

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

**Aplicação de Mapas Auto-Organizáveis na Detecção de Mudanças no Solo ao
Longo do Tempo**

Rodrigo Luiz Mendes Mota

Itajubá, Setembro de 2014

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

Rodrigo Luiz Mendes Mota

**Aplicação de Mapas Auto-Organizáveis na Detecção de Mudanças no Solo ao
Longo do Tempo**

**Dissertação submetida ao Programa de Pós-
Graduação em Ciência e Tecnologia da Computação
como parte dos requisitos para obtenção do Título de
Mestre em Ciência e Tecnologia da Computação.**

Área de Concentração: Matemática da Computação

**Orientador: Prof. Dr. Alexandre Carlos Brandão Ramos
Co-orientador: Prof. Dr. Elcio Hideiti Shiguemori**

**Setembro de 2014
Itajubá – MG**

Ficha catalográfica elaborada pela Biblioteca Mauá
Bibliotecária Jacqueline Rodrigues de Oliveira Balducci- CRB_6/1698

M917a

Mota, Rodrigo Luiz Mendes

Aplicação de Mapas Auto-Organizáveis na Detecção de Mudanças no Solo ao Longo do Tempo. /Rodrigo Luiz Mendes Mota. Itajubá, (MG) : [s.n.], 2014.

66 p. : il.

Orientador: Prof. Dr. Alexandre Carlos Brandão Ramos.

Co-orientador: Prof. Dr. Elcio Hideiti Shiguemori.

Dissertação (Mestrado) — Universidade Federal de Itajubá.

1. Detecção de mudanças. 2. Mapas auto-organizáveis de Kohonen. 3. Sensoriamento remoto. 4. Visão computacional.
I. Ramos, Alexandre Carlos Brandão, orient. II. Shiguemori, Elcio Hideiti, co-orientador. III. Universidade Federal de Itajubá.
IV. Título.

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

Rodrigo Luiz Mendes Mota

Aplicação de Mapas Auto-Organizáveis na Detecção de Mudanças no Solo ao Longo do Tempo

Dissertação aprovada por banca examinadora em 01 de setembro de 2014, conferindo ao autor o título de **Mestre em Ciência e Tecnologia da Computação**.

Banca Examinadora:

Prof. Dr. Alexandre Carlos Brandão Ramos (Orientador)

Prof. Dr. Elcio Hideiti Shiguemori (Co-orientador)

Prof. Dr. Roberto Affonso da Costa Júnior

Prof. Dr. Felipe Leonardo Lôbo Medeiros

**Itajubá / MG
2014**

AGRADECIMENTOS

Aos meus pais, Francisco e Vera, que iluminaram os caminhos com afeto e dedicação para que eu os trilhasse sem medo e cheio de esperança pela realização dos meus sonhos.

À minha irmã Laisa pela confiança demonstrada durante todo esse período.

A minha namorada Crislaine Ferreira pelo exemplo de dedicação, compreensão e paciência em todos os momentos.

Ao meu co-orientador Elcio Shiguemori e orientador Alexandre Ramos pela oportunidade, apoio, incentivo, paciência e colaboração em todas as etapas deste trabalho.

À equipe da TR Soluções, especialmente a Paulo Steele e Joana Marins pelo apoio e compreensão em todas as etapas desse trabalho.

À Universidade Federal de Itajubá e ao Instituto de Estudos Avançados que proporcionaram todas as condições para o desenvolvimento desta pesquisa e aos amigos que fiz aqui e que puderam me auxiliar nesse trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pelo auxílio financeiro prestado.

RESUMO

Esse trabalho tem como objetivo o desenvolvimento de uma metodologia, com a implementação de técnicas de processamento de imagens, dentre elas, os mapas auto-organizáveis de Kohonen, e visão computacional, para a detecção automática de diferenças no solo utilizando imagens digitais obtidas por sensores embarcados em satélites, com uso de imagens obtidas em tempos distintos.

As áreas de estudo foram a região da Floresta Nacional de Tapajós, no Pará, devido a diversidade quanto ao uso e ocupação da terra, que vem causando aumento da área desmatada, e a região do Lago Mead, entre os Estados de Nevada e Arizona nos Estados Unidos da América, que vem sofrendo com aumento de temperaturas, redução de chuvas e problemas de abastecimento da população na região nos últimos tempos.

Foram gerados resultados para cada uma das regiões, utilizando imagens obtidas entre os anos de 2008 e 2014. Os resultados apresentados foram satisfatórios para os testes realizados com imagens da região do Lago Mead. Entretanto, os testes com as imagens da Floresta Nacional de Tapajós não foram tão bons, mas pode-se afirmar que é possível realizar a detecção de mudanças com o uso dos mapas auto-organizáveis de Kohonen de forma automática, sem a intervenção de um especialista.

Palavras-chaves: detecção de mudanças, mapas auto-organizáveis de Kohonen, sensoriamento remoto, visão computacional

ABSTRACT

This work aims to develop a methodology with techniques of image processing, among them, Kohonen self-organizing maps and computer vision, for the automatic detection of differences in soil using digital images obtained by sensors installed in satellites, based the fact that these images were taken at different times.

The study areas were the regions of the Tapajós National Forest, due to the diversity of the use or occupation of the land, which caused the increase in deforested area, and the region of Lake Mead, between the states of Nevada and Arizona in USA, which has suffered from increased temperatures, reduced rainfall and supply problems of the population in the region lately.

Results for each of the regions were generated using satellite imagery taken between the years 2008 and 2014. The results were satisfactory for tests carried out with images of the Lake Mead region, while tests with images of the Tapajós National Forest were not very good, but it can be said that it is possible to perform change detection with the use of Kohonen automatically, without the intervention of a specialist.

Keywords: change detection, self-organizing maps, remote sensing, computer vision

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

LISTA DE SÍMBOLOS

| | | |
|---------|---|----|
| 1 - | INTRODUÇÃO | 6 |
| 1.1 - | Objetivos | 9 |
| 1.2 - | Organização do Trabalho | 10 |
| 2 - | REVISÃO BIBLIOGRÁFICA..... | 11 |
| 2.1 - | Processamento de Imagens..... | 11 |
| 2.2 - | Detecção de Mudanças em Imagens..... | 12 |
| 2.3 - | Mapas Auto-Organizáveis de Kohonen em Processamento de Imagens..... | 14 |
| 3 - | FUNDAMENTAÇÃO TEÓRICA | 17 |
| 3.1 - | Processamento de Imagens..... | 17 |
| 3.1.1 - | Classificação de Imagens Digitais..... | 18 |
| 3.1.2 - | Modelos de Classificação de Imagens | 18 |
| 3.1.3 - | Extração de Características das Imagens | 19 |
| 3.2 - | Redes Neurais Artificiais | 25 |
| 3.2.1 - | Mapas Auto-Organizáveis de Kohonen..... | 27 |
| 4 - | ESTUDO DE CASO | 34 |
| 4.1 - | Floresta Nacional de Tapajós | 34 |
| 4.2 - | Lago Mead..... | 35 |
| 4.3 - | Origem das Imagens..... | 36 |
| 5 - | METODOLOGIA | 38 |
| 6 - | EXPERIMENTOS E RESULTADOS | 42 |
| 6.1 - | Floresta Nacional de Tapajós | 42 |
| 6.2 - | Lago Mead..... | 47 |
| 7 - | CONCLUSÃO | 52 |
| 7.1 - | Conclusões..... | 52 |
| 7.2 - | Trabalhos Futuros | 53 |
| 7.3 - | Trabalhos Publicados | 54 |
| 8 - | REFERÊNCIAS BIBLIOGRÁFICAS | 55 |

LISTA DE FIGURAS

| | |
|--|----|
| Figura 3.1 - Passos do processamento de imagens digitais | 18 |
| Figura 3.2 - Esquema simplificado de um mapa sequencial, com as entradas, camada intermediária e as saídas. | 27 |
| Figura 3.3 - Esquema simplificado de um mapa sequencial. | 28 |
| Figura 3.4 - Esquema simplificado de um mapa bidimensional..... | 29 |
| Figura 4.1 - Localização da Floresta Nacional de Tapajós nas imagens dos sensores: (a) MODIS/TERRA e (b) ETM+/Landsat. | 34 |
| Figura 4.2 – Lago Mead visto da barragem da represa Hoover. | 36 |
| Figura 4.3 – Exemplos de imagens Tm/Landsat 5 da região da Floresta Nacional de Tapajós: (a) Imagem obtida em 23 de junho de 2008 e (b) Imagem obtida em 12 de julho de 2009. | 37 |
| Figura 5.1 – Esquema (diagrama de atividades) do algoritmo proposto nesse trabalho..... | 39 |
| Figura 6.1 – Imagem da região da Floresta Nacional de Tapajós. | 43 |
| Figura 6.2 – (a) e (b) são seções da Figura 6.1 e (c) é o gabarito de mudanças..... | 43 |
| Figura 6.3 – (a) e (b) são seções da Figura 6.1. | 45 |
| Figura 6.4 – Imagem da região do Lago Mead..... | 47 |
| Figura 6.5 – (a) e (b) são seções da Figura 6.4 e (c) é o gabarito de mudanças..... | 47 |
| Figura 6.6 – (a) e (b) são seções da Figura 6.4 e (c) é o gabarito de mudanças..... | 50 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 6.1 – Parâmetros da classificação da Figura 6.2..... | 43 |
| Tabela 6.2 – Resultados da classificação da Figura 6.2 | 44 |
| Tabela 6.3 – Parâmetros da classificação da Figura 6.3..... | 45 |
| Tabela 6.4 – Resultados da classificação da Figura 6.3 | 46 |
| Tabela 6.5 – Parâmetros da classificação da Figura 6.5..... | 48 |
| Tabela 6.6 – Resultados da classificação da Figura 6.5 | 48 |
| Tabela 6.7 – Parâmetros da classificação da Figura 6.6..... | 50 |
| Tabela 6.8 – Resultados da classificação da Figura 6.6 | 50 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|------|---|
| RNA | - Rede Neural Artificial |
| SVM | - <i>Support Vector Machine</i> |
| MLP | - <i>Multi-Layer Perceptron</i> |
| TM | - <i>Thematic Mapper</i> |
| FNT | - Floresta Nacional de Tapajós |
| HSV | - <i>Hue Saturation Value</i> |
| GLCM | - <i>Grey Level Co-occurrence Matrix</i> |
| RGB | - <i>Red Green Blue</i> |
| VANT | - Veículo Aéreo Não Tripulado |
| SNR | - <i>Signal-to-Noise Ratio</i> |
| SOM | - <i>Self Organizing Maps</i> |
| SAR | - <i>Synthetic Aperture Radar</i> |
| INPE | - Instituto Nacional de Pesquisas Espaciais |
| VP | - Verdadeiro Positivo |
| FN | - Falso Negativo |
| FP | - Falso Positivo |

LISTA DE SÍMBOLOS

- $f(x)$ - Sinal para detecção da borda.
- $G(x)$ - Resposta do filtro como borda.
- $n(x)$ - Ruído na detecção da borda.
- σ_n^2 - Amplitude quadrática média do ruído.
- X_{\max} - Distância média entre os máximos adjacentes e a resposta do ruído de $f(x)$.
- $G(x, y)$ - Aproximação do filtro de Canny.
- $P(x)$ - Frequência de ocorrência dos tons de cinza
- \underline{x} - Espaço de entrada.
- \underline{w}_j - Vetor de pesos sinápticos do neurônio j .
- $\underline{w}_j^T \underline{x}$ - Produtos internos do vetor de pesos sinápticos do neurônio j .
- $i(\underline{x})$ - Índice do neurônio que mais se aproxima do vetor de entrada.
- $h_{j,i}$ - Vizinhança topológica centrada no neurônio vencedor i .
- $d_{i,j}$ - Distância entre o neurônio vencedor i e o neurônio excitado j .
- $\sigma(n)$ - Tamanho da vizinhança topológica.
- $\Delta \underline{w}_j$ - Mudança no vetor de pesos sinápticos do neurônio j .
- η - Taxa de aprendizagem.
- n - Número da iteração.
- T_1, T_2 - Constantes de tempo

1 - INTRODUÇÃO

O uso de imagens digitais obtidas por sensores embarcados em satélites para a classificação é uma ferramenta de sensoriamento remoto prática e de fácil análise (HELLER e ULLIMAN, 1983). Assim, a aplicação desta técnica de sensoriamento remoto vem se tornando importante, juntamente com a quantidade de imagens geradas através do uso de satélites, que é uma grande fornecedora de dados sobre inúmeros aspectos que ocorrem na superfície terrestre.

Uma das dificuldades existentes é a extração automática de informações presentes nessas imagens para a caracterização do uso do solo, como áreas de agricultura, florestas, pastagens, áreas urbanas, solo exposto e água. Com essa caracterização, pode-se realizar estudos e monitoramento de áreas, como a invasão de áreas de pastagens e agricultura sobre a floresta, fenômeno que ocorre frequentemente na região amazônica (XAUD, EPIPHANIO e XAUD, 2011). A identificação automática dessas informações é de grande importância, pois pode-se processar uma grande quantidade de imagens digitais sem a necessidade de usuário, e as técnicas que vêm sendo aplicadas para extração de características são as Redes Neurais Artificiais (RNAs) (TAHIR, 2012).

As RNAs têm se mostrado eficientes na identificação automática de características, uma vez que seu estudo foi motivado desde o início pelo reconhecimento que o cérebro é capaz, com a capacidade de organizar suas estruturas, ou seja, seus neurônios, para a realização de certas computações (HAYKIN, 2001). Várias características do cérebro são reproduzidas pelas RNAs, principalmente na busca de adaptá-las na forma de adquirir a capacidade de interagir com o meio externo para desenvolver formas de obter conhecimento e aprendizado, e com isso, realizar reconhecimento e classificação de padrões, que consiste na identificação de características semelhantes em padrões num conjunto de dados (DUDA, HART e STORK, 2012).

As técnicas usadas para a classificação de padrões podem ser supervisionadas ou não supervisionadas. As supervisionadas, como os classificadores de múltiplas camadas, necessitam da apresentação da entrada e saída desejada, requerem pouca computação na ativação, e devem ser previamente

treinados com dados do passado, o que caracteriza que seus resultados não podem ser facilmente generalizados para o futuro (LEE; BOOTH e ALAM, 2005); e as técnicas não supervisionadas, que não necessitam de apresentação da saída desejada, como os mapas auto-organizáveis de Kohonen (LIPPMANN, 1989).

