onde η é a taxa de aprendizagem. Um neurônio aprende deslocando pesos sinápticos dos nós de entrada inativos para ativos. Se um neurônio ganha a competição, cada nó de entrada deste neurônio cede alguma proporção de seu peso sináptico e o peso cedido é então distribuído igualmente entre os nós de entrada ativos. Esta regra move o vetor de peso sináptico w_j do neurônio vencedor j em direção ao padrão de entrada x .

- **Aprendizagem baseada em memória:** aqui, as experiências são armazenadas em uma memória de exemplos de entrada-saída pré-classificada. Segundo Haykin (2001), essa memória é representada da seguinte forma: $(r_k, t_k)_{k=1}^N$, onde r_k é o vetor de entrada e t_k é a resposta desejada. Existem diversos algoritmos baseados em memória. O tipo mais simples é conhecido como regra do vizinho mais próximo. Quando se quer classificar um novo vetor de entrada, chamado de r_{teste} , repassa-o à rede e o algoritmo irá analisar os dados de treinamento em uma vizinhança local de r_{teste} , buscando um padrão semelhante. De acordo com esse procedimento, a vizinhança local será os dados

de treinamento que se encontram próximos ao vetor r_{teste} . O vetor r'_N será o vizinho mais próximo de r_{teste} se (HAYKIN, 2001):

$$\min t(r_k, r_{teste}) = t(r'_N, r_{teste}) \quad (3.14)$$

onde $t(r_k, r_{teste})$ é a distância euclidiana entre os vetores r_k e r_{teste} . A classe associada com a menor distância mínima, ou seja, o vetor r_N , é apresentada como a classificação de r_{teste} .

Cada tipo de algoritmo fornece vantagens específicas que devem ser avaliadas conforme a aplicação. Como a principal característica da rede neural é a capacidade de aprender e se adaptar, a escolha do algoritmo utilizado está diretamente relacionada, tornando sua escolha crucial para o desempenho da rede.

3.7 Arquitetura da Rede Neural

Outro detalhe importante a se considerar na estrutura de uma RNA é a maneira como os neurônios estão interligados, ou seja, sua arquitetura. A forma de organização dos neurônios em uma rede neural (topologia) está intrinsecamente ligada ao problema que se deseja solucionar e é fator importante na definição do algoritmo de aprendizagem a ser utilizado.

A rede neural artificial pode ser classificada tanto pela disposição dos neurônios em camadas e conexões entre elas (FAUSETT, 1994), e quanto pela estrutura e forma de treinamento (PHAN; LUI, 1995).

Geralmente, as redes neurais possuem uma camada de entrada, usada para receber os estímulos externos e podem apresentar ou não camadas intermediárias. Um exemplo de rede neural sem camada intermediária é a rede Adaline e a Perceptron de Camada Única (Figura 3.4). Já a Perceptron Multi-Camada, conforme a Figura 3.5, é o principal exemplo de rede neural com camada intermediária.


Segundo Russel e Norvig (2004), de acordo com as estruturas, as redes neurais podem se dividir em duas: redes alimentadas adiante e redes recorrentes. A arquitetura escolhida para a implementação da rede neural deve ter com o objetivo de facilitar o processo de aprendizagem, já que é a base para a obtenção de respostas satisfatórias ao problema. A seguir, serão abordadas as redes de uma única camada, redes de várias camadas e redes recorrentes.

3.7.1 Redes Alimentadas Adiante com Camada Única (Perceptrons)

Em uma rede neural adiante com camada única todas as entradas são conectadas às saídas, ou seja, existe somente uma camada de neurônios ligados diretamente aos nós

de entrada e eles mesmos já fornecem os dados de saída. Esta rede é do tipo alimentação direta. A soma dos produtos dos pesos pelas entradas é calculado em cada nó, e se o valor for superior a um limiar o neurônio dispara e a saída recebe valor 1, caso contrário, o neurônio não dispara e recebe o valor 0. A Figura 3.4 ilustra este tipo de rede com quatro nós tanto na camada de entrada quanto na camada de saída.

Figura 3.4 – Rede alimentada adiante com uma única camada de neurônio.



Fonte: o autor.

3.7.2 Redes Alimentadas Adiante com Múltiplas Camadas

Diferentemente da arquitetura anterior, as redes alimentadas diretamente com múltiplas camadas possuem uma ou mais camadas ocultas de neurônios. Sua função é processar os sinais de entrada antes de enviá-los aos neurônios de saída. Apesar da maior complexidade, essa arquitetura possibilita uma melhor qualidade de treinamento, pois há maior interação entre os neurônios.

A rede neural mais comum é o Perceptron Multi-Camada, onde cada neurônio recebe entradas a partir de camadas anteriores, com fluxo unidirecional de informações para a saída (PRATOLA; FRATE; LICCIARDI, 2011). O número de nós na(s) camada(s) oculta(s) definem a complexidade e o poder da rede neural a um dado treinamento (KAVZOGLU, 2009).


Cada neurônio desse tipo de rede possui uma função de ativação não-linear e diferenciável, tornando possível o cálculo do gradiente responsável pela indicação da direção de ajuste de pesos durante o treinamento. Os neurônios das camadas ocultas são responsá-

veis pelo poder de generalização da rede e, adicionam-se uma ou mais camadas (HAYKIN, 2001).

O número de neurônios nas camadas de entrada e saída segue as características do problema. No entanto, a melhor maneira de se estimar o número de neurônios nas camadas ocultas é através de tentativa e erro.

Na Figura 3.5 temos uma rede 10–4–2, ou seja, 10 neurônios/nós de entrada, 4 neurônios na camada oculta e 2 neurônios de saída ou, ainda podemos usar a notação de (HAYKIN, 2001): uma rede n, k_1, m com n nós de entrada, k_1 neurônios na camada oculta e m neurônios de saída. A rede neural da Figura 3.5 é chamada de totalmente conectada, pois cada nó da camada de entrada está conectada a todos os nós da camada seguinte. Contudo, se alguns dos elos de comunicação e conexões sinápticas estiverem faltando na rede, será chamada de rede parcialmente conectada (HAYKIN, 2001).

Figura 3.5 – Rede alimentada adiante totalmente conectada com uma camada oculta.



Fonte: o autor.

3.7.3 Redes Recorrentes


As redes neurais recorrentes, conforme a Figura 3.6, possuem conexões de realimentação em sua arquitetura, isto é, as saídas dos neurônios podem ser alimentadas de volta para suas entradas ou para os neurônios das camadas anteriores, permitindo um processo

dinâmico de informação (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010; OSÓRIO; VIEIRA, 1999).

Esse tipo de rede neural é facilmente adaptada, a partir do Perceptron Multi-Camada, bastando introduzir as conexões de realimentação em suas camadas. O uso de realimentação com atrasos introduz memória à rede tornando-a apropriada para predição (PRINCIPE; J-M, 1995).

Uma propriedade importante de uma rede recorrente é que ela pode ser descrita pelo modelo de espaço de estados e pode aproximar uma ampla classe de sistemas dinâmicos não-lineares. Elas são empregadas em processos dinâmicos como a previsão de dados em uma série histórica, processamento de sinais e robótica (HAYKIN, 2001).

Figura 3.6 – Rede Recorrente.



Fonte: o autor.

Capítulo 4

Estado da Arte

Imagens digitais da superfície terrestre, obtidas por meio de satélites, são importantes fontes de informação para várias áreas da atividade humana. A segmentação dessas imagens com a utilização das RNA's pode fornecer informações mais precisas e específicas, de acordo com diferentes objetivos. A agricultura (WANG *et al.*, 2010; PADILHA; KHATCHATOURIAN, 2008) e muitas outras atividades rurais, como o extrativismo (RUZ; ESTÉVES, 2005; FUNCK *et al.*, 2003) e a apicultura (SAMMOUDA *et al.*, 2014), o monitoramento ambiental (MACHADO *et al.*, 1993; FAN; ZHAO; WANG, 2014; FRATE; ANGIULI; SALVATORI, 2006) e o planejamento urbano (BOTELHO; CENTELHO, 2014), podem se beneficiar com a segmentação dessas imagens por meio de RNA's. As RNA's treinadas ajudam a avaliar, dinamicamente, a semelhança entre quaisquer duas amostras, permitindo a detecção e até mesmo o diagnóstico de tais imagens, o que traz grandes benefícios à humanidade.

Toda a evolução das redes neurais, até os dias atuais, somando a era de processamento de imagens, permitiu aos pesquisadores avanços ainda mais significativos no desenvolvimento de uma RNA. Por terem sido criadas inspiradas na rede neural biológica, as RNA's possuem algumas características importantes, como o aprendizado pela experiência, a generalização e a abstração de características, o que gera grande interesse para as pesquisas atuais (WASSERMAN, 1989).

Atualmente as RNA's estão sendo utilizadas em pesquisas nas mais diversas áreas. Por meio de sua utilização é possível segmentar objetos, classificar objetos em grupos, reconhecer e associar padrões, além de "predizer o futuro". Na astronomia, as imagens digitais do espaço sideral, obtidas por meio de satélites, são segmentadas com o uso de RNA's, conseguindo assim, separar estrelas de outros corpos (ZHU *et al.*, 2015).

Em imagens digitais de outros objetos, conseguidas por outras fontes e com boa resolução, também pode ser feita a segmentação com a utilização de RNA's a fim de melhor se analisar tais objetos, o que também pode ser feito em várias áreas da atividade humana. A indústria de madeira (RUZ; ESTÉVES, 2005; FUNCK *et al.*, 2003), a biologia (ZHANG;

TAN; CHEN, 2015) e, principalmente, a medicina (ZHANG; CHEN; LIN, 2009; HASSANIEN; ALI, 2012; WOLFER, 2012; CHAI *et al.*, 2010; HASSANIEN; EL-DAHSHAN; AL-QAHERI, 2010; SCUDDER, 1978; MUELLER; KAVEH; WADE, 1979) utilizam a segmentação de imagens com RNA's com sucesso.

Na literatura já produzida sobre a segmentação de imagens digitais com a utilização de RNA's, sejam as obtidas por satélites sejam as obtidas por aparelhos de raio-x, aparelhos de ultrasson, tomógrafos, aparelhos de ressonância magnética, radares, *scanners*, sonares e outros, são descritos vários exemplos de aplicação.

Na produção agrícola, o crescimento do agronegócio vem contribuindo para a inserção das pesquisas de processamento de imagens na agricultura. Wang *et al.* (2010), por exemplo, descreve a utilização de segmentação de imagens a partir de RNA's na agricultura, mais especificamente, na fruticultura. O uso dessa técnica permite a identificação e localização dos frutos que estão prontos para serem colhidos, o que leva a um melhor aproveitamento da produção. Padilha e Khatchatourian (2008) também mostra a utilização dessa técnica no espaço agrícola – na sojicultura – para identificar a variedade e analisar a qualidade dos grãos por meio de sua forma e tamanho. Sammouda *et al.* (2014) estudou a aplicação da técnica de segmentação de imagens de satélites a partir de RNA's na apicultura, na região rural da Arábia Saudita, determinando os lugares com condições climáticas mais favoráveis à produção dos apiários.

Machado *et al.* (1993) analisou a aplicação da técnica no monitoramento ambiental, mais especificamente, para avaliar o desmatamento de vegetação nativa na Amazônia e constatou que os resultados obtidos são muito bons e promissores. Fan, Zhao e Wang (2014) propõem a utilização da mesma técnica para identificar e avaliar o derramamento de petróleo e produtos parecidos no mar. Sendo assim, observa-se que a técnica é utilizada em várias situações e tem mostrado resultado em todas elas.

Frate, Angiuli e Salvatori (2006), Lopez *et al.* (2006), por sua vez, propõe um algoritmo de detecção de vazamento de óleo a partir de imagens de radar e Bento *et al.* (2009) propõe a localização automática de corrosão e depredação de oleodutos e demais equipamentos marítimos e terrestres. Nos estudos de (FRATE; ANGIULI; SALVATORI, 2006) os resultados obtidos são analisados por meio da sensibilidade e da robustez do algoritmo.

Nesse contexto, diversas técnicas para detecção de vazamentos em dutos vêm sendo pesquisadas a fim de evitar e/ou diminuir danos ao meio ambiente e perdas econômicas. Entretanto, destaca-se a citação de Stouffs e Michel (1993):

Nenhum método de detecção de vazamento é universalmente aplicável e os requisitos operacionais ditam qual é o método mais eficaz para o processo. Em geral, o ideal é utilizar mais de um sistema independente de detecção de vazamento em oleodutos importantes (STOUFFS; MICHEL, 1993).

Encontramos a segmentação de imagens a partir de RNA's também na indústria da

madeira. No entanto, para tal, suas aplicações exigem que as placas de madeira estejam em perfeitas condições, o que requer muitas técnicas de inspeção. Nesse sentido, [Ruz e Estéves \(2005\)](#), [Funck *et al.* \(2003\)](#) mostram que a segmentação dessas imagens é a tarefa mais importante em todo o processo de inspeção, para que os defeitos sejam indicados corretamente.

Na medicina, a segmentação de imagens a partir das RNA's são utilizadas em diversas aplicações, como nas decisões médicas (detecção e diagnóstico) ([ZHANG; CHEN; LIN, 2009](#); [HASSANIEN; ALI, 2012](#); [WOLFER, 2012](#); [CHAI *et al.*, 2010](#); [HASSANIEN; EL-DAHSHAN; AL-QAHERI, 2010](#); [SCUDDER, 1978](#); [MUELLER; KAVEH; WADE, 1979](#)). Na biologia a segmentação de imagens a partir das RNA's são utilizadas em imagens microscópicas ([ZHANG; TAN; CHEN, 2015](#)) e em imagens como raio-x, tomografia, ultrassom e ressonância magnética. Isso possibilita melhor avaliação dos exames clínicos por parte dos médicos e técnicos de saúde. Os estudos nesses tipos de imagens devem apresentar resultados cada vez mais precisos, como na detecção de aneurismas ([MARTINS *et al.*, 2008](#)), já que uma identificação errônea de uma patologia (ou ainda a não percepção desta) resulta em grandes problemas, tanto para pacientes quanto para a equipe médica.

Nos trabalhos de [Chai *et al.* \(2010\)](#), [Hassanien, El-Dahshan e Al-Qaheri \(2010\)](#), [Scudder \(1978\)](#), [Mueller, Kaveh e Wade \(1979\)](#), [Hinshan e Lent \(1983\)](#) são apresentadas técnicas em que uma imagem do corpo do paciente permite ao médico examinar e diagnosticar um problema sem a necessidade de processos invasivos tal como a biópsia. No trabalho de [Rocha *et al.* \(2007\)](#) é apresentado um sistema de segmentação de imagens utilizando as RNA's para o diagnóstico automatizado de doenças como no colo do útero que, segundo o INCA (Instituto Nacional do Câncer), é o terceiro tipo de doença mais comum em mulheres no Brasil.

Como se vê, várias aplicações de segmentação de imagens a partir de RNA's já foram criados, mas a aplicação de alguns deles em imagens obtidas por satélites ainda não é amplamente conhecida.

O método chamado Mapas de Auto-Organização (SOM) ou Mapa de Kohonen, utiliza uma rede neural não supervisionada. Seu uso já está bem descrito na literatura para a aplicação de imagens de tecido estampado ([XU; LIN, 2002](#)) e em imagens obtidas por sonar ([YAO *et al.*, 2000](#)). Embora sua aplicação em imagens de satélites ainda não seja bem conhecida, [Awad, Chehdi e Nasri \(2007\)](#) descreve a sua aplicação em cooperação com o algoritmo genético híbrido para segmentação de imagens de satélites. O método, assim, apresenta bons resultados, no entanto, possui como ponto negativo, a velocidade lenta.

O SOM também pode ser aplicado em parceria com outro método de segmentação de imagens, o K-means, conforme [Zhou *et al.* \(2007\)](#). O papel do K-means é segmentar a imagem em escala grosseira e o do SOM, em seguida, é segmentar a imagem em escala fina. Essa forma de segmentação, utilizando-se os dois métodos, requer mais tempo para que seja al-

cançada uma solução ótima. Vale lembrar que no K-means é necessária a pré-determinação do número de *clusters*.

Cruz e Galo (2003) utilizaram as RNA's em imagens de sensoriamento remoto de datas e sensores diferentes para separar classes de uso e cobertura da terra. Uma imagem TM/-Landsat foi adotada como referência para o treinamento e validação da rede neural e então aplicada na imagem. Os resultados obtidos indicaram que, passando os dados multiespectrais e multissensores por um pré-processamento, obedecendo às condições de similaridade espectral e à normalização radiométrica das bandas, a rede treinada gera resultados promissores.

Neste trabalho utilizamos a RNA denominada Rede Neural de Pulso Acoplado (do inglês - Pulse Coupled Neural Network (PCNN)). Ao longo dos anos, pesquisadores estudaram modelos de neurônios para tornar o modelo de PCNN original adequado para o processamento de imagens (JOHNSON H. RANGANATH; CAULFIELD, 1998; RANGANATH; KUNTIMAD; JOHNSON, 1995; LINDBLAD; KINSER, 2005). São também discutidos vários resultados e aplicações baseadas em PCNN's, tais como segmentação de imagem (CAUFIELD; KINSER, 1999; KUNTIMAD; RANGANATH, 1999; ZHANG; DONG; SHI, 2005), detecção de borda e objeto (DENG; MA, 2014; RANGANATH; G.KUNTIMAD, 1999) e fusão de imagens (WANG; MA, 2008; WANG; MA, 2007). A seguir descrevemos algumas contribuições importantes.

Ranganath e Kuntimad (1996) modificaram o modelo de Eckhorn para aplicações de processamento de imagens, incluindo segmentação de imagens, suavização e detecção de objetos. Johnson e Padgett (1999) resumem o modelo de PCNN original, revisam aplicações e enfatizam o potencial da rede para o processamento de imagem. Gu, Yu e Zhang (2004) propõe um modelo de PCNN de duas dimensões para o afinamento da imagem. Posteriormente, Gu, Yu e Zhang (2005) propõe a remoção de sombras, onde todos os neurônios são idênticos entre si. Shang e Yi (2007) também aplicaram o modelo de PCNN para o afinamento da imagem. Yang, Zhou e Zhou (2004) propuseram um método baseado em PCNN para detectar bordas em imagens de escala de cinza. Ji, Yi e Pu (2006) aplicaram a PCNN para classificação de impressões digitais. Hassanien e Ali (2012) também utilizaram a PCNN na segmentação de imagens, mais especificamente em mamografia digital. Recentemente, Wang *et al.* (2016) aplicou a PCNN como um método de agrupamento que segmenta as diferentes estruturas do dente.

