

**LUCAS SILVA DA SILVEIRA**

**IDENTIFICAÇÃO DE ÁREAS CULTIVADAS COM CAFÉ POR MEIO DE  
DESCRITORES TEXTURAIS**

Dissertação apresentada à  
Universidade Federal de Viçosa, como  
parte das exigências do Programa de  
Pós-Graduação em Engenharia  
Agrícola, para obtenção do título de  
*Magister Scientiae*.

VIÇOSA  
MINAS GERAIS – BRASIL

2013

**Ficha catalográfica preparada pela Seção de Catalogação e  
Classificação da Biblioteca Central da UFV**

T

S587i  
2013  
Silveira, Lucas Silva da, 1986-  
Identificação de áreas cultivadas com café por meio de  
descritores texturais / Lucas Silva da Silveira. – Viçosa, MG,  
2013.

ix, 74 f. : il. (algumas color.) ; 29 cm.

Inclui apêndices.

Orientador: Francisco de Assis de Carvalho Pinto.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Café - Cultivo. 2. Sensoriamento Remoto. 3. MATLAB  
(Programa de computador). I. Universidade Federal de Viçosa.  
Departamento de Engenharia Agrícola. Programa de  
Pós-Graduação em Engenharia Agrícola. II. Título.

CDD 22 ed. 633.73

**LUCAS SILVA DA SILVEIRA**

**IDENTIFICAÇÃO DE ÁREAS CULTIVADAS COM CAFÉ POR MEIO DE  
DESCRITORES TEXTURAIIS**

Dissertação apresentada à  
Universidade Federal de Viçosa, como  
parte das exigências do Programa de  
Pós-Graduação em Engenharia  
Agrícola, para obtenção do título de  
*Magister Scientiae*.

APROVADA: 19 de julho de 2013

---

Prof. Fábio Lúcio Santos

---

Prof. Elpídio Inácio Fernandes Filho

---

Prof. Domingos Sárvio Magalhães Valente

(Presidente da Banca)

*A Deus, aos meus pais José Luiz  
e Marlene Silva, ao meu irmão  
Alex e a todos que ajudaram  
nesta conquista..*

*Ofereço*

## **AGRADECIMENTOS**

Ao único digno de toda glória e louvor: DEUS.

Aos meus queridos pais, José Luiz e Marlene Silva, pelo amor, carinho e por todo incentivo e apoio incondicional.

Ao meu irmão Alex pela amizade, força e companheirismo.

À Universidade Federal de Viçosa, em especial ao Departamento de Engenharia Agrícola pela oportunidade da realização do curso de Mestrado.

Ao Professor Francisco de Assis de Carvalho Pinto, pela amizade, orientação, confiança e incentivo na realização deste trabalho.

Aos Professores Domingos Sárvio Magalhães Valente e Madelaine Venzon pelo auxílio e valiosas sugestões para o desenvolvimento deste trabalho.

Aos professores e colegas do Laboratório de Mecanização Agrícola e do Departamento de Engenharia Agrícola da UFV pelo auxílio, amizade e bom convívio.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa concedida.

Aos funcionários do Laboratório de Mecanização Agrícola pela ajuda no decorrer do curso.

Aos amigos de república Udson, Dalton, Marcos, Rafael e Arthur, pela amizade e ajuda.

A todos que de alguma forma contribuíram na realização deste trabalho.

## **BIOGRAFIA**

LUCAS SILVA DA SILVEIRA, filho de Marlene Silva da Silveira e José Luiz da Silveira, nasceu no dia 26 de setembro de 1986 no município do Rio de Janeiro, Rio de Janeiro.

Em Fevereiro de 2010, conclui o curso de Engenharia Agrícola pela Universidade Federal Rural do Rio de Janeiro.

Em Fevereiro de 2011, iniciou o curso de Mestrado em Engenharia Agrícola na área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa, submetendo-se a defesa de dissertação em Junho de 2013.

## SUMÁRIO

RESUMO .....	vii
ABSTRACT .....	ix
1. INTRODUÇÃO GERAL .....	1
2. REVISÃO BIBLIOGRÁFICA .....	4
2.1. Comportamento espectral da cultura cafeeira .....	4
2.2. Textura em imagens .....	5
2.2.1. Textura .....	5
2.2.2. Matrizes de co-ocorrência .....	7
2.3. Redes Neurais Artificiais (RNAs) .....	8
2.3.1. Aprendizado da rede .....	10
2.3.1.1. Aprendizado supervisionado .....	10
2.3.1.2. Aprendizado não supervisionado .....	11
2.3.2. Algoritmo de retropropagação de erro .....	11
2.3.3. Dificuldades no dimensionamento da rede .....	12
3. MATERIAL E MÉTODOS .....	13
3.1. Primeiro estudo de caso .....	15
3.1.1. Geração dos blocos de textura .....	15
3.1.2. Cálculo dos descritores de textura .....	16
3.1.3. Desenvolvimento das RNAs .....	17
3.1.4. Desempenho das RNAs .....	18
3.1.5. Classificação do recorte da imagem pela RNA .....	23
3.1.6. Desempenho da classificação da imagem .....	24
3.2. Segundo estudo de caso .....	25
4. RESULTADOS E DISCUSSÃO .....	30
4.1. Primeira estudo de caso .....	30
4.1.1. Análise dos parâmetros de entrada para composição das RNAs.....	30
4.1.2. Classificação do recorte da imagem utilizando a melhor RNA treinada	34
4.2. Segundo estudo de caso .....	37

4.2.1. Análise dos parâmetros de entrada para composição das RNAs.....	37
4.2. Classificação da imagem para o segundo estudo de caso .....	39
5. CONCLUSÕES .....	44
6. Referências Bibliográficas .....	45
APÊNDICE A .....	52
APÊNDICE B .....	54
APÊNDICE C .....	57
APÊNDICE D .....	65
APÊNDICE E .....	67
APÊNDICE F .....	69
APÊNDICE G .....	72

## RESUMO

SILVEIRA, Lucas Silva da, M. Sc., Universidade Federal de Viçosa, julho de 2013. **Identificação de áreas cultivadas com café por meio de descritores texturais**. Orientador: Francisco de Assis de Carvalho Pinto. Coorientadores: Domingos Sárvio Magalhães Valente e Madelaine Venzon.

