

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

Engenharia da Computação

Igor Matheus Oliveira e Silva

**USO DE TÉCNICAS COMPUTACIONAIS PARA O RECONHECIMENTO DE
ÁREAS SEM ARBORIZAÇÃO A PARTIR DE IMAGENS DE SATÉLITE**

Timóteo

2014

Igor Matheus Oliveira e Silva

**USO DE TÉCNICAS COMPUTACIONAIS PARA O RECONHECIMENTO DE
ÁREAS SEM ARBORIZAÇÃO A PARTIR DE IMAGENS DE SATÉLITE**

Monografia apresentada ao curso de Engenharia de Computação do Centro Federal de Educação Tecnológica de Minas Gerais Campus Timóteo, como requisito parcial de obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Douglas Nunes de Oliveira

Timóteo

2014

Igor Matheus Oliveira e Silva

**USO DE TÉCNICAS COMPUTACIONAIS PARA O RECONHECIMENTO DE
ÁREAS SEM ARBORIZAÇÃO A PARTIR DE IMAGENS DE SATÉLITE**

Monografia apresentada ao curso de Engenharia de
Computação do Centro Federal de Educação
Tecnológica de Minas Gerais Campus Timóteo,
como requisito parcial de obtenção do título de
Bacharel em Engenharia de Computação.

Orientador: Douglas Nunes de Oliveira

Professor Orientador

Professor Avaliador 1

Professor Avaliador 2

Timóteo

2014

A minha mãe,

Saudade eterna

AGRADECIMENTOS

Agradeço a Deus por tudo que ele realizou em minha vida e há de realizar, agradeço também aos meus pais que ajudaram financeiramente para a conclusão do curso e por serem presentes em minha educação. Sou grato também a minha namorada pelo companheirismo durante todo esse tempo de formação na graduação e aos meus orientadores Deismar Botega e Douglas Nunes por todo auxílio no meu trabalho de conclusão.

RESUMO

O trabalho consiste no desenvolvimento de uma ferramenta que possibilite a identificação de áreas sem arborização e com arborização através de imagens de satélite. Pretende-se gerar resultados positivos com esse sistema sendo possível identificar exatamente as áreas arborizadas e não arborizadas, auxiliando empresas e órgãos de interesse na identificação de tais áreas, que é de fundamental importância para a sociedade. Para a realização desse trabalho utilizou-se técnicas da área de inteligência artificial, no ramo de reconhecimento de padrões, assumindo que esse problema pode ser solucionado por algoritmos de reconhecimento. Os algoritmos utilizados foram o K-Nearest Neighbors e o Perceptron que são capazes de reconhecer certos padrões a partir de atributos do sistema, sendo assim, foi obtido um sistema que identifica áreas sem arborização e mostra qual a porcentagem dessa área em relação a toda imagem. Enfim o trabalho visa um bem social e ao mesmo tempo um aprofundamento no conteúdo de Inteligência Artificial, podendo tornar-se um software comercial.

Palavras-chave: Inteligência artificial. Reconhecimento de padrões. Área sem arborização. Ferramenta para construção de bases de imagens. Ferramenta para classificação.

ABSTRACT

The work is to develop a tool that enables the identification of areas without trees and with trees through satellite images. It is intended to generate positive results with this system it is possible to identify exactly the forested and non-forested areas, assisting companies and agencies interested in identifying such areas, which is of fundamental importance to society. To perform this work, we used techniques in the field of artificial intelligence in the field of pattern recognition, assuming that this problem can be solved by recognition algorithms. The algorithms used were K-Nearest Neighbors and the Perceptron that can recognize certain patterns from system attributes, and thus obtained was a system that identifies and unshaded areas show the percentage of that area in relation to the whole image . Anyway work aims a social good while deepening the content of Artificial Intelligence, can become a commercial software.

Keywords: Artificial Intelligence. Pattern recognition. Unshaded area. Tool for constructing bases of images. Tool for classification.

“Aquilo que o homem semear, isso mesmo colherá.”

(Paulo, capítulo 6, versículo 7).

LISTA DE FIGURAS

Figura 1 - Imagem inicial	12
Figura 2 - Imagem Classificada	13
Figura 3 - Esquema de unidade MCCulloch - Pitts.....	15
Figura 4 - Ilustração de problemas Linearmente Separável e Não Linearmente Separável	18
Figura 5 - Arquitetura Perceptron	23
Figura 6 - Arquitetura do MLP	25
Figura 7 - Distância Manhattan e Euclidiana	26
Figura 8 - Representação Knn.....	27
Figura 9 - Ilustração de Classificação Knn para $K = 3$	28
Figura 10 - Modelo de o Perceptron parar o TCC.....	31
Figura 11 - Seleção do ponto e como classificar a área	32
Figura 12 - Estrutura da subimagem armazenada no arquivo base	33
Figura 13 - Resultados apresentados para uma base pequena de treino	34
Figura 14 - Funcionamento da Tela de SCAN da imagem	35
Figura 15 - Pasta onde as imagens são salvas	37
Figura 16 - Início da imagem sendo percorrida e classificada	37
Figura 17 - Processo de SCAN percorrido pela metade.....	38
Figura 18 - Processo de SCAN no final	38
Figura 19 - Processo de SCAN completo.....	40

LISTA DE ABREVIATURAS

RNA - Rede Neural Artificial

TCC - Trabalho de Conclusão de curso

RGB - Red, Green, Blue

Knn - k-Nearest Neighbors algorithm

SUMÁRIO

1. INTRODUÇÃO	11
1.1. Definições do Problema	11
1.2. Motivação.....	11
1.3. Objetivo.....	12
2. ESTADO DA ARTE.....	14
2.1. Características Gerais das Redes Neurais	14
2.2. Processamento de Imagens.....	16
2.3. Reconhecimentos de Padrões	17
3. FUNDAMENTOS TEÓRICOS	19
3.1. Redes Neurais Artificiais.....	19
3.1.1. Classificações das Redes Neurais	20
3.1.2. Arquitetura da Rede Neural.....	22
3.1.3. Arquitetura Perceptron	22
3.1.4. Arquitetura MLP	23
3.2. Algoritmo k-Nearest Neighbors.....	26
4. MÉTODO.....	29
5. RESULTADOS.....	30
5.1. Técnicas utilizadas	30
5.2. Gerações da Base de Aprendizado	32
5.3. Escaneamento da imagem	35
6. CONCLUSÃO	41
7. TRABALHOS FUTUROS.....	42
8. REFERÊNCIAS	43

1. INTRODUÇÃO

1.1. Definições do Problema

O modelo da ocupação demográfica atual tem levado a níveis significativos de desmatamento e de falta de arborização, resultante de múltiplos fatores, tais como a abertura de estradas pioneiras, o crescimento das cidades, a ampliação de pecuária extensiva e a acelerada exploração.