A técnica dos mapas auto-organizáveis, desenvolvida por KOHONEN (2000), tem, além da classificação de padrões, outras aplicações como modelagem, processamento e reconhecimento de padrões em áudios (BRÜCKNER e WESARG, 2002); em aplicações que requerem o agrupamento de classes semelhantes presentes em imagens (KIANG, 2001) e segmentação de imagens, que é subdividir as imagens seguindo um determinado critério (HUANG, CHEN e HSU, 2002). Alguns exemplos mais específicos podem ser vistos no trabalho de SHIGUEMORI *et al.* (2007), que aborda o reconhecimento de pontos de referência em imagens aéreas como campos de futebol e passarelas; o agrupamento em imagens aéreas baseando-se em características similares realizado no trabalho de MOTA *et al.* (2014) e na classificação de imagens aéreas, visto em IWASHITA *et al.* (2012), utilizando as relações entre o solo, o relevo e a hidrologia para gerar um mapa de condutividade hidráulica e textura do solo.

Com a classificação de padrões, é possível realizar a detecção de mudanças em imagens, que é o processo de identificação de diferenças em um estado de um objeto ou fenômeno pela observação deles em diferentes tempos, envolvendo a aplicação de conjuntos multitemporais para a análise de efeitos temporais de certos fenômenos (SINGH, 1989). São diversas as finalidades de detecção de mudanças, como visto no trabalho de Su *et al.* (2011) que foca a detecção automática de tumores em seios em imagens de ultrassom, diagnosticando entre malignos e benignos, bem como nos demais trabalhos a seguir, que detectam mudanças em imagens de satélite para sensoriamento remoto, para analisar as mudanças de uso e cobertura do solo. Como primeiro exemplo de trabalho com essas análises, tem-se o trabalho de Guorui *et al.* (2004) que utiliza Máquina de Vetores de Suporte (SVM) para detecção de mudanças no Palácio Presidencial Iraquiano com imagens obtidas em 2002 e 2003. Outro trabalho nessa área é o de Frate *et al.* (2004) que mostra a detecção de mudanças em regiões urbanas, onde as imagens, com diferenças de um ano, tiveram classes classificadas em construções, asfalto, áreas verdes e solo cru, com uso da Rede Neural Perceptron de Múltiplas Camadas (MLP, do inglês

Multi-Layer Perceptron) e para obter as mudanças, as classes observadas no algoritmo foram comparadas entre si. Continuando na área, o trabalho de Aguirre-Gutiérrez, Seijmonsbergen e Duivenvoorden (2012) reforça que o uso de imagens de satélites e a classificação dos tipos do terreno, utilizando dos métodos da máxima verossimilhança e dos vizinhos mais próximos, fazem uma boa combinação para a detecção de mudanças, que utiliza imagens TM/Landsat ETM obtidas nas regiões montanhosas do México entre 1999 e 2006.

A aplicação de técnicas para estudos sobre a superfície terrestre converge com a quantidade de informações geradas através de imagens obtidas por satélites e correspondem a diversos fenômenos que ocorrem na superfície terrestre. Diversos trabalhos vêm lidando com esse tipo de informação, tratando com várias técnicas e realizando testes com imagens obtidas por diferentes satélites em diferentes regiões, como é possível mostrar nos seguintes trabalhos: a utilização de imagens em infravermelho para a detecção de fumaça e focos de incêndio tanto nos Estados Unidos quanto no Brasil, ressaltando que a variação do espectro eletromagnético dos sensores pode facilitar essa detecção (FRANÇA e FERREIRA, 2005); a utilização de imagens TM/Landsat 5 do sudeste de Roraima, de 1994 a 2009, para classificação do uso e cobertura do solo, que ainda resalta a importância do estudo do dinamismo do uso da terra nessas áreas devido à ocupação na região amazônica (XAUD *et al.*, 2011); o trabalho de Aguirre-Gutiérrez, Seijmonsbergen e Duivenvoorden (2012) que usa imagens TM/Landsat ETM obtidas em 1999 e 2007 para classificação de terreno e detecção de mudanças em uma região montanhosa no estado de Chihuahua, no norte mexicano.

No entanto, a maioria destas classificações é feita de forma manual ou tem parte da classificação feita manualmente, como em (XAUD *et al.*, 2011) onde foram necessários diversos testes para obtenção de um limiar adequado ao problema, e em (GUORUI *et al.*, 2004) onde foram selecionadas manualmente diversas imagens para treinamento do algoritmo. Além desses trabalhos, outros possuem resultados limitados em situações específicas, como em (AGUIRRE-GUTIÉRREZ; SEIJMONSBERGEN e DUIVENVOORDEN, 2012) que obteve classificações pouco eficientes em algumas classes e em (FRATE *et al.*, 2004) que apenas distingue as construções feitas em solo sem vegetação. As classificações usando técnicas estatísticas, como agrupamentos e análises de componentes principais, comparadas

às classificações realizadas pelos mapas auto-organizáveis de Kohonen, revelam que, na maioria das vezes, conseguem fornecer respostas mais específicas e de melhor qualidade (ASTEL *et al.*, 2007). Além disso, a capacidade de generalização das redes neurais artificiais é indicada para a identificação de características no solo (HEWITSON e CRANE, 2002). Outras vantagens do mapa auto-organizável de Kohonen são: sua grande eficiência em lidar com grandes conjuntos de dados; sua robustez ao lidar com conjunto de dados que possuam ruídos; representação intuitiva de modelos abstratos; e dispensa um treinamento prévio para a execução da rede, diferentemente de redes supervisionadas (MANGIAMELI, 1996).

O presente trabalho parte da hipótese que com a implementação de técnicas de processamento de imagens, o uso de mapas auto-organizáveis de Kohonen e visão computacional, é possível realizar o agrupamento de características das imagens digitais obtidas por sensores embarcados em satélites e, conseqüentemente, a detecção de mudanças no solo.

1.1 - Objetivos

A seguinte dissertação de mestrado tem como objetivo geral propor técnicas que sejam capazes de indicar, automaticamente, diferenças no solo em regiões de características distintas entre imagens obtidas da mesma região em tempos diferentes, e tem como objetivo específico a implementação de técnicas de processamento de imagens e visão computacional para que seja possível essa identificação de mudanças no solo.

As imagens em estudo são focadas em regiões com características diferentes. O primeiro caso aborda a Floresta Nacional do Tapajós (FNT), localizada no norte do Estado do Pará e foi escolhida por apresentar uma grande diversidade quanto ao uso e ocupação da terra (ESCADA *et al.*, 2009), ou seja, devido a existência de um conjunto rico de dados. O segundo caso aborda a região do Lago Mead, entre os Estados de Nevada e Arizona nos Estados Unidos da América, que vem sofrendo nos últimos anos com as mudanças climáticas e forma de uso de sua água e que vem reduzindo o tamanho de seu reservatório (BARNETT e PIERCE, 2008).

Para este trabalho, o mapa auto-organizável de Kohonen foi escolhido como técnica de classificação de imagens por ter sido aplicado com eficiência em problemas de classificação, como em Mota *et al.* (2014), e diferentemente de métodos supervisionados, onde é necessário o conhecimento da saída, e métodos estatísticos (ASTEL *et al.*, 2007) devido à sua natureza iterativa, e porque os resultados são menos dependentes dos dados em conformidade com uma distribuição específica e ainda sem a necessidade de treinar a rede para uma posterior classificação dos dados, que leva a um tempo de classificação maior (HEWITSON e CRANE, 2002).

1.2 - Organização do Trabalho

Esta dissertação está organizada em seis Capítulos. A revisão bibliográfica onde são apresentados demais trabalhos relacionados à identificação de mudanças no solo se encontra no Capítulo 2. No Capítulo 3 são descritos o processamento de imagens, as redes neurais artificiais, a detecção de bordas e o método para análise de texturas. No Capítulo 4, são abordados os estudos de caso desse trabalho. No Capítulo 5 são exibidas as metodologias para a elaboração desse trabalho. No Capítulo 6 são exibidos os resultados obtidos com a aplicação da metodologia proposta. No Capítulo 7 são apresentadas as conclusões, contribuições e trabalhos futuros.

2 - REVISÃO BIBLIOGRÁFICA

Neste Capítulo são abordados os diferentes temas envolvidos na pesquisa. Inicialmente são apresentados alguns trabalhos relacionados ao processamento de imagens, como textura, detecção de bordas, reconhecimento de padrões, entre outras técnicas. Posteriormente, o histórico de detecção de mudanças em imagens, assim como sua definição e resultados obtidos em outras pesquisas. Em seguida, são apresentados os parâmetros utilizados dessas imagens para fazer detecção de mudanças. Por fim, são apresentados trabalhos que utilizam os mapas auto-organizáveis de Kohonen em imagens, bem como seus resultados.

2.1 - Processamento de Imagens

Existem diferentes técnicas de processamento de imagens e visão computacional que podem englobar a detecção de objetos, reconhecimento de padrões e pontos de interesse, detecção de bordas e detecção de mudanças, entre outras técnicas. Nessa seção são mostrados alguns trabalhos relacionados a essa área.

Uma das técnicas consiste no reconhecimento de pontos de interesse (RODRIGUES *et al.*, 2009), que utiliza o sistema de cor HSV, que possui uma maneira intuitiva de especificar uma cor e a separação do componente de brilho da informação de cor, e é considerado mais apropriado para aplicações de processamento de imagens em relação ao RGB (FORD e ROBERTS, 1998). Utiliza também a matriz de coocorrência de nível de cinza (GLCM) para a extração de características de textura nas imagens. O GLCM mostra a relação entre *pixels* e sua vizinhança dada a distância entre os *pixels* e a orientação, e de acordo com isso, pode-se obter dados como energia, entropia, contraste entre outros. Estudos comprovam que a textura melhora a precisão da classificação (HARALICK; SHANMUGAM e DINSTEIN, 1973). O trabalho de Yang, Beitler e Yu (2012) recomenda o uso de características não-correlacionadas de textura, com extração de no máximo cinco informações: homogeneidade, aleatoriedade, heterogeneidade,

suavidade e simetria, para evitar resultados inconsistentes no uso dessas informações. Em outro afirma-se que a textura também é uma das técnicas de análise de imagem que pode ser utilizada para a extração de informação estrutural de florestas em uma imagem digital (WULDER, 1998).

Com o reconhecimento de padrões, se torna possível a detecção de objetos. Isso pode ser observado no trabalho de detecção de construções a partir de imagens aéreas (PERSSON, SANDVALL e DUCKETT, 2005). Nele se ressalta a dificuldade da extração de características das imagens, principalmente em construções, e as imagens aéreas podem trazer complicações ao desenvolvimento do algoritmo para fazer a detecção e classificação dos dados. Essas complicações são devidas à qualidade da imagem, condições de luminosidade, resolução, orientação, condições de tempo e estações do ano. No trabalho ressalta-se também a importância de não se utilizar os dados RGB da imagem, pois como essas imagens sofrem com condições de luminosidade, que afeta todos os três parâmetros do RGB, diferentemente do HSV. O trabalho de Wang e Suter (2003) ressalta também esse ponto salientando que o HSV não sofre variância a condições ambientais, e que o H, que representa a matiz, é invariante à luminosidade e a sombras.

Outro trabalho que lida com processamento de imagens trata da solução de problemas de detecção de bordas em imagens (SUJATHA e SELVATHI, 2012) que mostra diversos trabalhos na bibliografia de detecção de bordas e faz uma comparação entre eles. Como a borda pode ser mais um parâmetro nesse trabalho, (SUJATHA e SELVATHI, 2012) compara os métodos entre si e ressalta que o método Sobel é ineficiente, o método Gabor, apesar de possuir boa precisão e confiabilidade, é lento e por fim, o método Canny (1986) possui boa performance e seria a melhor opção a ser usada nesse trabalho.

2.2 - Detecção de Mudanças em Imagens

Detecção de mudanças em múltiplas imagens do mesmo cenário obtidas em tempos diferentes é um problema que tem tido grande interesse devido à variedade de aplicações, principalmente em sensoriamento remoto, segurança e diagnósticos

médicos. Diversas propostas têm sido apresentadas e nelas tentam se comparar *pixels* ou características obtidas nessas imagens (MA; LI; GU, 2011), onde também é apresentada uma proposta que utiliza informações espectrais (informações sobre as cores dos pixels) e estruturais (textura, bordas) como entropia (que representa o grau de dispersão dos níveis de cinza de uma imagem (HARALICK; SHANMUGAM e DINSTEN, 1973)), contraste, movimento angular (que representa a homogeneidade da imagem), nível de brilho, média, desvio-padrão e razão em uma biblioteca de características para detectar mudanças, obtendo resultados satisfatórios na detecção de mudanças.

Mais um outro trabalho focado em mudanças, mas com aplicação em uma área totalmente distinta, a área de segurança, Gromek e Jenerowicz (2011) utiliza regiões de interesse de imagens aéreas diferentes, obtidas através de satélite, da mesma região e inicialmente, faz um tratamento nas imagens utilizando filtros para reduzir ruídos. Posteriormente, forma um vetor de atributos dessas regiões de interesse, contendo, por exemplo, tamanho, refletância, coeficiente de formas e esses vetores são comparados para se detectar as mudanças, com o foco de detectar imigração ilegal no monitoramento de fronteiras, onde apresentou ser insuficiente para esse tipo de monitoramento.

Mais um trabalho na área envolve a detecção de mudanças (GUORUI *et al.*, 2004), mas com a realização da detecção através de um SVM, onde os vetores são mapeamentos feitos em espaço de características de dimensão elevada por meio de um mapeamento não linear que aumenta a separação entre regiões com e sem mudanças. Uma mudança é notável quando a distância medida é maior que o limiar de detecção dado. As mudanças foram detectadas em amostras de imagens do palácio presidencial iraquiano e atingiram 96% de sucesso em algumas amostras, mas que tiveram bastante trabalho manual no treinamento da rede.

Considerando o objetivo desse trabalho que é a detecção de mudanças em imagens aéreas, o trabalho de Frate *et al.* (2004) mostra a detecção de mudanças em regiões urbanas. Nele, as imagens de áreas urbanas foram base do trabalho onde cada classe poderia ser caracterizada como ruas, solo e áreas verdes. A classificação dessas imagens foi feita inicialmente através de um MLP que é uma rede neural supervisionada, onde o vetor de entrada continha a refletância extraída em quatro canais da imagem e o vetor de saída continha as correspondentes

classes. Posteriormente foi feita uma classificação apenas para as ruas, para separar as diferentes categorias de asfalto. Foi criada uma camada bidimensional de neurônios de saída e unidimensional para entrada, utilizando também a refletância como parâmetro de entrada. Para realizar a detecção de mudanças, foram utilizadas imagens com diferenças de um ano entre elas, e feita a comparação entre as classes observadas no algoritmo de classificação supervisionada, onde foi possível diferenciar as construções dos demais componentes da imagem.