A importância da cafeicultura para o Brasil é notória, em especial para o estado de Minas Gerais que é o estado brasileiro responsável pela maior parte da produção nacional. Nas regiões sul e da zona da mata onde estão concentradas a maior parte da lavoura no estado de Minas Gerais, há a predominância de pequenas propriedades e o cultivo é feito em região de montanha o que acaba dificultando o mapeamento por métodos automatizados. A aplicação de Redes Neurais Artificiais (RNAs) tendo como variáveis de entrada os descritores de Haralick tem se mostrado uma abordagem promissora na discriminação de classes de maior complexidade. Neste contexto objetivou-se desenvolver um sistema para identificar áreas cultivadas com café utilizando RNAs tendo como variáveis de entrada os descritores de Haralick. A área de estudo está localizada no município de Araponga, onde foram selecionados 59 talhões com plantios de café, sendo levantados dados relativos à idade e data de recepa. O software utilizado para o processamento e classificação da imagem foi o MATLAB, e para avaliar o desempenho da classificação foi o Arcgis. A metodologia para o desenvolvimento da RNA consistiu em duas etapas: na primeira a RNA foi treinada com amostras representativas de cada classe de interesse (café, mata, água, solo exposto e pastagem e área urbana), verificando assim o potencial em discriminar entre as classes de saída; na segunda etapa o objetivo foi classificar as plantações de café de acordo com a idade e com a data de recepa. Utilizou-se o índice Kappa para avaliar o desempenho da RNA, uma vez que o uso desse coeficiente é satisfatório na avaliação da precisão de uma classe temática. O índice Kappa para discriminar a região cafeeira das outras classes temáticas foi de 65,18%, o que pode ser considerado um índice bom. Para classificar os plantios de café em função da idade e data de recepa o índice Kappa foi variável (0,675 a

0,4783), sendo considerado muito bom para a fazenda Itatiaia e razoável para a fazenda Pedra Redonda.

## ABSTRACT

SILVEIRA, Lucas Silva da, M. Sc., Universidade Federal de Viçosa, July, 2013. **Identification of coffee cultivated areas through textural descriptors.** Advisor: Francisco de Assis de Carvalho Pinto. Co-advisors: Domingos Sárvio Magalhães Valente e Madelaine Venzon.

The importance of coffee agriculture in Brazil is notorious, especially for the State of Minas Gerais, which is the Brazilian state that accounts for most of the national production. In the Southern region and in Zona da Mata they are concentrated most of the crops of the State; also, small holdings are predominant in the region and cultivation is done in mountain region, what makes it difficult mapping the crops by automated methods. The application of Artificial Neural Networks (ANNs), having as input variables Haralick's descriptors, has shown a promising approach for the discrimination of higher complexity classes. In this context, it aimed to develop a system to identify areas where coffee is cultivated using ANNs, having as input variables Haralick's descriptors. The studied area is located at the city of Araponga, where 59 fields were selected with coffee plantations for data collection. The software used for processing and sorting the images was MATLAB; and for evaluating the sorting performance, Arcgis was used. The methodology for the development of ANN consisted in two steps: in the first step, the ANN was trained with representative samples of each class of interest (coffee, forest, water, bare soil, and grassland, and urban area), thus verifying the potential to discriminate output classes; in the second step the objective was to classify the coffee plantations accordingly with the age. Kappa index was used for evaluating the performance of ANN; the usage of this coefficient is satisfactory for assessing the accuracy of a thematic class. Kappa index for discriminating the coffee region of the other class of interest was 65,18%, what can be considered a good index. To classify the coffee plantations accordingly with the age, Kappa index was variable (0.675 to 0.4783), being very good for the Itatiaia farm and reasonable to the Pedra Redonda farm.

## 1. INTRODUÇÃO GERAL

O cultivo do café (*Coffea arabica* L.) é importante para a economia do país, tanto para o mercado interno quanto para o externo. A produção total de café beneficiado no País em 2012 foi de 50,48 milhões de sacas de 60 quilos beneficiados (CONAB, 2013). O estado de Minas Gerais possui a maior área plantada, com 1.208,8 mil hectares na qual predomina a espécie arábica com 97,7%.

Para o gerenciamento racional da atividade cafeeira, a caracterização e o mapeamento dos seus agroecossistemas constituem informação imprescindível para o direcionamento das atividades agrícolas, para a preservação dos recursos naturais existentes e para a sustentabilidade do agronegócio café. Essa caracterização precisa ser constantemente atualizada no tempo e no espaço, visando o estabelecimento dos parâmetros necessários para o monitoramento da atividade (TRABAQUINI et al., 2011).

Os dados referentes às áreas de plantio e quantidade produzida são obtidos através de questionários feitos junto a produtores, cooperativas e órgãos públicos. Segundo Ippoliti-Ramilo et al. (1999), essa metodologia caracteriza-se pelo alto custo e pela dificuldade de obtenção de dados em curtos períodos de tempo, o que acaba limitando a sua aplicação. O avanço das ferramentas computacionais têm auxiliado a extração de informações adquiridas a partir de imagens orbitais para várias atividades agrícolas (RUDORFF et al., 2010; GALVÃO et al., 2009; SOARES et al., 2008; RIZZI e RUDORFF, 2007).

A aplicação do Sensoriamento Remoto (SR) representa um avanço significativo na obtenção de informações para a agricultura, como mostra o trabalho de Lamparelli et al. (2012), que identificaram diferentes condições de cultivo de plantas de café, após o período de colheita, usando mineração de dados e o comportamento espectral de imagens obtidas através do satélite Hyperion.