Nesse mesmo sentido, Wang *et al.* (2010) usaram uma PCNN simplificada para separar o pepino do fundo. Lei e Yang (2010) usaram um novo algoritmo baseado na rede neural de pulso acoplado de busca bidirecional (BPCNN) para a segmentação de imagens coloridas. Song, Xiao-Hui e Liu (2010) propôs um algoritmo de segmentação de imagens baseado em um modelo de PCNN melhorado. Li *et al.* (2013) propuseram um algoritmo imune para ajustar os parâmetros PCNN de forma adaptativa. Gao, Zhou e Guo (2013) propôs uma versão iterativa do algoritmo de (LI *et al.*, 2013) para a segmentação automática de imagens.

Após as considerações supracitadas, entende-se que a segmentação de imagens digitais utilizando RNA's vem apresentando resultados promissores e contribuindo para avanços em diversas áreas. Os bons resultados obtidos quando essa técnica é bem empregada, estimula novos estudos de aplicações, tanto nas áreas nas quais já se aplica a técnica, quanto em outras áreas.

Após breve apresentação desse panorama, define-se que o presente estudo tem como objetivo geral o desenvolvimento, implementação e comparação de duas metodologias baseadas em RNA's na segmentação de imagens. Primeiramente, uma rede será treinada para segmentar imagens presentes na literatura para, posteriormente, serem aplicadas as imagens de satélite.

Capítulo 5

Métodos

5.1 Introdução

Existem várias técnicas de segmentação de imagens sendo utilizadas na literatura. Neste capítulo, veremos duas técnicas baseadas em Redes Neurais Artificiais para segmentação de imagens de satélite. A primeira técnica que discutiremos é o modelo original da Rede Neural de Pulso Acoplado, cujo termo em inglês é *Pulse Coupled Neural Network* (PCNN). A segunda técnica que discutiremos é o modelo proposto para a rede PCNN original.

A Rede Neural de Pulso Acoplado (PCNN) 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 alimentação 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 esta descoberta, uma rede neural chamada rede de Eckhorn foi desenvolvida buscando modelar o comportamento do córtex visual do gato.

Na rede de Eckhorn, neurônios com entradas semelhantes geram pulsos simultaneamente, preenchendo lacunas temporais e variando a magnitude dos dados de entrada. No entanto, de acordo com Kuntimad e Ranganath (1999), o neurônio de Eckhorn tem algumas limitações quando é usado para processamento de imagem. Estas limitações são: em primeiro lugar, a análise e interpretação matemática dos resultados são igualmente difíceis, isso porque dificilmente se prevê o comportamento dos neurônios na rede. Segundo, o agrupamento de pixels de uma imagem com base na proximidade espacial e na similaridade de brilho é ambíguo, tal agrupamento ambíguo de pixels é indesejável em aplicações de processamento de imagem. Finalmente, a determinação de valores apropriados para os parâmetros de rede não é uma tarefa trivial e esses parâmetros precisam ser inicializados experimentalmente (KUNTIMAD; RANGANATH, 1999).


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 original e uma PCNN proposta em imagens de satélite do Estado de Goiás, a fim de

verificar a eficácia desse modelo por meio de experimentos e comparar imagens presentes na literatura.

5.2 Rede Neural de Pulso Acoplado - Modelo Original

O modelo de PCNN original desenvolvido por Eckhorn (ECKHORN *et al.*, 1990) é uma rede neural simples não supervisionada construída através da simulação das atividades dos neurônios do córtex visual do gato. A PCNN consiste em três partes principais (LINDBLAD; KINSER, 2005): o campo de entrada, o campo de modulação e o gerador de pulso, conforme Figura 5.1. A PCNN produz um pulso de saída quando estimulada, gerando imagens binárias. O modelo matemático da PCNN pode ser descrito pelas Equações 5.1 - 5.5 (SONG; XIAO-HUI; LIU, 2010; WANG *et al.*, 2010):

Figura 5.1 – Modelo de PCNN Original.



Fonte: (GAO; ZHOU; GUO, 2013).

$$F_{ij}(n) = e^{-\alpha_F} F_{ij}(n-1) + V_F \sum_{k,l} M_{i,j,k,l} Y_{ij}(n-1) + S_{ij} \quad (5.1)$$

$$L_{ij}(n) = e^{-\alpha_L} L_{ij}(n-1) + V_L \sum_{k,l} W_{i,j,k,l} Y_{ij}(n-1) \quad (5.2)$$

$$U_{ij}(n) = F_{ij}(n)(1 + \beta L_{ij}(n)) \quad (5.3)$$

$$Y_{ij} = \begin{cases} 1 & \text{se } U_{ij}(n) > E_{ij}(n), \\ 0 & \text{caso contrário} \end{cases} \quad (5.4)$$

$$E_{ij}(n) = e^{-\alpha_E} E_{ij}(n-1) + V_E Y_{ij}(n) \quad (5.5)$$

O campo de entrada contém duas partes: a entrada de alimentação (*feeding*) $F_{ij}(n)$ e a entrada de enlace (*linking*) $L_{ij}(n)$. A entrada de alimentação $F_{ij}(n)$ é conhecido como entrada primária da rede neural e é alimentado pela intensidade dos pixels da imagem (i, j) . S_{ij} pixels da imagem. A entrada de enlace $L_{ij}(n)$ também conhecida como entrada secundária é a entrada que comunica com os neurônios vizinhos através da matriz peso W . M e W referem-se à vizinhança. Cada pixel da imagem é ligado a um único neurônio e cada neurônio é conectado com os neurônios vizinhos através de sinapses ligadas a entrada de enlace. A entrada F do neurônio recebe o estímulo de entrada S , que correspondente à intensidade do pixel. V_F e V_L são constantes de amplitude e α_F e α_L são constante de decaimento do tempo.

A atividade interna do neurônio $U_{ij}(n)$ é dada combinando as entradas de alimentação e enlace no campo de modulação, onde β é o coeficiente de ligação. O gerador de pulso Y_{ij} é binário. $E_{ij}(n)$ é o limiar dinâmico, onde α_E é a constante limiar de decaimento do tempo e V_E é a constante amplitude do limiar. Se a atividade interna é grande, então, o neurônio irá gerar um pulso. Para α_E pequeno, a rede PCNN pode trabalharmeticulosamente, mas esse processo vai demorar muito tempo para terminar, enquanto, se α_E for maior, o tempo de processamento decresce (WANG *et al.*, 2010).

Quando $U_{ij}(n) > E_{ij}(n)$, 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, consequentemente, $Y_{ij}(n) = 0$, quando o limiar é maior do que a atividade interna.

5.3 Modelo de PCNN Proposto

Nesta seção descrevemos o modelo de PCNN proposto e discutimos a intuição sobre a nossa proposta em relação ao modelo de PCNN original. A entrada de alimentação da PCNN original tem dois parâmetros, nomeadamente, V_F (a constante de amplitude do limiar) e α_F (a constante de tempo de decaimento).

Para reduzir a complexidade da PCNN original e aumentar a velocidade computacional, certas modificações foram realizadas. Na entrada de alimentação, simplificamos os parâmetros α_F e V_F da Equação 5.1, resultando na Equação 5.6.

Observando a Equação 5.1 notamos que o neurônio com fator exponencial de decaimento α_F está inclinado a receber a entrada acumulada o tempo todo. Além disso, o fator de decaimento pode causar um comportamento inesperado dos neurônios e influenciar o desempenho do processo de segmentação, e ainda, ser responsável por uma resposta mais lenta da rede. Já o parâmetro de amplitude do limiar V_F pode reduzir ou aumentar a influência dos neurônios vizinhos. Assim, simplificando a entrada F_{ij} consideramos somente o pixel da imagem S_{ij} como informação na entrada primária.

Os resultados obtidos se mostraram significativos, minimizando o tempo computacional e maximizando a qualidade do processo de segmentação, otimizando assim o método. Semelhante ao modelo matemático da PCNN original, o modelo proposto é descrito pela Equação 5.6 e as Equações 5.2 - 5.5:

$$F_{ij}(n) = S_{ij} \quad (5.6)$$


De forma semelhante a rede PCNN original, o número de neurônios na rede é igual ao número de pixels na imagem de entrada, existindo uma correspondência um-para-um entre pixels de imagem e neurônios. A Equação 5.6 indica que a intensidade de cada pixel é inserida na entrada de alimentação F_{ij} do neurônio que está conectado com ele. Enquanto isso, cada neurônio é conectado com outros neurônios pela entrada de enlace L_{ij} no seu campo de 8 vizinhos, Equação 5.2. Cada saída do neurônio tem dois estados, 1 (disparo) ou 0 (sem disparo). Na Equação 5.4, Y_{ij} é a saída do neurônio. As equações 5.2 - 5.6 descrevem a forma como cada neurônio opera e é arranjado no modelo de PCNN proposta para segmentação de imagens, como mostra a Figura 5.2.

Algoritmo 5.1 – Algoritmo para segmentação de imagem com o modelo de PCNN proposto.

- 1: Inicialize com a imagem de entrada em tons de cinza e determine os parâmetros da rede neural de pulso acoplado, α_L ; α_E ; V_L ; V_E ; β e K é o número de iterações.
 - 2: Inicialize $E = 1's$, $L = 1's$ e $Y = 0's$.
 - 3: **for** $t = 1, \dots, K$ **do**
 - 4: $F_{ij}(n) = S_{ij}$.
 - 5: $L_{ij}(n) = e^{-\alpha_L} L_{ij}(n-1) + V_L \sum_{k,l} W_{i,j,k,l} Y(n-1)$.
 - 6: $U_{ij}(n) = F_{ij}(n)(1 + \beta L_{ij}(n))$.
 - 7: $E_{ij}(n) = e^{-\alpha_E} E_{ij}(n-1) + V_E Y_{ij}(n-1)$.
 - 8: **if** $U_{ij}(n) > E_{ij}(n)$ **then**
 - 9: $Y_{ij}(n) = 1$
 - 10: **else**
 - 11: $Y_{ij}(n) = 0$
 - 12: **end if**
 - 13: **end for**
 - 14: Salve Y como imagem segmentada.
-

Para facilitar a compreensão do modelo de PCNN proposto, descrevemos o processo através do Algoritmo 5.1. Na etapa 1) o usuário insere a imagem de entrada em tons de cinza

Figura 5.2 – Modelo PCNN Proposto.



Fonte: o autor.

e determina os parâmetros da rede. No passo 2) determina os parâmetros E , L e Y . Do passo 3) ao passo 7), de acordo com a característica da PCNN, segmenta a imagem original para obter o resultado de segmentação considerando os pixels locais e a similaridade da intensidade da mesma área na imagem original. No passo 8), quando a atividade interna do neurônio é maior do que o limiar, o neurônio emite um pulso que causa o disparo. Uma vez que as iterações foram esgotadas o resultado de segmentação é salvo em um arquivo de imagem; passo 14). Para a matriz gaussiana (W) usamos:

$$W = \begin{bmatrix} \frac{\sqrt{2}}{4\sqrt{2}+8} & \frac{2}{4\sqrt{2}+8} & \frac{\sqrt{2}}{4\sqrt{2}+8} \\ \frac{2}{4\sqrt{2}+8} & 0 & \frac{2}{4\sqrt{2}+8} \\ \frac{\sqrt{2}}{4\sqrt{2}+8} & \frac{2}{4\sqrt{2}+8} & \frac{\sqrt{2}}{4\sqrt{2}+8} \end{bmatrix}.$$

Capítulo 6

Resultados

Neste capítulo avaliamos de forma quantitativa o modelo de PCNN proposto para a segmentação de imagem em diferentes imagens de satélite do Estado de Goiás, onde tem-se a presença de rios e áreas agrícolas. Também foram realizados testes com imagens presentes nos trabalhos de [Kuntimad e Ranganath \(1999\)](#), [Zhou *et al.* \(2007\)](#) e [Wang *et al.* \(2010\)](#), comparando aqueles obtidos com os resultados obtidos usando a PCNN original. O objetivo era segmentar cada imagem em objetos e no plano de fundo.


Os resultados apresentados a seguir, foram executados no software Matlab. As configurações da máquina utilizada para a execução das simulações foram: Notebook Itautech com processador AMD C-60, memória ram de 4Gb, com placa de vídeo Radeon 1 GHz e sistema operacional Windows 7.

As imagens de satélite foram obtidas pelo satélite CBERS-2B (*China-Brazil Earth Resources Satellite* ou Satélite Sino-Brasileiro de Recursos Terrestres), disponíveis no site do INPE. Este satélite foi lançado no espaço em 2007 e operou até o início de 2010. De acordo com o INPE o satélite CBERS-2, foi o primeiro satélite de sensoriamento remoto no mundo a distribuir imagens gratuitamente, fazendo do Brasil um exemplo mundial e contribuindo para a divulgação do uso das imagens de satélites no mundo.

A Figura 6.1 e a Figura 6.2 mostram os resultados de segmentação para as imagens tiradas da literatura e imagens de satélite do Estado de Goiás, respectivamente. A primeira coluna mostra as imagens originais. A segunda coluna mostra as imagens *ground truth*. A terceira e a quarta colunas mostram o resultado da segmentação usando a PCNN original e o modelo proposto, respectivamente. Na Figura 6.2, no experimento 1 identificamos um reservatório de água situada entre os municípios de Cascalho Rico e Três Ranchos, no experimento 2 identificamos parte do Rio Paranaíba, e nos experimentos 3 e 4 identificamos áreas agrícolas.

Avaliamos a eficácia e a eficiência do modelo proposto na segmentação de diferentes imagens. Quanto à eficácia, analisamos as correspondências entre o resultado de segmen-

Figura 6.1 – Imagens originais na primeira coluna e resultados de segmentação obtidos pelos métodos analisados: segunda coluna - *ground truth*; terceira coluna - PCNN Original; quarta coluna - PCNN Proposta.



Fonte: Imagem 1 (ZHOU *et al.*, 2007); Imagem 2 (KUNTIMAD; RANGANATH, 1999); Imagem 3 (WANG *et al.*, 2010).

tação produzido e a imagem *ground truth*. As medidas de correspondência utilizadas são: número de pixels verdadeiros positivos, número de pixels falsos negativos, número de pixels falsos positivos, número de pixels verdadeiros negativos, valor preditivo positivo (também conhecido como precisão cujo termo em inglês é *precision*), taxa de verdadeiro positiva (também conhecida como sensibilidade cujo termo em inglês é *sensitivity* ou *recall*), taxa de falso positivo (também conhecido do inglês como *fall-out*) e acurácia (do inglês *accuracy*). Estas medidas são descritas por R. (2011), mas aqui adaptamos as definições dessas medidas para o contexto de correspondência na segmentação de imagens, considerando uma segmentação binária em que há objetos e o plano de fundo. A seguir descrevemos as medidas de correspondência utilizadas.


Verdadeiro positivo (VP) : número de pixels corretamente segmentado como objeto;

Falso negativo (FN) : número de pixels erroneamente segmentado como plano de fundo;

Falso positivo (FP) : número de pixels erroneamente segmentado como objeto;

Verdadeiro negativo (VN) : número de pixels correctamente segmentado como fundo.

Figura 6.2 – Imagens originais na primeira coluna e resultados de segmentação obtidos pelos métodos analisados: segunda coluna - *ground truth*; terceira coluna - PCNN Original; quarta coluna - PCNN Proposta.



Fonte: www.inpe.br

Taxa de verdadeiro positivo (TPR) :

$$TPR = \frac{VP}{(VP + FN)}; \quad (6.1)$$

É a proporção do pixel pertencente ao objeto que foi segmentado como objeto.

Taxa de falso positivo (FPR) :

$$FPR = \frac{FP}{(FP + VN)}; \quad (6.2)$$

É a proporção dos pixels pertencentes ao fundo que foi segmentado como objeto.

Valor preditivo positivo (PPV) :

$$PPV = \frac{VP}{(VP + FP)}; \quad (6.3)$$

É a proporção de pixels segmentados como pertencentes ao objeto que realmente correspondem ao objeto. PPV pode ser pensado como uma medida de exatidão na segmentação dos objetos. Um PPV baixo indica um grande número de falsos positivos.

Acurácia (ACC) :

$$ACC = \frac{VP + VN}{(VP + VN + FP + FN)} = \frac{VP + VN}{(N)}. \quad (6.4)$$

Corresponde ao número de pixels da imagem segmentada que combinam com o *ground truth* dividida pelo total de pixels na imagem (N).

É trivial alcançar TPR de 100%, basta segmentar todos os pixels como objeto. Da mesma forma, é trivial conseguir FPR de 100%. Além disso, é trivial conseguir FPR de 0%, basta retornar todos os pixels como pertencentes ao fundo. Da mesma forma, é trivial conseguir TPR de 0%.

Ambos os métodos foram executados com parâmetros otimizados obtidos empiricamente e percebemos que os resultados do modelo proposto apresenta melhores resultados nas imagens de satélite 6.2. Esta análise foi confirmada através das medidas de correspondência, relatadas nas Tabelas 6.1 e 6.2, para imagens presentes nos trabalhos de Kuntimad e Ranganath (1999), Zhou *et al.* (2007) e Wang *et al.* (2010) e para imagens obtidas pelo satélite CBERS-2B do Estado de Goiás disponibilizadas pelo INPE, respectivamente. Cada uma das medidas de correspondência apresentadas é de suma importância na análise quantitativa da segmentação de imagens. No entanto, a "acurácia" tem uma correlação mais direta com o julgamento humano da segmentação de imagem satisfatória.

Analisando os resultados da Tabela 6.1 e 6.2 em relação à acurácia, vemos que de 7 imagens usadas como experimento apenas uma imagem (Tabela 6.1), experimento 3, a acurácia do modelo proposto, que foi de 91.96%, não apresentou melhor resultado que o modelo original, que foi de 94.92%. Em geral, o modelo proposto tem acurácia média de 91.72%, enquanto a PCNN original tem acurácia média de 84.74%.

Observamos também que 71.43% das imagens experimentadas o TPR do modelo proposto foi maior que a PCNN original, significando que o método proposto foi superior na identificação dos pixels dos objetos. De modo geral, o modelo proposto tem TPR média de 95.31%, enquanto a PCNN original tem TPR média de 89.30%.