Considerando também que esse trabalho utiliza imagens de regiões não urbanas, o trabalho de Aguirre-Gutiérrez, Seijmonsbergen e Duivenvoorden (2012) usa imagens TM/Landsat ETM para classificação de terreno, utilizando o método da máxima verossimilhança, que leva em conta a variância e covariância de suas características para atribuir um dado pixel a uma determinada classe, e método dos vizinhos mais próximos com o uso de informações estruturais e espectrais da imagem, e detecção de mudanças, baseado em regras de conhecimento, em uma região montanhosa no norte mexicano, onde obteve-se 77% de sucesso, que é atribuído a um processo de treinamento supervisionado e determinação de um limiar de forma arbitrária.

2.3 - Mapas Auto-Organizáveis de Kohonen em Processamento de Imagens

O processamento de imagens é frequentemente utilizado como classificação não supervisionada, como métodos de agrupamento. Esses métodos examinam os *pixels* em uma imagem e os incorporam em um conjunto de classes através do agrupamento desses *pixels*, por exemplo, para realizar agrupamento de classes com características similares entre si. A premissa inicial é que os *pixels* que pertencem à mesma classe possuam atributos similares (GONÇALVES *et al.*, 2008). Como os mapas auto-organizáveis de Kohonen se tratam de um método não supervisionado, são exibidos aqui alguns trabalhos que ilustram o uso desse método.

Os mapas auto-organizáveis de Kohonen também podem ser utilizados na área médica como visto em Su *et al.* (2011) para a detecção e classificação de tumores nos seios. A imagem, que é obtida através de ultrassom, após ser tratada

com redução de ruídos e melhoria de contraste, têm seus atributos obtidos através de parâmetros de textura da imagem, como entropia, desvio-padrão, suavidade, uniformidade, média, contraste, energia e correlação, e assim podendo detectar a ocorrência de tumores, através da segmentação das imagens. Para se verificar a classificação desses tumores em malignos ou benignos, é utilizada a propagação de afinidade após a imagem ser processada pelos mapas auto-organizáveis de Kohonen.

Também utilizando-se de imagens aéreas, tem-se o exemplo visto em Iwashita *et al.* (2012), onde foram necessários estudos para estimar os processos de intemperismo do solo, e neles foram utilizadas as relações entre o solo, o relevo e a hidrologia. Essas relações entram como variáveis nos mapas auto-organizáveis de Kohonen, onde é calculado um coeficiente de correlação entre elas. Posteriormente esse número, junto com as características topográficas, geram um mapa de condutividade hidráulica e textura do solo.

Coincidindo mais com a pesquisa proposta aqui, segue o trabalho de Shiguemori *et al.* (2007), que aborda o reconhecimento de pontos de referência usando os mapas auto-organizáveis de Kohonen e uma rede neural MLP e que foram utilizados para reconhecer referências em imagens aéreas. Foi utilizado um detector de bordas, linhas e cantos (função de Gabor), e os dados resultantes dessa função foram atributos da camada de entrada das redes neurais. O trabalho salienta a dificuldade que sistemas de reconhecimento têm em diferenciar a resolução, rotação e translação entre as imagens de referência e as imagens aéreas. Nos resultados, a rede neural MLP foi considerada melhor.

Se utilizando agora de imagens obtidas através de VANTs (Veículos Aéreos Não-Tripulados), os trabalhos de Mota *et al.* (2014) e Felizardo *et al.* (2013) mostram que é possível realizar agrupamentos nas imagens se baseando em características similares encontradas, mostrando que é possível realizar a identificação de falhas em linhas de transmissão de energia.

Já o trabalho de Persson, Sandvall e Duckett (2005) ressalta a dificuldade em se fazer a detecção de mudanças através de imagens, pois podem se diferenciar em resolução, tipo de sensor, orientação, qualidade, alcance, condições de luminosidade em diferentes tempos e estações, com construções podem obstruir

umas às outras. Para a detecção de construções pode-se utilizar: a detecção de bordas; filtros, que removem os pequenos objetos e a baixa vegetação; textura; e brilho. Em seu algoritmo são utilizadas a extração de linhas, a detecção de cantos e detecção de retângulos em um mapa auto-organizável.

Com base nos trabalhos apresentados nessa seção, é possível abordar o uso de mapas auto-organizáveis focando a detecção de mudanças, desde que sejam utilizados atributos das imagens, como bordas, informações de textura e dados de HSV.

3 - FUNDAMENTAÇÃO TEÓRICA

3.1 - Processamento de Imagens

Segundo Gonzales e Woods (2000) o processamento de imagens consiste basicamente na realização de cinco etapas (Veja Figura 2.1):

- Aquisição da imagem, onde se têm dois elementos necessários para a aquisição dessas imagens: um dispositivo que seja sensível a uma banda de energia eletromagnética e um dispositivo digitalizador, para a conversão para forma digital;
- Pré-processamento: tem a função de melhorar a imagem, buscando aumentar as chances de sucesso para os processos seguintes. Envolve técnicas de realce de contraste, remoção de ruído e isolamento de regiões;
- A segmentação divide uma imagem de entrada em partes ou objetos constituintes. É um dos processos automáticos mais difíceis no processamento de imagens. A saída desta etapa é normalmente um conjunto de dados em forma de *pixels*, correspondendo a fronteira de uma região ou a seus pontos constituintes;
- Representação e descrição: nesta etapa do processamento os dados são transformados de maneira adequada para o processamento computacional que se segue, sendo enfatizadas características de interesse. O processo de descrição é também chamado de seleção de características, onde características extraídas representam informações quantitativas de interesse ou que sejam fundamentais na descrição de classes e objetos; e
- O reconhecimento é o processo que atribui um rótulo a um objeto e a interpretação envolve a atribuição do significado a um conjunto de objetos reconhecidos.

Na Figura 3.1 pode-se observar ainda a presença de uma base de conhecimento que interage com os módulos de processamento, onde está o conhecimento sobre o domínio do problema.

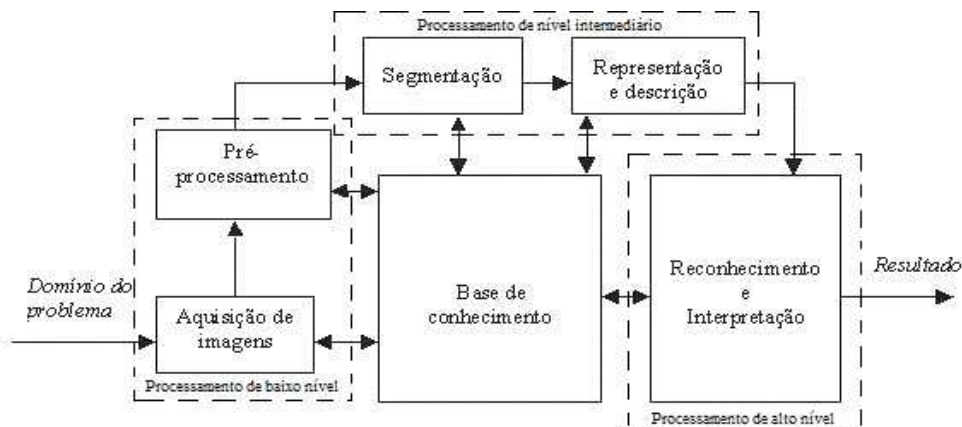


Figura 3.1 - Passos do processamento de imagens digitais
 Fonte: Gonzales e Woods, 2000.

3.1.1 - Classificação de Imagens Digitais

A análise de imagens consiste num processo de descobrimento, identificação e reconhecimento dos padrões que sejam relevantes para uma dada aplicação (GONZALES e WOODS, 2000). As técnicas de análise de imagem se subdividem em três áreas: processamento de baixo nível; nível intermediário; e alto nível. O processamento de baixo nível lida com as funções que podem ser vistas como reações automáticas, que não requer qualquer inteligência para a classificação. Já no processamento de nível intermediário, é tratada a extração e caracterização das regiões em uma imagem resultante do processo de baixo nível. E por fim, o processamento de alto nível, que envolve o reconhecimento e a interpretação.

A classificação é o processo pelo qual um objeto, pertencente a um conjunto de dados, é atribuído a uma classe, definida dentro de um conjunto de classes, de acordo com a similaridade de suas características. Para imagens digitais, a similaridade é verificada nos padrões espectrais, e a classificação pode ser realizada por vários modelos: heurísticos, estatísticos, neurais, entre outros.

3.1.2 - Modelos de Classificação de Imagens

Os principais modelos de classificação de imagens podem ser supervisionados ou não supervisionados (KÖRTING, 2006):

- Classificação supervisionada: o usuário seleciona amostras representativas para cada uma das classes, o classificador é treinado, tornando possível a localização dos demais *pixels* pertencentes às classes pré-definidas;
- Classificação não-supervisionada: nessa classificação, cada *pixel* da imagem é associado a uma classe espectral sem que se tenha um conhecimento prévio do número das diferentes classes existentes na imagem, e uma maneira de atingir esse objetivo é pelo uso de algoritmos de agrupamento, os quais são utilizados nesse trabalho.

De uma maneira geral, os classificadores podem ser divididos em classificadores "*pixel a pixel*" ou classificadores por região (KÖRTING, 2006). Classificadores "*pixel a pixel*" utilizam apenas a informação espectral, isoladamente, de cada pixel para encontrar regiões homogêneas. Os classificadores por regiões utilizam, além de informação espectral de cada pixel, a informação espacial que envolve a relação entre os *pixels* e seus vizinhos.

3.1.3 - Extração de Características das Imagens

Na extração de características de imagens pode-se obter atributos para o reconhecimento de objetos em uma imagem, bem como, servir de base para um melhor processamento da imagem (GONZALES e WOODS, 2000). Nessa seção são exibidos alguns métodos para extração de características da imagem que serão utilizados nesse trabalho.

3.1.3.1 - Detecção de Bordas

As bordas caracterizam limites e são áreas com contrastes fortes da intensidade com um salto na intensidade de um pixel ao seguinte. As bordas detectadas em uma imagem podem reduzir significativamente a quantidade de dados, removendo a informação inútil e preservando as propriedades estruturais importantes da imagem. É usada em diversas aplicações do processamento de imagens para obter informações, como uma etapa à extração de característica e a segmentação de objetos (FISHER *et al.*, 2004).

Existem diversos filtros para detecção de bordas, como o Gabor (MEHROTRA, NAMUDURI e RANGANATHAN, 1992), Sobel (1978) e Canny (1986), e nesse trabalho é utilizado o filtro de Canny devido a sua melhor performance em relação aos outros, explicado em Sujatha e Selvathi (2012).

O detector de bordas Canny (1986) é um operador gaussiano de primeira derivada que suaviza os ruídos e localiza as bordas. Para o algoritmo Canny foram considerados três principais pontos:

- **Boa detecção:** o detector de bordas deve ter baixa probabilidade de falhar na detecção das bordas e baixa probabilidade de marcar *pixels* fora das bordas;
- **Boa localização:** a distância entre os *pixels* da borda encontrados pelo detector de bordas e a borda verdadeira deve ser a menor possível; e
- **Única resposta:** minimizar o número de bordas. O detector de bordas não pode identificar múltiplas bordas aonde existe somente uma.

Com esses pontos observados, é possível transformá-los em um formalismo matemático. Iniciou-se com a análise do comportamento dos pontos em uma dimensão, considerando a razão entre sinal e ruído. Para o sinal, considera-se $f(x)$ e a resposta do filtro uma borda $G(x)$. A resposta do filtro a essa borda, com centro em H_G é dada por uma integral de convolução, obtida em CANNY (1986):

$$H_G = \int_{-w}^w G(-x)f(x)dx \quad (3.1)$$

Sendo que o filtro tem uma resposta de pulso limitada por $[-w, w]$ e zero fora desse intervalo. Para o ruído $n(x)$ considerar a raiz quadrada de sua resposta:

$$H_n = n_0 \sqrt{\int_{-w}^w f^2(x)dx} \quad (3.2)$$

Sendo n_0^2 a amplitude quadrática média do ruído por unidade de comprimento. Portanto, o primeiro ponto pode ser formalizado como a razão entre essas duas respostas, a relação sinal-ruído (SNR, do inglês *signal-to-noise ratio*).

$$SNR = \frac{|\int_{-w}^w G(-x)f(x)dx|}{n_0 \sqrt{\int_{-w}^w f^2(x)dx}} \quad (3.3)$$

Para o segundo ponto, foi considerada a necessidade de uma medida que cresce à medida que a localização melhor e, para isso, usou a inversa da distância da raiz da média quadrática. A marcação de bordas acontece em máximos locais da resposta do operador $f(x)$, ou seja, onde $f'(x)$ seja nulo.

Canny (1986) demonstrou que usando os dois primeiros aspectos, o detector produz um resultado truncado, semelhante a usar um filtro por diferença de caixas. Esse tipo de filtro tende a produzir muitos máximos locais, os quais deveriam ser considerados errados, de acordo com o primeiro ponto observado. A distância média entre os máximos adjacentes e a resposta do ruído de $f(x)$, denominada X_{max} restringe a escolha de $f(x)$ de acordo com o terceiro ponto observado:

$$X_{max}[f(x)] = kW \quad (3.4)$$

Onde k é uma fração de um coeficiente definido e W a largura do operador. Uma variante foi desenvolvida permitindo a determinação de bordas. Para valores pequenos de X_{max} , o operador de Canny se aproxima da ação do filtro por diferença de caixas. Para grandes valores de X_{max} , ele se aproxima da ação de um filtro do tipo primeira derivada da Gaussiana, onde a Gaussiana é dada abaixo:

$$G(x, y) = \sigma^2 \exp - \left(\frac{x^2 + y^2}{2\sigma^2} \right) \quad (3.5)$$

Portanto, a aproximação do filtro de Canny para a detecção de bordas é a primeira derivada da função Gaussiana, obtido através da convolução da imagem de entrada. A imagem de saída desse processo terá suas bordas realçadas, independente da presença de ruídos na imagem.

3.1.3.2 - Análise de texturas

A textura é definida como uma combinação entre magnitude e frequência da variação tonal em uma imagem, sendo esta produzida pelo efeito conjunto de todas as pequenas feições que compõem uma área particular na imagem. Embora possam ser consideradas como propriedades independentes, tonalidade e textura, na realidade, possuem relações íntimas. Sem variações na tonalidade, nenhuma mudança em textura pode ser percebida (CROSTA, 1993). A textura está ligada à tonalidade e, em determinadas circunstâncias, uma pode dominar a outra. Esta

relação pode ser entendida da seguinte forma: quando uma área pequena de uma imagem tem pouca variação dos níveis de cinza, a propriedade dominante é a textura (HARALICK, SHANMUGAM e DINSTEIN, 1973).