De acordo com texto Arborização (2014), com uma maior área verde na cidade, a temperatura é mais baixa, evitando as ilhas de calor que se formam rapidamente em grandes metrópoles com urbanização intensa, como São Paulo e Rio de Janeiro no Brasil, Nova Iorque, Pequim, Bombaim, Cairo, Cidade do México, entre outras. Portanto, a arborização é de grande importância para a população de uma cidade, pois melhora a qualidade do ar, reduz a propagação do som e absorve parte dos raios solares e da poluição atmosférica.

Este trabalho tem como tema a criação de um sistema usado capaz de identificar áreas com desmatamento e áreas com arborização por meio de imagens de satélites utilizando técnicas de inteligência artificial.

Levando em conta a importância do ambiente verde na sociedade, será fundamental tal identificação, pois esta servirá como ferramenta de apoio a empresas ou órgãos que queiram saber onde existem áreas sem árvore.


1.2. Motivação

Algumas empresas e órgãos necessitam identificar áreas sem arborização. Auxiliar os profissionais da área ambiental na identificação dessas áreas é a grande motivação deste trabalho.

1.3. Objetivo

O objetivo principal desse trabalho é o uso de técnicas eficientes na área de Inteligência Artificial para o reconhecimento de áreas sem arborização a partir de imagens de satélite, podendo tornar uma ferramenta para auxiliar em tais identificações. A figura 1 representa uma imagem inicial de satélite, onde mostra uma determinada área que se deseja classificar

Figura 1 - Imagem inicial




Fonte: Bairro Bethânia, Repositório Digital Google Maps.

A partir da imagem acima é possível criar uma base de micro imagens utilizadas para treinamento de um algoritmo de classificação, onde inicialmente as classificações serão áreas sem vegetações e com vegetações.

A figura 2 demonstra um exemplo de classificação.

Figura 2 - Imagem Classificada



Fonte: Adaptado de Google Maps, 2013.

Para que se possa criar um software desse tipo é necessário desenvolver um sistema de reconhecimento de padrões, por meio de técnicas apropriadas, tais como: redes neurais, classificador Knn, classificador Bayesiano, entre outras. Este sistema deverá ser capaz de identificar na imagem localização de áreas sem vegetação e áreas com vegetações e classificá-las. Além do uso das técnicas de redes Neurais, será necessário o conhecimento de processamento de imagem digital.

2. ESTADO DA ARTE

Warren McCulloch e Walter Pitts. McCulloch passou 20 anos estudando o funcionamento do sistema nervoso e em 1942 convidou Pitts para participar de sua equipe na busca do primeiro modelo de um neurônio artificial.

Foi a partir de muitas pesquisas que os dois criaram em 1943 o primeiro modelo artificial para neurônio biológico, sendo tal modelo publicado no artigo “A Logical Calculus of the Ideas Immanent in Nervous Activity”, *Bulletin of Mathematical Biophysics*, 5: 115-133. Outras importantes publicações desenvolvidas foram por Hebb (1949), e Rosenblatt (1958).

Estas publicações introduziram o primeiro modelo de redes neurais simulando “máquinas”, o modelo básico de rede de auto-organização, e o modelo Perceptron de aprendizado supervisionado, respectivamente (BRAGA; CARVALHO; LUDERMIR, 2000). Além dos citados acima, outros pesquisadores realizaram estudos importantes sobre o modelo de redes nas áreas da visão, memória, controle e auto-organização.

Atualmente existem várias pesquisas utilizando redes neurais, e as pesquisas são de áreas diversificadas. Um artigo publicado por Burke (1994) utiliza uma rede neural chamada backpropagation para prever com mais precisão a sobrevivência do câncer de mama.


2.1. Características Gerais das Redes Neurais

A rede neural tem a capacidade de modificar o resultado apresentado de acordo com meio produzido pelo ambiente. Seu funcionamento é bastante simples, possui unidades de processamento que são adaptados por determinados pesos, as operações são efetuadas sobre a entrada e então são reconhecidas as informações apresentadas (BARRETO, 1997).

Levando em conta as modificações dos pesos, encontram-se diferentes resultados, por isso se diz que as redes neurais se adaptam ao meio, que são representados por pesos (BARRETO, 1997). A figura 3 ilustra o modelo de McCulloch e Pitts (1943) no qual a operação de uma rede neural pode ser representada por:

- Sinais que são apresentados à entrada;
- Cada sinal é multiplicado por um peso, que indica influência na saída do neurônio.
- É feita a soma ponderada dos sinais;
- De acordo com o limite apresentado a rede, é determinada a saída.

Figura 3 - Esquema de unidade McCullock - Pitts.



Fonte: Tatibanae e Kaetsu, 2001

Seguindo o modelo proposto por McCullock e Pitts (1943) temos p sinais de entrada $X_1, X_2, \dots, X_p$ e pesos $w_1, w_2, \dots, w_p$ e o limitador t , onde os sinais assumem valores booleanos (0 ou 1) e os pesos assumem valores reais.

No modelo proposto o nível de atividade a que é modificado pelos padrões apresentado é dado pela somatória da multiplicação dos sinais de entrada e seus respectivos pesos:

$$a = (w_1X_1 + w_2X_2 + \dots + w_pX_p)$$

E a saída y é dada por:

$$y = 1, \text{ se } a \geq t$$

$$y = 0, \text{ se } a < t$$

Segundo McCulloch e Pitts (1943) t é o valor que decide o resultado da saída, quase todas as redes neurais tem uma forma de treinamento, na qual a saída depende das modificações efetuadas sobre os pesos, sendo assim os modelos de redes aprendem através dos padrões apresentados.

2.2. Processamento de Imagens

Com o avanço da tecnologia e a possibilidade de utilização de imagens para auxílio em tomadas de decisão, o campo de estudos em processamento de imagens cresceu grandemente. De forma simples o processamento de imagens tem como entrada uma imagem e como saída as características extraídas dessa imagem (GONZALEZ, 2000). Estas características podem ser utilizadas por um algoritmo de reconhecimento de padrões, por exemplo.