Também analisamos o tempo computacional em cada experimento. A Figura 6.3 e 6.4 mostra o tempo computacional dos métodos para imagens presentes nos trabalhos de Kuntimad e Ranganath (1999), Zhou *et al.* (2007) e Wang *et al.* (2010) e para imagens obtidas pelo satélite CBERS-2B do Estado de Goiás disponibilizadas pelo INPE, respectivamente. Verificamos que a PCNN original teve um tempo computacional superior em todos os experimentos. Em geral, o modelo proposto tem um tempo computacional médio de 10309.28 segundos, enquanto a PCNN original tem um tempo computacional médio de 16260.42 segundos.

Ou seja, o modelo proposto apresenta uma redução de 36.60% no tempo computacional em relação a PCNN original. Assim, ao compararmos os resultados da PCNN Original com os resultados do modelo proposto, temos que o nosso modelo obteve melhores resultados tanto em relação às medidas de correspondência quanto com relação ao tempo computacional.

Tabela 6.1 – Medidas de avaliação quantitativa com relação às imagens presentes na literatura

Imagem	Medidas de avaliação quantitativa (PCNN Original × PCNN Proposta)															
	TP		TN		FP		FN		PPV (%)		TPR (%)		FPR (%)		ACC (%)	
	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*
1	21553	21513	42782	43798	21762	20746	803	843	49.76	50.94	96.48	96.23	33.92	32.14	74.03	75.16
2	16909	16909	41907	42226	8653	8334	115	115	66.15	66.98	99.32	99.32	17.11	16.48	87.03	87.50
3	11033	12960	126193	119992	3826	10027	3518	1591	74.25	56.38	75.82	89.07	2.94	7.71	94.92	91.96


Fonte: o autor.

Tabela 6.2 – Medidas de avaliação quantitativa com relação às imagens de satélite

Imagem	Medidas de avaliação quantitativa (PCNN Original × PCNN Proposta)															
	TP		TN		FP		FN		PPV (%)		TPR (%)		FPR (%)		ACC (%)	
	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*	PCNN	PCNN*
1	16221	76081	70732	15931	6386	300	10	1037	71.75	99.61	99.94	98.66	8.28	1.85	93.15	98.57
2	2313	1299	77221	80075	4388	1534	78	1092	34.52	45.85	96.74	54.33	5.38	1.88	94.68	96.87
3	4822	4762	30904	32463	4221	2662	54	114	53.32	64.14	98.89	97.66	12.02	7.58	89.31	93.06
4	4376	3933	48595	83255	35174	514	0	443	11.06	88.44	100	89.88	41.99	0.61	60.10	98.91


Fonte: o autor.

Figura 6.3 – Desempenho computacional das imagens presentes na literatura.



Fonte: o autor.

Figura 6.4 – Desempenho computacional das imagens de satélite.



Fonte: o autor.

Capítulo 7

Conclusão

O uso de ferramentas computacionais para auxiliar o processo de segmentação de imagens é constantemente discutido e estudado pela comunidade científica. O presente trabalho analisou a eficácia e a eficiência da utilização das redes neurais na segmentação de imagens, principalmente imagens de satélite. Nesse sentido, apresentamos uma nova proposta de segmentação para o modelo de Rede Neural de Pulso Acoplado (do inglês - PCNN) e utilizamos vários experimentos para fazermos uma análise quantitativa entre a PCNN original e a PCNN proposta.

Como já foi dito anteriormente, a segmentação de imagens tem como objetivo subdividir uma imagem de entrada em suas partes constituintes ou objetos. Portanto, a segmentação consiste em atribuir um rótulo a cada pixel da imagem, identificando-o a qual região ele pertence, de acordo com suas características comuns. Apesar de existirem várias técnicas de segmentação de imagens, empregamos um método inspirado no neurônio biológico, que são as Redes Neurais Artificiais (RNAs). Além disso, a principal importância da RNA está associada à capacidade de aprender por meio da experiência e armazenar o conhecimento adquirido.

Neste trabalho apresentamos de forma geral, conceitos fundamentais relacionados ao processamento de imagens. Tais conceitos foram definidos e exemplificados. Posteriormente, realizamos uma revisão dos conceitos sobre o neurônio biológico necessários para o entendimento das Redes Neurais Artificiais, seguido do estado da arte relacionado à Segmentação de Imagens usando Redes Neurais Artificiais. Neste sentido, descrevemos uma nova proposta de segmentação de imagens utilizando a PCNN.

A partir deste ponto, propomos uma modificação simples na PCNN original, a qual apresentou resultados promissores demonstrando sua potencialidade. A partir da análise dos resultados descritos nas Tabelas 6.1 e 6.2, comparados com a PCNN original, o modelo proposto foi mais efetivo, ou seja, teve correspondências mais precisas com as imagens *ground truth*. Nesta análise observamos que de 7 imagens utilizadas como experimento

apenas uma imagem (Tabela 6.1), experimento 3, o modelo proposto não apresentou um melhor resultado de acurácia que o modelo original. De modo geral, o modelo proposto obteve uma acurácia média de 91.72% e uma TPR média de 95.31% enquanto a PCNN original obteve uma acurácia média de 84.74% e uma TPR média de 89.30%. Além disso, ao analisarmos as Figuras 6.3 e 6.4 confirmamos também que o método proposto teve um desempenho computacional significativamente menor, onde a média total dos nossos resultados foram 36.60% mais rápidos.

Com todas as informações aqui expostas, acreditamos que o campo de segmentação de imagens utilizando Redes Neurais Artificiais é acima de tudo extremamente vasto e promissor. Além disso, percebemos que ao lidar com processamento de imagem, temos um amplo campo de pesquisa e esses pesquisadores referidos no trabalho são apenas o começo de um conhecimento ainda mais amplo que está em desenvolvimento. Por ser um assunto que ao longo dos anos ganhou credibilidade, e devido á descobertas relacionadas a ela a cada momento, tornou-se bastante atrativo para profissionais de diferentes áreas, tornando-se um assunto interdisciplinar. Os conhecimentos obtidos até hoje atraem o interesse de diferentes profissionais das ciências, que buscam, cada um em sua área, novos caminhos através da modelagem neural.

Como sugestões para trabalhos futuros, a experiência adquirida com este trabalho permite apontar as seguintes possibilidades: analisar o processo de convergência do método de segmentação proposto e verificar a possibilidade da rede proposta gerar como resultado uma imagem não binarizada para que possa ser feito uma correspondência com imagens *ground truth* que discriminem diferentes texturas.

REFERÊNCIAS

ALBANEZ D. O.; BATISTA, M. A. e. S. S. F. Image segmentation based in pulse coupled neural network. *III ERIGO 2015 - Escola Regional de Informca de Goi*, 2015. Citado na página 101.

_____. _____. *I Worshop em Matemca Industrial, Modelagem e Otimiza*, 2015. Citado na página 113.

_____. Image segmentation by otsu method. *Enacomp - XII Encontro Anual de Computa*, 2015. Citado na página 91.

_____. Segmenta de imagens usando rede neural hopfield. *13 Congresso de Pesquisa, Ensino e Extens CONPEEX*, 2016. Citado na página 131.

ALBANEZ D. O. E BATISTA, M. A. O que gmenta de imagens? *V Workshop de lgebra da UFG - Regional Catal*, 2016. Citado na página 137.

_____. Segmenta de imagens utilizando redes neurais artificiais. *Semana de Defesas 2016/1 do Curso de Ciia da Computa - UFG/RC/IBiotec*, 2016. Citado na página 117.

ALBANEZ D. O.; LINO, S. S. e. M. J. J. Aplica de algoritmos de otimiza a absorvedor dinco de vibra. *II Conpeex Regional Catal*, 2016. Citado na página 123.

AWAD, M.; CHEHDI, K.; NASRI, A. Multi component image segmentation using genetic algorithm and artificial neural network. *Computer Journal of Geosciences and Remote Sensing Letters*, IV, n. 4, p. 571–575, 2007. Citado na página 63.

AZEVEDO, E.; CONCI, A. *Computação Gráfica: geração de imagem*. Rio de Janeiro: Campus, 2003. Citado na página 37.

BENTO, M. *et al. Image processing techniques applied for corrosion damage analysis*. Rio de Janeiro - RJ, 2009. Citado na página 62.

BOTELHO, G. R. *Processamento de imagens no auxílio à detecção de câncer de pele utilizando redes neurais artificiais*. Monografia (Graduação) — Universidade Federal de Goiás - Campus Catalão, Catal GO, 2007. Citado na página 42.

BOTELHO, M. F.; CENTELHO, J. A. S. *Identificação de edificações presentes em imagem de alta resolução utilizando redes neurais e dados do laser scanner*. 2014. Disponível em: <<https://www.ufpe.br/cgtg/ISIMGEO/CD/html/Fotogrametria%20e%20Sensoriamento%20Remoto/Artigos/f025.pdf>>. Acesso em: 11 mar. 2016. Citado na página 61.

- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC, 2007. Citado 2 vezes nas páginas 52 e 53.
- CAUFIELD, H. J.; KINSER, J. M. Finding shortest path in the shortest time using pcnn's. *IEEE Transactions on Neural Networks*, X, n. 3, p. 604 – 606, 1999. Citado na página 64.
- CHAI, J. W. *et al.* Image segmentation by em-based adaptive pulse coupled neural networks in brain magnetic resonance imaging. *Computerized Medical Imaging and Graphics*, XXXIV, n. 4, p. 308320, 2010. Citado 2 vezes nas páginas 62 e 63.
- CRUZ, N. C.; GALO, M. L. B. T. Aplicação de redes neurais artificiais na classificação de imagens multitemporais e multisensor. In: COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS. Curitiba, 2003. v. 3. Citado na página 64.
- DENG, X.; MA, Y. Pcn model analysis and its automatic parameters determination in image segmentation and edge detection. *Chinese Journal of Electronics*, v. 23, n. 1, p. 97–103, 2014. Citado na página 64.
- ECKHORN, R. *et al.* Feature linking via synchronization among distributed assemblies: Simulations of results from cat visual cortex. *Neural Computation*, II, n. 3, p. 293 – 307, 1990. Citado 2 vezes nas páginas 67 e 68.
- EMARUCHI, B. *et al.* Land cover mapping using an artificial neural networks. *ISPRS mapping and geographic information systems*, XXX, p. 84–89, 1994. Citado 2 vezes nas páginas 46 e 47.
- FAN, J.; ZHAO, D.; WANG, J. Oil spill gf-1 remote sensing image segmentation using an evolutionary feedforward neural network. *Neural Networks (IJCNN), International Joint Conference on*, p. 460 – 464, 2014. Citado 2 vezes nas páginas 61 e 62.
- FAUSETT, L. *Fundamentals of neural networks - architectures, algorithms, and applications*. New Jersey: Prentice Hall, 1994. Citado na página 56.
- FRATE, F. D.; ANGIULI, E.; SALVATORI, L. Neural networks for oil spill detection using ers and envisat imagery. *Proceeding of SeaSar*, 2006. Citado 2 vezes nas páginas 61 e 62.
- FUNCK, J. W. *et al.* Image segmentation algorithms applied to wood defect detection. *Computers and Electronics in Agriculture*, XLI, p. 157–179, 2003. Citado 2 vezes nas páginas 61 e 63.
- GAO, C.; ZHOU, D.; GUO, Y. Automatic iterative algorithm for image segmentation using a modified pulse-coupled neural network. *Neurocomputing*, CXIX, p. 332 – 338, 2013. Citado 2 vezes nas páginas 64 e 68.
- GOMES, J.; VELHO, L. *Computação Gráfica: Imagem*. Rio de Janeiro: IMPA, 1994. Citado na página 41.
- GONZALES, R. C.; WOODS, R. E. *Digital Image Processing*. New Jersey: Prentice Hall, 2001. Citado 14 vezes nas páginas 25, 29, 30, 31, 32, 33, 35, 37, 38, 39, 40, 42, 43 e 52.
- GU, X.; YU, D.; ZHANG, L. Image thinning using pulse coupled neural network. *Pattern Recognition Letters*, v. 25, n. 9, p. 1075–1084, 2004. Citado na página 64.
- _____. Image shadow removal using pulse coupled neural network. *IEEE Transactions on Neural Networks*, v. 16, n. 3, p. 692 – 698, 2005. Citado na página 64.

GUYON, I. Neural networks and applications tutorial. *Physics Reports*, XVII, n. 3, p. 215 – 259, 1991. Citado na página 47.

HARDEBERG, J. Y. Color imaging: Device-independent color, color hardcopy, and graphic arts v. In: DESKTOP SCANNING TO SRGB, 3963. San Jose - CA, 2000. p. 47. Citado na página 40.

HASSANIEN, A. E.; ALI, J. M. Digital mammogram segmentation algorithm using pulse coupled neural networks. *Proceedings third international conference on image and graphics*, p. 92 – 95, 2012. Citado 3 vezes nas páginas 62, 63 e 64.

HASSANIEN, A. E.; EL-DAHSHAN, E. A.; AL-QAHERI, H. Prostate boundary detection in ultrasound images using biologically-inspired spiking neural network. *Applied Soft Computing*, XI, n. 2, p. 20352041, 2010. Citado 2 vezes nas páginas 62 e 63.

HAYKIN, S. *Redes Neurais: princípios e prática*. Porto Alegre: Bookman, 2001. Citado 12 vezes nas páginas 25, 26, 45, 46, 47, 51, 52, 54, 55, 56, 58 e 59.

HINSHAN, W.; LENT, A. H. An introduction to nmr imaging: From the bloch equation to the imaging equation. *Proceedings of the IEEE*, LXXI, n. 3, p. 338 – 350, 1983. Citado na página 63.

Jl, L.; Yl, Z.; PU, X. Fingerprint classification by spcnn and combined lvq networks. In: *Proceedings of the Second international conference on Advances in Natural Computation*. Xian, China: [s.n.], 2006. v. 4221, p. 395 – 398. Citado na página 64.

JOHNSON H. RANGANATH, G. K. J. L.; CAULFIELD, H. J. Pulse-coupled neural networks. In: *Neural Networks and Pattern Recognition*. San Diego, CA: Academic Press, 1998. p. 1 – 56. Citado na página 64.

JOHNSON, J. L.; PADGETT, M. L. Pcn models and applications. *IEEE Transactions on Neural Networks*, v. 10, n. 3, p. 480 – 498, 1999. Citado na página 64.

KAVZOGLU, T. Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling Software*, XXIV, n. 7, p. 850 – 858, 2009. Citado na página 57.

KOVÁCS, Z. L. *O cérebro e sua mente - Uma introdução à neurociência computacional*. São Paulo: Acadêmica, 1997. Citado na página 29.

KUNTIMAD, G.; RANGANATH, H. Perfect image segmentation using pulse coupled neural network. *IEEE Transactions on Neural Networks*, X, n. 3, p. 591 – 597, 1999. Citado 5 vezes nas páginas 64, 67, 73, 74 e 76.

LEI, K.; YANG, L. A new algorithm of image segmentation based on bidirectional search pulse-coupled neural network. *IEEE International Conference on Computational Aspects of Social Networks*, XI, n. 6, p. 101 – 104, 2010. Citado na página 64.

LI, J. *et al.* Image segmentation with pcnn model and immune algorithm. *Journal of Computers*, VIII, n. 9, p. 2429 – 2436, 2013. Citado na página 64.

LINDBLAD, T.; KINSER, J. *Image processing using pulse-coupled neural networks*. 2nd. ed. [S.l.]: Springer, 2005. Citado na página 64.

LINDBLAD, T.; KINSER, J. M. *Image processing using pulse-coupled neural networks*. [S.l.]: Springer, 2005. Citado na página 68.

LIPORACE, F. dos S. *Um sistema neural para o monitoramento do desflorestamento na região Amazônica utilizando imagens do landsat*. Monografia (Dissertação de Mestrado) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1994. Citado 2 vezes nas páginas 47 e 52.

LOPEZ, D. *et al.* Combining features to improve oil spill classification in sar images. *Lecture Notes in Computer Science*, v. 4109, p. 928936, 2006. Citado na página 62.

LUDEIG, A.; CANPOLIM, S. Esquecer é tão bom quanto lembrar. *Revista Época*, XI, n. 6, p. 115–133, 2010. Citado na página 49.

LUGER, F. G. *Inteligência Artificial - Estruturas e Estratégias para a Resolução de Problemas Complexos*. [S.l.]: University of New Mexico at Albuquerque, 2004. Citado 3 vezes nas páginas 45, 46 e 54.

MACHADO, R. *et al.* Monitoring the deforestation of the amazon region with neural network. *Neural Networks: IJCNN '93-Nagoya. Proceedings of 1993 International Joint Conference on*, II, p. 1239–1242, 1993. Citado 2 vezes nas páginas 61 e 62.

MARTINS, C. *et al.* Automatic microaneurysm detection and characterization through digital color fundus images. In: ANAIS DO SIMPÓSIO BRASILEIRO DE REDES NEURAIS (SBRN). Salvador - BA, 2008. Citado na página 63.

MUELLER, R. K.; KAVEH, M.; WADE, G. Reconstructive tomography and applications to ultrasonics. *Proceedings of the IEEE*, LXVII, n. 4, p. 567 – 587, 1979. Citado 2 vezes nas páginas 62 e 63.

OSÓRIO, F.; VIEIRA, R. Sistemas híbridos inteligentes. In: XIX CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO, 8. Rio de Janeiro, 1999. p. 609–614. Citado 2 vezes nas páginas 53 e 59.

PADILHA, F. R. R.; KHATCHATOURIAN, O. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. *Revista Brasileira de Engenharia Agrícola*, XXVIII, n. 4, p. 759 – 769, 2008. Citado 2 vezes nas páginas 61 e 62.

PETROU, M.; BOSDOGIANNI, P. *Image Processing: The Fundamentals*. 1999. Citado 2 vezes nas páginas 30 e 32.

PHAN, D. T.; LUI, X. *Neural networks for identification, prediction and control*. London: Springer-Verlag, 1995. Citado na página 56.

PRATOLA, C.; FRATE, F. D.; LICCIARDI, G. S. . D. S. . G. Characterizing land cover from x-band cosmo-skymed images by neural networks. *Urban Remote Sensing Event*, XXIV, n. 7, p. 49 – 52, 2011. Citado na página 57.

PREDINI, H.; R.SCHWARTZ, W. *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. São Paulo: Editora Thomson Learning, 2007. Citado na página 42.

PRINCIPE, J.; J-M, K. Dynamic modelling of chaotic time series with neural networks. *Advances in Neural Information Processing Systems*, VII, n. 7, p. 311 – 318, 1995. Citado na página 59.