A textura constitui uma característica importante em análises de diversos tipos de imagens, desde aquelas obtidas de equipamentos multiespectrais através de aeronaves ou satélites até imagens de culturas de células ou amostras de tecidos com aplicação na área médica (HARALICK, 1979).

Na área de sensoriamento remoto, a textura é considerada um elemento importante usado em interpretação visual de imagens. Em análises visuais, a textura refere-se ao padrão aparente de uma determinada área, descrita pelas características lisa, rugosa e grossa. Em análises digitais, a textura reflete o padrão espacial ou frequência de variação de tons em uma determinada área, produzida por uma associação de feições pequenas demais para serem identificadas individualmente, mas que permitem a identificação e a delimitação de áreas com propriedades superficiais. Além disso, a textura contém informações importantes sobre o arranjo estrutural das superfícies e o ambiente que as circunda, ou seja, a informação contextual da área analisada (HARALICK, SHANMUGAM e DINSTEIN, 1973).

Sendo a textura uma característica importante na interpretação visual de imagens, sua utilização pode melhorar o desempenho de classificadores digitais, principalmente em imagens com alta resolução espacial (ULABY, MOORE e FUNG, 1986).

As abordagens estatísticas de Haralick, Shanmugam e Dinstein (1973) fazem uso das funções densidade de probabilidade de tons de cinza, que geralmente são calculadas como distribuições conjuntas de probabilidade condicionada dos tons de cinza de pares de *pixels* em uma dada área da imagem.

Mais especificamente, sob o aspecto metodológico, este trabalho abordará o procedimento originalmente desenvolvido por (HARALICK, SHANMUGAM e DINSTEIN, 1973), denominado método matriz de co-ocorrência dos níveis de cinza, o GLCM.

O método GLCM fornece as probabilidades condicionais conjuntas de todas as possíveis combinações de pares de *pixels* para uma dada janela de uma imagem

W_{nm} (HARALICK, SHANMUGAM e DINSTEIN, 1973). A co-ocorrência dos tons de cinza representa a probabilidade de que quaisquer dois pares de tons de cinza ocorram, condicionada à distância entre *pixels* β e à orientação δ utilizadas no cálculo computacional. Algebricamente, pode-se expressar por

$$Pr(x) = \{C_{ij} | \beta, \alpha\} \quad (3.6)$$

Com

$$C_{ij} = \frac{p(i,j)}{\sum P_{ij}} \quad (3.7)$$

onde P é a frequência de ocorrência dos tons de cinza i e j . A soma sobre índice n refere-se ao número total de pares de *pixels*, que é dependente do parâmetro β e dos subscritos n e m de W_{nm} .

As texturas examinadas neste trabalho foram: a energia (representa a homogeneidade da imagem); a entropia (que representa informações de textura); e o contraste (estimativa das variações locais) e suas fórmulas são apresentadas a seguir, conforme Haralick, Shanmugam e Dinstein (1973):

$$Energia = \sum_i \sum_j \{p(i,j)\}^2 \quad (3.8)$$

A energia é uma medida da homogeneidade de uma imagem. Um cenário homogêneo conterá apenas alguns níveis de cinza, de modo que GLCM terá poucos, mas relativamente elevados valores de $p(i, j)$. Assim, a soma dos quadrados será alta. Valores mais altos indicam uniformidade textural. Portanto, quando a imagem é homogênea, a energia terá valores elevados (YANG, BEITLER e YU, 2012).

$$Entropia = \sum_i \sum_j p(i,j) \log(p(i,j)) \quad (3.9)$$

A entropia mede a aleatoriedade da textura de uma imagem (distribuição de intensidade). A entropia é elevada quando todas as probabilidades $p(i, j)$ são iguais. Portanto, uma imagem homogênea terá um valor de entropia inferior, enquanto que uma região heterogênea irá resultar num maior valor de entropia (YANG, BEITLER e YU, 2012).

$$\text{Contraste} = \sum_{n=0}^{Ng-1} n^2 \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \quad (3.10)$$

Contraste é uma medida das variações locais apresentadas em uma imagem. É altamente correlacionada com a diferença entre os maiores e os menores valores de um conjunto contínuo de pixels. Se houver uma grande variação em uma imagem, o contraste irá ser elevado (YANG, BEITLER e YU, 2012).

Quando os elementos de C_{ij} crescem, as estatísticas de energia e entropia crescem conjuntamente. As probabilidades conjuntas serão maiores onde houver menor variação local na textura. Quanto mais dissimilares os níveis de cinza forem, maiores serão as estatísticas de contraste.

3.1.3.3 - Transformações Geométricas

Transformações geométricas são operações de processamento de imagens cujo principal efeito é a alteração da posição espacial dos pixels que a compõem. Como nesse trabalho se tem a utilização de características das imagens que se mostrem invariáveis a efeitos como rotação, translação e escala, uma descrição desses pontos é apresentada a seguir.

1 - Translação

Segundo Gonzales e Woods (2000), a translação de uma imagem consiste no deslocamento linear de cada pixel de coordenadas (x,y) na horizontal ou na vertical, mapeando a imagem para o ponto de coordenadas (x',y') , obtidas através da equação:

$$(x', y') = (x + \Delta x, y + \Delta y) \quad (3.11)$$

onde Δx é o deslocamento na vertical e Δy é o deslocamento na horizontal.

2 - Rotação

A rotação de uma imagem em um ângulo arbitrário, pode ocorrer tanto no sentido horário quanto no anti-horário. Rotações com ângulos múltiplos de 90° são mais simples de implementar, pois consistem na cópia de linhas reordenadas em

colunas na direção em que se deseja rotacionar a imagem. De forma matemática, a rotação de cada ponto (x,y) de uma imagem por um ângulo arbitrário θ , mapeará este ponto na localidade de coordenadas (x',y') , obtidas através das equações (GONZALES e WOODS, 2000):

$$x' = x \cos \theta + y \sin \theta \quad (3.12)$$

$$y' = y \cos \theta - x \sin \theta \quad (3.13)$$

3 - Escala

Segundo Gonzales e Woods (2000), a escala é o processo de redimensionar imagens digitais. De forma matemática, a escala de cada ponto (x,y) de uma imagem em $n \times m$ resulta em (x',y') , obtida através da equação:

$$(x', y') = (nx, my) \quad (3.14)$$

3.2 - Redes Neurais Artificiais

As redes neurais artificiais também são utilizadas em processamento de imagens. De forma geral, uma rede neural artificial é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse; é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital (HAYKIN, 2001).

Para conseguir um grande desempenho, as redes neurais artificiais utilizam um grande número de interligações entre células computacionais simples chamadas de “neurônios”. Dessa forma, pode-se utilizar a seguinte definição de uma RNA vista como uma máquina adaptativa.

Uma RNA é um processador maciça e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: o conhecimento é adquirido pela RNA a partir de seu ambiente através de um processo de aprendizagem; e forças de conexão entre os neurônios são utilizadas para armazenar conhecimento adquirido.

O aprendizado é realizado através do algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede neural (as forças de conexão) de uma forma ordenada para aproximar a resposta da RNA do objetivo do projeto desejado. Os modelos neurais computacionais, as RNAs, procuram aproximar o processamento dos computadores ao cérebro humano.

As RNAs extraem seu poder computacional de sua estrutura e de sua habilidade de aprender e generalizar. A generalização se refere ao fato da RNA produzir saídas adequadas para valores que não foram apresentados anteriormente a ela. Devido a essas capacidades de processamento de informação é que as RNAs podem resolver problemas complexos.

O neurônio artificial é um dispositivo lógico-matemático que procura simular as funções e o comportamento de um neurônio biológico. Assim sendo, os dendritos são substituídos por entradas, onde ligações com o corpo celular artificial são realizadas através de elementos denominados pesos, que simulam as sinapses. Os estímulos captados pelas entradas são processados pela função de soma ponderada dos sinais, e o limiar de disparo do neurônio biológico é substituído pela função de transferência (HAYKIN, 2001).

Com a combinação de diversos neurônios artificiais, forma-se a chamada RNA, cujo diagrama está apresentado na Figura 3.2. A partir de uma RNA formada, uma série de valores pode ser aplicada sobre um neurônio, sendo que este está conectado a outros pela rede neural. Estes valores, ou entradas, são multiplicados no neurônio pelo valor do peso de sua sinapse. Posteriormente, esses valores são somados. Se esta soma ultrapassar um valor limite estabelecido, um sinal é propagado pela saída, axônio, deste neurônio. Em seguida, essa mesma etapa se realiza com os demais neurônios da rede neural. Isso quer dizer que os neurônios vão enfrentar algum tipo de ativação, dependendo das entradas e dos pesos sinápticos (HAYKIN, 2001).




Figura 3.2 - Esquema simplificado de um mapa sequencial, com as entradas, camada intermediária e as saídas.
 Fonte: HAYKIN (2001)

Existem várias formas de se desenvolver uma rede neural. Ela deve ser montada de acordo com os problemas a serem resolvidos, para isso deve-se determinar a arquitetura da RNA. Em sua arquitetura é determinado o número de camadas usadas (formadas por neurônios) e a quantidade de neurônios em cada camada. Existem dois tipos principais de redes neurais, as supervisionadas e as não supervisionadas (HAYKIN, 2001): supervisionadas classificam padrões de acordo com seu aprendizado e se obtém uma resposta de acordo com esse aprendizado. Como exemplos, têm-se as redes MLP e o perceptron de camada única; e não supervisionadas classificam padrões sem um aprendizado prévio, de acordo com a similaridade entre os padrões, tendo como principal exemplo o mapa auto-organizável de Kohonen (KOHONEN, 2000), descrito na seção seguinte.

3.2.1 - Mapas Auto-Organizáveis de Kohonen

Os mapas auto-organizáveis de Kohonen são redes neurais competitivas, ou seja, têm aprendizagem não supervisionada que possuem a habilidade de formar mapeamentos que preservam a topologia entre os espaços de entrada e saída da rede neural. Seu desenvolvimento foi motivado por uma característica do cérebro

humano que é organizado em várias regiões de maneira que entradas sensoriais são representadas por mapas topologicamente ordenados. Essas redes neurais são utilizadas em vários projetos como ferramentas para resolver problemas não-lineares de alta dimensão nos campos da estatística, processamento de sinais e imagens, teoria de controle, análise financeira, física experimental, química e medicina (CASTRO e CASTRO, 2001).

O mapa é um arranjo de neurônios que procura estabelecer e preservar noções de vizinhança e que apresenta propriedades de auto-organização, onde há um mapeamento do espaço original para o espaço em que está definido o arranjo de neurônios (CASTRO e CASTRO, 2001).

Nos arranjos unidimensionais, o mapa é dado por uma sequência ordenada de neurônios lineares, sendo o número de pesos igual ao número de entradas, e há uma relação entre os pesos dos neurônios no espaço igual ao número de entradas, como pode ser observado na Figura 3.3.

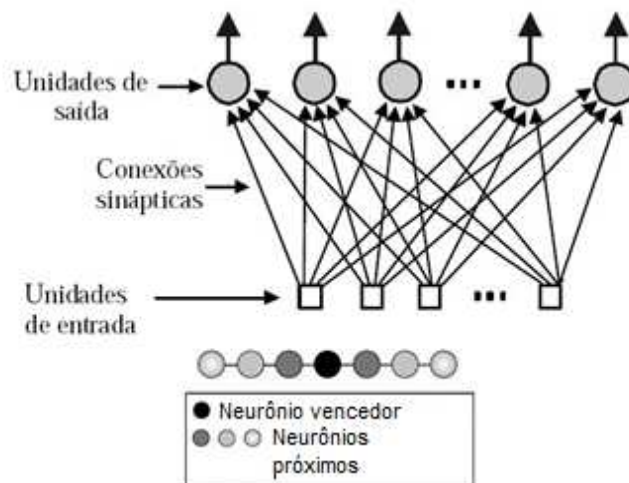


Figura 3.3 - Esquema simplificado de um mapa sequencial.
Adaptado de KOHONEN, 2000.

Nos arranjos bidimensionais, o mapa é dado por vários neurônios dispostos um ao lado dos outros, como na Figura 3.4.

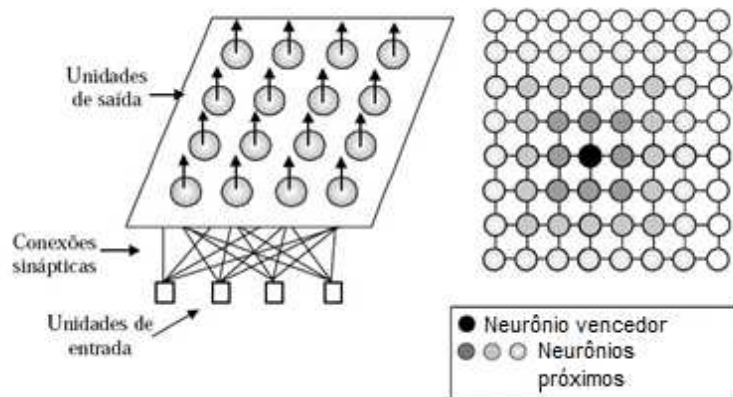


Figura 3.4 - Esquema simplificado de um mapa bidimensional.
Adaptado de KOHONEN, 2000.

O funcionamento da rede neural inicia quando são atribuídos os pesos sinápticos. A partir disso, três processos essenciais estão envolvidos na formação da rede: a competição, onde para cada padrão de entrada é calculado o valor de ativação dos neurônios e estabelecida uma competição entre eles, e o vencedor é aquele que obtiver o maior valor; a cooperação, que se inicia quando o neurônio vencedor determina a localização da vizinhança topológica de neurônios, provendo assim as bases para a cooperação entre tais neurônios vizinhos; e por fim, a adaptação sináptica, que permite aos neurônios excitados atualizar seus pesos, e esses ajustes são de acordo com a resposta do neurônio vencedor à aplicação de um realçado padrão de entrada (VON ZUBEN et. al., 2007).

As seções seguintes descrevem detalhadamente cada um dos processos da rede e seu algoritmo.

3.2.1.1 - Processo competitivo

Seja m a dimensão do espaço de dados de entrada e um padrão de entrada selecionado aleatoriamente a partir do espaço de entrada denotado por Castro e Castro (2001) como:

$$\mathbf{x} = [x_1 \ x_2 \ x_3 \ \dots \ x_m] \quad (3.15)$$

O vetor de pesos sinápticos de cada neurônio na rede tem a mesma dimensão do espaço de entrada. Seja o vetor de pesos sinápticos do neurônio j denotado por:

$$w_j = [w_{j1} \ w_{j2} \ \dots \ w_{jm}] \quad (3.16)$$

com $j = 1, 2, \dots, n$ e onde n é o número de neurônios na rede.

Ao selecionar o neurônio com o maior produto interno, significa que foi determinada a localização onde a vizinhança topológica de neurônios excitados deverá estar centrada.