Segundo Marques Filho e Vieira Neto (1999), A área de processamento de imagens vem sendo de crescente interesse por permitir viabilizar grande número de aplicações. O primeiro grande impulso do processamento de imagens veio com os primeiros computadores digitais de grande porte e o início do programa espacial norte-americano.

Atualmente existem várias aplicações que utilizam processamento de imagens e com crescimento expressivo. Em Medicina o uso da tecnologia de processamento facilita na interpretação das imagens produzidas por equipamentos até mais antigos, um exemplo é o raios-X. Almeida (1988) mostra o uso de processamento em imagens médicas.

Em Biologia, outro exemplo é a capacidade de processar imagens obtidas por microscópico, podendo, por exemplo, contar o número de cromossomos ou o número de células de certo tipo. Segundo GONZALEZ (2000), graças ao processamento de imagens vem acontecendo outros avanços na área de Geografia, Sensoriamento Remoto, Astronomia, entre outras. Sendo assim muitas áreas estão sendo beneficiadas com o avanço do processamento de imagens.

Há diversos artigos e revistas relatando o processamento de imagem e métodos para tornar eficientes os processamentos, já que é bem custoso processar uma imagem. O Chinês Mao Keji propôs em seu artigo Development and Application of Online Image Processing System Based on Applet and JAI (2009) uma arquitetura de software de processamento de imagem web gratuito para realizar o processamento, utilizando algoritmos avançados e um sistema de processamento distribuídos em plataforma Java Applet e JAI.

2.3. Reconhecimentos de Padrões

Segundo Cortes (1995) o termo padrão pode ser definido como o oposto de caos; uma entidade, vagamente definida, à qual pode ser dado um nome. Dessa maneira uma figura ou um símbolo pode ser um exemplo de padrão.

Basicamente, o reconhecimento de padrões é a área de pesquisa que tem por objetivo a classificação de objetos (padrões) em um número de categorias ou classes (THEODORIDIS E KOUTROUMBAS, 1999).


O reconhecimento de padrão é bastante utilizado no nosso meio, seja para classificação de spams em um email ou na detecção de rostos em uma imagem, no geral se trata de organizar informações a partir de dados coletados.

Com o uso de reconhecimento de padrões, baseando em informações de destinatários e configurações previamente aplicadas, é possível categorizar as mensagens e classificá-las. Campos (2001) fez um estudo de técnicas de uso de reconhecimento de padrões em métodos para identificação de faces.

O Reconhecimento de padrões utiliza diversas técnicas para classificar as entradas, no qual, para cada entrada existe uma saída correspondente, sendo resultante de operações entre a entrada e o peso, por esse motivo as entradas não podem ser muito genérica. Campos (2001).

Existem dois tipos de problemas na área de reconhecimento de padrões e redes neurais que é fundamental o entendimento deles, que são problemas linearmente separáveis e os não linearmente separáveis que podem ser facilmente ilustradas na figura 4.

Figura 4 - Ilustração de problemas Linearmente Separável e Não Linearmente Separável



Fonte: Introduzindo Redes Neurais e Perceptron, 2008.

A linha verde representa a divisão que uma rede faz para classificar uma base com duas classificações, existem diversos algoritmos para classificar uma rede linearmente separável e não linearmente separável. O Perceptron simples, o classificador bayesiano e o Knn são exemplos de classificadores utilizados normalmente em problemas linearmente separáveis. Já o Multilayer Perceptron é usado, normalmente, em problemas não linearmente separáveis, esses algoritmos são citados na seção três.

3. FUNDAMENTOS TEÓRICOS

A inteligência Artificial é uma área de pesquisa da computação dedicada a buscar métodos ou dispositivos computacionais que possuam a capacidade racional do ser humano de solucionar os problemas de maneira ampla e inteligente. Conforme Charniak e McDermott apud Bittencourt (1998), a IA pode ser definida de outro modo, “Inteligência artificial é o estudo das faculdades mentais através do uso de modelos computacionais”.

De acordo com Rabuske (1995), IA é o resultado da aplicação de técnicas e recursos, especialmente de natureza não numérica, viabilizando a solução de problemas que exigiriam do humano certo grau de raciocínio e de perícia. A inteligência artificial abrange varias áreas de pesquisas, como teoria dos jogos, teoremas de redes neurais artificiais, otimização combinatória, classificação de informação, sendo esse ultimo o problema enfrentado para a classificação da presença de arborização. Nos próximos tópicos serão tratados todos os conceitos relacionados ao trabalho proposto.

3.1. Redes Neurais Artificiais

Uma RNA pode ser definida como um arranjo de unidades (neurônios interconectados) que trabalham em paralelo para classificar e generalizar dados de entrada em classes de saída (HAYKIN, 2001).

As redes neurais podem ser organizadas em camadas conectadas, podendo ser a “camada de entrada”, a(s) camada(s) escondida(s) ou oculta(s) e a camada de saída. Na camada de entrada não ocorre processamento, os dados são apresentados à rede. A camada de entrada se comunica a uma ou mais camadas ocultas onde ocorre o processamento por meio de um sistema de conexões ponderadas. A camada de saída apresenta o resultado do processamento. (German e Gahegan, 1996).

A pesquisa das redes neurais se baseia em realizar funções diversas, no qual certas funções podem ser empregadas na área da computação. De acordo com Braga, Carvalho e Ludermit (2000), na maioria dos casos os neurônios são modelos compostos de vários elementos que trabalham em paralelo e classificam a saída de acordo com os padrões estipulados.

De acordo com Simon Haykin (1999) quando se utiliza o aspecto das redes neurais para o desenvolvimento de determinado projeto na área computacional deve-se levar em conta as seguintes etapas:

- ✓ Desenvolvimento de modelos neurais motivado por neurônios biológicos;
- ✓ Modelos de conexões sinápticas;
- ✓ Regra de ajuste dos pesos.

Já o Aprendizado é caracterizado por meio de exemplos. Segundo Braga, carvalho e Ludemir (2000), “o objetivo principal do aprendizado em Redes Neurais é a obtenção de modelos com boa capacidade de generalização tendo como base o conjunto de dados”. Para um determinado conjunto de dados, o algoritmo de aprendizado deve ser responsável pela adaptação dos parâmetros da rede, de maneira que, em um número finito de iterações do algoritmo, exista convergência para uma solução. O critério de convergência varia de acordo com o algoritmo usado para os ajustes dos pesos.