Utilizar as características texturais para realizar inferições em imagens orbitais é também uma opção, como Shiguemori et al. (2007) que desenvolveram um sistema de classificação de imagens em tempo real com a utilização de descritores de textura retirados de um banco de dados gerado a partir de uma imagem orbital. O sistema de reconhecimento consistia no treinamento de uma rede neural baseado nesses descritores de textura para classificação em tempo real de imagens aéreas que foram tomadas a partir de uma câmera acoplada a um helicóptero.

A classificação de imagens é um procedimento pelo qual, a partir de uma imagem observada, obtém uma nova imagem, onde a cada posição é atribuído um único rótulo, entre K possíveis. A classificação tenta identificar regiões da imagem onde os pixels tenham características similares, com o objetivo de identificar regiões ou áreas de interesse que caracterizem um determinado objeto, ou tema. Neste contexto, são inseridos os descritores de textura de Haralick que descreveram textura como sendo as variações tonais repetitivas e organizadas em uma pequena região da imagem (HARALICK et al., 1973).

Os métodos de classificação de imagens têm sido largamente utilizados devido a sua aplicabilidade em sistemas automáticos de mapeamento em áreas agrícolas. As Redes Neurais Artificiais (RNAs) têm se apresentado como uma alternativa aos métodos tradicionais para o reconhecimento de padrões. As RNAs são modelos não lineares, inspirados na funcionalidade dos neurônios biológicos para otimização e previsão de sistemas complexos.

Tais fatos justificam o uso dessa tecnologia no estudo da determinação da área de plantio da cultura do cafeeiro de maneira espacial e temporal. Promover a identificação desse atributo de maneira automatizada contribuirá para o manejo mais racional dessa cultura. Dessa forma, pretende-se fazer uso desses dados para interpretação e mapeamento de áreas cafeeiras por meio de métodos que permitam tal

inclusão, como o processamento de imagens e o treinamento de redes neurais.

O objetivo geral deste trabalho foi desenvolver um sistema para identificar áreas cultivadas com café utilizando imagens orbitais, e os objetivos específicos foram:

- Analisar diferentes resoluções radiométricas e diferentes dimensões de blocos da imagem para gerar os descritores de textura;
- Desenvolver um algoritmo para discriminar lavouras de café em imagens orbitais utilizando-se redes neurais artificiais;
- Desenvolver um classificador utilizando redes neurais artificiais para discriminar diferentes idades do cafeeiro nas lavouras de café.

## **2. REVISÃO BIBLIOGRÁFICA**

### **2.1. Comportamento espectral da cultura cafeeira**

Para o gerenciamento mais racional das áreas agrícolas é importante fazer uma estimativa da área plantada, e uma das primeiras tarefas é gerar o mapa de distribuição de uma dada cultura. A abordagem mais utilizada para esta tarefa é realizada de forma operacional, através de métodos baseados em entrevistas com agricultores ou entidades relacionadas ao setor agrícola.

No entanto, essa abordagem é demorada e cara, o que dificulta fazer sua atualização constantemente (MARTÍNEZ-VERDUZCO et al., 2012). Para contornar esse problema, pesquisadores vêm estudando maneiras de fazer o levantamento e monitoramento de áreas agrícolas, utilizando técnicas de sensoriamento remoto (CLAVERIE et al., 2012; AMORÓS LÓPEZ et al., 2011; PEÑA-BARRAGÁN et al., 2011).

O estudo da vegetação através do sensoriamento remoto é bastante complexo devido à vários fatores, entre eles: as propriedades de reflexão foliar variadas numa mesma planta, múltiplos componentes refletores, não uniformidade de estruturas inter e intraplantas. Além de estar assentada sobre um substrato constituído de solo e restos vegetais, que apresentam propriedades de reflexão próprias (PONZONI e SHIMABUKURO, 2010).

A cultura cafeeira tem sido mapeada com sucesso por diversos pesquisadores (MARTÍNEZ-VERDUZCO et al., 2012; GOMEZ et al., 2010; NIEDERHAUSER et al., 2008). Especificamente em Minas Gerais, obtiveram bons resultados no mapeamento e caracterização da cultura cafeeira na região (LAMPARELLI et al., 2012.; MOREIRA et. al., 2010).

Moreira et. al. (2010) relatam que as lavouras cafeeiras apresentam uma significativa variação na resposta espectral. Isto é devido, dentre outras coisas: a uma grande diversidade de práticas de

manejo, lavouras de diferentes idades, áreas de diferentes tamanhos, espaçamentos (tradicional, adensado e superadensado) e variedades (Catuaí, Mundo Novo, Acaiá, Icatu e Caturra).

No entanto, a resposta espectral da cultura cafeeira é bastante complexa, em função das diversas variáveis que envolvem a caracterização da mesma e do ambiente em que está inserida (MOREIRA et al., 2004). Além disso, a resposta espectral do café e da vegetação natural é muito semelhante (LOPEZ-GOMEZ et al., 2008), isso acaba dificultando a sua discriminação em região de montanha, pois o plantio nessa região se dá próximo de áreas florestais (MARTÍNEZ-VERDUZCO et al., 2012). Com isso é esperado uma confusão entre essas duas classes. Por outro lado, o que mais diferencia visualmente uma área de mata, de uma área ocupada por café é a textura das imagens (GOMEZ et al., 2010).

Usar as características texturais no processo de classificação de imagens vem ganhando destaque na comunidade científica (WOOD et al., 2012; RUIZ et al., 2011; TSANEVA et al., 2010). Isso se deve ao fato que muitas cenas naturais são muito similares espectralmente. Com isso há uma baixa exatidão na classificação, quando somente esses atributos espectrais são utilizados. Apesar dessa similaridade espectral, em muitos casos, essas mesmas cenas apresentam características texturais muito distintas. Dessa forma um algoritmo de classificação com base em características texturais poderia ter um potencial de exatidão na classificação muito maior.