O critério para determinar qual vetor de entrada se aproxima do vetor de pesos sinápticos é matematicamente equivalente a minimizar a distância euclidiana ou distância de Manhattan entre ambos os vetores (CASTRO e CASTRO, 2001).

Empregando o índice $i(x)$ para identificar o neurônio que mais se aproxima do vetor de entrada é possível então determiná-lo aplicando a condição mostrada na Equação 3.16, que resume a essência do processo de competição entre os neurônios.

$$i(x) = \arg \min \|x - w_j\| \quad (3.17)$$

para $j = 1, 2, \dots, n$.

O particular neurônio i que satisfaz a condição expressa na equação acima é chamado de neurônio vencedor para o vetor de entrada.

3.2.1.2 - Processo cooperativo

O neurônio vencedor localiza o centro de uma vizinhança topológica de neurônios cooperativos e um neurônio que está "ligado" tende a excitar mais os neurônios mais próximos. Assim, a vizinhança topológica ao redor do neurônio vencedor i decai suavemente com a distância lateral (CASTRO e CASTRO, 2001).

Em outras palavras, seja $h_{j,i}$ a vizinhança topológica centrada no neurônio vencedor i e circundada por um conjunto de neurônios excitados cooperativos, dos quais um neurônio típico é denotado por j . Seja $d_{i,j}$ a distância entre o neurônio vencedor i e o neurônio excitado j . Então, a vizinhança topológica $h_{j,i}$ é uma função unimodal da distância $d_{i,j}$ tal que satisfaça a duas afirmações:

- A vizinhança topológica é simétrica ao redor do ponto máximo definido por $d_{i,j} = 0$;
- A amplitude da vizinhança topológica decresce monotonicamente com o aumento da distância lateral $d_{i,j}$ decaindo a zero para $d_{i,j} \rightarrow \infty$.

Uma escolha para h_{ji} que satisfaça a estes requerimentos é a função Gaussiana apresentada na Equação 3.17, que é independente da localização do neurônio vencedor.

$$h_{j,i}(x) = \exp\left(\frac{-d_{2j,i}}{2\sigma^2}\right) \quad (3.18)$$

onde parâmetro σ expressa a largura efetiva da vizinhança topológica e mede o grau com que os neurônios excitados participam no processo de aprendizagem.

Para que exista cooperação entre neurônios vizinhos, é necessário que a vizinhança topológica seja mais dependente da distância lateral entre o neurônio vencedor i e o neurônio excitado j no espaço de saída, do que de alguma medida de distância no espaço de entrada original (CASTRO e CASTRO, 2001).

Uma característica do mapa auto-organizável de Kohonen é que o tamanho da vizinhança topológica diminui ao longo do tempo. Isso é satisfeito fazendo a largura da função topológica diminuir com o tempo. Uma escolha para a dependência da largura no tempo é o decaimento exponencial descrito pela equação:

$$\sigma(n) = \sigma_0 \exp\left(\frac{-n}{\tau_1}\right) \quad (3.19)$$

com $n = 0, 1, 2, \dots$ onde σ_0 é o valor inicial da largura, e τ_1 é uma constante de tempo. De forma correspondente, a vizinhança topológica assume uma forma variante com o tempo. Assim, à medida que o tempo n aumenta, a largura diminui a uma taxa inversamente proporcional, e a vizinhança topológica encolhe de forma correspondente.

3.2.1.3 - Processo adaptativo

O último processo envolvido na formação auto-organizada de um mapa auto-organizável de Kohonen é o processo adaptativo dos pesos sinápticos (CASTRO e CASTRO, 2001).

Para que a rede neural possa se auto-organizar, o vetor de pesos sinápticos do neurônio j deverá variar com relação ao vetor de entrada \underline{x} . Um peso sináptico é aumentado quando há ocorrência simultânea de atividades pré e pós-sinápticas. Dada uma tal função, podemos expressar a mudança no vetor de pesos sinápticos

do neurônio j por:

$$\Delta w_j = \eta h_{j,i(x)} (x - w_j) \quad (3.20)$$

onde η é a taxa de aprendizado. Finalmente, usando o formalismo de tempo-discreto, dado o vetor de pesos sinápticos do neurônio j no tempo n , o vetor de pesos atualizado no tempo $n+1$ é definido pela Equação 3.20, o qual é aplicado a todos os neurônios que estão dentro da vizinhança topológica do neurônio vencedor i :

$$w_j(n+1) = w_j(n) + \eta(n) h_{j,i(x)}(n) (x - w_j(n)) \quad (3.21)$$

A equação 3.20 tem o efeito de mover o vetor de pesos sinápticos do neurônio vencedor i na direção do vetor de entrada. Sob repetidas apresentações dos dados de treino, os vetores de pesos sinápticos tendem a seguir a distribuição dos vetores de entrada devido a atualização da vizinhança. O algoritmo, portanto, conduz a uma ordenação topológica do mapa de características no espaço de entrada, no sentido de que os neurônios que são adjacentes no mapa tenderão a ter vetores de pesos sinápticos similares (CASTRO e CASTRO, 2001).

O parâmetro taxa de aprendizado $\eta(n)$ pode variar com o tempo. Em particular, a taxa de aprendizado deve iniciar em um valor η_0 e então decrescer gradualmente com o aumento do tempo n . Esta condição pode ser satisfeita escolhendo um decaimento exponencial para $\eta(n)$, conforme:

$$\eta(n) = \eta_0 \exp\left(\frac{-n}{\tau_2}\right) \quad (3.22)$$

com $n = 0, 1, 2, \dots$ e τ_2 é uma outra constante de tempo.

3.2.1.4 - Algoritmo de SOM

Segundo Fausett (1994), os passos do algoritmo SOM são:

0. Inicializar os pesos w_{ij} . Definir os parâmetros dos vizinhos topológicos e a taxa de aprendizagem.
1. Enquanto uma condição é falsa, executar passos 2 a 8.
2. Para cada vetor de entrada \underline{x} , executar passos 3 a 5.
3. Para cada j , calcular a função de distância.

4. Encontrar o índice J cujo $D(J)$ seja o mínimo.
5. Para todo j numa vizinhança de J , e para todo i , calcular $w_{ij}(n+1) = w_{ij}(n) + \eta(n)h_{j,i(x)}(n)(x - w_j(n))$.
6. Atualizar taxa de aprendizagem.
7. Reduzir o raio de atuação da vizinhança.
8. Verificar teste de parada.

A taxa de aprendizagem η é uma função de decréscimo de tempo. O mapa auto-organizável de Kohonen indica que uma função linear decrescente é satisfatória para práticas computacionais e uma função geométrica decrescente produziria resultados similares.

O raio de vizinhança de uma unidade também reduz o processo de agrupamento.

A formação do mapa ocorre em duas fases: A fase inicial de correção de ordem e a convergência final. A segunda fase demora muito mais e requer uma pequena taxa de aprendizagem.

4 - ESTUDO DE CASO

As áreas de estudo são parte da Floresta Amazônica Brasileira, mais precisamente no estado do Pará, que considera regiões com predominância de floresta tropical úmida e áreas planas e no deserto dos Estados Unidos da América, entre os Estados de Nevada e Arizona, no lago Mead, formado no rio Colorado.

4.1 - Floresta Nacional de Tapajós

O primeiro caso é parte da Floresta Nacional do Tapajós entre as coordenadas 4°10'S e 55°30'W; 2°45'S e 54°45'W, ilustrado na Figura 4.1. A região da floresta possui uma área estimada de 600.000 ha e é caracterizada por um clima quente e úmido, com média térmica máxima anual variando entre 31°C a 33°C enquanto a média mínima varia entre 24°C a 25°C (ESPÍRITO SANTO *et al.*, 2005). O índice de precipitação pluviométrica anual varia entre 1800 a 2800 mm, com nítida divisão na distribuição das chuvas, que são abundantes no primeiro semestre, mas possuem baixa intensidade no restante do ano. A região possui principalmente floresta tropical úmida e é considerada como uma área plana com variações altimétricas entre 50 m e 200 m aproximadamente (ZEE BR-163, 2008).

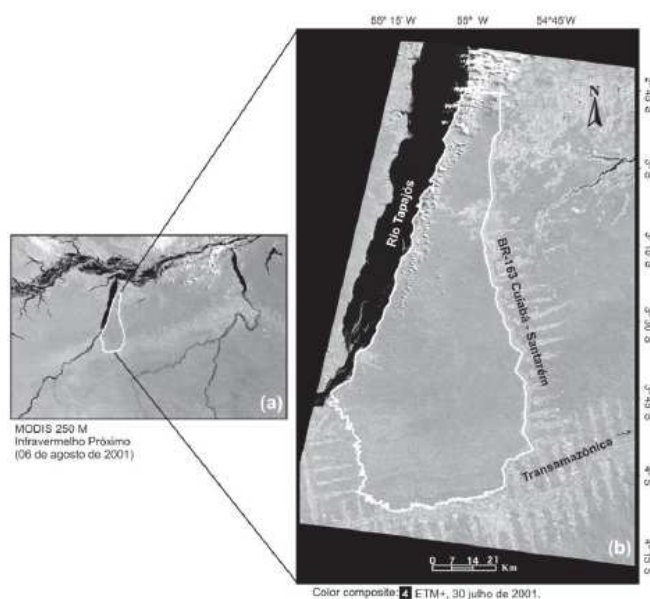


Figura 4.1 - Localização da Floresta Nacional de Tapajós nas imagens dos sensores: (a) MODIS/TERRA e (b) ETM+/Landsat.
Fonte: ESPÍRITO SANTO *et al.*, (2005).

Por volta de 1970, o governo iniciou uma política de incentivo a ocupação da Amazônia brasileira, financiando assim a construção da rodovia BR-163 (Cuiabá-Santarém), o que intensificou a ocupação da área e também o desmatamento e as atividades associadas a este processo, como a extração de madeira, abertura de áreas agrícolas e de pastagens (PEREIRA, 2012). Como resultado dessa política de incentivo a ocupação da região, as áreas de desmatamento na floresta, que se apresentam através de áreas de vegetação secundária denominadas por "Capoeiras", concentraram-se principalmente ao longo dessa rodovia e suas adjacências (NEGRI, 2009).

Atualmente, a região apresenta uma grande diversidade quanto ao uso e ocupação da terra sendo possível destacar as atividades pecuárias e a produção agrícola de grãos (ESCADA *et al.*, 2009). Assim, a escolha dessa região como área de estudo se deve a existência de um conjunto rico de dados, da possibilidade de existência de diversas classes de cobertura da terra, já discriminadas por Pereira (2012).

4.2 - Lago Mead

O segundo caso ocorre no rio Colorado entre os estados de Nevada e Arizona nos Estados Unidos da América, na área de coordenadas 36°05'28.5"N 114°30'36.3"W. O lago Mead é o maior lago artificial americano formado em decorrência da construção da represa Hoover na década de 1930.

O rio Colorado possui bastante importância tanto na sociedade quanto na economia da região sudoeste americana, pois serve de abastecimento para pelo menos 20 milhões de habitantes nos estados de Nevada, Califórnia e Arizona, de destino turístico e para geração hidrelétrica de energia, e vem sofrendo bastante com a redução do seu volume de água, e estudos nos últimos 20 anos vêm indicando os problemas para essa redução, como o aumento das temperaturas, a redução de chuvas e o abastecimento da população que vem crescendo na região (BARNETT e PIERCE, 2008).

Com uma visitação em campo em abril de 2014 foi possível observar que o nível do lago da represa já atingiu níveis bem diferentes do que é visto hoje em dia,

conforme ilustrado na Figura 4.2.



Figura 4.2 – Lago Mead visto da barragem da represa Hoover.

4.3 - Origem das Imagens

As imagens apresentadas nesse trabalho foram obtidas através do TM/Landsat 5 e TM/Landsat 8 nas páginas de GLOVIS (2014) e DGI-INPE 2 (2013). Landsat é um programa espacial gerido pelos Estados Unidos e fornece registros baseado em espaço contínuo da superfície terrestre desde 1972, e seus satélites coletam medidas de continentes da Terra e em torno de regiões costeiras que permitiram estudar florestas, produção de alimentos, de água e uso do solo, ecossistemas, geologia, entre outras atividades (NASA, 2013). Os sensores TM (*Thematic Mapper*) desse satélite têm uma cobertura quase contínua desde 1982 e cobrem diversas bandas do espectro eletromagnético. As imagens empregadas neste trabalho utilizam as bandas 3, 4 e 5, com resolução de 30 metros. A banda 3, que possui intervalo espectral de 0,63 a 0,69 μm , tem as características de apresentar bom contraste entre diferentes tipos de cobertura vegetal, permite o mapeamento da drenagem através da visualização da mata galeria e entalhe dos cursos dos rios em regiões com pouca cobertura vegetal, e com isso permite a identificação de áreas agrícolas. A banda 4, que possui intervalo espectral de 0,76 a 0,90 μm permite o mapeamento da rede de drenagem e delineamento de corpos de água, com a vegetação aparecendo bem clara nas imagens e apresenta

sensibilidade à rugosidade da copa das florestas e serve para mapear áreas ocupadas com vegetação queimada. A banda 5, que possui intervalo espectral de 1,55 a 1,75 μm , apresenta sensibilidade ao teor de umidade das plantas, servindo para observar estresse na vegetação, e sofre perturbações em caso de ocorrer excesso de chuva antes da obtenção da cena pelo satélite (DGI-INPE, 2013).

Com o software de sensoriamento remoto ENVI, foi possível fundir as imagens das bandas 3, 4 e 5 em uma imagem visível em formato compacto. Na Figura 4.3 (a) é apresentada a imagem da região amazônica obtida em 2008 e na Figura 4.3 (b) obtida em 2009.




Figura 4.3 – Exemplos de imagens Tm/Landsat 5 da região da Floresta Nacional de Tapajós: (a) Imagem obtida em 23 de junho de 2008 e (b) Imagem obtida em 12 de julho de 2009.

5 - METODOLOGIA

Nesse capítulo é apresentada a metodologia proposta nessa dissertação para a obtenção da detecção de mudanças em imagens aéreas.

Nesse trabalho, imagens digitais obtidas por sensores embarcados em satélites são usadas para a detecção de mudanças de cobertura terrestre. O primeiro passo consiste na obtenção das imagens, conforme indicado na **Erro! Fonte de referência não encontrada.**, que devem ser obtidas em tempos distintos e serem de uma mesma região, a fim de se detectar as mudanças ocorridas nessa região.