R., S. *Computer Vision: algorithms and applications*. [S.l.]: Springer, 2011. Citado na página 74.

RANGANATH, H. S.; G.KUNTIMAD. Object detection using pulse coupled neural network. *IEEE Transactions on Neural Networks*, v. 10, n. 3, p. 615 – 620, 1999. Citado na página 64.

RANGANATH, H. S.; KUNTIMAD, G. Iterative segmentation using pulse-coupled neural networks. *SPIE*, n. 2760, p. 543 – 554, 1996. Citado na página 64.

RANGANATH, H. S.; KUNTIMAD, G.; JOHNSON, J. L. Pulse coupled neural networks for image processing. In: *Proceedings of IEEE Southeastcon*. Raleigh, NC: [s.n.], 1995. Citado na página 64.

RIBEIRO, E. F. *Caracterização de Imagens Utilizando Redes Neurais*. Monografia (Dissertação de Mestrado) — Universidade Federal de Uberlândia, Uberlândia - MG, 2009. Citado 6 vezes nas páginas 30, 32, 39, 41, 43 e 49.

ROCHA, E. L. da *et al.* *Diagnóstico Automatizado de Doenças no Colo do Útero Baseado em Redes Neurais Artificiais e Processamento de Imagens Digitais*. 2007. Disponível em: <<http://periodicos.unesc.net/iniciacaocientifica/article/view/173>>. Acesso em: 29/03/2015. Citado 2 vezes nas páginas 42 e 63.

RODRIGUES, A. F. Graduação, *Localização e Reconhecimento de Placas de Sinalização Utilizando um Mecanismo de Atenção Visual e Redes Neurais Artificiais*. Campina Grande: [s.n.], 2002. Citado na página 32.

RUSSEL, S.; NORVIG, P. *Inteligência Artificial*. [S.l.]: Elsevier, 2004. Citado 2 vezes nas páginas 46 e 56.

RUZ, G. A.; ESTÉVES, P. A. Remote sensing image segmentation based on self organizing map at multiple scale. *Intelligent Production Machines and Systems D.T. Phan, E.E. Eldukhri and A.J. Soroka*, 2005. Citado 2 vezes nas páginas 61 e 63.

SAMMOUDA, R. *et al.* Agriculture satellite image segmentation using a modified artificial hopfield neural network. *Computers in Human Behavior*, XXX, p. 436 – 441, 2014. Citado 2 vezes nas páginas 61 e 62.

SCHOENMAKERS, R.; WILKINSON, G.; SCHOAUTEN, T. Segmentation of remotely-sensed images: a redefinition for operational applications. *International Geoscience and Remote Sensing Symposium*, n. 1, p. 1087–1090, 1991. Citado na página 35.

SCUDDER, H. J. Introduction to computed aided tomography. *Proceedings of the IEEE*, LXVI, n. 6, p. 628 – 637, 1978. Citado 2 vezes nas páginas 62 e 63.

SELLI, M. F.; SELEGHIM, P. J. 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, 2007. Citado na página 47.

SHANG, L.; YI, Z. A class of binary images thinning using two pcnns. *Neurocomputing*, v. 70. Citado na página 64.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. São Paulo: Atliber Editora Ltda, 2010. Citado 5 vezes nas páginas 47, 48, 52, 53 e 59.

SONG, Y.-M.; XIAO-HUI, Z.; LIU, G.-I. One segmentation algorithm of multi-target image based on improved pcnn. *Intelligent Systems and Applications (ISA), 2nd International Workshop on*, p. 1 – 4, 2010. Citado 2 vezes nas páginas 64 e 68.

SOUTO, R. P. *Segmentação de Imagem Multiespectral utilizando-se o Atributo Matiz*. São José dos Campos: INPE, 2000. Citado na página 39.

STOUFFS, J.; MICHEL, G. Pipeline leak detection based on mass balance: Importance of the packing term. *Journal of Loss Prevention in the Process Industries*, v. 6, n. 5, p. 307 – 312, 1993. Citado na página 62.

TAMURA, H.; MORI, S.; YAMAWAKI, Y. Textural features corresponding to visual perception. *IEEE Transactions on Systems, Man, and Cybernetics*, VIII, n. 8, p. 460–473, 1978. Citado na página 42.

VILELA, A. L. M. *Anatomia e Fisiologia Humana ?- Coordenação e Regulação*. 2015. Disponível em: <<http://www.afh.bio.br/nervoso/nervoso1.asp>>. Acesso em: 13 dez. 2015. Citado na página 48.

WANG, H. *et al.* A simplified pulse-coupled neural network for cucumber image segmentation. *IEEE International Conference on Computational and Information Sciences*, p. 1053 – 1057, 2010. Citado 6 vezes nas páginas 61, 62, 64, 73, 74 e 76.

WANG, L. *et al.* An automatic segmentation and classification framework based on pcnn model for single tooth in microct images. *PLoS ONE*, v. 11, n. 6, p. doi:10.1371/journal.pone.0157694, 2016. Citado na página 64.

WANG, Z.; MA, Y. Dual-channel pcnn and its application in the field of image fusion. In: *Proceedings of the 3rd International Conference on Natural Computation*. [S.l.: s.n.], 2007. v. 1, p. 755–759. Citado na página 64.

_____. Medical image fusion using m-pcnn. *An International Journal on Multi-Sensor Multi-Source Information Fusion*, v. 9, n. 2, p. 176–185, 2008. Citado na página 64.

WANG, Z. *et al.* Image and vision computation. *Image and Vision Computation*, XXVIII, n. 1, 2010. Citado 2 vezes nas páginas 68 e 69.

WASSERMAN, P. D. *Neural Computing Theory and Practice*. New York: Van Nostrand Reinhold, 1989. Citado 2 vezes nas páginas 45 e 61.

WOLFER, J. Pulse coupled neural networks and image morphology for mammogram pre-processing. In: 3RD INTERNATIONAL CONFERENCE ON INNOVATIONS IN BIO-INSPIRED COMPUTING AND APPLICATIONS, 6337679. San Jose - CA, 2012. p. 286 – 290. Citado 2 vezes nas páginas 62 e 63.

XU, B.; LIN, S. Automatic color identification in printed fabric images by a fuzzy neural network. *Computer Journal of AATICC Review*, II, n. 9, p. 42 – 45, 2002. Citado na página 63.

YANG, Z.; ZHOU, Q.; ZHOU, D. Gray image edge detection method based on pcnn. In: *Computer Engineering Applications*. Xi'an, China: [s.n.], 2004. v. 40, n. 4, p. 92 – 94. Citado na página 64.

- YAO, K. *et al.* Unsupervised segmentation using a self organizing map and a noise model estimation in sonar imagery. *Computer Journal of Pattern Recognition*, XXIII, n. 9, p. 1575–1584, 2000. Citado na página 63.
- YIN, L.; ZHANG, G.; WU., Z. A scale-synthesis method for high resolution remote sensing image segmentation. *IEEE Transaction on Geoscience and Remote Sensing*, L, n. 10, p. 1–9, 2012. Citado na página 25.
- ZHANG, H.; CHEN, N.; LIN, Y. Segmentation of mri based on graph space construction, information and automation. *Computers in Human Behavior*, p. 1433 – 1437, 2009. Citado 2 vezes nas páginas 62 e 63.
- ZHANG, J.; DONG, J.; SHI, M. An adaptive method for image filtering with pulse-coupled neural networks. *IEEE Int. Conf. on Image Processing*, II, n. 5-6, p. 133 –136, 2005. Citado na página 64.
- ZHANG, X.; TAN, G.; CHEN, M. A reliable distributed convolutional neural network for biology image segmentaion. *Cluster, Cloud and Grid Computing (CCGrid), 2015 15th IEEE/ACM International Symposium on: Shenzhen, China*, 2015. Citado 2 vezes nas páginas 62 e 63.
- ZHOU, Z. *et al.* Remote sensing image segmentation based on self organizing map at multiple scale. *Proceedings of SPIE Geoinformatics: Remotely Sensed Data and Information*, VIDC-CLII, p. 122–126, 2007. Citado 4 vezes nas páginas 63, 73, 74 e 76.
- ZHU, Y. *et al.* Exploiting segmentation and context in deep neural network for object detection. *University of Toronto*, 2015. Disponível em: <<http://arxiv.org/abs/1502.04275v1>>. Acesso em: 25 set. 2015. Citado na página 61.
- ZUCKER, S. W.; KANT, K. Multiple-level representations for texture discrimination. In: IEEE CONFERENCE ON PATTERN RECOGNITION AND IMAGE PROCESSING, 8. Dallas, TX, 1981. p. 609–614. Citado na página 42.

ANEXO A

Image Segmentation by Otsu Method

Artigo publicado no XII Encontro Anual de Computação - Enacomp, na forma poster, promovido pela Universidade Federal de Goiás - Regional Catalão, realizado entre os dias 16 e 18 de setembro de 2015 (ALBANEZ D. O.; BATISTA, 2015c). O referido trabalho foi premiado com o 1º lugar, de melhor Artigo Pôster.

Como a segmentação de imagem tornou-se uma tarefa indispensável em muitas aplicações e a fim de analisar esta questão, neste artigo utilizamos uma técnica de *thresholding* que é bem conhecida. Devido à sua aplicabilidade inúmeros métodos de *thresholding* foram propostos ao longo dos anos e neste trabalho procuramos realizar o estudo de segmentação de imagens e como resultado deste estudo foi implementado o Algoritmo do Otsu que tem como objetivo converter imagens em tons de cinza em imagens binárias (preto e branco) tornando-as mais identificáveis.

Durante este estudo apresentamos um método para selecionar automaticamente um *threshold* ótimo a partir de um histograma de nível de cinza. O método mostrou-se eficaz na melhoria da qualidade visual das imagens. O método de Otsu caracteriza-se pela sua natureza não paramétrica e não supervisionada da seleção do *threshold* e pode ser recomendado como o mais simples e padrão para seleção do *threshold* automático que pode ser aplicado a vários problemas práticos.

Image Segmentation by Otsu Method

Daniela O. Albanez¹, Marcos N. Rabelo¹, Sérgio F. da Silva¹, Marcos A. Batista¹

¹Graduate Program in Modeling and Optimization, Federal University of Goiás
Av. Dr. Lamartine Pinto de Avelar, 1120, CEP 75704-020, Catalão, GO, Brasil

doalbanez@hotmail.com, rabelo@dmate.ufpe.br, sergio@ufg.br, marcos.batista@pq.cnpq.br

Abstract. *Image segmentation has become an indispensable task in many image applications. In order to analyze this issue, the use of thresholding technique is well-known. Because of its applicability, quite a number of thresholding methods have been proposed over the years. This paper attempts to undertake the study of image segmentation and as a result of this study was implemented OTSU algorithm that has the goal to convert images to black and white and so make them better identifiable.*

1. Introduction

Segmentation is usually first step in the analysis of an image, with the idea of segmenting an object by dividing the parts, or parts considered homogeneous according to some criterion uniformity, and ends when the objects interest has been separated. There are several segmentation techniques being used in literature. In general this technique is based on value number of each pixel in the texture analysis and image histogram [Gonzalez and Woods 2002].

The image segmentation consists in to subdivide the image into its constituent parts. The idea of image segmentation is to classify pixels of set of pixels. It is the first analysis stage image [Acharya and Ray 2005, Gonzalez and Woods 2002, Petrou and Bosdogianni 1999]. Segmentation helps identify differences between two or more objects, both among themselves and between each other and the background. The segmentation is based on the basic properties of intensity values in gray levels and may be a discontinuity or similarity. The discontinuity is due to the partition of the image by intensity values of gray. While the similarity is based on partitioning an image into regions that are similar according to a set of pre-defined criteria, thresholding and region growing are examples of methods in this category.

Thresholding is the identification of the best threshold in which object distinct from the background, several methods have been proposed [Otsu 1978, Kapur and Wong 1985]. In this context, there are two types of thresholding algorithms:

- Global thresholding algorithms
- Local or adaptive thresholding algorithms

In global thresholding, a single threshold for all the image pixels is used. When the pixel values of the components and its background are fairly consistent in their respective values over the entire image, global thresholding could be used. In adaptive thresholding, different threshold values for different local areas are used. In this paper adaptive thresholding is used. In order to perform the analysis of images by thresholding technique, we will employ Otsu's method, which is considered one of the best method for adaptive thresholding images [Otsu 1978].

2. Theoretical Foundation

2.1. Histogram

The histogram is a graph that represents values of the shades of the pixels of an image with a particular brightness [Gonzalez and Woods 2002, Petrou and Bosdogianni 1999], in other words, is the representation of the distribution of colors in an image. The histogram shows detail in the shadows, midtones, highlights, but first of all shows the global image description. If the histogram is narrow, then the image is barely visible, it is because the image gray levels are low. On the other hand, an image with higher contrast and provides a uniform visibility of these gray level histogram [Acharya and Ray 2005].

According [Gonzalez and Woods 2002], the histogram is a discrete probability density function represented by:

$$p_x = \frac{n_x}{N} \quad (1)$$

where:

x is the gray level,

n_x is the number of the pixels in the image having gray level x and

N is the total number of the pixels in the image.

The $x \in \{1, 2, \dots, L\}$, where L is the value of the pixels in the scanned image.

2.2. Thresholding

The thresholding is one of the simplest techniques of segmentation, it causes the image to grayscale becomes a binary image, separating regions of an image in two other regions - the white background determined by the value (1) and the black object determined by the value (0), thus having a black/white image. This is only possible by defining a threshold T that separates groups of image gray levels [Parker 2011, Jahne and Haubecker 2000, Gonzalez and Woods 2002].

Segmentation occurs by scanning the image, pixel by pixel, thereby distinguishing the background of the object, depending on the relationship between the pixel value and the threshold value. However, the thresholding is effective when the subject is very different gray levels, thus the gray levels of the object and background form distinctly two peaks and the thresholding is trivial.

Suppose that the gray level histogram corresponds to an image $f(x, y)$ composed of dark objects on the light background, in such a way that object and background pixels have gray levels grouped into two dominant modes. One obvious way to extract the objects from the background is to select a threshold T that separates these modes. Then any point (x, y) for which $f(x, y) > T$ is called an object point, otherwise, the point is called a background point.

Mathematically, thresholding may be defined as:

$$g(x, y) = \begin{cases} \text{object} & \text{if } f(x, y) > T, \\ \text{background} & \text{if } f(x, y) \leq T. \end{cases} \quad (2)$$

where $f(x, y)$ is the input image, T is the threshold and $g(x, y)$ is the output image (thresholding).

Usually it is very common to use the histogram to select a threshold for the thresholding and a threshold is obvious, when occurs at the low point between two peaks in the histogram. In this context, a histogram is a vector having the same number of dimensions as the image does gray levels, [Parker 2011, Petrou and Bosdogianni 1999].

2.3. Adaptive Thresholding

The adaptive thresholding technique which is a local aspects analyzes the image and determines a threshold for each region defining whether the pixel is considered black or white.

This technique has algorithms from simple solutions to the optimal solution of local thresholding. This technique is well known and there are several algorithms with different answers depending on the type of image [Ballard 1982, Sezgin 2004].

2.4. Otsu's Method

The Otsu method [Otsu 1978] is considered one of best methods for adaptive thresholding images, but its quality is directly coupled at the cost of complexity. The thresholding operation is considered to be the partitioning of the pixels of an image L gray levels into two classes, C_0 and C_1 , which can represent the object and the background, or vice versa, and this partition will be in the gray level t . This is a non-parametric method and unsupervised, which seeks to automatically select the limits of gray levels that best separate or segment the elements of interest in an image of two classes. Thus we have:

$$\begin{aligned} C_0 &= 1, 2, \dots, k \\ C_1 &= k + 1, \dots, L \end{aligned} \quad (3)$$

A measure of region homogeneity is variance, regions with high homogeneity will have low variance. Otsu's method selects the threshold by maximizing the between-class variance (or, conversely, minimizes the within-class variance) of the two groups of pixels separated by the thresholding operator. It does not depend on modeling the probability density functions, however, it assumes a bimodal distribution of gray level values, if the image approximately fits this constraint, it will do a good job.

The normalized histogram is a probability distribution function.

$$\begin{aligned} p_x &= \frac{n_x}{N} \\ \sum_{x=1}^L p_x &= 1 \quad p_x \geq 0 \end{aligned} \quad (4)$$

Then the probabilities of class occurrence and the class mean levels, respectively, are given by:

$$\omega_0 = Pr(C_0) = \sum_{x=1}^k p_x = \omega(k) \quad (5)$$

$$\omega_1 = Pr(C_1) = \sum_{x=k+1}^L p_x = 1 - \omega(k) \quad (6)$$

The mean gray level value of the background pixels and the object pixels respectively will be:

$$\mu_0 = \sum_{x=1}^k xPr(x|C_0) = \sum_{x=1}^k xp_x/\omega_0 = \mu(k)/\omega(k) \quad (7)$$

$$\mu_1 = \sum_{x=k+1}^L xPr(x|C_1) = \sum_{x=k+1}^L xp_x/\omega_1 = \frac{\mu_T - \mu(k)}{1 - \omega(k)} \quad (8)$$

where

$$\omega(k) = \sum_{x=1}^k p_x \quad (9)$$

and

$$\mu(k) = \sum_{x=1}^k xp_x \quad (10)$$

are the *zeroth* and the first-order cumulative moments of the histogram up to the k_{th} level, respectively,

$$\mu_T = \mu(L) = \sum_{x=1}^L xp_x \quad (11)$$

is the total mean level of the original picture. The relation is true for any choice of k :

$$\begin{aligned} \omega_0\mu_0 + \omega_1\mu_1 &= \mu_T \\ \omega_0 + \omega_1 &= 1 \end{aligned} \quad (12)$$

The variance of the background and the object pixels will be:

$$\sigma_0^2 = \sum_{x=1}^k (x - \mu_0)^2 Pr(x|C_0) = \sum_{x=1}^k (x - \mu_0)^2 p_x/\omega_0 \quad (13)$$

$$\sigma_1^2 = \sum_{x=k+1}^L (x - \mu_1)^2 Pr(x|C_1) = \sum_{x=k+1}^L (x - \mu_1)^2 p_x/\omega_1 \quad (14)$$

The variance of the whole image is:

$$\sigma_T^2 = \sum_{x=1}^L (x - \mu_T)^2 p_x \quad (15)$$

It can be shown that the variance can be written as follows:

$$\begin{aligned} \sigma_T^2 &= \omega_0\sigma_0^2 + \omega_1\sigma_1^2 + \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2 \\ &= \sigma_W^2 + \sigma_B^2 \end{aligned} \quad (16)$$

where σ_W^2 is defined to be the within-class variance and σ_B^2 is defined to be the between-class variance.