## **2.2. Textura em imagens**

### **2.2.1. Textura**

Embora o termo textura seja popular e de fácil compreensão, não existe uma definição universalmente aceita (ILEA e WHELAN, 2011). Ela pode ser caracterizada como variações locais dos valores de pixels que

se apresentam de maneira regular ou aleatória ao longo do objeto ou da imagem (SKLANSKY, 1978).

A classificação da imagem por características texturais é geralmente feita em duas etapas: extração das características e classificação dos atributos (TSANEVA et al., 2010). A extração das características é usada para diferenciar um objeto do outro. Isso é importante para caracterizar as classes existentes na imagem, para serem utilizados na etapa posterior que é a classificação.

Há três abordagens principais utilizadas para classificação de imagens por meio de suas características texturais: a estatística, a estrutural e a espectral (GONZALEZ e WOODS, 2000). Na abordagem estatística é utilizado um conjunto de medidas estatísticas locais para representar uma imagem. Na abordagem estrutural, a textura é caracterizada a partir de primitivas de textura que são ordenadas a partir de regras sintáticas, formando padrões. Já a abordagem espectral é fundamentada nas propriedades do espectro de Fourier, permitindo a detecção de periodicidade global em imagens através da identificação de pontos máximos de espectro.

Haralick et al. (1973) propôs uma metodologia embasada em estatística de segunda ordem. Neste método são definidas características provenientes da matriz de co-ocorrência. Essas matrizes de co-ocorrência utilizam o relacionamento espacial existente entre os pixels de uma imagem de acordo com os níveis de cinza. Através dessas matrizes são elaboradas diversas medidas estatísticas, conhecidas como descritores de textura de haralick.

Neste trabalho, a técnica para caracterização de textura foi baseado na abordagem estatística. Deste ponto em ela será elucidada com mais detalhes.

### 2.2.2. Matrizes de co-ocorrência

Uma imagem digital pode ser caracterizada como uma matriz em que o índice de linha ( $N_i$ ) e coluna ( $N_j$ ) identificam um ponto na imagem, e o valor do elemento na matriz identifica o nível de cinza ( $N_g$ ) naquele ponto. Cada elemento nessa matriz “M” é chamado de pixel, e ela tem dimensão ( $N_i \times N_j$ ) segundo a notação linha-coluna. A imagem digital pode ser definida como uma função bidimensional  $f(i,j)$  com  $i,j \in Z^2$ .

A matriz de co-ocorrência é uma matriz quadrada, de dimensão  $N_g \times N_g$  cujo elemento da linha  $i$  coluna  $j$ , denominado  $p_d(i,j)$  corresponde a frequência relativa  $P(i, j, d, \Theta)$ , e leva em consideração dois pixels vizinhos separados pela distância  $d$  na orientação  $\Theta$ , um pixel com tom de cinza  $i$  e outro com tom de cinza  $j$ . Normalmente são utilizados quatro direcionamentos:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ , conforme pode ser visto na Figura 1.

Essa matriz é construída de forma que para cada pixel  $p(i,j)$  presente na imagem, uma janela em torno dele, com distância  $d$  e direção  $\Theta$  será criado um valor na matriz de co-ocorrência de tons de cinza.

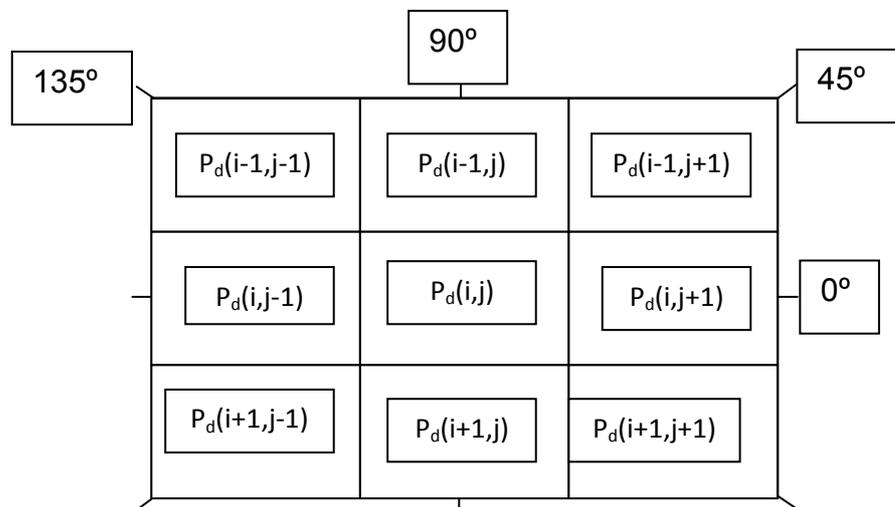


Figura 1: Variação das janelas angulares ( $\Theta$ ) utilizadas no cálculo das matrizes de co-ocorrência. (Adaptado de PEDRINI e SCHWARTZ, 2008).

As matrizes de co-ocorrência são a base para o cálculo dos descritores de textura de Haralick. Neste trabalho foram usados seis descritores de textura: Contraste, Correlação, Entropia, Homogeneidade, Segundo momento angular e a Variância.

### **2.3. Redes Neurais Artificiais (RNAs)**

O desenvolvimento de sistemas inteligentes também conhecidos como inteligência computacional, baseou-se na hipótese que esses sistemas poderiam mimetizar comportamentos e raciocínios humanos. As RNAs estão inseridas dentro dessa área conhecida como sistemas inteligentes, e são modelos computacionais inspirados no sistema nervoso do ser humano. Elas possuem a capacidade de aquisição, manutenção e generalização (baseado em informações) do conhecimento, podendo ser útil em várias tarefas como: classificação de imagens captadas de satélite, classificação de padrões de escrita e de fala, identificação de anomalias em imagens médicas, entre outras (HAYKIN, 2001).