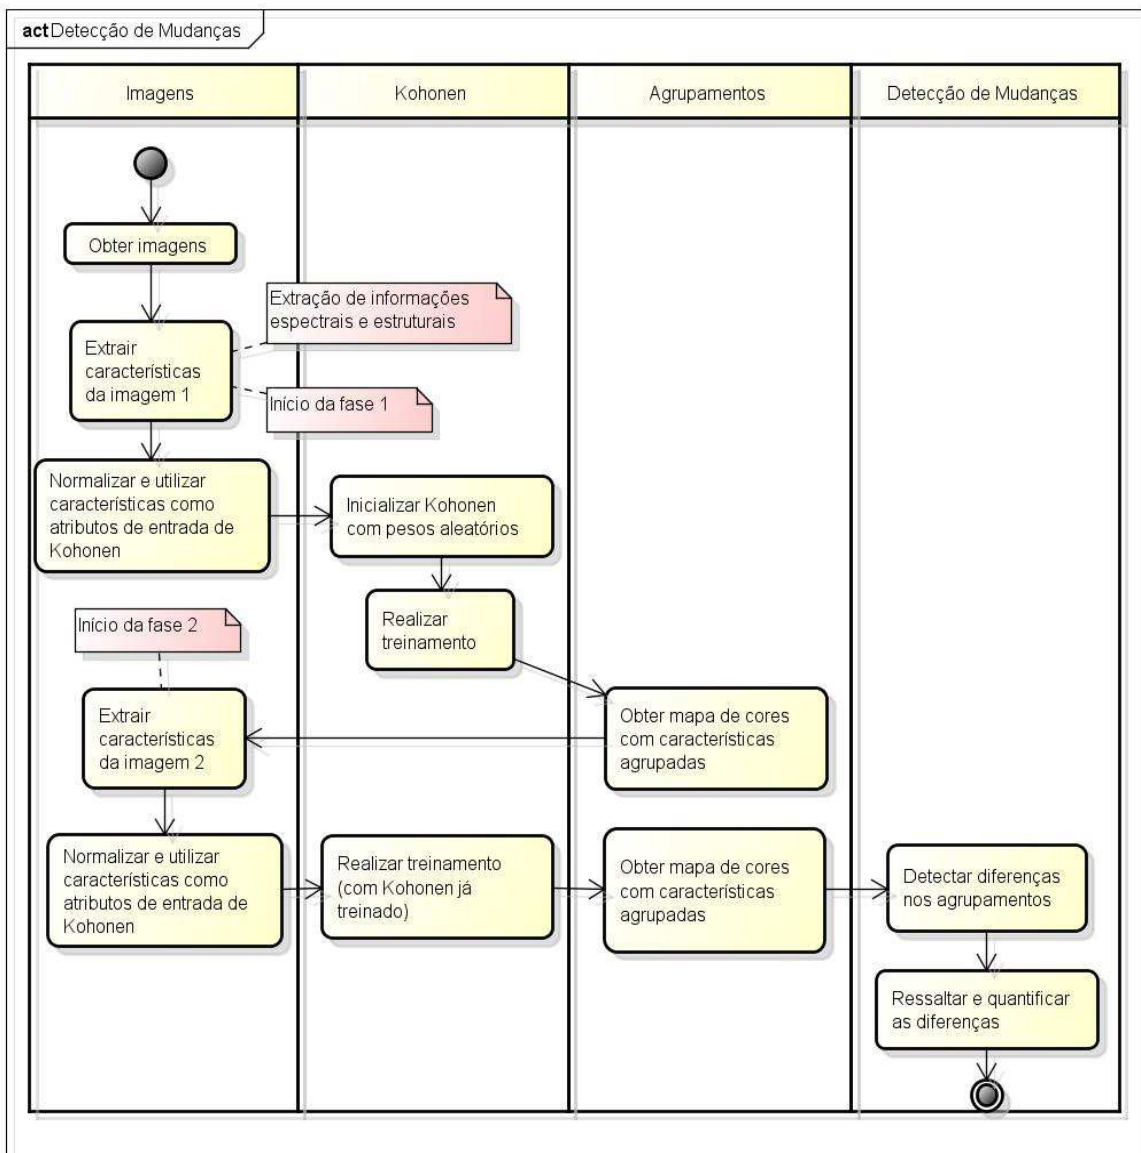


Figura 5.1 – Esquema (diagrama de atividades) do algoritmo proposto nesse trabalho.

Em seguida, são extraídas características das imagens como informações espectrais (informações sobre as cores dos pixels) e estruturais (dados de textura e bordas) das imagens que serão os parâmetros de treinamento dos mapas auto-organizáveis de Kohonen. As primeiras informações extraídas são as informações espectrais, isto é, dados do sistema de cor HSV, recomendado na Seção 2.1. O HSV fornece dados de matiz (tonalidade), saturação e brilho de cada *pixel*, mas que nesse trabalho, serão as médias para cada um dos valores em cada *pixel* dentro da janela dada. A janela é uma seção da imagem, onde para cada pixel percorrido na imagem, obtém-se uma janela de $n \times n$ pixels em torno desse *pixel*, onde n é um parâmetro empregado na execução da extração de características. Outra informação extraída da imagem faz uso da matriz de coocorrência de níveis de cinza, que mostra a relação entre *pixels* e sua vizinhança dado a distância entre os *pixels* e a orientação. O GLCM fornece vários dados de textura, mas nesse trabalho são utilizados a energia, a entropia e o contraste, obtidos para cada janela fornecida. Ainda outra informação extraída das imagens são os atributos de bordas. Existem várias técnicas para tal, abordadas na Seção 3.1.3.1 - , onde se justifica a utilização pelo método criado por Canny nesse trabalho.

Para apresentação dessas informações como parâmetros de entrada ao mapa auto-organizável de Kohonen, é necessário um pré-processamento para que todas as informações sejam normalizadas em relação à faixa de ativação da rede neural.

Como configuração do mapa auto-organizável de Kohonen, foram definidos em cada teste os seguintes atributos:

- Número de iterações ou épocas: quantas vezes o algoritmo será repetido.
- Taxa de aprendizagem: taxa de aprendizagem interfere com a atualização dos pesos sinápticos. Taxa de aprendizagem muito pequena requer um maior número de iterações para convergir para o resultado desejado. No entanto, uma taxa muito elevada provoca oscilações e também dificulta a convergência. A taxa foi definida em 3 para todos os testes (KOHONEN, 2000).

- Número de neurônios ou classes: cada neurônio representa uma classe, isto é, uma característica distinta. O número de neurônios deve ser colocado de acordo com a forma como o usuário quer ter alguma generalização no agrupamento de neurônios. Quanto menor o número de neurônios mais generalista será o agrupamento (KOHONEN, 2000).
- Tipo de distância: o tipo pode ser tanto a distância Euclidiana ou a distância de Manhattan, que são utilizadas para minimizar a distância entre o vetor de pesos sinápticos e o vetor de entrada (KOHONEN, 2000).
- Tipo de topologia: a topologia define o arranjo entre os neurônios no mapa e assim afetando a vizinhança topológica quando se encontra o neurônio vencedor no processo competitivo. Os tipos podem ser quadrado ou hexagonal (KOHONEN, 2000).

Para a apresentação dos dados ao mapa auto-organizável de Kohonen, é necessária a inicialização dos pesos, que é definida de forma aleatória.

Assim pode-se iniciar a fase 1, onde as informações extraídas da primeira imagem (definida aqui como a imagem obtida menos recentemente) são apresentadas como parâmetros para treinamento, que é a fase de maior custo computacional quando se usam redes neurais artificiais. Para o treinamento, é necessário informar o número de iterações dos mapas auto-organizáveis de Kohonen e raio de ação da vizinhança topológica. Arbitrariamente, foi definido o raio de vizinhança inicial igual a 3, que é reduzido ao longo do tempo para diminuir o processo de agrupamento.

Após o treinamento, é possível obter a informação de qual agrupamento pertence cada entrada apresentada, sendo possível realizar o agrupamento das características semelhantes da imagem, além de quantificar as entradas que correspondem a cada agrupamento. Os resultados desses agrupamentos são exibidos em um mapa de cores, com cada cor representando um agrupamento.

Com o mapa auto organizável de Kohonen já treinado pela primeira imagem e conseqüentemente com seus pesos atualizados, inicia-se a fase 2, onde são apresentadas como parâmetros para classificação as informações extraídas da segunda imagem (imagem obtida mais recentemente). Nessa fase, a taxa de aprendizagem é igual a zero, ou seja, os pesos não serão atualizados, assim

somente o processo competitivo importa nessa fase. Além disso, não são necessárias diversas iterações como na fase 1, já que não há atualização dos pesos. Após a classificação, é possível obter a qual agrupamento pertence cada entrada e assim agrupar as características similares, bem como exibir esses agrupamentos em um mapa de cores.

Com os agrupamentos obtidos, é possível analisar quais regiões tem as mesmas características, e assim, detectar as mudanças que ocorreram de uma imagem para outra, uma vez que o mapa auto-organizável de Kohonen é treinado inicialmente pela imagem mais antiga, e posteriormente, treinada pela imagem mais recente.

Para que a geração dos resultados seja possível, existem algumas restrições quanto às imagens:

- As imagens devem estar na mesma translação;
- As imagens devem estar na mesma rotação;
- As imagens devem estar na mesma escala;

Uma vez que as imagens são georreferenciadas, essas condições são atendidas.

6 - EXPERIMENTOS E RESULTADOS

Com o objetivo de avaliar os resultados obtidos, essa seção descreve os resultados e algumas análises. Com a finalidade de melhor avaliar o algoritmo proposto, utilizou-se um gabarito de mudanças elaborado por um especialista para cada uma das amostras testadas de forma a comparar com os resultados obtidos pelo estudo proposto. Os resultados foram obtidos em um computador com processador Intel Core i5 2.4 GHz e foram avaliados com relação à Precisão (P) e Sensibilidade (S) (FAWCETT, 2006), como é mostrado nas Equações 6.1 e 6.2, onde VP são verdadeiros positivos (mudanças identificadas corretamente), FP são falsos positivos (mudanças identificadas pelo algoritmo que não são mudanças reais) e FN são falsos negativos (mudanças não identificadas).

$$P = \frac{VP}{VP + FP} \times 100 \quad (6.1)$$

$$S = \frac{VP}{VP + FN} \times 100 \quad (6.2)$$

6.1 - Floresta Nacional de Tapajós

Foram selecionadas amostras da região da Floresta Nacional de Tapajós em tempos distintos (Figura 6.1), para que fosse possível distinguir as mudanças que ocorreram. As amostras se encontram na mesma translação, rotação e escala.

A partir da Figura 6.1 foram seccionadas algumas imagens onde as mudanças são mais explícitas ou onde não há mudança alguma para que essas fossem as imagens de teste do algoritmo proposto. A Figura 6.2 ilustra a parte seccionada da Figura 6.1 junto com o gabarito elaborado pelo especialista e a Tabela 6.1 mostra os parâmetros utilizados nos testes, que foram selecionados de forma arbitrária, como tamanho de janela, função de distância, topologia da rede neural, quantidade de classes, número de épocas e os atributos das imagens a serem utilizadas, e os resultados são apresentados na Tabela 6.2. As imagens têm a dimensão de 51x51 pixels e o gabarito encontrou mudanças em 315 pixels.




Figura 6.1 – Imagem da região da Floresta Nacional de Tapajós.

- (a) Obtida em 23 de junho de 2008;
- (b) Obtida em 12 de julho de 2009;
















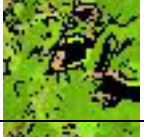


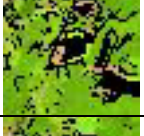



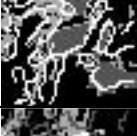

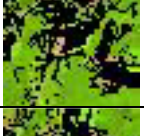





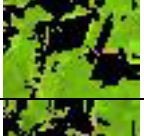








Figura 6.2 – (a) e (b) são seções da Figura 6.1 e (c) é o gabarito de mudanças.

Tabela 6.1 – Parâmetros da classificação da Figura 6.2

| # | Parâmetros de Kohonen | | | | | Atributos da Imagem | | | | | | |
|----|-----------------------|------------|-----------|---------|--------|---------------------|---|---|-------|----------|---------|-----------|
| | Janela | Distância | Topologia | Classes | Épocas | H | S | V | Borda | Entropia | Energia | Contraste |
| 1 | 15 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 2 | 11 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 3 | 7 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 4 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 5 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 6 | 5 | Manhattan | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 7 | 5 | Euclidiana | Hexagonal | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 8 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 9 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 10 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ |
| 11 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ | ✗ |
| 12 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ | ✗ |

Tabela 6.2 – Resultados da classificação da Figura 6.2

| # | Resultados | | | | | | Imagens | | |
|----|------------|-----|-----|-----------|----------|---------------|--|---|---|
| | VP | FP | FN | Tempo (s) | Precisão | Sensibilidade | Agrupamento 1 | Agrupamento 2 | Mudanças |
| 1 | 68 | 345 | 247 | 13,66 | 16% | 22% |  |  |  |
| 2 | 140 | 768 | 175 | 11,67 | 15% | 44% |  |  |  |
| 3 | 130 | 835 | 185 | 11,67 | 13% | 41% |  |  |  |
| 4 | 124 | 791 | 191 | 12,02 | 14% | 39% |  |  |  |
| 5 | 151 | 505 | 164 | 11,60 | 23% | 48% |  |  |  |
| 6 | 151 | 505 | 164 | 11,45 | 23% | 48% |  |  |  |
| 7 | 68 | 345 | 247 | 12 | 16% | 22% |  |  |  |
| 8 | 226 | 772 | 89 | 12 | 23% | 72% |  |  |  |
| 9 | 226 | 771 | 89 | 17,06 | 23% | 72% |  |  |  |
| 10 | 225 | 772 | 90 | 11,67 | 23% | 71% |  |  |  |
| 11 | 240 | 833 | 75 | 11,53 | 22% | 76% |  |  |  |
| 12 | 240 | 833 | 75 | 5,98 | 22% | 76% |  |  |  |

Os resultados apresentados na Tabela 6.2 juntamente com os parâmetros apresentados na Tabela 6.1 mostram que quanto menor a janela e somente com o uso de informações espectrais, o algoritmo se comporta melhor, atingindo uma precisão de 22% e sensibilidade de 76%. Também não são necessárias muitas épocas para se chegar a esse resultado, ou seja, a partir de 1000 épocas o algoritmo não melhora os resultados, como mostram os testes #8, #9, #10, #11 e #12.

Mais uma parte foi seccionada da Figura 6.1, sendo ilustrada pela Figura 6.3 e a Tabela 6.3 mostra os parâmetros utilizados nos testes, que foram selecionados de forma arbitrária, e a Tabela 6.4 mostra os resultados. As imagens têm a dimensão de 33x33 pixels e não há mudanças significativas na cobertura do solo, a fim de verificar se o algoritmo é sensível a encontrar mudanças onde não existem. Portanto, não é possível calcular aqui a precisão e a sensibilidade nesse caso, já que não existem verdadeiros positivos.








































Figura 6.3 – (a) e (b) são seções da Figura 6.1.