Por meio das ocorrências de estímulo da rede pelo meio externo, o algoritmo de aprendizado provoca mudança nos parâmetros da rede e, finalmente, a mudança nos parâmetros acarreta em mudança no comportamento da RNA. Espera-se que a alteração no comportamento da rede melhore o desempenho de forma gradual.

Em problemas de aproximação e classificação, a entrada é composta por pares de (x, y_d) , tendo então um aprendizado supervisionado, sendo apresentada previamente a saída desejada y_d para um determinado valor de entrada x . A cada iteração de entrada há um ajuste dos pesos, que deve modificar a saída y de forma que a diferença entre y e y_d diminua. Haykin (1999).

3.1.1. Classificações das Redes Neurais

A classificação é uma capacidade conceitual humana, que utiliza as categorias como ferramentas. O processo de classificação envolve a associação ordenada e sistemática de cada entidade a uma única classe dentro de um conjunto de classes mutuamente exclusivas e que não se sobrepõem (JACOB, 2004).

Existem diversos tipos de RNA e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado que pode ser: supervisionada e não supervisionada.

Como aponta Portugal e Fernandes (1995), no aprendizado supervisionado, todas as entradas de treinamento são rotuladas, ou seja, é apresentado ao algoritmo tanto a entrada (atributos) quanto a saída (classe), já o aprendizado não supervisionado, inicialmente não apresenta classificações nas entradas.

Algumas redes biológicas que são não supervisionadas identificam padrões entre os dados de entradas e desenvolvem habilidades de categorizar as estradas, os estágios iniciais da visão e da audição são alguns exemplos desse tipo de rede. Segundo Braga, Carvalho e Ludermit (2000), essas redes definem seus parâmetros por si próprias e os algoritmos utilizam um conjunto de regras de sua própria natureza para o ajuste dos pesos.

As redes também podem ser classificadas quanto à suas características: contínua, discreta, determinística e estocástica, ou quanto à sua estrutura: redes de múltiplas camadas e redes recursivas. A classificação é feita a partir dos atributos de entrada e aplicando os algoritmos de classificações sendo capaz de rotular as entradas. Um exemplo pode ser visto no quadro 1.

QUADRO 1 - Exemplo de classificação

Atributo1 (R)	Atributo2 (G)	Atributo 3 (B)	Classificação (S)
155	155	155	Classe 1
160	2	3	Classe 2
0	0	20	Classe 1
255	255	255	Classe 1
1	100	100	Classe 2
100	100	100	Classe 1
2	239	29	Classe 2

Fonte: O Autor.

3.1.2. Arquitetura da Rede Neural

Braga, Carvalho e Ludermir (2000), definem a arquitetura de uma RNA como sendo um parâmetro importante na sua concepção, uma vez que restringe o tipo de problema que pode ser tratado pela rede.

Uma rede neural pode ter uma ou várias camadas. As redes que possuem uma única camada são as redes que possuem um nó entre uma entrada e uma saída da rede. Esse tipo de rede é indicado para a solução de problemas linearmente separáveis. Já as redes multicamadas possuem uma ou mais camada entre as camadas de entrada e saída. Essas camadas são chamadas de camadas escondidas ou ocultas. (LOESCH E SARI, 1996; TIERRA, 2003).

De acordo com Braga, Carvalho e Ludermir (2000), A topologia das Redes Neurais Artificiais depende da forma como os Neurônios se conectam para formar uma "Rede" de neurônios. A topologia pode ser de redes diretas (Feed-forward) ou de redes recorrentes (Feedback). Para cada de topologia há formas de aprendizado de algoritmos diferenciados.

3.1.3. Arquitetura Perceptron


Segundo Haykin(1999), a rede perceptron é um modelo de rede inovador proposto por Rosembat, seu algoritmo utiliza o aprendizado supervisionado, sua estrutura de rede é composta por unidades básicas de nodos, seu modelo de convergência usa nodos McCulloch Pitts Neuron (MCP) no qual são treinados com o algoritmo de Perceptron, e caso o problema seja linearmente separável, o modelo convergirá.

De acordo com Simon Haykin (1999), a arquitetura do Perceptron é constituída de três camadas, a camada de entrada, a camada de associação e a camada de resposta, sendo a ultima a única que possui os pesos ajustáveis. O algoritmo de treinamento do Perceptron busca ajustar os pesos para definir uma reta que separe em diferentes classes, fazendo com que a rede classifique corretamente as entradas.

O Perceptron é capaz de separar somente problemas que envolvem funções linearmente separáveis, o que é uma condição que não se enquadra na maioria dos problemas, por isso esse modelo não teve uma vida muito longa, sendo muito criticado por Minsky e Papert (1969) com relação a sua capacidade computacional.

Na obra: “Na Introduction to computational geometry”, Minsky e Papert, mostraram que as operações de portas envolvendo E, OU, OU_EXCLUSIVO são exemplos de problemas que podem ser resolvidos por Perceptron simples, agora quando se trata de portas envolvendo o XOR o Perceptron não é capaz de solucionar, pois envolve problemas não linearmente separáveis. A figura 5 representa a arquitetura do Perceptron.

Figura 5 - Arquitetura Perceptron



Fonte: Rede Neural Artificial – Perceptron, 2012.

3.1.4. Arquitetura MLP

Minsky e Papert (1969) analisaram o Perceptron simples e demonstraram que não era possível usá-lo para solucionar problemas que não sejam linearmente separáveis. O trabalho de Rumelhart, Hinton e Williams (RUMELHART e MCCLELLAND, 1986) contribuiu para os estudos da área de RNA, no qual foi desenvolvido um algoritmo de treinamento backpropagation chamado de MLP.

Perceptron de Múltiplas camadas ou Multilayer Perceptron (MLP) é uma rede com uma camada de entrada, uma ou mais camadas ocultas neurônios e uma camada de saída com o número de neurônio igual ao número de sinais de saída.


Segundo Simon Haykin (1999), o MLP é uma generalização da rede Perceptron, e tem sido aplicado com sucesso para resolver diversos problemas difíceis, assim como esta, é treinada de forma supervisionada, utilizando regras de aprendizagem que minimiza o erro. De acordo com Haykin (1999) o mecanismo utilizado para aprendizagem e treinamento da rede MLP é conhecido como algoritmo de retropropagação do erro.