As RNAs são compostas por elementos computacionais denominados neurônios artificiais. Os neurônios artificiais foram inspirados a partir da análise de geração e propagação de impulsos elétricos pela membrana celular dos neurônios. Desse modo, eles devem funcionar recebendo e retransmitindo informações (HAYKIN, 2001).

A forma como os neurônios artificiais são agrupados é uma importante característica que define o tipo de arquitetura das RNAs. Estes agrupamentos são baseados na maneira como os neurônios são conectados no cérebro humano, de forma que as informações possam ser processadas de forma dinâmica ou interativa (BRAGA et al., 2000).

Existem RNAs de camada simples (Perceptron), que possuem um único neurônio tanto na camada de entrada da rede quanto na camada de

saída e são indicados para solução de problemas linearmente separáveis (HAYKIN, 2001). E existem as redes neurais de múltiplas camadas, onde a camada de entrada é aquela na qual os padrões são apresentados à rede, as camadas intermediárias são responsáveis por grande parte do processamento, podendo ser consideradas como extratoras de características, e a camada de saída é aquela onde o resultado final é concluído e apresentado.

A Figura 2 ilustra um esquema representativo de uma RNA com arquitetura de múltiplas camadas.

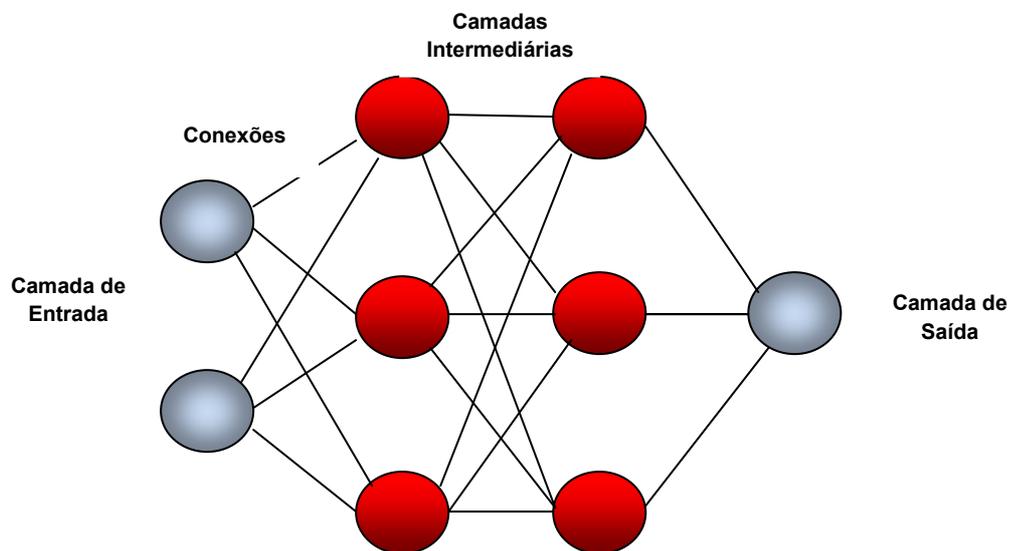


Figura 2: Esquema representativo de uma RNA com arquitetura de múltiplas camadas (Adaptado de BRAGA et al., 2000).

As redes neurais possuem uma etapa de treinamento, onde os pesos são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem a partir de experiências, e são capazes de generalizar diante de informações que não lhe foram apresentadas durante o treinamento (HAYKIN, 2001).

### **2.3.1. Aprendizado da rede**

A principal característica de uma RNA é a sua capacidade de adaptação e aprendizagem por meio de exemplos, e com isso melhorar o seu desempenho. Graças a essa característica a rede é capaz de lidar com um volume de dados imprecisos e situações não definidas, tendo a capacidade de generalizar o conhecimento em um conjunto de dados desconhecidos (BRAGA et al., 2000).

Na etapa de aprendizagem, a RNA extrai informações relevantes dos padrões que lhes são apresentados. Ela faz um ajuste dos parâmetros de forma contínua, estimuladas pelo ambiente no qual está operando. Isto é feito para que a RNA adquira de modo gradativo uma boa capacidade de resposta para o maior número de situações possíveis (HAYKIN, 2001).

Existem dois paradigmas de aprendizado da rede (supervisionado e não supervisionado) e eles se diferem pela maneira como ocorrem os ajustes dos parâmetros.

#### **2.3.1.1. Aprendizado supervisionado**

É o método mais comum de aprendizado das RNAs, neste método tanto a entrada quanto a saída desejada, são indicados por um agente externo, conhecido como supervisor da rede. Neste tipo de treinamento temos a regra de aprendizado do tipo correção dos erros. Conforme os padrões são apresentados à rede, a resposta calculada é comparada com a resposta desejada, ajustando os pesos das conexões para minimizar o erro (BRAGA et al., 2000). O aprendizado supervisionado se aplica em problemas em que se deseja obter um mapeamento entre os padrões de entrada e saída.

### **2.3.1.2. Aprendizado não supervisionado**

Já no treinamento não supervisionado, não há um supervisor externo para acompanhar o processo de aprendizado. Os vetores de entrada são apresentados à rede, e ela deverá ser capaz de organizá-los pela similaridade de suas propriedades. Para haver o aprendizado não supervisionado há necessidade de existir uma redundância mínima entre os dados de entrada (BRAGA et al., 2000). O aprendizado não supervisionado visa desvendar os padrões estatísticos existentes entre os dados, para que ele possa organizá-los em grupos (clusters).

### **2.3.2. Algoritmo de retropropagação de erro**

O algoritmo de retropropagação de erro (Backpropagation) é o método mais conhecido (HAYKIN, 2001). Ele usa o paradigma do aprendizado supervisionado, e a regra da correção dos erros, para ajustar os parâmetros da rede. Os parâmetros são ajustados em cada uma das camadas da rede, isto é feito para minimizar a soma do erro médio quadrático entre a saída calculada por uma arquitetura e a saída desejada.