Tabela 6.3 – Parâmetros da classificação da Figura 6.3

| # | Parâmetros de Kohonen | | | | | Atributos da Imagem | | | | | | |
|----|-----------------------|------------|-----------|---------|--------|---------------------|---|---|-------|----------|---------|-----------|
| | Janela | Distância | Topologia | Classes | Épocas | H | S | V | Borda | Entropia | Energia | Contraste |
| 1 | 15 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 2 | 11 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 3 | 7 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 4 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 5 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 6 | 5 | Manhattan | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 7 | 5 | Euclidiana | Hexagonal | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 8 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 9 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ |
| 10 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ |
| 11 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ | ✗ |
| 12 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✗ | ✗ | ✗ | ✗ | ✓ | ✗ | ✓ |

Tabela 6.4 – Resultados da classificação da Figura 6.3

| # | Resultados | | | | Imagens | | |
|----|------------|-----|----|-----------|---|---|---|
| | VP | FP | FN | Tempo (s) | Agrupamento 1 | Agrupamento 2 | Mudanças |
| 1 | 0 | 560 | 0 | 6,42 |  |  |  |
| 2 | 0 | 464 | 0 | 5,96 |  |  |  |
| 3 | 0 | 505 | 0 | 5,94 |  |  |  |
| 4 | 0 | 539 | 0 | 5,88 |  |  |  |
| 5 | 0 | 254 | 0 | 6,04 |  |  |  |
| 6 | 0 | 254 | 0 | 6,03 |  |  |  |
| 7 | 0 | 254 | 0 | 5,87 |  |  |  |
| 8 | 0 | 254 | 0 | 9,03 |  |  |  |
| 9 | 0 | 254 | 0 | 7,07 |  |  |  |
| 10 | 0 | 413 | 0 | 6,99 |  |  |  |
| 11 | 0 | 491 | 0 | 7,11 |  |  |  |
| 12 | 0 | 728 | 0 | 9,78 |  |  |  |

Os resultados apresentados na Tabela 6.4 juntamente com os parâmetros apresentados na Tabela 6.3 mostram que o algoritmo se comporta melhor sem o uso das informações de textura, detectando o menor número de mudanças possível, sendo possível afirmar que se obteve um acerto de 77% na melhor situação.

6.2 - Lago Mead

Foram selecionadas amostras da região do Lago Mead em tempos distintos (Figura 6.4), para que fosse possível distinguir as mudanças que ocorreram no local. As amostras se encontram na mesma translação, rotação e escala.

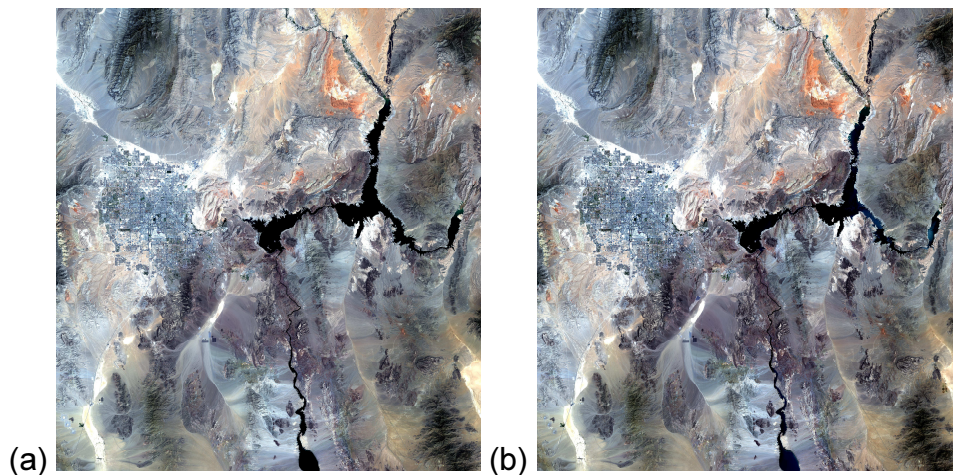


Figura 6.4 – Imagem da região do Lago Mead.

- (a) Obtida em abril de 2013;
- (b) Obtida em junho de 2014;

A partir da Figura 6.4 foram seccionadas algumas imagens onde as mudanças são mais explícitas. Na Figura 6.5 são apresentadas as partes seccionadas da Figura 6.4. Na Figura 6.5 (a) a imagem da região do Lago Mead obtida em 2013, Figura 6.5 (b) obtida em 2014 e Figura 6.5 (c) o gabarito elaborado pelo especialista. Na Tabela 6.5 são apresentados os parâmetros utilizados nos testes, que foram selecionados de forma arbitrária, e os resultados são apresentados na Tabela 6.6. As imagens têm a dimensão de 70x70 pixels e o gabarito encontrou mudanças em 398 pixels.







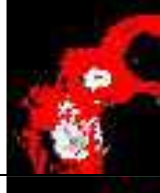








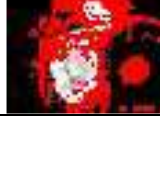

















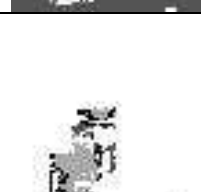





Figura 6.5 – (a) e (b) são seções da Figura 6.4 e (c) é o gabarito de mudanças.

Tabela 6.5 – Parâmetros da classificação da Figura 6.5

| # | Parâmetros de Kohonen | | | | | Atributos da Imagem | | | | | | |
|----|-----------------------|------------|-----------|---------|--------|---------------------|---|---|-------|----------|---------|-----------|
| | Janela | Distância | Topologia | Classes | Épocas | H | S | V | Borda | Entropia | Energia | Contraste |
| 1 | 15 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 2 | 11 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 3 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 4 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 5 | 5 | Manhattan | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 6 | 5 | Euclidiana | Hexagonal | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 7 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 8 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ |
| 9 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ |
| 10 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ |
| 11 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ | ✗ |
| 12 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✗ | ✗ | ✗ | ✗ | ✓ | ✗ | ✓ |

Tabela 6.6 – Resultados da classificação da Figura 6.5

| # | Resultados | | | | | | Imagens | | |
|---|------------|------|-----|-----------|----------|---------------|--|---|---|
| | VP | FP | FN | Tempo (s) | Precisão | Sensibilidade | Agrupamento 1 | Agrupamento 2 | Mudanças |
| 1 | 19 1 | 1134 | 207 | 18,41 | 14% | 48% |  |  |  |
| 2 | 24 2 | 1064 | 156 | 18,92 | 19% | 61% |  |  |  |
| 3 | 24 3 | 1293 | 155 | 18,21 | 16% | 61% |  |  |  |
| 4 | 23 5 | 1271 | 163 | 18,05 | 16% | 59% |  |  |  |
| 5 | 23 5 | 1270 | 163 | 18,14 | 16% | 59% |  |  |  |

| | | | | | | | | | |
|----|----------------|------|-----|-------|-----|-----|--|---|---|
| 6 | $\frac{23}{6}$ | 1275 | 162 | 17,89 | 16% | 59% |  |  |  |
| 7 | $\frac{23}{9}$ | 1278 | 159 | 18,05 | 16% | 60% |  |  |  |
| 8 | $\frac{23}{5}$ | 1270 | 163 | 25,60 | 16% | 59% |  |  |  |
| 9 | $\frac{30}{4}$ | 583 | 94 | 16,19 | 34% | 76% |  |  |  |
| 10 | $\frac{27}{4}$ | 543 | 124 | 16,00 | 34% | 69% |  |  |  |
| 11 | $\frac{26}{7}$ | 573 | 131 | 16,05 | 32% | 67% |  |  |  |
| 12 | $\frac{23}{7}$ | 1061 | 161 | 25,04 | 18% | 60% |  |  |  |

Os resultados apresentados na Tabela 6.6 juntamente com os parâmetros apresentados na Tabela 6.6 mostram que o algoritmo se comporta melhor para este estudo de caso em relação ao apresentado na Tabela 6.2, atingindo uma precisão de 34% e sensibilidade de 76%, novamente obtendo seu melhor desempenho quando não se utiliza dados de textura.

Mais uma parte foi seccionada da Figura 6.4 e são ilustradas pela Figura 6.5 juntamente com seu gabarito e a Tabela 6.7 mostra os parâmetros utilizados nos testes, que foram selecionados de forma arbitrária, e os resultados são

apresentados na Tabela 6.8. As imagens têm a dimensão de 50x50 pixels e o gabarito encontrou mudanças em 454 pixels.




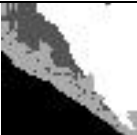




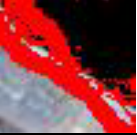


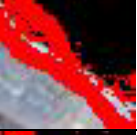















Figura 6.6 – (a) e (b) são seções da Figura 6.4 e (c) é o gabarito de mudanças.

Tabela 6.7 – Parâmetros da classificação da Figura 6.6

| # | Parâmetros de Kohonen | | | | | Atributos da Imagem | | | | | | |
|----|-----------------------|------------|-----------|---------|--------|---------------------|---|---|-------|----------|---------|-----------|
| | Janela | Distância | Topologia | Classes | Épocas | H | S | V | Borda | Entropia | Energia | Contraste |
| 1 | 15 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 2 | 11 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 3 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| 4 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 5 | 5 | Manhattan | Quadrada | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 6 | 5 | Euclidiana | Hexagonal | 4 | 1000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 7 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ |
| 8 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ |
| 9 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ |
| 10 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ |
| 11 | 5 | Euclidiana | Quadrada | 4 | 2000 | ✓ | ✓ | ✗ | ✗ | ✗ | ✗ | ✗ |
| 12 | 5 | Euclidiana | Quadrada | 4 | 1000 | ✗ | ✗ | ✗ | ✗ | ✓ | ✗ | ✓ |

Tabela 6.8 – Resultados da classificação da Figura 6.6

| # | Resultados | | | | | | Imagens | | |
|---|------------|-----|-----|-----------|----------|---------------|---------------|---------------|----------|
| | VP | FP | FN | Tempo (s) | Precisão | Sensibilidade | Agrupamento 1 | Agrupamento 2 | Mudanças |
| 1 | 21 1 | 456 | 243 | 10,96 | 32% | 46% | | | |
| 2 | 26 3 | 548 | 191 | 10,88 | 32% | 58% | | | |
| 3 | 34 2 | 572 | 112 | 10,99 | 37% | 75% | | | |
| 4 | 35 7 | 488 | 97 | 11,11 | 42% | 79% | | | |

| | | | | | | | | | |
|----|----------------|-----|-----|-------|-----|-----|--|---|---|
| 5 | $\frac{35}{7}$ | 491 | 97 | 10,73 | 42% | 79% |  |  |  |
| 6 | $\frac{35}{7}$ | 488 | 97 | 10,95 | 42% | 79% |  |  |  |
| 7 | $\frac{35}{5}$ | 488 | 99 | 10,65 | 42% | 78% |  |  |  |
| 8 | $\frac{35}{7}$ | 490 | 97 | 16,12 | 42% | 79% |  |  |  |
| 9 | $\frac{37}{9}$ | 488 | 75 | 11,35 | 44% | 83% |  |  |  |
| 10 | $\frac{40}{9}$ | 350 | 45 | 11,12 | 54% | 90% |  |  |  |
| 11 | $\frac{41}{2}$ | 359 | 42 | 11,07 | 53% | 91% |  |  |  |
| 12 | $\frac{27}{6}$ | 641 | 178 | 16,09 | 30% | 61% |  |  |  |

Os resultados apresentados na Tabela 6.8 juntamente com os parâmetros apresentados na Tabela 6.7 mostram que o algoritmo teve seu melhor comportamento até então. Em relação a todos os testes realizados, foi obtido uma precisão de 54% e sensibilidade de 90%, mais uma vez, não considerando os atributos de textura, e sendo nítida a detecção de mudança pelo algoritmo, realçando em vermelho a seca que ocorre na região.

7 - CONCLUSÃO

7.1 - Conclusões

Neste estudo foi abordada a identificação automática de diferenças no solo em regiões de características distintas. Essa identificação automática é importante para diversas aplicações principalmente quando se tem um grande número de imagens e dados nelas analisados.

Foram implementadas técnicas de processamento de imagem e visão computacional para detecção de mudanças no solo. Foram testados diferentes cenários, como um caso na Floresta Nacional de Tapajós e um outro caso entre os estados de Arizona e Nevada nos Estados Unidos da América, onde se localiza o lago Mead.

As imagens da Floresta Nacional de Tapajós foram obtidas em épocas distintas (junho de 2008 e julho de 2009) em regiões contendo mudanças geradas por desmatamento e as atividades associadas como a extração de madeira, abertura de áreas agrícolas e de pastagens.

As imagens do Lago Mead foram obtidas também em épocas distintas (abril de 2013 e junho de 2014) em regiões contendo mudanças geradas pelas condições climáticas e forma do uso de sua água, que vem causando uma baixa no nível da represa.

O emprego das técnicas de inteligência computacional, como a rede neural de Kohonen, possibilitou o tratamento de regiões da imagem com variações dos dados. Foram comparados diversos parâmetros com o objetivo de identificar os mais indicados para solucionar o problema proposto, como tamanho da janela, função de distância, tipo de topologia, número de classes, número de épocas e atributos de imagens.

Com o uso da rede neural foi possível identificar padrões nos terrenos e conseqüentemente mudanças principalmente em regiões com mudanças ocorridas pelo desmatamento ou seca.

Os métodos mostraram-se menos adequados na identificação de mudanças

na Amazônia, pois os índices de precisão ficaram abaixo em relação ao que foi mostrado na literatura. No entanto, para a detecção de mudanças no lago Mead, o desempenho foi melhor, sendo comparáveis aos que são mostrados na literatura.

Com a análise dos resultados pode-se afirmar que é possível realizar a detecção de mudanças com o uso de Kohonen de forma automática, ou seja, com intervenção de um especialista.

Portanto com este estudo verifica-se que o emprego de rede neural de Kohonen aplicado a detecção de mudanças é aplicável à automatização do processo de identificação de mudanças no solo nas situações mostradas.