A retropropagação funciona da seguinte forma: um padrão é apresentado à camada de entrada, e dependendo de cada padrão apresentado, os nodos calculam a resposta que é produzida na camada de saída. O erro da saída é calculado e propagado para a entrada novamente, modificando os pesos e recalculando novamente, tornando o erro cada vez menor.

Após obter um erro muito pequeno, os pesos são considerados satisfatórios e ficam mantidos na rede. A rede neural utiliza esses pesos como feedforward, ou seja, se houver a necessidade de classificar utilizando essa rede, não haverá mais treinamento, somente será apresentada a camada de entrada, e a rede retornará a saída usando os pesos satisfatórios para os cálculos.

Na figura 6 é apresentando a arquitetura MLP, nela nota-se a camada de entrada, intermediária e a camada de saída.

Figura 6 - Arquitetura do MLP



Fonte: Icmc - Repositório Digital da USP.

3.2. Algoritmo k-Nearest Neighbors


K-Nearest Neighbors é um método de classificação supervisionado e normalmente é utilizado em problemas linearmente separáveis, para utilizá-lo é necessário ter armazenado as entradas com suas respectivas classificações.

“Este método foi descrito primeiramente nos anos 1950. Mas foi somente a partir dos anos 60, quando computadores mais potentes surgiram, que o método ganhou popularidade. Ele tem sido muito usado, desde então, principalmente em reconhecimento de padrões.” (SANDRA, 2006).

O método da distância mínima atribui cada elemento desconhecido à classe cuja média é mais próxima, ou seja, a atribuição de uma classe ao elemento depende da distância em relação à classe a qual este foi atribuído (isso implica que todas as distâncias devem ser verificadas, até que se ache a menor delas) (HODGSON, 1988).

O método Knn pode utilizar diferentes distâncias para fazer o cálculo da classificação, uma delas são a distância Manhattan e a Euclidiana. A distância Manhattan é o cálculo da soma das diferenças do atributo X_f , X_i e Y_f , Y_i . Já a distância Euclidiana é a distância direta entre os pontos (X_1, Y_1) e (X_2, Y_2) , é possível ver a diferença das distâncias na figura 7.


Figura 7 - Distância Manhattan e Euclidiana



Fonte: O Autor.

O Algoritmo Knn é um algoritmo bastante simples e intuitivo, um exemplo é o caso da figura 8. Suponha que existam áreas arborizadas representadas com a cor azul e áreas não arborizadas representada com a cor vermelha, deseja-se classificar uma entrada representada como a cor preta.


Figura 8 - Representação Knn



Fonte: O Autor.

Para classificar essa entrada é necessário calcular a distância dessa entrada com cada um dos registros existentes, e considerar as K menores distâncias da entrada e a classe das K menores distâncias, depois basta verificar a classe com maior frequência entre os K exemplos mais próximos e assumir a entrada com essa classificação, segue o exemplo ilustrado na figura 9.

Figura 9 - Ilustração de Classificação Knn para $K = 3$



Fonte: O Autor.

4. MÉTODO

Durante o desenvolvimento foi necessário a realização de alguns passos para chegar ao resultado esperado, esses passos são:

- Estudo das características de áreas com e sem arborização.
- Estudo das técnicas de aprendizagem de máquina para classificação.
- Definição das técnicas a serem utilizadas para classificação de áreas sem arborização.
- Implementação da ferramenta para construção de base de imagens e classificação sistema.
- Implementação dos algoritmos escolhidos para classificação de áreas arborizadas.
- Criação da base de treinamento, teste e validação.
- Classificação usando as técnicas Knn e Perceptron.
- Levantamento dos resultados e análise comparativa dos resultados entre o algoritmo Knn e Perceptron.
- Conclusão dos resultados, levando em consideração se satisfaz com o proposto inicialmente.

A realização do passo-a-passo foi importante para o aprendizado sobre temas da área de Inteligência Artificial e para o conhecimento de novas ferramentas. A escolha da ferramenta, dos algoritmos e dos passos da metodologia interfere diretamente no resultados do desenvolvimento.

5. RESULTADOS

Neste trabalho, decidiu-se utilizar imagens de satélites disponibilizadas gratuitamente no Google Maps. Esta decisão foi tomada pela facilidade de acessá-las e pelo volume de informações disponibilizadas. Foram codificados dois métodos de reconhecimento de padrões e criada uma aplicação para facilitar a extração rotulada da base de dados e aplicação destes métodos em imagens de satélite.

As imagens foram retiradas da mesma distância para manter a proporção de intensidade do tom RGB da imagem e não interferir no treino da base. O próximo passo foi montar uma base de subimagens de tamanho 7x7 pixels (totalizando 49 pixels) de áreas arborizadas e não arborizadas, a montagem da base é toda automática, sendo criado pelo próprio sistema, o usuário necessita apenas identificar os pontos que farão parte da base.

5.1. Técnicas utilizadas

Em um primeiro momento optou-se por utilizar o Perceptron Simples e o Knn para a classificação das imagens. Estes algoritmos foram escolhidos pela simplicidade e facilidade em implementar e de treinar as informações armazenadas. As amostras utilizadas no treino destes dois algoritmos são as subimagens salvas no arquivo base.

O Knn classifica uma nova amostra ou nova subimagem da seguinte forma: calcula-se a distância desta nova amostra com todas as amostras contidas na base de dados, utilizaram-se dois métodos de cálculo de distância: Euclidiano e Manhattan; verifica-se quais são as K amostras da base de dados que se encontram mais próximas da amostra a ser classificada. Nesse TCC K é uma constante definida previamente com valor sete; dentre destas K amostras, se houver uma maior frequência de amostras rotuladas como área arborizadas a nova amostra será classificada como tal, caso contrário, será classificada como área não arborizada.