Since the total variance σ does not depend on T , the T minimizing σ_W^2 will be the T maximizing σ_B^2 . Let's consider maximizing σ_B^2 , we can rewrite σ_B^2 as follows:

$$\sigma_B^2(k) = \frac{[\mu_T \omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (17)$$

Therefore, the optimal threshold k^* is:

$$\sigma_B^2(k^*) = \max_{1 \leq k < L} \sigma_B^2(k) \quad (18)$$

2.5. Algorithm

The Otsu's method is used to generate a black and white image by calculating the threshold automatically. He believes that the input image have two classes of pixels, the object and the background, seeking for the optimum threshold to segment the image with better quality. The Otsu algorithm follows these steps:

1. Get the frequency of each intensity $1 \leq x < L$.
2. Divide each frequency by the total number of pixels , obtaining the probability (histogram normalization).
3. Get the partial sums accumulated ω and μ of each intensity through the odds.
4. For each intensity k , calculate $\sigma_B^2(k)$. If this is the highest value, update the optimal threshold k^* with k .
5. For each pixel, if the pixel intensity is less than or equal to k^* , it is considered object; otherwise, background.

3. Experiments Verifications

The following text aims to present the results achieved in implementing the Otsu's method in targeting RGB images and also images of text. The algorithm assumes that the image to be threshold contains two classes of pixels (object and background) then calculates the optimum threshold separating those two classes so that their combined spread (within-class variance) is minimal.

In this section some experiments were performed to verify the quality of the results obtained from the implementation of the Otsu's method for some images. In Figure 1(a) we quantified the original image with 256 gray levels. After segmenting the image using Otsu's method, we obtain the optimum threshold T value to 0.3412 in 0 – 1 scale, as shown in Figure 1(b).

In Figure 2(a) we quantified the original image. After segmenting the image using Otsu's method, we obtain the optimal threshold T value to 0.4275 in 0 – 1 scale, as shown in Figure 2(b).

In Figure 3(a) we quantified the original image. After segmenting the image using Otsu's method, we obtain the optimum threshold value the 0.5608 in 0 – 1 scale, as shown in Figure 3(b).

In Figure 4(a) we quantified the original image. After segmenting the image using Otsu's method, we obtain the optimum threshold value the 0.4902 in 0 – 1 scale, as shown in Figure 4(b).



(a)



(b)

Figure 1. (a) Original image. (b) Image thresholded with Otsu's method.



(a)



(b)

Figure 2. (a) Original image. (b) Image thresholded with Otsu's method.

In Figure 5(a) we quantified the original image. After segmenting the image using Otsu's method, we obtain the optimum threshold value the 0.5765 in 0 – 1 scale, as shown in Figure 5(b).

4. Conclusions

The use of computational tools to aid the image segmentation process is increasingly being discussed and studied by the scientific community. The objective of this work was to implement the Otsu's algorithm that aims thresholding an image to a black and white image. Only after the thresholding of the images is that they should be targeted to later find a optimum threshold.

In this paper, we shown a method for automatically selecting an optimal threshold from a gray level histogram. The method was effective in improving job the visual quality of the images. Otsu's method is characterized by its nonparametric and unsupervised nature of threshold selection and may be recommended as the most simple and standard one for automatic threshold selection that can be applied to various practical problems.

One advantage of this method is that it is not restricted to the type of image histogram. That is, histograms can be applied to unimodal, bimodal or multimodal, but has




(a)




(b)

Figure 3. (a) Original image. (b) Image thresholded with Otsu's method.



(a)



(b)

Figure 4. (a) Original image. (b) Image thresholded with Otsu's method.


better performance in images with higher intensity variance [Otsu 1978].

Acknowledgments


The authors would like to thank the Coordination of Higher Education Personnel Training (Capes), Brazilian National Council for Scientific and Technological Development (CNPq) and Research Support Foundation of Goiás State (FAPEG) for the financial support.

References

- Acharya, T. and Ray, A. K. (2005). *Image Processing - Principles an applications*. John Wiley & Sons.
- Ballard, D. H., B. C. M. (1982). *Computer Vision*. Prentice-Hall.
- Gonzalez, R. and Woods, R. (2002). *Digital Image Processing*. Prentice-Hall.
- Jahne, B. and Haubecker, H. (2000). *Computer Vision and Applications: A Guide for Students and Practitioners*. Prentice-Hall.



(a)



(b)

Figure 5. (a) Original image. (b) Image thresholded with Otsu's method.

- kapur, J.N.; Sahoo, P. K. and Wong, A. K. C. (1985). *Computer Vision, Graphics and Image Processing*. Academia Press.
- Otsu, N. (1978). *A threshold selection method from gray-level histogram*. IEEE Transactions on Systems, Man, and Cybernetics.
- Parker, J. R. (2011). *Algorithms for Image Processing and Computer Vision*. Wiley Publishing, 2nd edition.
- Petrou, M. and Bosdogianni, P. (1999). *Image Processing: The Fundamentals*. John Wiley & Sons.
- Sezgin, M., S. B. (2004). *Survey over image thresholding techniques and quantitative performance evaluation*, volume 13. Journal of Electronic Imaging.

ANEXO B

Image Segmentation Based in Pulse Coupled Neural Network

Artigo publicado no III ERIGO 2015 - Escola Regional de Informática de Goiás, na forma de apresentação oral, realizado no Senac - Goiânia no dia 5 de dezembro de 2015, o qual gerou proveitosas discussões após a apresentação ([ALBANEZ D. O.; BATISTA, 2015a](#)).

Neste artigo descrevemos o método de segmentação de imagem usando Redes Neurais de Pulso Acoplado (do inglês PCNN). O modelo sofreu uma simples alteração na entrada *feeding* em relação ao modelo de PCNN original, o qual consideramos como entrada apenas o pixel da imagem. Comparamos os resultados obtidos com os resultados apresentados na literatura, e em seguida, aplicamos a PCNN em imagens de satélite para mostrar a sua eficácia.

Diante dos resultados obtidos verificamos que, embora tenhamos implementado uma simples rede neural para segmentação de imagens os resultados foram promissores, indicando que a rede PCNN foi eficaz na segmentação de imagens de satélite determinando áreas de irrigação e rios, demonstrando assim sua potencialidade.

Image Segmentation Based in Pulse Coupled Neural Network

Daniela O. Albanez, Sérgio F. da Silva, Marcos A. Batista

¹Graduate Program in Modeling and Optimization, Federal University of Goiás
Av. Dr. Lamartine Pinto de Avelar, 1120, CEP 75704-020, Catalão, GO, Brasil

doalbanez@hotmail.com, sergio@ufg.br, marcos.batista@pq.cnpq.br

Abstract. *This article describes the method of image segmentation using pulse coupled neural networks (PCNN's). The model undergoes a simple change in feeding input with respect to original PCNN, which we consider as input only the image pixel. We will compare the results with results presented in the literature, then we will apply the PCNN to target satellite images and show its effectiveness.*

1. Introduction

Segmentation is usually first step in the analysis of an image, with the idea of segmenting an object by dividing the parts, or parts considered homogeneous according to some criterion uniformity, and ends when the objects interest has been separated.

The image segmentation consist in to subdivide the image into its constituent parts. The idea of image segmentation is to classify pixels of set of pixels. It is the first analysis stage image [Gonzalez and Woods 2002]. Segmentation helps identify differences between two or more objects, both among themselves and between each other and the background.

There are several segmentation techniques being used in literature. In this article we use Pulse Coupled Neural Network (PCNN) for image segmentation.

This technique began to be studied in the 80's and 90's researching the phenomena of synchronous pulse in cat's visual cortex, Eckhorn introduced the linking field network, he discovered that the brain in an oscillating way created binary images that could extract different features from the visual impression [Eckhorn et al. 1990]. With that discovery they developed a neural network, called Eckhorn's network, to simulate this behavior.

In Eckhorn's network, neurons with similar inputs generate pulses simultaneously, filling temporal gaps and varying the magnitude of the input data. According to [Kuntimad and Ranganath 1999] Eckhorn's network has some limitations when it is used for image processing, but network performance depends on the proper selection of the parameters.

Over the years researchers studied neuron models to make it suitable for images processing, with result, applications based on PCNN's are discussed [Kuntimad and Ranganath 1999, Zhang and Shi 2005, Caufield and Kinser 1999]. [Ranganath and Kuntimad 1996] modified Eckhorn's model for image processing applications including image segmentation, smoothing and object detection.

As PCNN is a single-layer neural network model, and in the use of PCNN for image processing, a neuron corresponds to a pixel, at the same time, the neuron corresponding to the pixel link the neighboring neurons. The aim of our paper




Figure 1. Original PCNN Model [Gao and Guo 2013]

is to describe results of comparative experiences of some images were segmented using pulse coupled neural networks in the literature and present various kinds of Goiás State satellite images which we apply a PCNN and demonstrate the effectiveness of this model through experiments. The results of comparative experiments are present in the [Kuntimad and Ranganath 1999, Wang and Tian 2010, Zhou 2014].

The remainder of the paper is organized as follows: In Sect. 2, we briefly review the original PCNN model. In Sect. 3 we make a short comment on the image segmentation based on PCNN and proposed a model. In Sect. 4, the PCNN image segmentation algorithm is described. In Sect. 5, we compare the results obtained with results presented in the literature and we apply the PCNN to target satellite images. Finally, conclusions are in Sect. 6.

2. Original PCNN Model

In this section, we describe the Pulse Coupled Neural Network (PCNN) and its principle of segmentation. The PCNN model was developed by Eckhorn [Eckhorn et al. 1990] is a simple network that does not require training and the network was constructed by simulating the activities of the cat's visual cortex neurons. PCNN model consists of three main parts [Lindblad and Kinser 2005]: input field, modulation field, and spike generator, as shown in Fig.1. PCNN produces an output of binary pulse images when stimulated with images. The mathematical model of the PCNN can be described in following equations [Song and Liu 2010, Wang and Yang 2010]:

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

$$L_{ij}(n) = e^{\alpha_L} L_{ij}[n-1] + V_L \sum_{k,l} W_{i,j,k,l} Y_{ij}[n-1] \quad (2)$$

$$U_{ij}(n) = F_{ij}(n)[1 + \beta L_{ij}(n)] \quad (3)$$

$$Y_{ij} = \begin{cases} 1 & \text{if } U_{ij}(n) > E_{ij}(n), \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

$$E_{ij}(n) = e^{\alpha_E} E_{ij}(n-1) + V_E Y_{ij}(n) \quad (5)$$

The input field contains two parts: a feeding receptive field $F_{ij}(n)$ and linking receptive field $L_{ij}(n)$. Feeding receptive field is intensity of image pixels (i, j) . S_{ij} is a external stimulus. Linking receptive field is input communicate with neighboring neurons through the weight matrice W . M e W refer to the Gaussian weight function with the distance. Each pixel in the image is connected to a unique neuron and each neuron is connected with surrounding neurons through a radius of linking receptive field. The input F the neuron is receiving the input stimulus S which is its corresponding to the intensity of a pixel of size $M \times N$.

The internal activity of the neuron $U_{ij}(n)$ is result by combining the feeding and linking inputs in the modelation field, where β is the linking coefficient. If the internal activity is large, then the neuron will generate a pulse. V_F and V_L are amplitude constant and α_F and α_L and decay time constant.

Spike generated is composed of the variable threshold comparator and pulse generator. $E_{ij}(n)$ is the dynamic threshold, where α_E is the decay time constant of threshold and V_E is the amplitude constant of the threshold and V_E enhances the threshold value of fired neuron. The PCNN can work meticulously, if smaler α_E and it will take much time to finish the processing, while, larger α_E decrease time of PCNN [Wang and Yang 2010].

When neuron threshold $E_{ij}(n)$ exceeds $U_{ij}(n)$, the spike generator will shut down and threshold began to decrease exponentially [Yang 2009]. If $U_{ij}(n) > E_{ij}(n)$, the neuron will emit a pulse that causes fire, while the corresponding neuron output $Y_{ij}(n) = 1$, this state of firing will be delivered to adjacent neurons if neighbor neurons have similar intensity, now, when the threshold starts decaying until the next internal activity of the neuron. The output of the neuron is then iteratively feedback with a delay of single iteration. The output of the neuron is consequently $Y_{ij}(n) = 0$ when the threshold is larger than the internal activity U .

3. Image Segmentation Based in PCNN

In this section, we present a modified model for image segmentation. In the proposed model, the parameter F was reduced. Image segmentation is an important issue in image processing which is a technique that groups pixels into regions, setting object regions. Segmentation uses the features extracted from the image, for this it is necessary a good selection of parameters for which there is perfect segmentation. The PCNN is a single

neural network model which is more suitable for real-time image processing. In the use of PCNN for image processing, it is usually that a neuron corresponds to a pixel.

More and more researchers have sought knowledge to segmentation images using pulse coupled neural network, we can name some examples low:

[Wang and Tian 2010] used simplified PCNN for separating the cucumber from background.

[Lei and Yang 2010] used a new algorithm based on bidirectional search pulse-coupled neural network (BPCNN) in the color image segmentation.

[Song and Liu 2010] proposed a multi-target image segmentation algorithm based on the improved PCNN model.

[Li and Gao 2013] proposed a immune algorithm which helped PCNN parameters be to adjusted adaptively.

[Gao and Guo 2013] proposed a iterative algorithm of [Li and Gao 2013] for automatic image segmentation.

When it speaks to image processing we have a wide field of research and these researchers referred to above are just the start to an even wider knowledge that is under development. Similar to the mathematical model of the PCNN, the proposed model is described by the following process:

$$F_{ij}(n) = S_{ij} \quad (6)$$

In this model we propose only change the feeding receptive field F , we consider as input only the image pixel S . While the other equations remain the same, as shown in Fig.2.

When PCNN is used in the image segmentation, the number of neurons in the network is equal to the number of pixels in the input image. One-to-one correspondence exists between image pixels and neurons. Equation (6) indicates that each pixel's intensity is inputted to the F_{ij} channel of the neuron that is connected with it. Meanwhile, each neuron is connected with neurons by the L_{ij} channel in its 8-neighbor field, equation (2). Each neuron's output has two states, 1(firing) or 0(no firing). In (4), Y_{ij} is the output of neuron. Equations (2)-(6) describe how each neuron operates and is arranged in PCNN for image segmentation.

4. PCNN Based Image Segmentation Algorithm

First, introduce the symbols that will be used in PCNN image segmentation algorithm. F is the feeding input matrix, is the input image grayscale. L is the linking input matrix, m is Gaussian matrix

$$\begin{bmatrix} \frac{\sqrt{2}}{4\sqrt{2}+8} & \frac{2}{4\sqrt{2}+8} & \frac{\sqrt{2}}{4\sqrt{2}+8} \\ \frac{2}{4\sqrt{2}+8} & 0 & \frac{2}{4\sqrt{2}+8} \\ \frac{\sqrt{2}}{4\sqrt{2}+8} & \frac{2}{4\sqrt{2}+8} & \frac{\sqrt{2}}{4\sqrt{2}+8} \end{bmatrix}.$$




Figure 2. PCNN model proposed

Y is the neuron output matrix. U is the internal activity matrix and E is the threshold matrix. Seg is the segmentation matrix. α_E is the decay time constant of threshold and V_E is the amplitude constant of the threshold. V_L and α_L are amplitude constant and decay time constant, respectively. Re is the matrix that is used to save the image segmated result. Each neuron has the same linking coefficient β . F , L , U , E , Y , Seg , Re have the same dimensions equal to the image size. "*" indicates array multiplication.

PCNN image segmentation algorithm is described in the following.

1. Initialize with the input image to grayscale and determine the parameters of pulse-coupled neural network, α_L ; α_E ; V_L ; V_E ; β and K is the number of interactions.
2. $F = S$.
3. $L = e^{\alpha_L} L[n - 1] + V_L \sum_{k,l} W_{i,j,k,l} * Y[n - 1]$.
4. $U = F * [1 + \beta L]$.
5. $E = e^{\alpha_E} E[n - 1] + V_E Y$.
6. If $Y = 1$; $Seg(i, j)$
else $Y = 0$, go back to 3.
7. Then save it as the image segmentation Re , end.

In step 1), enters with the input image grayscale and determines the parameters of the network, each image was used a certain value to the parameters, so that the end result is a perfect segmentation.




Figure 3. (a)Original image [Kuntimad and Ranganath 1999]. (b)Segmented image [Kuntimad and Ranganath 1999]. (c) Image segmentation by PCNN.

From step 2) to step 5), according to the characteristic of PCNN, segment the original image to obtain the segmentation result considering of places of pixels and the similarity of the intensity of the same area in the original image.

In step 6), when a neuron has fired, increase its threshold to the constant large enough to prevent it from firing again. The result of image segmentation ,Re , obtains in step 7).


5. Experiments Results

In this section, we compare and discuss the experimental results presented in [Kuntimad and Ranganath 1999, Wang and Tian 2010, Zhou 2014] with what we have accomplished, moreover, we present experimental results with satellite images.

In Figure 3(a) shows the original image and the result obtained by [Kuntimad and Ranganath 1999] in Figure 3(b) with values $\beta = 0.4, V_E = 300, \alpha_E = 15, V_L = 1.0$ and $\alpha_L = 0.5$. The result when applying PCNN segmentation is represented in Figure 3(c) with values $\beta = 0.1, V_E = 50, \alpha_E = 1.0, V_L = 1.0$ and $\alpha_L = 1.0$. We observed that despite presenting some parameters with different values, the result obtained was the same as [Kuntimad and Ranganath 1999].

In Figure 4(a) shows the original image [Zhou 2014]. In his work [Zhou 2014] compares various methods of image segmentation to the model proposed by him, thus showing the effectiveness of a PCNN as we see the result obtained by [Zhou 2014] in Figure 4(b) with values $\beta = 0.1, V_E = 20, \alpha_E = 1.0, V_L = 0.2, \alpha_L = 1.0, \alpha_F = 0.1$ and $V_F = 0.5$. The result when applying PCNN segmentation is represented in Figure 4(c) with values $\beta = 0.1, V_E = 50, \alpha_E = 1.0, V_L = 1.0$ and $\alpha_L = 1.0$. Again we note that despite having some parameters with different values the result was the same as [Zhou 2014].