O treinamento pelo método de retropropagação do erro, o backpropagation, se dá em duas fases. Primeiro os padrões são apresentados à rede, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte, até a camada de saída, onde é obtida a resposta da rede. Se essa resposta não estiver correta é calculado o erro. A segunda fase consiste em uma segunda passagem, através da rede a partir da última camada, durante a qual o erro é repassado para cada elemento de processamento e os parâmetros correspondentes são modificados (BRAGA et al., 2000).

### **2.3.3. Dificuldades no dimensionamento da rede**

Segundo Braga et al. (2000), existem várias dificuldades para o dimensionamento das RNAs em relação à definição dos seguintes parâmetros: quantidade de camadas, o número de neurônios de cada camada, a função de ativação e a regra de treinamento. Uma pequena diferença na determinação desses parâmetros pode resultar em grande diferença no tempo de treinamento e capacidade de generalização da rede.

A utilização de um número muito grande de camadas escondidas não é recomendada. Pois durante o treinamento, o erro quadrático médio é utilizado para atualizar os pesos da camada seguinte. A última camada é a única que tem o real valor do erro cometido. Sendo assim a penúltima camada escondida recebe uma estimativa da estimava. Desta forma, a utilização de um número de camadas diferente do ideal pode levar a problemas de convergência da rede (HAYKIN, 2001).

Na maioria dos casos, uma rede com apenas uma camada intermediária é capaz de aproximar qualquer função contínua, e redes com duas camadas intermediárias são capazes de aproximar qualquer função.

Já o número ideal de neurônios nas camadas intermediárias, pode se tornar um problema mais complexo, pois não existe na literatura uma regra geral que determine de forma precisa qual deve ser o número de neurônios para a solução de um determinado tipo de problema. Caso se utilize neurônios demais há a possibilidade da rede memorizar os dados (overfitting), com isso ela começa a piorar o desempenho quando confrontada com um novo conjunto de dados. Já quando a rede possui um baixo número de neurônios (underfitting) ela não será capaz de produzir resultados satisfatórios (BRAGA et al., 2000).

### 3. MATERIAL E MÉTODOS

A área de estudo está localizada no município de Araponga, na região da Zona da Mata Mineira conforme mostra a Figura 3, com coordenadas 20° 40' de latitude Sul e 42° 31' de longitude Oeste. Esse município possui altitudes que variam de 600m a 2000m, solos argilosos, e o clima da região apresenta verões brandos e invernos fortes. Segundo a classificação climática de Köppen (1928), destaca-se o subtipo tropical de altitude (Cwa), com chuvas durante o verão e temperatura média anual em torno de 19 °C, com variações médias entre 12 e 26°C.

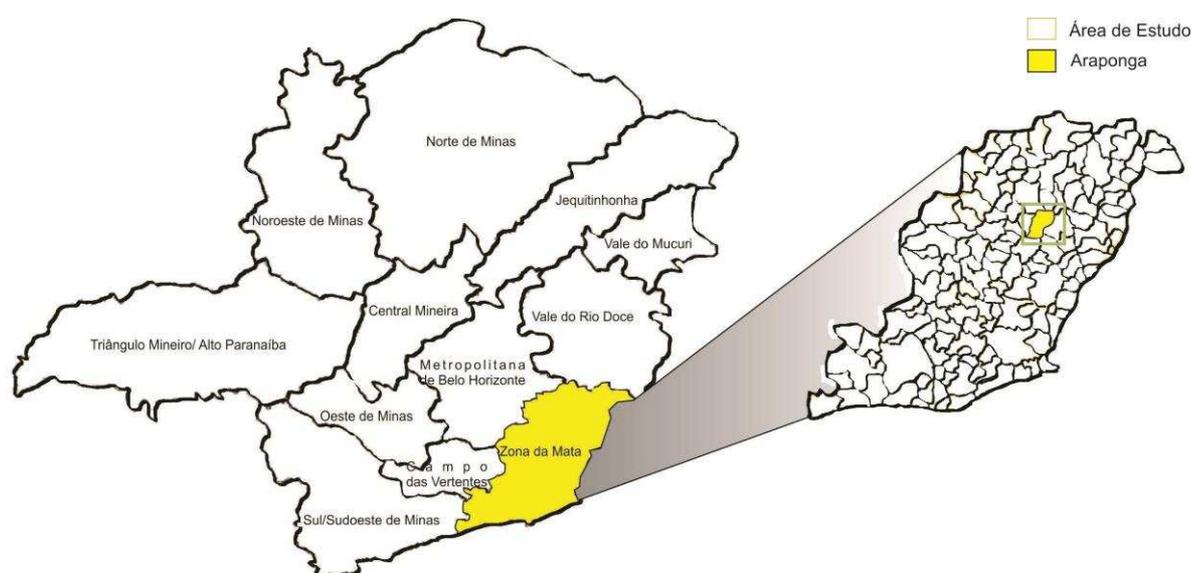


Figura 3: Localização da área de estudo: Araponga no estado de Minas Gerais (Adaptado de ALVES et al., 2012).

Para fazer a classificação automatizada utilizando redes neurais artificiais, foi adquirida uma imagem de alta resolução do satélite GeoEye-1 com data de passagem no dia 11/07/2012. Essa imagem tem resolução espacial de 1,64 m no modo multiespectral, resolução radiométrica de 11 bits, e quatro bandas espectrais: azul (450-520 nm), verde (520-600 nm), vermelho (625-695 nm) e infravermelho (760-900

nm). A área abrangida pela imagem foi de 10 km x 10 km, o que garante a cobertura de várias lavouras de café com diferentes idades no entorno da cidade de Araponga.