Sendo r, g, b as cores (R, G, B) do pixel da nova subimagem e r_i, g_i, b_i as cores (R, G, B) das subimagens da base, o cálculo de distância entre duas amostra é descrito pelas seguintes equações, onde o somatório varia de zero a quarenta e seis, pois cada amostra contém 47 entradas:


$$(1 - Euclidiana) \sqrt{\sum_{i=0}^{46} (r - ri)^2, \sum_{i=0}^{46} (g - gi)^2, \sum_{i=0}^{46} (b - bi)^2}$$

$$(2 - Manhattan) \sum_{i=0}^{46} (r - ri), \sum_{i=0}^{46} (g - gi), \sum_{i=0}^{46} (b - bi)$$

O Perceptron utilizado neste trabalho foi desenhado para receber 147 entradas, sendo estas as três tons de cores (RGB) de cada pixel de uma amostra qualquer que possui 49 pixels. Este Perceptron possui apenas uma saída com dois valores possíveis: 0 ou 1, no qual zero representa áreas arborizadas e um áreas não arborizadas. Para a o cálculo da saída foi utilizado à função sigmóide representada pela equação abaixo.

$$(Função\ sigmóide) \ f(x) = \left(\frac{2}{(1 + e^{-2x})} - 1 \right)$$

Figura 10 - Modelo de o Perceptron parar o TCC



Fonte: O Autor.


5.2. Gerações da Base de Aprendizado

Foi criado um sistema para manipulação da base de dados, esse sistema possui duas opções de telas, que são a opção de ‘CRIAR BASE’ ou a de ‘ESCANEAR’.

A opção de criar base permite a interação do usuário com a foto de satélite da seguinte forma:

- Primeiramente é necessário abrir uma imagem do computador, acessando o ícone de pasta e escolhendo o caminho da imagem.
- Seleciona-se a opção ‘Ponto’ como visto na figura 11;
- Depois basta clicar em qualquer ponto da imagem; neste momento é criada uma seleção quadrada de tamanho 7x7 abaixo desse ponto, no qual o ponto clicado é o valor (x,y) superior esquerdo.
- O próximo passo é selecionar uma das opções: “Área arborizada” ou “Área sem arborização”;
- Por último o usuário possui a opção de adicionar na base clicando no botão ‘ADICIONAR NA BASE’ esse botão irá colher todas as informações dos valores de rgb da área selecionada e sua classificação e adicioná-las na base.

Figura 11 - Seleção do ponto e como classificar a área



Fonte: O Autor.

Os valores referentes ao tom R, G, B do ponto é guardado em um arquivo texto que armazena informações de todos os pontos adicionados, ele se encontra na pasta principal do projeto, seu nome é 'base.txt'. Este arquivo é utilizado como base para a aplicação, sempre que é executado o programa o arquivo é carregado.

É importante o armazenamento e expansão desta base para aumentar a precisão dos métodos utilizados. Cada subimagem ou amostra é formada por 49 pixels, armazenados no mesmo arquivo texto, contendo em cada linha o valor RGB separado por um espaço e ao final dos 49 pixels, há outra linha contendo a classificação; sendo '1' para arborizada e '2' para não arborizada, um exemplo da estrutura de armazenamento dos pixels da subimagem pode ser visto na figura 12.

Figura 12 - Estrutura da subimagem armazenada no arquivo base

R	G	B	
41.0	69.0	55.0	
19.0	47.0	33.0	
21.0	49.0	35.0	
37.0	63.0	52.0	
39.0	62.0	52.0	
28.0	49.0	42.0	
32.0	51.0	45.0	
36.0	62.0	49.0	
18.0	44.0	31.0	
15.0	41.0	28.0	
25.0	48.0	38.0	
27.0	48.0	39.0	
19.0	38.0	32.0	
28.0	47.0	41.0	
32.0	53.0	44.0	
21.0	42.0	33.0	
14.0	35.0	26.0	
14.0	34.0	25.0	
12.0	32.0	23.0	
22.0	39.0	31.0	
32.0	49.0	41.0	
29.0	48.0	42.0	
25.0	45.0	36.0	
19.0	36.0	28.0	
13.0	30.0	22.0	
12.0	29.0	21.0	
25.0	42.0	34.0	
29.0	46.0	38.0	
23.0	42.0	36.0	
26.0	41.0	34.0	
19.0	34.0	27.0	
14.0	30.0	20.0	
18.0	34.0	24.0	
15.0	31.0	21.0	
36.0	53.0	43.0	
1	=>Classificação		

49 linhas


Fonte: O Autor.

Lembrando que a base é criada sempre pelo o usuário do sistema, sendo assim, é importante criar uma base certa, identificando os pontos e classificando os corretamente, pois caso o usuário adicione um ponto com uma classificação errada, esse ponto trará diferenças no resultado final.

O botão ‘CLASSIFICAR’ no sistema funciona para acionar o método de classificação, os métodos acionados são o classificador Knn e o Perceptron simples.

Sempre que selecionado o botão ‘CLASSIFICAR’ é possível visualizar a quantidade de acertos de cada método. Inicialmente os algoritmos dividem o arquivo em três partes aleatórias, sendo treinadas duas partes e realizado testes com uma parte. A parte de teste é passada ao classificador Knn e ao Perceptron, os algoritmos interpretam a base de teste e retornam a quantidade de acertos. Os resultados obtidos variam de 80% a 100% de acertos.

Figura 13 - Resultados apresentados para uma base pequena de treino



```

<terminated> RedimensionarImagemJFrame [Java Application] C:\Program Files\Java\jre7\bin\javaw.exe (10/02/2014 13:51:40)
Classificacao esperada: 2.0 --- Classificacao encontrada com distancia Euclidiana: 2.0 --- Classificacao encontrada com distancia Manhattan: 2.0
Classificacao esperada: 2.0 --- Classificacao encontrada com distancia Euclidiana: 2.0 --- Classificacao encontrada com distancia Manhattan: 2.0
Classificacao esperada: 1.0 --- Classificacao encontrada com distancia Euclidiana: 1.0 --- Classificacao encontrada com distancia Manhattan: 1.0
Classificacao esperada: 1.0 --- Classificacao encontrada com distancia Euclidiana: 1.0 --- Classificacao encontrada com distancia Manhattan: 1.0
Classificacao esperada: 1.0 --- Classificacao encontrada com distancia Euclidiana: 1.0 --- Classificacao encontrada com distancia Manhattan: 1.0
Classificacao esperada: 1.0 --- Classificacao encontrada com distancia Euclidiana: 1.0 --- Classificacao encontrada com distancia Manhattan: 1.0
Classificacao esperada: 2.0 --- Classificacao encontrada com distancia Euclidiana: 2.0 --- Classificacao encontrada com distancia Manhattan: 2.0
Classificacao esperada: 2.0 --- Classificacao encontrada com distancia Euclidiana: 2.0 --- Classificacao encontrada com distancia Manhattan: 2.0
Classificacao esperada: 2.0 --- Classificacao encontrada com distancia Euclidiana: 2.0 --- Classificacao encontrada com distancia Manhattan: 2.0
Classificacao esperada: 2.0 --- Classificacao encontrada com distancia Euclidiana: 2.0 --- Classificacao encontrada com distancia Manhattan: 2.0

Quantidade de Acertos para Distancia Euclidiana: 11.0Acertos / 100.0% de acertos
Quantidade de Acertos para Distancia Manhattan: 11.0Acertos / 100.0% de acertos
  
```

Fonte: O Autor.