In Figure 5(a) shows the original image [Wang and Tian 2010]. In his work [Wang and Tian 2010] used the simplified model PCNN to separate the cucumber complex background, in Figure 5(b) the parameters used were $V_E = 100$ and $\alpha_E = 0.90$. The result when applying PCNN segmentation is represented in Figure 5(c) with values $\beta = 0.1, V_E = 40, \alpha_E = 1.0, V_L = 0.7$ and $\alpha_L = 1.0$. Unlike the previous figures, in Figure 4(c) shows an improvement in Cucumber segmentation, setting better its format.



(a)



(b)



(c)

Figure 4. (a)Original image [Zhou 2014]. (b)Segmented image [Zhou 2014]. (c) Image segmentation by PCNN.




Figure 5. (a)Original image [Wang and Tian 2010]. (b)Segmented image [Wang and Tian 2010]. (c)Segmented image using PCNN




Figure 6. (a)Satellite image of reservoir and dam between the municipalities of Cascallho Rico and Três Ranchos in the state of Goiás in Brazil. (b)Image segmentation 6(a).

The proposed method is also applied on satellite images which contains water and agriculture area. In Figure 6(a) shows a satellite image of reservoir and dam between the municipalities of Cascallho Rico and Três Ranchos. The result when applying PCNN segmentation is represented in Figure 6(b) with values $\beta = 0.1$, $V_E = 40$, $\alpha_E = 1.0$, $V_L = 0.7$ and $\alpha_L = 1.0$. In Figure 7(a) shows a satellite image of the river Paranaíba in the state of Goiás in Brazil. The result when applying PCNN segmentation is represented in Figure 7(b) with values $\beta = 0.1$, $V_E = 40$, $\alpha_E = 1.0$, $V_L = 0.7$ and $\alpha_L = 1.0$. We realize that PCNN makes a perfect segmentation of water.

In Figure 8(a) and Figure 9(a) shows a original satellite images determining agriculture areas. The result when applying PCNN segmentation is represented in Figure 8(b) with values $\beta = 0.1$, $V_E = 60$, $\alpha_E = 1.0$, $V_L = 0.7$ and $\alpha_L = 1.0$. The result when applying PCNN segmentation is represented in Figure 9(b) with values $\beta = 0.1$, $V_E = 60$, $\alpha_E = 1.0$, $V_L = 0.9$ and $\alpha_L = 1.0$. We realize that PCNN makes a perfect segmentation of agriculture areas.

As can be seen from the presented results, the PCNN is giving good result for




Figure 7. (a)Satellite image of the river Paranaíba. (b)Image segmentation 7(a).




Figure 8. (a)Original satellite image of agriculture areas . (b)Image segmentation 8(a).




Figure 9. (a)Original satellite image of agriculture areas . (b)Image segmentation 9(a).

images and also satellite images of Goiás State region in Brazil.

6. Conclusions

In this article we compared results of our neural network with results presented in the literature and we present results of the segmentation of satellite imagery of the State of Goiás in Brazil obtained using pulse coupled neural network. As one could see, although we have implemented a simple neural network to network presented promising results, the results indicate that PCNN network was effective in satellite imagery segmentation determining irrigation areas and rivers, demonstrating its potentiality.

Acknowledgments

The authors would like to thank the Coordination of Higher Education Personnel Training (Capes), Brazilian National Council for Scientific and Technological Development (CNPq) and Research Support Foundation of Goiás State (FAPEG) for the financial support.

References

- Caufield, H. J. and Kinser, J. M. (1999). Finding shortest path in the shortest time using pcnn's. volume 10, pages 604 – 606. IEEE Transactions on Neural Networks.
- Eckhorn, R., Reitboeck, H. J., Arndt, M., and Dicke, P. (1990). *Neural Computation*. Mit Press.
- Gao, C.; Zhou, D. and Guo, Y. (2013). Automatic iterative algorithm for image segmentation using a modified pulse-coupled neural network. volume 119, pages 332 – 338. Neurocomputing.
- Gonzalez, R. and Woods, R. (2002). *Digital Image Processing*. Prentice-Hall, 2th edition.

- Kuntimad, G. and Ranganath, H. (1999). Perfect image segmentation using pulse coupled neural network. pages 591 – 597. IEEE Transactions on Neural Networks.
- Lei, K. and Yang, L. (2010). A new algorithm of image segmentation based on bidirectional search pulse-coupled neural network. pages 101 – 104. IEEE International Conference on Computational Aspects of Social Networks.
- Li, J.; Zou, b. D.-L. and Gao, X. (2013). Image segmentation with pcnn model and immune algorithm. volume 8, pages 2429 – 2436. Journal of Computers (Finland).
- Lindblad, T. and Kinser, J. M. (2005). *Image Processing Using Pulse-Coupled Neural Networks*. Springer, 2th edition.
- Ranganath, H. S. and Kuntimad, G. (1996). Iterative segmentation using pulse-coupled neural networks. volume 2760, pages 543 – 554. Proc. SPIE.
- Song, Yin-Ma; Z. X.-H. and Liu, G.-l. (2010). One segmentation algorithm of multi-target image based on improved pcnn. volume 10. International Workshop on Intelligent Systems and Applications, IEEE Transactions on Neural Networks.
- Wang, Haiqing; Ji, C. G.-B. and Tian, G. (2010). A simplified pulse-coupled neural network for cucumber image segmentation. pages 1053 – 1057. IEEE International Conference on Computational and Information Sciences.
- Wang, Zhaobin; Ma, Y. C.-F. and Yang, L. (2010). Review of pulse-coupled neural networks. pages 5–13. Image and Vision Computation.
- Yang, B. (2009). Search in two-way pulse coupled neural network and image segmentation. volume 28. J. Automation Technology and Application.
- Zhang, J.; Dong, J. and Shi, M. (2005). An adaptive method for image filtering with pulse-coupled neural networks. Proc. IEEE Int. Conf. on Image Processing.
- Zhou, Dongguo; Gao, C. G.-Y. (2014). A coarse-to-fine strategy for iterative segmentation using simplified pulse-coupled neural network. volume 18, pages 557 – 570. Soft Comput.

ANEXO C

Image Segmentation Based in Pulse Coupled Neural Network

Artigo publicado como resumo no I Workshop em Matemática Industrial, Modelagem e Otimização, na forma de apresentação oral, promovido pela Universidade Federal de Goiás - Regional Catalão, realizado entre os dias 16 e 18 de novembro de 2015 ([ALBANEZ D. O.; BATISTA, 2015b](#)).

Neste artigo discutimos a mesma proposta do artigo descrito no Anexo B. Contudo, como o presente trabalho foi publicado na categoria resumo, apresentamos apenas um exemplo de segmentação de imagem de satélite com a Rede Neural de Pulso Acoplado.

Image Segmentation Based in Pulse Coupled Neural Network

Marcos A. Batista,

Graduate Program in Modeling and Optimization, Federal University of Goiás
75704-020, Catalão, Go

E-mail: marcos.batista@pq.cnpq.br,

Daniela de O. Albanez,

doalbanez@hotmail.com,

Sérgio F. da Silva

Graduate Program in Modeling and Optimization, Federal University of Goiás
75704-020, Catalão, GO

E-mail: sergio@ufg.br

Abstract: *This article describes the method of image segmentation using pulse coupled neural networks (PCNN's). The model undergoes a simple change in feeding input with respect to original PCNN, which we consider as input only the image pixel. We will compare the results with results presented in the literature, then we will apply the PCNN to target satellite images and show its effectiveness.*


Keywords: *Image segmentation, Pulse Coupled Neural Network (PCNN), Satellite Images.*

The image segmentation consist into subdivide the image into its constituent parts. Segmentation helps identify differences between two or more objects, both among themselves and between each other and the background. In this article we use Pulse Coupled Neural Network (PCNN) for image segmentation.


The PCNN model was developed by Eckhorn [1] is a simple network that does not require training and the network was constructed by simulating the activities of the cat's visual cortex neurons. As PCNN is a single-layer neural network model, each neuron corresponds to a pixel, at the same time, the neuron corresponding to the pixel link the neighboring neurons. PCNN model consists of three main parts [2]: input field, modulation field, and spike generator. PCNN produces an output of binary pulse images when stimulated with images.

The proposed method is also applied on satellite images which contains water and agriculture area. The method present Goiás State satellite images which we apply a PCNN and demonstrate the effectiveness of this model through experiments.

As one could see, although we have implemented a simple neural network to network presented promising results, the results indicate that PCNN network was effective in satellite imagery segmentation determining irrigation areas and rivers, demonstrating its potentiality.



(a)



(b)

Figura 1: (a) Satellite image of reservoir and dam between the municipalities of Cascallho Rico and Três Ranchos in the state of Goiás in Brazil. (b) Image segmentation 1(a).

Referências

1 . Eckhorn, R. and Reitboeck, H. J. and Arndt, M. and Dicke, P., Neural Computation, Cambridge, MA, USA: Mit Press, v. 2, n. 3, 1990.

2 . Lindblad, T. and Kinser, J. M., Image Processing Using Pulse-Coupled Neural Networks, 2nd ed., Springer, 2005.


ANEXO D

Segmentação de Imagens Utilizando Redes Neurais Artificias

Trabalho publicado na Semana de Defesas 2016/1 do Curso de Ciências da Computação, na forma de apresentação oral, promovido pelo curso de Ciências da Computação da universidade Federal de Goiás - Regional Catalão, realizado entre os dias 16 e 18 de agosto de 2016 ([ALBANEZ D. O. E BATISTA, 2016b](#)).

A referida apresentação foi um resumo dos estudos realizados durante o mestrado para o desenvolvimento da dissertação.





Segmentação de Imagens utilizando Redes Neurais Artificiais

Daniela de Oliveira Albanez
Orientador: Prof. Drº. Marcos A. Batista

Catalão, 16 de Agosto de 2016.



Apresentação



- Introdução
- Objetivos
- Fundamentação Teórica
- Estado da Arte
- Metodologia
- Desafios
- Experimentos
- Referências

2



Introdução



- Questão ambiental.
- Monitoramento e mineração do uso da terra.



3



Objetivos



- Segmentar imagens de satélite.
- Redes neurais artificiais.




4



Fundamentação Teórica



- Definição de imagem.
- Pixel.



5



Fundamentação Teórica



- O que é Segmentação de Imagens?
 - Métodos de segmentação de imagens.
- O que é Rede Neural Artificial?
 - Inspirada no neurônio biológico.

6

Fundamentação Teórica

Diagram illustrating the structure of a biological neuron, showing the Dendritos (dendrites), Axônio (axon), Corpo celular (cell body), and Terminações do axônio (axon terminals).

7

Fundamentação Teórica

Diagram illustrating the structure of a simple artificial neuron model. It shows input signals X_i entering weights w_{ij} , which are summed at a junction Σ along with a bias b_j . The result u_j is then passed through an activation function $\sigma(\cdot)$ to produce the output y_j .

8

Estado da Arte

- ❑ Agricultura [4, 5, 6];
- ❑ Astronomia [7];
- ❑ Biologia [8];
- ❑ Indústria da madeira [9, 10];
- ❑ Monitoramento ambiental [11, 12, 13];
- ❑ Medicina [14, 15, 16, 17, 18, 19, 20, 21, 22].

9

Metodologia

- ❑ Segmentar imagens utilizando as RNA's
 - ❑ Rede Neural de Pulso Acoplado
 - ❑ Eckhorn (80's and 90's)

10

Desafios







- ❑ Mestrado Modelagem e Otimização
 - ❑ Programação
 - ❑ Teoria
 - ❑ Pessoal

11

Modelo Original PCNN

Diagram illustrating the structure of the original Pulse-Coupled Neural Network (PCNN) model. It shows the input field x_{ij} entering a network of neurons. The network includes a linking stage Σ and a feeding stage Σ , which are coupled to a spike generator. The output is a field of spikes y_{ij} .


12





Experimentos

UFG



(a)

(b)

Fig. 4: a) Imagem do reservatório de água entre os municípios de Cascalho Rico e Três Ranchos.


b) Segmentação da imagem pela PCNN.

19



Experimentos

UFG



(a)

(b)

Fig. 5: a) Imagem do Rio Paranaíba.


b) Segmentação da imagem pela PCNN.

20



Experimentos

UFG



(a)

(b)

Fig. 6: a) Imagem de áreas de agricultura.


b) Segmentação da imagem pela PCNN.

21



Experimentos

UFG



(a)

(b)

Fig. 7: a) Imagem de áreas de agricultura.

b) Segmentação da imagem pela PCNN.

22



Referências

UFG

[1]Kuntimad, G. and Ranganath, H.. Perfect Image Segmentation Using Pulse Coupled Neural Network, IEEE Transavtions on Neural Networks, v.10, n.3, p.591 - 597, 1999.

[2] Wang, Haiqing; Ji, Changying; Gu, Baoxing and Tian, Guangzhao, A Simplifiel Pulse-Coupled Neural Network for Cucumber Image Segmentation. In: IEEE International Conference on Computational and Information Sciences,p. 1053 - 1057, 2010, doi:10.1109/ICCIS.2010.260.

[3] Zhou, Dongguo; Gao, Chao; Guo, Yongcai, A Coarse-to-Fine Strategy for Iterative Segmentation Using Simplified Pulse-Coupled Neural Network, Soft Comput, v. 18, n.3, p.557 - 570, 2014, doi:10.1007/s00500-013-1077-8.

[4] Wang, Haiqing; Ji, Changying; Gu, Baoxing and Tian, Guangzhao. A Simplifiel Pulse-Coupled Neural Network for Cucumber Image Segmentation. In: IEEE International Conference on Computational and Information Sciences, p. 1053 -1057, (2010), doi:10.1109/ICCIS.2010.260.

[5] Sammouda, R.; Adgaba, N.; Touir, A.; Al-Ghamdi, A.. Agriculture satellite image segmentation using a modified artificial Hopfield neural network. Computers in Human Behavior, 30, p. 436 - 441, (2014).

[6] Padilha, F. R. R.; Khatchatourian, O.. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. Engenharia Agrícola, v. 28, n 4, Jaboticabal (2008), doi.org/10.1590/S0100-69162008000400016.

23



Referências

UFG

[7] Zhu, Y.; Urtasun, R.; Salakhutdinov, R. and Fidler, S.. Exploiting segmentation and context in deep neural network for object detection. University of Toronto, 15 february (2015).

[8] Zhang, X.; Tan, G. and Chen, M.. A reliable distributed convolutional neural network for biology image segmenitaon. Cluster, Cloud and Grid Computing (CCGrid), 15th IEEE/ACM International Symposium on: Shenzhen, China: May (2015).

[9] Ruz, G. A. and Estéves, P. A.. Image segmentation using fuzzy min-max neural networks for wood defect detection. Intelligent Production Machines ans Systems D.T. Phan, E.E. Eldukhri and A.J. Soroka (Eds), (2005).

[10] Funck, J. W.; Zhong, Y.; Butler, D. A.; Brunner, C. C.; Forrer, J. B.. Image segmentation algorithms applied to wood defct detection. Computers ans Electronics in Agriculture, v.41, p.157-179, (2003).

[11] Machado, R.J.; Barbosa, V.C. ; Liporace, F.D.S. and Ferlin, C.. Monitoring the deforestation of the Amazon region with neural network. Neural Networks: IJCNN ' 93-Nagoya. Proceedings of 1993 International Joint Conference on, v.2, p. 1239-1242, (1993).

[12] Fan, J.; Zhao, D. and Wang, J.. Oil spill GF-1 remote sensing image segmentation using an evolutionary feedforward neural network. Neural Networks (IJCNN), International Joint Conference on, p.460-464, July (2014).

24

4



Referências



[13] Del Frate, F.; Angiuli, E. and Salvatori, L.. Neural networks for oil spill detection using ers and envisat imagery. In: Proceeding of SeaSar: january (2006).

[14] Zhang, H., Chen, N., Lin, Y.. Segmentation of MRI based on graph space construction, information and automation. In: Proceedings of communication, networking broadcasting, p. 1433-1437, (2009).

[15] Hassanien, A. E., Ali, J. M.. Digital mammogram segmentation algorithm using pulse coupled neural networks. In: Proceedings – third international conference on image and graphics, p. 92–95, (2012).

[16] Wolfer, J.. Pulse coupled neural networks and image morphology for mammogram preprocessing. In: Proceedings – 3rd International conference on innovations in bio-inspired computing and applications, IBICA, p. 286–290, (Article number 6337679), (2012).

[17] Chai, J.W., Chen, C. C., Fu, J. C., Li, I. C., Wong, S. T. C.. Image segmentation by EM-based adaptive pulse coupled neural networks in brain magnetic resonance imaging. Computerized Medical Imaging and Graphics, 34,p. 308–320, (2010).

[18] Hassanien, A. E., El-Dahshan, E.-S. A., Al-Qaheri, H.. Prostate boundary detection in ultrasound images using biologically-inspired spiking neural network. Applied Soft Computing, 11, p. 2035–2041, (2010).

25



Referências




[19] Scudder, H. J.. Introduction to Computed Aided Tomography. Proc. IEEE, vol. 66, p. 628-637, (1978).

[20] Mueller, R. K.; Kaveh, M. and Wade, G.. Reconstructive Tomography and Applications to Ultrasonics, Proc. IEEE, vol. 67, p. 567-587, (1979).

[21] Hinshan,W. and Lent, A. H. An Introduction to NMR Imaging: From the Bloch Equation to the Imaging Equation, Proc. IEEE, vol. 71, p. 338-350, (1983).

[22] Rocha E. L. da; Nicoleit. E. R. M. M. d. S. P. W. T. d. A. M. S. A.. Diagnóstico Automatizado de Doenças no Colo do Útero Baseado em Redes Neurais Artificiais e Processamento de Imagens Digitais. [S.l.], (2007).

26




Obrigado!

ANEXO E

Aplicação de Algoritmos de Otimização a Absorvedor Dinâmico de Vibração

Artigo publicado no II Congresso de pesquisa, ensino e extensão Regional Catalão - CONPEEX - RC, na forma de apresentação oral, promovido pela Universidade Federal de Goiás - Regional Catalão, realizado entre os dias 28 e 30 de setembro de 2016 ([ALBANEZ D. O.; LINO, 2016](#)).

Este artigo foi o resultado de um trabalho em grupo realizado na disciplina de Otimização Clássica, sob orientação do Professor Drº José dos Reis Vieira de Moura Junior. Nele estudamos o modelo de absorvedor dinâmico de vibração (ADV) eficiente na redução de vibração estrutural e usamos um método de otimização clássica, Multiplicadores de Lagrange Aumentado, que é um método de otimização sequencial.