Foram desenvolvidos dois classificadores utilizando-se redes neurais artificiais (RNAs) para dois estudos de caso. No primeiro estudo de caso foi desenvolvido um classificador para discriminar as plantações de café das outras classes temáticas (área urbana, mata, solo exposto, água). O segundo estudo de caso foi desenvolvido para discriminar estágio de desenvolvimento das plantações de café de acordo com a idade de plantio e data de recepa. Em ambas as situações as RNAs dos classificadores tiveram como parâmetros de entrada os descritores de textura. Os descritores de textura foram calculados com amostras de blocos recortadas de cada classe de interesse na imagem original.

Em ambos os estudos os classificadores foram desenvolvidos com base nos seguintes passos: geração dos blocos de textura, cálculo dos descritores de textura, desenvolvimento das RNAs, desempenho das RNAs treinadas, classificação da imagem pela RNA e desempenho da classificação da imagem.

### 3.1. Primeiro estudo de caso

#### 3.1.1. Geração dos blocos de textura

Foram selecionadas na imagem regiões representativas de cada classe de interesse, conforme pode ser conferido na Figura 4. Essas classes foram definidas da seguinte forma: **café**: correspondente aos cafezais em todas as suas fases de desenvolvimento; **mata**: correspondente a vegetação silvestre de porte variado, incluindo matas ciliares e plantio de eucaliptos; **área urbana**: área com grande concentração de construções; **solo exposto e pastagem**: área onde não há ocorrência de construções; e **água**: área correspondente a rios, lagos e represas.

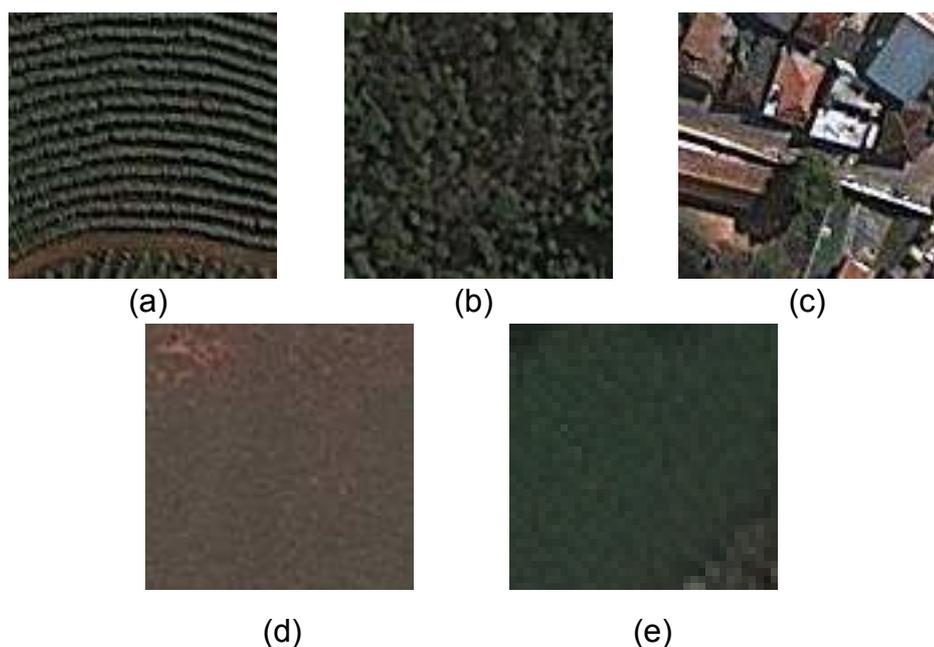


Figura 4: Exemplo dos recortes das regiões representativas de cada classe de interesse: Classe café (a); Classe mata (b); Classe área urbana (c); Classe solo exposto e pastagem (d); Classe água (e).

### 3.1.2. Cálculo dos descritores de textura

Para selecionar as amostras representativas de cada classe de interesse, foi desenvolvido no programa computacional MATLAB® uma rotina de recorte da imagem (Apêndice A).

Para obtenção dos descritores texturais, foram selecionadas 40 amostras de cada uma dessas classes, com três janelas de diferentes dimensões: 5x5, 7x7 e 9x9 pixels. Esse processamento foi feito com o auxílio de uma rotina desenvolvida no sistema computacional MATLAB® (Apêndice B).

Foi calculada uma matriz de co-ocorrência para cada combinação de tamanho de bloco recortado, banda espectral (azul, verde, vermelho e infravermelho), resolução radiométrica (8, 5 e 2 bits) e ângulo de orientação do pixel vizinho (0°, 45°, 90° e 135°). Os descritores texturais foram calculados de acordo com a Tabela 1.

Tabela 1: Descritores de textura utilizados, segundo Haralick et al. (1973)

Descritor	Equação
Contraste	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i-j)^2 P(i, j) \quad (01)$
Correlação	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{ijP(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (02)$
Entropia	$-\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j) \ln P(i, j) \quad (03)$
Homogeneidade	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{P(i, j)}{1 + (i-j)^2} \quad (04)$
Segundo momento angular	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} [P(i, j)]^2 \quad (05)$

Variância	$\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - m)^2 P(i, j) \quad (06)$
-----------	--

**Ng**: quantidade de níveis de cinza na imagem, **P(i,j)**: pixel na posição (i,j) na matriz de co-ocorrência, **μ<sub>x</sub>**: média na direção x, **μ<sub>y</sub>**: média na direção y, **σ<sub>x</sub>**: desvio padrão da média na direção x, **σ<sub>y</sub>**: desvio padrão da média na direção y.

Os cálculos dos descritores texturais foram realizados segundo uma rotina elaborada no programa MATLAB<sup>®</sup> (Apêndice C). Esses dados foram tabulados em uma planilha do Ms Excel, na qual foram utilizados como dados de entrada na rede neural.