Na figura 13 é possível ver a impressão, que indica o valor esperado da classificação da área e o valor encontrado utilizando o algoritmo Knn com distâncias Euclidiana e Manhattan.


5.3. Escaneamento da imagem

Após os resultados positivos encontrados com as bases de teste, foi possível criar a escaneamento da imagem, que se trata de percorrer qualquer imagem de satélite e identificar quais são as áreas arborizadas e não arborizadas na imagem. Para escolher essa opção basta clicar no botão de ‘ESCANEAR’ da tela inicial.

Na figura 14 é possível ver a Tela de escâner aberta, definidas com as funcionalidades numeradas, sendo:

- 1- Botão para abrir a imagem no painel.
- 2- Opção de escolher o método para escanear a imagem.
- 3- Tamanho da base já criada, esse número representa a quantidade de entradas 7x7 pixels salvas no arquivo base.txt.
- 4- O botão ‘escanear’ realiza a escaneação da imagem por completo e mostra o resultado.
- 5- Painel onde a imagem será aberta e onde ocorrerá a simulação do escâner.
- 6- Opções de cor.

Figura 14 - Funcionamento da Tela de SCAN da imagem



Fonte: O Autor


Ao clicar no botão ‘ESCANEAR’ a imagem será totalmente escaneada e no momento do escaneamento serão mostradas as áreas arborizadas e não arborizadas. O escaneamento é possível pelo fato da base de teste e treino estar armazenados no arquivo base. O funcionamento do escaneamento da imagem é da seguinte forma: foi criado um algoritmo de processamento de imagem que percorre toda a imagem, pixel á pixel; cada pixel é passado para o algoritmo de classificação como entrada, e o algoritmo retorna a classificação do pixel.

No caso da classificação ser arborizada o algoritmo pinta o pixel com o negativo do valor rgb natural dele, ou seja, pega o valor máximo de RGB (255, 255,255) e subtraí pelo valor RGB do pixel (r, g, b), já em área sem arborização, o algoritmo pinta o pixel com o tom azul dele, ou seja, subtrai o valor red e green máximo do pixel original, no caso ficaria $(255,255,0) - (r, g, b)$.

No número 6 indicado na figura 14, há a opção de cor do escaneamento, é uma funcionalidade para salvar as imagens em diferentes tipos de cores, o que ajuda fazer comparações entre imagens e até mesmo facilita a compreensão em identificar as áreas desmatadas. Após o escaneamento, as imagens são salvas em todos os tipos de opções de cores em uma pasta do programa chamado img como visto na figura 15.


A figura 16, 17 e 18 ilustra a imagem sendo percorrida por etapas e classificada, pintando as tonalidades negativas para áreas arborizadas e tonalidades azuis para as áreas não arborizadas.

Figura 15 - Pasta onde as imagens são salvas




Fonte: O Autor

Figura 16 - Inicio da imagem sendo percorrida e classificada




Fonte: O Autor

Figura 17 - Processo de SCAN percorrido pela metade



Fonte: O Autor

Figura 18 - Processo de SCAN no final



Fonte: O Autor

Após o escâner completo, é informada a legenda com as classificações e a porcentagem de área arborizada na imagem. Na figura 19 é possível ver a imagem totalmente classificada e a legenda.

Utilizando o Perceptron obtiveram-se resultados semelhantes ao do Knn, o Perceptron comparado com o Knn é muito mais lento no momento do treino, porém é mais eficiente com relação ao tempo de resposta na hora do escaneamento. Considere N o número de treinos do Perceptron, Q a quantidade de entradas, Qa a quantidade de atributos de uma entrada e Qc a quantidade de classificações; a ordem do Knn e do Perceptron no treino é:


$$O(Knn) = \left(Q/3 \right) * (2/3 * Q + Qc)$$

$$O(Perceptron) = (N * Q + 2 * Qa)$$

Levando em consideração que está sendo utilizados duas classificações, 147 atributos, 49 entradas e 100 treinos, o que implica no Perceptron ser mais de nove vezes mais lento no momento do treinamento do que o Knn.

No entanto, no momento da escaneação, para cada pixel, o Perceptron realiza 147 multiplicações para determinar a sua classificação, já o Knn determina novamente as K menores distâncias com relação a esse pixel, e atribui ao pixel à classificação de acordo com a maior frequência de classificação das K menores distâncias, o que torna o Knn mais lento no escaneamento, ainda mais se o tamanho da base for muito grande, tornando ainda mais demorado.

Figura 19 - Processo de SCAN completo



Fonte: O Autor

6. CONCLUSÃO

O trabalho tem objetivo principal à criação de um software capaz de classificar áreas com falta de arborização a partir de imagens de satélite, utilizando algoritmos de classificação de padrões e redes neurais. A princípio a ideia era usar o Knn e o Perceptron e verificar as áreas apontadas como arborizadas por esses algoritmos, identificando a porcentagem de acertos e de erros na classificação da arborização, depois o foco era analisar algum aspecto que diferenciasse na resposta de cada algoritmo.

Os resultados entre os algoritmos se assemelham quando comparado à porcentagem de acertos ou até mesmo ao analisar as imagens geradas após o escaneamento, no entanto o Perceptron é mais lento no momento do treino e muito mais rápido no escaneamento, sendo assim, o Knn seria uma pior escolha caso fosse usado uma base muito grande, pois o escaneamento da imagem iria ser custoso, demorando horas para escanear uma imagem de 500x500 pixels.

O trabalho proposto é de fundamental importância não só no que diz respeito à aprendizagem de fundamentos da área de Inteligência artificial, como também poderá ser muito útil para diversas empresas e órgãos que necessitam detectar tais áreas, e possivelmente pode virar um software para patrulhamento auxiliando numa vida mais verde e saudável para a população.

Enfim o desenvolvimento do projeto auxiliou no aprendizado em tópicos específicos da área de inteligência artificial, tais como reconhecimento de padrões e redes neurais, e também mostrou a importância de um projeto voltado para um bem ambiental e social.