Os absorvedores dinâmicos de vibrações são constituídos por massa, mola e elementos de amortecimento, que são acoplados a um sistema mecânico para proporcionar a atenuação da vibração. Com base nesta metodologia, um modelo massa-mola foi utilizado para a simulação numérica e o problema de otimização foi definida como a minimização da função objetivo que descreve a amplitude de vibração da estrutura primária. Utilizou-se para a minimização do Lagrangeano Aumentado, os métodos de Newton, Davidon-Fletcher-Powell (DFP) e Broydon-Fletcher-Goldfarb-Shanno (BFGS). Foram apresentados alguns resultados da análise e comparação de sua eficiência.

APLICAÇÃO DE ALGORITMOS DE OTIMIZAÇÃO A ABSORVEDOR DINÂMICO DE VIBRAÇÃO

Albanez, Daniela de Oliveira, doalbanez@hotmail.com¹

Lino, Sémebber Silva, semebber@hotmail.com¹

Moura Jr., José dos Reis Vieira de, zereis@ufg.br¹

¹Universidade Federal de Goiás/Regional Catalão

Resumo: Neste artigo estuda-se o modelo de absorvedor dinâmico de vibração (ADV) eficiente na redução de vibração estrutural e usa-se um método de otimização clássica, Multiplicadores de Lagrange Aumentado, que é um método de otimização sequencial. Absorvedores dinâmicos de vibrações são constituídos por massa, mola e elementos de amortecimento, que são acoplados a um sistema mecânico para proporcionar a atenuação da vibração. Com base nesta metodologia, um modelo massa-mola é utilizado para a simulação numérica e o problema de otimização é definida como a minimização da função objetivo que descreve a amplitude de vibração da estrutura primária. Utiliza-se para a minimização do Lagrangeano Aumentado, os métodos de Newton, Daivdon-Fletcher-Powell (DFP) e Broydon-Fletcher-Goldfarb-Shanno (BFGS). Serão apresentados alguns resultados da análise e comparação de sua eficiência.

Palavras-chave: Absorvedor dinâmico de vibração. Otimização. Lagrangeano aumentado.

MODALIDADE DE INSCRIÇÃO: INVESTIGAÇÃO CIENTÍFICA

1. INTRODUÇÃO

Várias estruturas, equipamentos ou máquinas utilizadas na construção civil, no setor industrial, no transporte e, até mesmo, eletrodomésticos estão submetidos a vibrações, que podem danificá-los, comprometendo sua integridade, ou mesmo causando desconforto e insegurança para seus usuários ou operadores. Diante deste problema surge a necessidade de controlar os níveis de vibração estrutural, de modo a garantir as condições satisfatórias de operação, segurança e conforto.

Uma estratégia eficiente e econômica, o uso, desenvolvimento e o aperfeiçoamento de absorvedores dinâmicos de vibrações (ADV's), cuja a primeira análise foi realizada por Ormondroyd e Den Hartog (HARTOG; ORMONDROYD, 1928), em ressalva a importância tecnológica, tem se mostrado objeto de interesse de pesquisadores e engenheiros, tanto no âmbito acadêmico quanto no industrial.

Em sua forma mais simples, de acordo com Steffen Jr. e Rade (2001), um ADV é um dispositivo de parâmetros concentrados (massa, rigidez e amortecimento), que uma vez acoplado à estrutura primária, cujas vibrações deseja-se atenuar, é capaz de absorver a energia vibratória no ponto de conexão.

Largamente utilizados, os ADV's mais comumente usados são os passivos, compostos por elementos de parâmetros concentrados de inércia, rigidez e amortecimento, classicamente projetados de forma que sua frequência natural seja sintonizada à frequência natural, admitida como fixa.

Entretanto, os ADV's passivos podem apresentar massa muito maior do que o necessário para se atenuar a vibração do sistema, e muitas vezes se quer um dispositivo essencialmente pequeno em relação ao sistema original. Um absorvedor de vibrações acoplado à uma máquina industrial não pode ter o mesmo tamanho ou massa que a própria máquina, porque isso deixaria o processo impraticável. Tem-se, então, a necessidade de se otimizar os parâmetros do ADV para que a massa seja a menor possível, entrando no conceito de otimização.

O conceito de otimização é intrínseco à natureza e ao homem, na sua tentativa de buscar a excelência. A otimização é uma importante ferramenta nas ciências e na análise de sistemas físicos. De forma bem simples, otimizar é procurar o melhor, o mais simples ou mais rápido, ou mais barato. É buscar o maior ou o menor (VANDERPLAATS, 1999). Nesse ponto de vista, o processo de otimização, na maioria das vezes, procura por extremos e é nessa abordagem que este trabalho se baseia.

Este trabalho propõe buscar a otimização dos parâmetros de um sistema não amortecido submetido a uma força harmônica externa, de forma reduzir a massa necessária do ADV acoplado a uma massa principal, para atenuar a vibração da mesma.


2. ABSORVEDORES DINÂMICOS NÃO AMORTECIDOS APLICADOS À

SISTEMAS PRIMÁRIOS DE UM GRAU DE LIBERDADE

De acordo com Ormondoyd e Den Hartog (1928), Warburton (1981) e Den Hartog (1956) os ADV's são sistemas constituídos por massa, de mola e os elementos de amortecimento (estrutura secundária), que estão acoplados com um sistema mecânico (estrutura primária), a fim de atenuar as vibrações da estrutura primária em uma dada banda de frequência.

Considere o sistema vibratório de dois graus de liberdade, sem amortecimento, em que o subsistema (m_1, k_1) associado à estrutura primária cujas vibrações desejam serem atenuadas pelo subsistema de acoplamento (m_2, k_2) constituindo o absorvedor dinâmico de vibração, tal como ilustrado na Figura 1.

Figura 1. Estrutura primária e ADV.



Fonte: Realizado pelo autor, (2016).

Admite-se o sistema primário excitado por uma força harmônica de amplitude F e frequência de excitação Ω , de valor fixo, não coincidindo necessariamente com a frequência natural do sistema, expressa por:

$$F(t) = F e^{i\Omega t} \quad (1)$$

O funcionamento do absorvedor, parte do princípio de que, escolhidos os valores dos parâmetros (m_2, k_2), de modo que $\Omega^2 = k_2/m_2$, leve a massa primária (m_1) a responder harmonicamente para esta frequência de excitação, com amplitude nula.

A frequência natural do sistema absorvedor quando conectado diretamente à base fixa, é definida por: $\omega_a = \sqrt{k_2/m_2}$.

Com o intuito de demonstrar tal afirmação, são escritas as equações do movimento do sistema acoplado:

$$\begin{cases} m_1 \ddot{x}_2(t) + (k_1 + k_2)x_1(t) - k_2 x_2(t) = F(t) & (2.a) \\ m_2 \ddot{x}_2(t) + k_2[x_2(t) - x_1(t)] = 0 & (2.b) \end{cases}$$

Em regime permanente, as respostas harmônicas são expressas por:

$$x_1(t) = X_1 e^{i\Omega t} \quad (3.a)$$

$$x_2(t) = X_2 e^{i\Omega t} \quad (3.b)$$

Efetuada-se a derivação das respostas harmônicas:

$$\dot{x}_1(t) = (i\Omega)X_1 e^{i\Omega t}; \ddot{x}_1(t) = (i\Omega)^2 X_1 e^{i\Omega t} \quad (4.a)$$

$$\dot{x}_2(t) = (i\Omega)X_2 e^{i\Omega t}; \ddot{x}_2(t) = (i\Omega)^2 X_2 e^{i\Omega t} \quad (4.b)$$

Substituindo-se as segundas derivadas nas equações do movimento do sistema acoplado:

$$\begin{cases} m_1((i\Omega)^2 X_1 e^{i\Omega t}) + (k_1 + k_2)X_1 e^{i\Omega t} - k_2 X_2 e^{i\Omega t} = F(t) & (5.a) \\ m_2((i\Omega)^2 X_2 e^{i\Omega t}) + k_2[X_2 e^{i\Omega t} - X_1 e^{i\Omega t}] = 0 & (5.b) \end{cases}$$

$$\begin{cases} X_1(-m_1\Omega^2 + k_1 + k_2) - k_2 X_2 = F & (6.a) \\ -k_2 X_1 + X_2(m_2\Omega^2 + k_2) = 0 & (6.b) \end{cases}$$

Resolvendo o sistema algébrico, encontramos a seguinte expressão para a amplitude X_1 do sistema primário:


$$X_1 = \frac{(-m_2\Omega^2 + k_2)F}{m_1 m_2 \Omega^4 + ((-k_1 - k_2)m_2 - m_1 k_2)\Omega^2 + k_1 k_2} \quad (7)$$

$$X_2 = \frac{k_2 F}{m_1 m_2 \Omega^4 + ((-k_1 - k_2)m_2 - m_1 k_2)\Omega^2 + k_1 k_2} \quad (8)$$

Pela equação acima, observa-se que a amplitude da resposta X_1 do sistema primário anula-se quando $m_2\Omega^2 = k_2$, o que comprova a afirmação feita anteriormente, sobre o funcionamento dos ADVs de um grau de liberdade.

A equação da amplitude X_1 , é exemplificada na Figura 2, onde nota-se a função de resposta em frequência típica de um sistema de dois graus liberdade, com a existência de duas frequências naturais. A introdução do ADV permite geração de uma antirressonância na função de resposta em frequência (FRF) pontual da massa m_1 , à frequência $\Omega = \sqrt{k_2/m_2}$.

Fig.2. Função Resposta de Frequência



Fonte: Realizado pelo autor, (2016).

Introduzindo $X_1 = 0$ em (6.a), temos que $\Omega = \sqrt{k_2/m_2}$, a amplitude de vibração de massa m_2 é dada por:

$$X_2 = -\frac{F}{k_2} \quad (9)$$

Assim, a força exercida pelo sistema absorvedor sobre o sistema primário é:

$$F = -k_2 X_2 \quad (10)$$

Portanto, o sistema secundário exerce sobre o sistema primário, uma força igual e oposta à força de excitação, tendo como consequência o equilíbrio deste sistema.

Os ADV's, na maioria das vezes são utilizados para atuarem de forma a atenuar os níveis de vibração do sistema primário quando este se encontra operando em sua frequência natural, ou próximo a ela.

Sendo assim, o ADV deve ser projetado da forma que sua frequência natural coincida com a do sistema primário, de modo a satisfazer:

$$\frac{k_2}{m_2} = \frac{k_1}{m_1} \Rightarrow \omega_n = \omega_a \quad (11)$$

Desta forma, a partir da equação da amplitude X_1 , quando o numerador for igual a zero, a amplitude da resposta X_1 , do sistema primário também será igual a zero e, isso ocorre quando a frequência de excitação Ω , que é igual à frequência natural do sistema primário, coincidindo com a frequência natural do ADV, ω_n .

3. PROJETO DE OTIMIZAÇÃO

Na busca de parâmetros que reduzam a vibração do sistema primário, há a necessidade de viabilização desses parâmetros, ou seja, ajustar a massa e a constante de rigidez do ADV. Assim, o objetivo deste trabalho é reduzir a amplitude de vibração do sistema primário, ajustando os parâmetros massa e rigidez do absorvedor, visando os menores valores possíveis para eles.

Para tanto, utilizou-se o Método dos Multiplicadores de Lagrange Aumentado, que é um método de otimização sequencial. Foram utilizados para a minimização do Lagrangeano Aumentado, os métodos de Newton, Davidon-Fletcher-Powell (DFP) e Broydon-Fletcher-Goldfarb-Shanno (BFGS).

O método de Newton é uma das ferramentas mais importantes em otimização. Tanto o algoritmo básico quanto suas variantes são muito utilizados para minimização.

Utiliza aproximações quadráticas da função $f(x)$ para o cálculo do mínimo, utilizando a Série de Taylor em torno de um ponto inicial $\underline{x}^k$:

$$p(\underline{x}) \approx f(\underline{x}^k) + \nabla f(\underline{x}^k)(\underline{x} - \underline{x}^k) + \frac{1}{2}(\underline{x} - \underline{x}^k)^T \nabla^2 f(\underline{x}^k)(\underline{x} - \underline{x}^k)$$

Desprezando a parte não-linear, a condição necessária para um ponto de mínimo de $p(x)$ é dada para $\nabla q(\underline{x}) = 0$, ou seja:

$$\nabla f(\underline{x}^k) + \nabla^2 f(\underline{x}^k)(\underline{x} - \underline{x}^k) = 0$$

Assim, tem-se um processo iterativo:

$$\underline{x}^{k+1} = \underline{x}^k - [\nabla^2 f(\underline{x}^k)]^{-1} \nabla f(\underline{x}^k)$$

Tem-se uma direção de busca:

$$\underline{d}^k = -[\nabla^2 f(\underline{x}^k)]^{-1} \nabla f(\underline{x}^k)$$

Se a função é quadrática (com $[\nabla^2 f(\underline{x}^k)] > 0$), então o processo iterativo anterior encontra o mínimo em uma única iteração.

O processo iterativo pode ser mudado de forma a eliminar a inversão de matriz:

$$\underline{\Delta x}^k = \underline{x}^{k+1} - \underline{x}^k$$

$$[\nabla^2 f(\underline{x}^k)] \underline{\Delta x}^k = -\nabla f(\underline{x}^k)$$

$$\underline{x}^{k+1} = \underline{x}^k + \underline{\Delta x}^k$$

O processo iterativo pode também ser mudado, de forma que se tenha uma minimização unidimensional na direção $\underline{d}^k$ para um parâmetro λ .

Este procedimento é semelhante ao realizado no Método do Gradiente, mas com a direção de busca dada por $\underline{d}^k = -[\nabla^2 f(\underline{x}^k)]^{-1} \nabla f(\underline{x}^k)$:

$$\underline{x}^{k+1} = \underline{x}^k - \lambda^k \frac{[\nabla^2 f(\underline{x}^k)]^{-1} \nabla f(\underline{x}^k)}{\|[\nabla^2 f(\underline{x}^k)]^{-1} \nabla f(\underline{x}^k)\|}$$

Já o Método Davidon-Fletcher-Powell (DFP) foi originalmente desenvolvido por Davidon para encontrar uma aproximação para a inversa da matriz Hessiana e depois melhorado por Fletcher e Powell.

Além de construir a aproximação da inversa da matriz Hessiana a fim de atualizar seu espaço de busca, esse método gera as direções do gradiente conjugado oferecendo ótimos resultados, tão bons quanto os de segunda ordem, utilizando o parâmetro $\theta=0$.

$$S^q = -H^q \nabla F(x^q)$$

Esta aproximação faz com que o método seja classificado como Método Quase-Newton pois os mesmos irão encontrar aproximações sucessivas para a inversa da matriz Hessiana e contornar os problemas de implementação do Método de Newton.

Entretanto, o Método de Broyden-Fletcher-Goldfarb-Shanno (BFGS) foi proposto para problemas de minimização irrestrita. Esse método

possui o algoritmo mais bem sucedido para atualização da inversa, pois o mesmo possui uma evolução semelhante que o Método DFP, sendo muitas vezes denominado na literatura como método DFP complementar, onde sua única diferença é utilizar o parâmetro $\theta = 1$.

A função objetivo utilizada foi a amplitude do sistema, isto é X_1 . Como se deseja $k_2/m_2 = k_1/m_1$, isso se torna uma restrição de igualdade relacionada ao projeto. Também é necessário atribuir limites inferiores e superiores para as variáveis de projeto (massa e rigidez).

Dessa forma o projeto é formulado da seguinte forma:

Minimizar:

$$|X_1| = \left| \frac{(k_2 - m_2 \Omega^2)F}{m_1 m_2 \Omega^4 + ((-k_1 - k_2)m_2 - k_2 m_1)\Omega^2 + k_2 k_1} \right|$$

Sujeito a:

$$\frac{k_2}{m_2} - \frac{k_1}{m_1} = 0$$

$$k_2^l \leq k_2 \leq k_2^u$$

$$m_2^l \leq m_2 \leq m_2^u$$

Para a implementação computacional foram atribuídos os seguintes valores:

$$k_1 = 1000$$

$$m_1 = 1,2$$

$$k_2^{(0)} = 200$$

$$m_2^{(0)} = 0,24$$

$$50 \leq k_2 \leq 300$$

$$0,1 \leq m_2 \leq 0,4$$

4. RESULTADOS E DISCUSSÃO

Os resultados obtidos utilizando o Método dos Multiplicadores de Lagrange Aumentado são apresentados abaixo.

A direção de Newton pode não ser de descida, assim, não se pode garantir uma convergência global quando o problema a ser resolvido envolver uma função arbitrária. Veja nos valores expressos na tabela 1, que isso não se aplica para a função X_1 .

Tabela 1. Resultados do método Lagrangeano Aumentado e Newton.

Int.	k_2	m_2	Amplitude
1	2.1378e+002	2.5638e-001	2.8083e-006
2	1.3546e+002	1.6255e-001	8.9750e-010
3	1.3546e+002	1.6255e-001	3.3211e-015
4	1.3546e+002	1.6255e-001	3.2219e-016

5	1.3546e+002	1.6255e-001	4.9414e-016
6	1.3546e+002	1.6255e-001	8.3647e-017
7	1.3546e+002	1.6255e-001	1.5490e-017
8	1.3546e+002	1.6255e-001	7.4353e-017
9	1.3546e+002	1.6255e-001	1.8588e-017
10	1.3546e+002	1.6255e-001	3.2529e-017
11	1.3546e+002	1.6255e-001	3.0980e-018
12	1.3546e+002	1.6255e-001	3.0980e-018
13	1.3546e+002	1.6255e-001	1.3941e-017
14	1.3546e+002	1.6255e-001	1.5490e-018
15	1.3546e+002	1.6255e-001	1.5490e-018
16	135.45579	0.16255	0.00000
17	135.45579	0.16255	0.00000
18	1.3546e+002	1.6255e-001	1.5490e-018

Org. Realizado pelo autor, (2016).


Rigidez do Absorvedor: $k_2 = 135,45579$

Massa do Absorvedor: $m_2 = 0,16255$

Amplitude: $|X_1| = 1,5490 \times 10^{-18}$.

No entanto, para uma classe de funções convexas tais como da função X_1 , obtida nesse escopo, pode-se tirar conclusões positivas, conforme sua solução gráfica explicitada na Figura 3.

Figura 3 - Gráfico de Resposta em frequência para os parâmetros iniciais e os otimizados.



Fonte: Realizado pelo autor, (2016).

Para tais problemas, uma condição necessária para sua otimização é que o gradiente deva ser zero.