7.2 - Trabalhos Futuros

Durante a realização deste trabalho foi possível identificar outras funcionalidades ou melhorias que poderiam ser desenvolvidas que incluem:

- Outros parâmetros das imagens: Poder-se-ia avaliar o uso de outras informações das imagens para servir de parâmetros de entrada da rede neural de Kohonen a fim de melhorar os resultados;
- Interpretação das mudanças: O poderia ser capaz de interpretar as mudanças que ocorreram, como por exemplo, em uma represa, se houver uma detecção nas margens da represa, interpretar se o nível da represa subiu ou desceu;
- Análise sequencial de imagens: O projeto poderia ser capaz de analisar uma sequência de imagens, que poderia ser obtida através de um VANT e detectar, em tempo real, a existência de mudanças na região sobrevoada, desde que ele tenha consigo um repositório de imagens da região em um tempo passado para fazer essa análise;
- Previsão de mudanças: Seria possível realizar a previsão de mudanças, com imagens obtidas em diversos tempos distintos e históricos de mudanças.

7.3 - Trabalhos Publicados

- **MOTA, R. L. M.**; SHIGUEMORI, E. H.; RAMOS, A. C. B.; Application of Self-Organizing Maps at Change Detection in Amazon Forest. In: 11th International Conference on Information Technology: New Generations, 2014, Las Vegas. Proceedings of the 11th International Conference on Information Technology: New Generations, p. 371-376, 2014.
- **MOTA, R. L. M.**; FELIZARDO, L. F.; SHIGUEMORI, E. H.; RAMOS, A. C. B.; MORA-CAMINO, F.; Expanding Small UAV Capabilities with ANN: A Case Study for Urban Areas Inspection. British Journal of Applied Science & Technology, v. 4, p. 387-398, 2014.
- **MOTA, R. L. M.**; SHIGUEMORI, E. H.; RAMOS, A. C. B.; Aplicação de Mapas Auto-Organizáveis na Detecção de Mudanças no Solo ao Longo do Tempo. In: II Simpósio de Ciência e Tecnologia do IEAV, 2013, São José dos Campos. Anais do II Simpósio de Ciência e Tecnologia do IEAV, 2013.
- FELIZARDO, L. F.; **MOTA, R. L. M.**; SHIGUEMORI, E. H.; NEVES, M. T.; RAMOS, A. C. B.; MORA-CAMINO, F.; Using ANN and UAV for Terrain Surveillance: A Case Study for Urban Areas Observation. In: 13th International Conference on Hybrid Intelligent Systems, 2013, Tunis. Proceedings of the 2013 Thirteenth International Conference on Hybrid Intelligent Systems, 2013.
- **MOTA, RODRIGO L.**; FELIZARDO, LUIZ F.; SHIGUEMORI, ELCIO H.; RAMOS, ALEXANDRE B.; MORA-CAMINO, FELIX; Expanding small UAV capabilities with ANN: A case study for urban areas observation. In: 2013 IEEE Second International Conference on Image Information Processing (ICIIP), 2013, Shimla. 2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013). p. 516-520, 2013.

8 - REFERÊNCIAS BIBLIOGRÁFICAS

AGUIRRE-GUTIÉRREZ, J.; SEIJMONSBERGEN, A. C.; DUIVENVOORDEN, J. F. Optimizing land cover classification accuracy for change detection, a combined pixel-based and object-based approach in a mountainous area in Mexico. *Applied Geography*, v. 34, p. 29–37, maio 2012.

ASTEL, A.; TSAKOVSKI, S.; BARBIERI, P.; SIMEONOV, V.; Comparison of self-organizing maps classification approach with cluster and principal components analysis for large environmental data sets. v. 41, p. 4566–4578, 2007.

BARNETT, T. P., PIERCE, D. W.. Human-induced changes in the hydrology of the western United States. *Science*, 319(5866), 1080-1083, 2008.

BRÜCKNER, B.; WESARG, T. Self-Organizing Neural Networks—Recent Advances and Applications, volume 78 of *Studies in Fuzziness and Soft Computing*, chapter Modeling Speech Processing and Recognition in the Auditory System Using the Multilevel Hypermap Architecture, pages 145–64. Physica-Verlag Heidelberg, 2002.

CANNY, J. A computational approach to edge detection. *IEEE transactions on pattern analysis and machine intelligence*, v. 8, n. 6, p. 679–98, jun. 1986.

CASTRO, F. C. C.; CASTRO, M. C. F., *Redes Neurais Artificiais*, PUCRS, Porto Alegre, RS, Brasil, 2001. Disponível em <http://www.ee.pucrs.br/~decastro/RNA_hp/pdf/RNA_C7.pdf>. Acesso em 15 de abril de 2010.

CROSTA, A. P., *Processamento Digital de Imagens de Sensoriamento Remoto*, I.G/UNICAMP – Campinas, SP, Brasil, 1992.

DGI-INPE, Landsat Informações, Disponível em <http://www.dgi.inpe.br/Suporte/files/Cameras-LANDSAT57_PT.php>. Acesso em 15 de novembro de 2013.

DGI-INPE 2, INPE/OBT/DGI - Divisão de Geração de Imagens, Disponível em < http://www.dgi.inpe.br/siteDgi/index_pt.php>. Acesso em 15 de novembro de 2013.

DUDA, R. O., HART, P. E., STORK, D. G. *Pattern classification*. John Wiley & Sons. 2012.

ESCADA, M.; VIEIRA, I.; KAMPEL, S. *Processos de ocupação nas novas*

fronteiras da Amazônia: o interflúvio do Xingu/Iriri. *Estudos Avançados*, v. 19, n. 54, p. 9–23, 2005.

ESCADA, M. I. S.; KAMPEL, S. A.; RENN_O, C. D.; PINHEIRO, T. F. Levantamento do uso e cobertura da terra e da rede de infraestrutura no distrito florestal da BR-163. Instituto Nacional de Pesquisas Espaciais, 2009. Projeto Integrado de Modelagem da Cobertura da Terra no Pará.

FAUSSET L., *Fundamentals of Neural Networks - Architectures, Algorithms, and Applications*, Prentice Hall, 1994.

FAWCETT, T., An introduction to ROC analysis, *Pattern Recognition Letters*, vol. 27, n.8, p. 861-874, 2006.

ESPÍRITO-SANTO, F. D. B.; SHIMABUKURO, Y. E.; ARAGÃO, L. E. O. E. C.; MACHADO, E. L. M. Análise da composição florística e fitossociológica da floresta nacional do Tapajós com o apoio geográfico de imagens de satélites. *Acta Amazônica*, 35 (2): 155-173, 2005.

FELIZARDO, L. F.; MOTA, R. L. M.; SHIGUEMORI, E. H.; NEVES, M. T.; RAMOS, A. C. B. ; MORA-CAMINO, F. . Using ANN and UAV for Terrain Surveillance: A Case Study for Urban Areas Observation. In: 13th International Conference on Hybrid Intelligent Systems, 2013.

FISHER, R.; PERKINS, S.; WALKER, A.; WOLFART, E.; *Hypermedia Image Processing Reference*, University of Edinburgh, 2004. Disponível em <http://homepages.inf.ed.ac.uk/rbf/HIPR2/>. Acessado em 06 de novembro de 2013.

FORD, A.; ROBERTS, A. *Colour Space Conversions*. p. 1–31, University of Westminster, London, UK, 1998.

FRANÇA, D. DE A.; FERREIRA, N. J. Considerações sobre o uso de satélites na detecção e avaliação de queimadas, *Anais do XII Simpósio Brasileiro de Sensoriamento Remoto*, p. 3017–3023, Goiânia, Brasil, 2005.

FRATE, F. D.; SCHIAVON, G.; SOLIMINI, C; Application of neural networks algorithms to QuickBird imagery for classification and change detection of urban areas. v. 00, n. C, p. 1091–1094, 2004.

GLOVIS. GLOVIS: The USGS Global Visualization Viewer. Disponível em <http://glovis.usgs.gov/>. Acesso em 30 de julho de 2014.

GONÇALVES, M. L. et al. An unsupervised method of classifying remotely sensed images using Kohonen self-organizing maps and agglomerative hierarchical clustering methods. [s.l: s.n.]. v. 29p. 3171–3207, 2008.

GONZALES, R.C.; WOODS R. E., *Processamento de Imagens Digitais*, Editora Edgard Blücher, São Paulo, Brasil, 2000.

GROMEK, A., JENEROWICZ, M., *Sar Imagery Change Detection Method For Land Border Monitoring*, Institute of Electronic Systems , Warsaw University of Technology Space Research Centre , Polish Academy of Sciences, MultiTemp, 2011 213–216.

GUORUI, M. A., HAIGANG, S. U. I., PINGXIANG, L. I., QIANQING, Q. I. N. (2004). A Distance-Based Kernel Change Detection Algorithm, 5(1), 1–5.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEIN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 3, n. 6, p. 610–621, nov. 1973.

HARALICK, R. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5), 1979.

HAYKIN, S., *Redes Neurais Princípios e Prática*. Tradução: Paulo Martins Engel, 2. Ed, Porto Alegre, Bookman, 2001.

HELLER, R. C, ULLIMAN, J. J. Forest resource assessments. *Manual of remote sensing*, v. 2, p. 2246, 1983.

HEWITSON, B. C.; CRANE, R. G. Self-organizing maps : applications to synoptic climatology. v. 22, p. 13–26, 2002.

HUANG, H. Y., CHEN, Y. S., AND HSU, W. H. Color image segmentation using a self-organizing map algorithm. *Journal of Electronic Imaging*, 11(2):136–148, 2002.

IWASHITA, F., FRIEDEL, M. J., RIBEIRO, G. F., FRASER, S. J. Intelligent estimation of spatially distributed soil physical properties. *Geoderma*, v. 170, p. 1–10, jan. 2012.

KIANG, M. Y. Extending the kohonen self-organizing map networks for clustering analysis, *COMPUTATIONAL STATISTICS & DATA ANALYSIS*, 38(2):161–180, 2001.

KOHONEN, T., *Self-Organizing Maps*, 3rd edition, Springer, 2000.

KÖRTING, T. S., *Classificação de Imagens por Regiões*, Divisão de Processamento de Imagens, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, Brasil, 2006.

LEE, K.; BOOTH, D.; ALAM, P. A comparison of supervised and unsupervised neural networks in predicting bankruptcy of Korean firms. *Expert*

Systems with Applications, v. 29, n. 1, p. 1–16, jul. 2005.

LIPPMANN, R. Pattern classification using neural networks. Communications Magazine, IEEE, p. 47-64, November, 1989.

MA, G., SUI, H., LI, P., QIN, Q. A Distance-Based Kernel Change Detection Algorithm. v. 5, n. 1, p. 1–5, 2004.

MA, Y.; LI, H.; GU, H. A Study of Fast Change Detection Algorithm Based on Feature Library of Remote Sensing Imagery. 2011 International Symposium on Image and Data Fusion, p. 1–3, ago. 2011.

MANGIAMELI, P. A comparison of SOM neural network and hierarchical clustering methods. v. 2217, n. 96, 1996.

MEHROTRA, R.; NAMUDURI, M.; RANGANATHAN, N., Gabor filter-based edge detection, Pattern Recognition, vol.25, Iss.12, pp.1479–1494, 1992.

MOTA, R. L. M.; FELIZARDO, L. F.; SHIGUEMORI, E. H.; RAMOS, A. C. B.; MORA-CAMINO, F.; Expanding Small UAV Capabilities with ANN: A Case Study for Urban Areas Inspection. British Journal of Applied Science & Technology, v. 4, p. 387-398, 2014.

NASA, Landsat Science, Disponível em <<http://landsat.gsfc.nasa.gov/>>. Acesso em 15 de novembro de 2013.

NEGRI, R. G. Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia. 170f. Dissertação (Mestrado). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP. 2009.

PEREIRA, L.O. Diferentes métodos de integração de dados ópticos e radar para mapeamento do uso e cobertura da terra na mesorregião do baixo amazonas. 236f. Dissertação (Mestrado). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP. 2012.

PERSSON, M.; SANDVALL, M.; DUCKETT, T. Automatic Building Detection from Aerial Images for Mobile Robot Mapping. 2005 International Symposium on Computational Intelligence in Robotics and Automation, p. 273–278, 2005.

RODRIGUES, R. C. B. et al. Color and Texture Features for Landmarks Recognition on UAV Navigation. Anais do XIV Simpósio Brasileiro de Sensoriamento Remoto, p. 7111–7118, Natal, Brasil, 2009.

SHIGUEMORI, E. H. et al. Landmarks Recognition for Autonomous Aerial Navigation by Neural Networks and Gabor Transform. v. 6497, n. 12, p. 1–9, 2007.

SINGH, A. Digital change detection techniques using remotely-sensed data.

International Journal of Remote Sensing, v. 10, n. 6, p. 989–1003, jun. 1989.

SOBEL, I., Neighborhood coding of binary images fast contour following and general array binary processing, Elsevier Computer Graphics and Image Processing, Vol. 8, Iss.1, pp.127-135, 1978.

SU, Y. et al. Automatic detection and classification of breast tumors in ultrasonic images using texture and morphological features. The open medical informatics journal, v. 5, n. Suppl 1, p. 26–37, jan. 2011.

SUJATHA, C.; SELVATHI, D. An Optimal Solution For Image Edge Detection Problem Using Simplified Gabor Wavelet. International Journal of Computer Science, v. 2, n. 3, p. 99–115, 2012.

TAHIR, A. A. Integrating artificial neural network and classical methods for unsupervised classification of optical remote sensing data. EURASIP Journal on Advances in Signal Processing, v. 2012, n. 1, p. 165, 2012.

ULABY, F.T., MOORE, R.K. e FUNG, A. K., Microwave remote sensing, active and passive, v. 1, 2 e 3, Artech House Inc. U.S.A, 1986.

VON ZUBEN, F; CASTRO, L. N., Rede Neural de Kohonen e Aprendizado Não-Supervisionado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, SP, Brasil, 2007. Disponível em <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia353_03/topico10_03.pdf>. Acesso em 11 de setembro de 2012.

WANG, H., SUTER, D., Color image segmentation using global information and local homogeneity. In Proceeding of 7th Conference of Digital Image Computing: Techniques and Applications, p. 89-98, Sydney, Australia, Dezembro, 2003.

WULDER, M. Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. Progress in Physical Geography, v. 22, n. 4, p. 449–476, 1 out. 1998.

XAUD, M.; EPIPHANIO, J.; XAUD, H. Análise das mudanças de uso e cobertura da terra no sudeste de Roraima–Brasil. Anais do XV Simpósio Brasileiro de Sensoriamento Remoto, p. 6779–6785, Curitiba, Brasil, 2011.

YANG, X.; BEITLER, J. J.; YU, D. S. Ultrasound GLCM texture analysis of radiation-induced parotid-gland injury in head-and-neck cancer radiotherapy: An in vivo study of late toxicity. v. 39, n. September, p. 5732–5739, 2012.

ZEE BR-163. Zoneamento ecológico-econômico da rodovia BR-163: caracterização da área de estudo. 2008. Disponível em:

<<http://zeebr163.cpatu.embrapa.br>>. Acesso em 23 de agosto de 2012.