7. TRABALHOS FUTUROS

No momento é possível classificar somente áreas arborizadas e não arborizadas, uma proposta futura para esse projeto seria a opção de classificar mais componentes, alguns exemplos são: classificar carro, telhado da casa, sombras, rios, lagos, etc.

O Perceptron de Múltiplas Camadas também poderia ser implementado em propostas futuras, sendo base de novas comparações. Outra proposta futura seria aumentar a base e verificar a precisão e comportamento dos métodos em relação ao aumento da base.

Existem alguns sistemas de classificação, no entanto pagos, sendo assim outra proposta futura para esse projeto seria torna-lo acessível a todos. Caso esse sistema seja open source pode ser que, outras pessoas implantem mais funções e o sistema cresça com intuito de atender as necessidades de empresas e órgãos que necessite das funcionalidades presentes nele.

8. REFERÊNCIAS

ALMEIDA, A. B. **Usando o Computador para processamento de Imagens Médicas**. Informática Médicas. V. 1, nº6, 1988.

ARBORIZAÇÃO. In Wikipédia: a enciclopédia livre. Disponível em: <<http://pt.wikipedia.org/wiki/Arboriza%C3%A7%C3%A3o>> Acesso em: 8 out 2013.

BAIRRO BETHÂNIA. **Google Maps**. Disponível em: <<https://www.google.com.br/maps/place/Av.+Jos%C3%A9+Barcelos+-+Bethania,+Santana+do+Para%C3%ADso+-+MG/@-19.4412502,-42.5372925,2830m/data=!3m1!1e3!4m2!3m1!1s0xb001d986e87a3d:0x6775973618cc0b07>> Acesso em: 25 Set. 2013.

BARRETO, Jorge M. **Introdução às Redes Neurais Artificiais**. Anais V Escola Regional de Informática da SBC Regional Sul, 5 a 10 de maio de 1997. Páginas 41 - 71.

BORGES, E. M. **Rede Neural Artificial – Perceptron**. Disponível em: < <http://www.borges-solutions.com/rede-neural-artificial-perceptron/>> Acesso em 05 Set 2013.

BITTENCOURT, Guilherme. **Inteligência Artificial: ferramentas e teorias**. Florianópolis: UFSC, 1998.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. Ed. Rio de Janeiro: LTC, 2007. 226 p.

CAMPOS, T. E, “**Técnicas de seleção de características com aplicações em reconhecimento de faces**”. Dissertação de mestrado apresentada ao Instituto de Matemática e Estatística da Universidade de São Paulo. Orientador: Dr. Roberto Marcondes Cesar Junior. São Paulo: 2011.

CARVALHO, A. P. L. F. **Redes Neurais Artificiais**. Disponível em: <www.icmc.usp.br/pessoas/andre/research/neural/> Acesso em: 25 Set. 2013.

CORTES, C.; VAPNIK, V.. **Support vector networks**. Machine Learning, 20(3):273–297, 1995. 3.2.

FERNANDES, L. G. L., Portugal, M. S. e Navaux, P. O. A. (1994), "**Um Estudo de Poder Preditivo das Redes Neurais Artificiais Comparado a Métodos Econométricos Tradicionais**", Anais do IO Simpósio Brasileiro de Redes Neurais, Caxambu (MG), p. 139-144.

GERMAN, G.W.H.; GAHEGAN, M.N. **Neural Network Architectures for the Classification of Temporal Image Sequences**. Comp. Geosci., v. 22, n. 9, p. 969-979, 1996.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Edgard Blücher, 2000.

HAYKIN, Simon. **Redes Neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p., 2001.

HODGSON, M. E. **Reducing the computational requirements of the minimum-distance classifier**. Remote sensing of environment, vol. 25, p. 117-128, 1988.

JACOB, Elin. **Classification and categorization: a difference that makes a difference**. Library trends, v. 52, n.3, p. 515-540, 2004.

ICMC - Repositório Digital da USP. **Redes Neurais Artificiais**. Disponível em: <<http://www.icmc.usp.br/pessoas/andre/research/neural>>. Acesso em: 15 fev. 2014.

LOESCH, C.; SARI, S. **Redes Neurais Artificiais. Fundamentos e Modelos**. Blumenau: FURB, 1996.

MAOKEJI; **Development and Application of Online Image Processing System Based on Applet and JAI**, 2009. On International Conference Environmental Science and Information Application Technology, 2009.ESIAT 2009.

MARCEL, C. **Introduzindo Redes Neurais e Perceptron**. Disponível em: <http://aimotion.blogspot.com.br/2008/12/artigo-introduzindo-redes-neurais-e_5497.html> Acesso em 05 Set. 2014.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**, Rio de Janeiro: Brasport, 1999.

MINSKY, M. e PAPERT, S. / **Perceptrons: An Introduction to Computational Geometry**,

MIT Press, Cambridge, MA. - 1969;

RABUSKE, Renato Antônio. **Inteligência Artificial**. Florianópolis: UFSC, 1995.

ROSEMBLATT, F. **The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain**. Psychological Review, 65, p.386-408, 1958.

RUMELHART, D. E.; MCCLELLAND, J. L. On learning the past tenses of English verbs. In: MCCLELLAND, J. L.; RUMELHART, D. E. (Eds.). **Parallel distributed processing**. Cambridge, MA: MIT Press, 1986. V.2, p. 216-271.

SANDRA, A: **Curso Introdutório de Mineração de Dados** - Compilação de Notas de Aulas, 2006, 201 páginas.

SILVA, J. D. S. **Uso de Redes neurais em visão computacional e processamento de imagens**. Disponível em: <www2.ic.uff.br/~jsilva/monografia_RNA.pdf> Acesso em 18 Jan. 2014.

SILVA, J. M. N. **Rede Hopfield e Redes Estocaticas**. Niterói: 2003 TATIBANA, C. Y.; KAETSU, D. Y. Uma introdução as Redes Neurais. Disponível em: <www.din.uem.br/ia/neurais/> Acesso em: 22 Set. 2013.

Theodoridis, S. and Koutroumbas, K. (1999). **"Pattern Recognition"**, Academic Press, USA, 1st edition.

W. S. McCulloch e W. Pitts. **A Logical Calculus of the Ideas Immanent in Nervous Activity**. Bull. Math. Biophysics, 5:115-133, 1943.