Os métodos de Newton, DFP e o BFGS não são garantidos para convergir a menos que a função analisada tenha uma expansão de Taylor quadrática

perto de um ponto ótimo, obtidas utilizando o Método dos Multiplicadores de Lagrange Aumentado, que apresenta vantagens quanto ao seu uso.

Dentre as mesmas, se destaca o progresso na análise e implementação de métodos de otimização eficientes para resolver problemas simples produzem um efeito positivo quase imediato quanto sua eficiência e robustez.

Em vários problemas práticos, a Hessiana do Lagrangiano é uma matriz estruturalmente densa (ou seja, qualquer entrada pode ser diferente de zero para Hessianas calculadas em diferentes pontos) mas geralmente esparsa (dado um ponto no domínio, a Hessiana do Lagrangiano neste ponto é esparsa).

Estes métodos usam ambas as primeira e segunda derivadas da função. No entanto, os métodos DFP e BFGS também provaram ter um bom desempenho, de acordo com os dados fomentados nas tabelas 2 e 3, que tem suas soluções gráficas representadas através das figuras 4 e 5.

Tabela 2. Resultados do método Lagrangeano Aumentado e DFP.

Int.	k_2	m_2	Amplitude
1	1.9995e+002	0.23979	3.0008e-006
2	2.0039e+002	0.24047	1.3101e-014
3	2.0039e+002	0.24047	2.6566e-010
4	2.0039e+002	0.24047	8.8552e-011
5	2.0039e+002	0.24047	1.2882e-016
6	2.0039e+002	0.24047	7.7226e-011
7	2.0039e+002	0.24047	2.5742e-011
8	2.0039e+002	0.24047	1.1324e-016
9	2.0039e+002	0.24047	1.0617e-017
10	2.0039e+002	0.24047	6.3698e-018
11	2.0040e+002	0.24048	9.9079e-018
12	2.0042e+002	0.24051	5.8020e-017
13	2.0049e+002	0.24058	4.2426e-018
14	2.0068e+002	0.24081	2.7666e-015
15	2.0126e+002	0.24151	2.6390e-015
16	2.0296e+002	0.24355	5.5889e-016
17	2.0721e+002	0.24865	7.2816e-018
18	2.2234e+002	0.26681	2.8746e-018


Org. Realizado pelo autor, (2016).

Rigidez do Absorvedor: $k_2 = 222,34074$

Massa do Absorvedor: $m_2 = 0,26681$

Amplitude: $|X_1| = 2,8746 \times 10^{-18}$

Figura 4 - Gráfico de Resposta em frequência para os parâmetros iniciais e os otimizados.



Fonte: Realizado pelo autor, (2016).

Tabela 3. Resultados do método Lagrangeano Aumentado e BFGS.

Int.	k_2	m_2	Amplitude
1	1.9995e+002	0.23979	3.0008e-006
2	2.0039e+002	2.4047e-001	2.2721e-014
3	2.0039e+002	2.4047e-001	3.0554e-010
4	2.0039e+002	2.4047e-001	1.0052e-010
5	2.0039e+002	2.4047e-001	5.9454e-017
6	2.0039e+002	2.4047e-001	2.2083e-016
7	2.0039e+002	2.4047e-001	9.9089e-018
8	2.0039e+002	2.4047e-001	4.6006e-017
9	2.0039e+002	2.4047e-001	9.2010e-018
10	2.0039e+002	2.4047e-001	1.2032e-017
11	2.0040e+002	2.4048e-001	9.9079e-018
12	2.0042e+002	2.4051e-001	3.3963e-017
13	2.0049e+002	2.4058e-001	4.5255e-017
14	2.0068e+002	2.4081e-001	7.1987e-016
15	2.0126e+002	2.4151e-001	9.4094e-016
16	2.0317e+002	2.4380e-001	3.9729e-016
17	2.0868e+002	2.5042e-001	3.9160e-018


18	.6617e+002	23.1940e-001	8.0235e-019
Org. Realizado pelo autor, (2016).			

Rigidez do Absorvedor: $k_2 = 266,17004$

Massa do Absorvedor: $m_2 = 0,31940$

Amplitude: $|X_1| = 8,0235 \times 10^{-19}$

Figura 5 - Gráfico de Resposta em frequência para os parâmetros iniciais e os otimizados.



Fonte: Realizado pelo autor, (2016).

Analisando os gráficos obtidos nos métodos de Newton, DFP e BFGS, percebe-se que os mesmos são praticamente iguais e requereram o mesmo número de iterações na busca pelo ótimo.

Portanto, para otimizar a função X_1 , todos os métodos necessitaram de apenas 18 iterações para encontrar o ótimo.

5. CONCLUSÃO

Foi apresentado um estudo teórico de absorvedores dinâmicos de vibrações, sendo considerado um absorvedor simples, constituído de um grau de liberdade e sem amortecimento.

O melhor resultado foi obtido utilizando o método de Newton que proporcionou uma boa redução da amplitude de vibração do sistema primário, como visto na figura 4, além disso, ele foi

o único método que possibilitou a redução dos parâmetros. Apesar deste método não ter apresentado a melhor redução da amplitude, seu resultado é razoável e o ajuste de parâmetros é desejável para o ADV.

As aplicações numéricas, a partir do método sequencial de otimização, evidenciou a viabilidade da redução dos parâmetros massa e rigidez do absorvedor, sem perda de eficácia, isto é, sem aumentar a amplitude de vibração e com ganho em eficiência.

A análise do absorvedor com amortecimento, o que contribui para atenuar vibrações numa banda de frequência mais ampla, ao custo de uma eficiência mais baixa na massa principal do ponto de ressonância é proposta viável de uma publicação futura, utilizando os métodos de Newton, DFP e o BFGS como método de otimização para se obter sua solução ótima.

REFERÊNCIAS

- HARTOG, J. P. D. **Mechanical Vibrations**, New York: McGraw-Hill, 1956.
- HARTOG, J. P. D.; ORMONDOYD, J. Theory of the Dynamics Vibration Absorber. **Transactions of the American Society of Mechanical Engineers**, v. 50, p. 9-22, 1928.
- RADE, D.; STEFFEN, V. **Dynamics Vibration Absorber Encyclopedia of Vibration**, Springer, 2001.
- VANDERPLAATS, GARRET N. **Numerical optimization techniques for engineering design**. McGraw-Hill Book Company, 1999.
- WABURTON, G. B. Optimum Absorber Parameters for Structural Dynamics, **Earth-quake Engineering and Structural Dynamics**, v. 9, p. 251, 1981

RESPONSABILIDADE AUTURAL

“O(s) autor(es) é(são) o(s) único(s) responsável(is) pelo conteúdo deste trabalho”.

ANEXO F

Segmentação de Imagens usando Rede Neural Hopfield

Artigo publicado como resumo expandido no 13º Congresso de pesquisa, ensino e extensão - CONPEEX, apresentado na forma pôster, promovido pela Universidade Federal de Goiás - Campus Samambaia, realizado entre os dias 17 e 19 de outubro de 2016 ([ALBANEZ D. O.; BATISTA, 2016](#)).

A segmentação de imagens é um componente importante dos sistemas de visão computacional, cujo objetivo é a partição de uma dada imagem em regiões significativas podendo rotular cada região. Além disso, é um pré-requisito para o alto nível de compreensão da imagem e interpretação. Uma classe em si é constituída por técnicas de segmentação na adoção de técnicas de classificação baseados em redes neurais.

Neste trabalho apresentamos uma rede neural Hopfield e propomos uma pequena mudança na função energia, como resultado, aplicamos o modelo proposto para segmentação de imagens presentes na literatura e em imagens de satélite do Estado de Goiás, mostrando assim sua potencialidade.

Neste estudo preliminar demonstramos a aplicabilidade da rede neural Hopfield para a segmentação de imagens de satélite da região de Goiás e imagens presentes na literatura obtidos usando o algoritmo da nova rede neural Hopfield com dois clusters, dados canais RGB. Mostramos que o desempenho da rede é ditada principalmente por otimização da função de energia. Para simplicidade, o critério de otimização que foi considerada aqui foi a distância Euclidiana. Além disso, a eliminação do termo de ruído permitiu uma melhor segmentação.

SEGMENTAÇÃO DE IMAGENS USANDO REDE NEURAL HOPFIEL

Daniela de Oliveira ALBANEZ; Marcos Aurélio BATISTA; Sérgio Ferreira da SILVA

Programa de Pós-Graduação em Modelagem e Otimização – UFG/ Regional Catalão

doalbanez@hotmail.com; marcos.batista@pq.cnpq.br; sergio@ufg.br;

Palavras-chave: Segmentação de imagens, Redes neurais artificiais, Rede neural Hopfield, Imagens de satélite.

JUSTIFICATIVA

A segmentação de imagens é um componente importante dos sistemas de visão computacional, cujo objetivo é a partição de uma dada imagem em regiões significativas podendo rotular cada região. Além disso, é um pré-requisito para o alto nível de compreensão da imagem e interpretação. Uma classe em si é constituído por técnicas de segmentação na adoção de técnicas de classificação baseados em redes neurais.

É bem conhecido que o desenho das redes neurais artificiais (RNA's) tentam imitar o processamento de informação de células neurais biológicas. Elas oferecem propriedades importantes como a capacidade de processamento para a classificação e agrupamento e boa robustez a distúrbios, que permite estimativas confiáveis.

A rede neural representa um conjunto muito complexo de interdependências que podem incorporar algum grau de não-linearidade, permitindo a função ser modelada. Normalmente, o número de classes é derivado com algum conhecimento a priori sobre o problema de uma fase de pré-processamento.

De acordo com Huang (1992), Tenorio (1987) e Li (2013) as redes neurais Hopfield foram aplicadas para segmentação de imagem e correspondência de imagem. Enquanto para Cheng (1996) o problema de segmentação de imagem foi abordado minimizando a função de custo, que é definido como a distância média, medida entre os valores de níveis de cinza e o membro de classes. Já Huang (1992) e Campadelli (1997) proporam uma estrutura de rede diferente que usou um neurônio $N \times M \times S$ com as colunas e as linhas que representam os $N \times M$ pixels da imagem e as camadas que representam as classes S do objeto na imagem segmentada.

OBJETIVOS

O presente trabalho tem como objetivo apresentar uma rede neural Hopfield e propor uma pequena mudança na função energia, como resultado, aplicar o modelo proposto para segmentação de imagens presentes na literatura e em imagens de satélite do Estado de Goiás, mostrando assim sua eficiência.

METODOLOGIA

As redes neurais Hopfield são redes neurais artificiais que têm *feedback* e podem ser usadas como memórias associativas, ou seja, a rede é capaz de armazenar informações com base no seu estado. Hopfield (1984) propôs uma arquitetura de rede neural composta de neurônios com respostas graduadas capaz de resolver problemas de otimização complexos, tais como um problema do caixeiro viajante (HOPFIELD e TANK, 1985).

A estrutura da rede neural Hopfield consistem em $N \times M$ neurônios onde cada linha representa um *pixel* e cada coluna representa um *cluster*. A rede classifica a imagem de N pixels entre P característica e M classe de tal forma que a atribuição dos *pixels* minimize a função energia (SAMMOUDA *et.al*, 2014):

$$E = \frac{1}{2} \sum_{k=1}^N \sum_{l=1}^M R_{kl}^2 V_{kl}^2 + c(t) \sum_{k=1}^N \sum_{l=1}^M N_{kl} V_{kl} \quad (1)$$

onde R_{kl} é a distância Mahalanobis, V_{kl} é a saída do neurônio, N_{kl} é um fonte de ruído, $c(t)$ é um parâmetro de controle da magnitude do ruído que deve ser selecionado de tal forma que se aproxima de zero como o tempo t tendendo a "infinito" e pode ser matematicamente como (SAMMOUDA e MIKI, 1993):

$$c(t) = \beta e^{-\alpha t} \quad (2)$$

onde $\beta > 0$ controla a amplitude inicial do ruído ($t = 0$) e $\alpha > 0$ determina a taxa de amortecimento do ruído. A saída no neurônio V_{kl} é determinada por (SAMMOUDA *et.al*, 2014):

$$\begin{cases} V_{kl}(t+1) = 1, & \text{se } U_{kl} < \text{Max}[U_{kl}] \\ V_{kl}(t+1) = 0, & \text{caso contrário.} \end{cases}$$

A minimização é alcançada através da resolução de um conjunto de equações de movimento que satisfazem (SAMMOUDA *et.al*, 2014):

$$\frac{\partial U_{kl}}{\partial t} = -\mu(t) \frac{\partial E}{\partial V_{kl}} \quad (3)$$

onde U_{kl} é uma entrada do neurônio e $\mu(t)$ é uma função escalar de tempo que é definida por (SAMMOUDA *et.al*, 2014):

$$\mu(t) = t(T_s - t) \quad (4)$$

onde t é o tamanho do passo e T_s é o valor máximo de interações.

Nossa contribuição para o presente trabalho consiste em reformular a função energia, para:

$$E = \frac{1}{2} \sum_{k=1}^N \sum_{l=1}^M R_{kl}^2 V_{kl}^2 - \sum_{k=1}^N \sum_{l=1}^M U_{kl} V_{kl} \quad (5)$$


onde o segundo termo da equação passa a ser negativo e eliminamos o ruído juntamente com o parâmetro de controle, considerando U_{kl} que é a entrada do neurônio e mudamos a distância Mahalanobis R_{kl} , para distância Euclidiana.

RESULTADOS/DISCUSSÃO

A nova rede neural Hopfield foi implementada em diferentes imagens com intuito de verificar sua eficiência, primeiramente foram realizados testes com imagens presentes na literatura e posteriormente com imagens de satélite do Estado de Goiás.

Na Figura 1 temos as imagens originais presentes na literatura, e na Figura 2 obtemos as imagens segmentadas pela nova rede neural Hopfield com dois *clusters*.

Figura 1: Imagem Original




(a)

(b)

(c)

Fonte: (a) (WANG *et.al*, 2010); (b) (ZHOU,GAO E GUO, 2014); (c) (KUNTIMAD E RANGANATH, 1999).


Figura 2: Imagem segmentada pela nova rede neural Hopfield



Fonte: (a), (b) e (c) Imagens segmentada pela rede Hopfield com dois *clusters* realizada pelo autor.


Na Figura 3 temos imagens de satélite do Estado de Goiás, podemos observar que na Figura 3 (a) observamos um reservatório de água entre os municípios de Cascalho Rico e Três Ranchos enquanto na Figura 3 (b) observamos uma área de agricultura. Na Figura 4 temos as imagens segmentadas pela nova rede neural Hopfield.

Figura 3: Imagem de satélite do Estado de Goiás



Fonte: (a) Reservatório de água entre os municípios de Cascalho Rico e Três Ranchos
(b) Rio Paranaíba

Figura 4: Imagem segmentada pela nova rede neural Hopfield



Fonte: (a) e (b) www.inpe.com.br
Imagens segmentadas com a nova rede neural Hopfiel com dois *clusters* realizada pelo autor.

A nova rede neural Hopfield foi implementada nas imagens de satélite que contém água e área de agricultura, mostrando assim, apesar da robustez, sua eficácia. Nos resultados obtidos pela nova rede neural Hopfield, percebemos que a rede neural fez uma boa segmentação da água presente nas imagens de satélite.

CONCLUSÃO

Este estudo preliminar demonstrou a aplicabilidade da rede neural Hopfield para a segmentação de imagens de satélite da região de Goiás e imagens presentes na literatura obtidos usando o algoritmo da nova rede neural Hopfield com dois *clusters* dados canais RGB. Mostrámos que o desempenho de rede é ditado principalmente por otimização da função de energia. Para simplicidade, o critério de otimização que foi considerada aqui a distância Euclidiana. Além disso, a eliminação de um termo de ruído que permitiu uma boa segmentação.

REFERÊNCIAS BIBLIOGRÁFICAS

Hopfield, J. J. Neurons with Graded Response have Collective Computational Properties like Those of Two-state Neurons, Proc. Natl. Acad. Sci. USA, vol. 81, p. 3088-3092, May, 1984.

Hopfield, J.J. e Tank, D.W. Neural computation of detection in optimization problems, Biol. Cybernet. 52, p. 141-152, (1985).

Kuntimad, G. e Ranganath, H. Perfect Image Segmentation Using Pulse Coupled Neural Network, IEEE Transactions on Neural Networks, v.10, n.3, p.591 - 597, 1999.

Sammouda, R. e Miki, N.. A comparison of Hopfield Neural Network and Boltzmann Machine in Segmenting MR Images of the Brain, IEEE Transaction on nuclear science, vol. 43,n. 6, p. 3361-3369, (1996).

Sammouda, R. *et al.* A. Agriculture satellite image segmentation using a modified artificial Hopfield neural network, Computers in Human Behavior, 30, p.436-441, (2014).

Wang, H. *et al.* A Simplified Pulse-Coupled Neural Network for Cucumber Image Segmentation. In: IEEE International Conference on Computational and Information Sciences, p. 1053 - 1057, 2010, doi:10.1109/ICCIS.2010.260.

Zhou, Dongguo; Gao, Chao; Guo, Yongcai, A Coarse-to-Fine Strategy for Iterative Segmentation Using Simplified Pulse-Coupled Neural Network, Soft Comput, v. 18, n.3, p.557 - 570, 2014, doi:10.1007/s00500-013-1077-8.

ANEXO G

O que é Segmentação de Imagens?

Artigo publicado no V Workshop de Álgebra da UFG - Regional Catalão, com ISSN 2447-8393, promovido pela Universidade Federal de Goiás - Regional Catalão, realizado entre os dias 7 e 10 de novembro de 2016 ([ALBANEZ D. O. E BATISTA, 2016a](#)).

Neste artigo realizamos 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. O presente trabalho teve como objetivo abordar de forma introdutória e simplificada o tema, para que desperte aos participantes do Workshop de Álgebra interesse e curiosidade sobre o assunto.

Por meio dos conceitos básicos o indivíduo pode 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 ressaltarmos que neste artigo utilizamos uma RNA conhecida como Rede Neural de Pulso Acoplado, 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 expostas neste trabalho levam a crer que o campo de RNA's é acima de tudo extremamente vasto e promissor.

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 evolui 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 (Albanez, 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 10×10 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:




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 β 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 α_F e α_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 α_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 α_E for pequeno, mas esse processo vai demorar muito tempo para terminar, enquanto, se α_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 Cascalho 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 Transavtions 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-systhesis 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 throught gabor transform and neural network processing. *Heat Transfer Engeneering*, 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.