### 3.1.3. Desenvolvimento das RNAs

Para fazer a classificação da imagem com os descritores texturais, foram desenvolvidas diversas RNAs no programa computacional Matlab 6.5<sup>®</sup> (Apêndice D). Utilizou-se o algoritmo de treinamento do tipo retro-propagação do erro (*backpropagation*), com a regra de aprendizagem de Levenberg-Marquardt. O vetor de entrada foi composto pelos descritores texturais, os quais foram determinados a partir de diferentes parâmetros: três resoluções radiométricas (8, 5 e 2), três tamanhos de bloco (9x9, 7x7 e 5x5), quatro ângulos de direção do pixel vizinho (0°, 45°, 90° e 135°) e quatro bandas espectrais (azul, verde, vermelho e infravermelho). A utilização desses diferentes combinações possibilitou a obtenção de 144 vetores, os quais foram avaliados.

A arquitetura da RNA utilizada foi do tipo 6-n<sub>1</sub>-n<sub>2</sub>-5: um vetor de entrada com seis variáveis, duas camadas intermediárias com n<sub>1</sub> e n<sub>2</sub> neurônios artificiais e cinco neurônios na camada de saída. O vetor de entrada foi composto pelos seis descritores texturais e o vetor de saída correspondia às cinco classes temáticas. O número de neurônios nas camadas intermediárias variou de 1 a 20. Nas duas camadas intermediárias usou-se a função de ativação tangente hiperbólica.

A camada de saída da rede foi predefinida com a função de ativação do tipo linear. O vetor da camada de saída da RNA foi codificado

da seguinte forma: (1, 0, 0, 0, 0) para a classe área urbana, (0, 1, 0, 0, 0) para a classe café, (0, 0, 1, 0, 0) para a classe água, (0, 0, 0, 1, 0) para a classe mata e (0, 0, 0, 0, 1) para a classe solo exposto e pastagem.

Para evitar o efeito do excesso de ajuste (*overfitting*), foi utilizado o método de parada mais cedo. Os dados foram subdivididos aleatoriamente em três subconjuntos: 60% dos dados utilizados no conjunto de treinamento, 20% dos dados utilizados na validação da rede e os 20% restantes, utilizados para o teste.

Tendo em vista que, no início do treinamento, os parâmetros livres são gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final do treinamento, cada uma das combinações das RNAs foram treinadas 10 vezes. Dentro dessas 10 RNAs treinadas, armazenou-se a que apresentou o menor erro quadrático médio relativo do teste.

#### **3.1.4. Desempenho das RNAs**

Para acessar o desempenho da RNA, foram selecionadas 40 novas amostras na imagem, de cada classe temática, totalizando 200 amostras (Apêndice E). A classificação foi avaliada comparando os resultados obtidos pela RNA com os valores da classificação visual.

A relação entre estes dois conjuntos informacionais foi resumida em uma matriz de confusão. A matriz de confusão identificou o erro global da classificação para cada categoria, mostrando também como se deram as confusões entre as categorias (BRITES et al., 1996).

A exatidão global foi computada dividindo-se o total de amostras corretamente classificadas (a diagonal da matriz de erros) pelo número total de amostras, conforme apresentado na Equação 7 (CONGALTON, 1991).

$$EG = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (7)$$

em que,

- $EG$  = Exatidão global da classificação, adimensional;
- $x_{ii}$  = Valor na linha  $i$  e coluna  $i$  (diagonal) da matriz de erros, adimensional;
- $n$  = Número total de amostras, adimensional; e
- $c$  = Número total de classes, adimensional.

O coeficiente Kappa, que leva em consideração a matriz de erros, incluindo os erros de classificação de omissão e comissão, foi também utilizado para avaliar a RNA. O coeficiente indicou o quanto o acerto do classificador foi melhor que o acerto ao acaso (COHEN, 1960). A Equação 8 foi utilizada para estimar o coeficiente Kappa (HUDSON e RAMM, 1987).

$$\hat{K} = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (8)$$

em que,

- $\hat{K}$  = Estimativa do coeficiente Kappa, adimensional;
- $x_{ii}$  = Valor na linha  $i$  e coluna  $i$  (diagonal) da matriz de erros, adimensional;
- $x_{i\oplus}$  = Total da linha  $i$ , adimensional;
- $x_{\oplus i}$  = Total da coluna  $i$ , adimensional;

$n$  = Número total de amostras, adimensional; e

$c$  = Número total de classes, adimensional.

O coeficiente Kappa é igual a zero quando o acerto obtido pelo classificador é igual ao acerto por acaso. Valores positivos de Kappa ocorrem quando o acerto é maior que ao acaso e negativos quando o acerto é pior do que uma classificação ao acaso (COHEN, 1960).

Para avaliar os valores de índice Kappa, utilizou-se a Tabela 2 (LANDIS e KOCH, 1977). Essa tabela serviu de referência para comparar a classificação dos blocos de textura e da imagem, utilizando os diferentes parâmetros estudados nessa pesquisa.

Tabela 2- Valores para avaliar o grau de concordância a partir do índice Kappa

Valor	Índice Kappa qualitativo
<0,00	Péssima
0,00 - 0,2	Ruim
0,21 - 0,4	Razoável
0,41 - 0,6	Boa
0,61 - 0,80	Muito Boa
0,81 - 1,0	Excelente

Para testar a diferença entre os índices Kappa calculados, e definir qual foi o conjunto de dados que gerou a RNA ótima, foi utilizado o teste Z (CONGALTON E MEAD, 1983), ao nível de significância de 5%, de acordo com a Equação 9.

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (9)$$

em que,

- Z = Valor de Z calculado, adimensional;
- $\hat{K}_1$  = Estimativa do coeficiente Kappa do classificador numa condição 1, adimensional;
- $\hat{K}_2$  = Estimativa do coeficiente Kappa do classificador numa condição 2, adimensional;
- $\text{var}(\hat{K}_1)$  = Variância da estimativa do coeficiente Kappa do classificador numa condição 1, adimensional; e
- $\text{var}(\hat{K}_2)$  = Variância da estimativa do coeficiente Kappa do classificador numa condição 2, adimensional.

A estimativa da variância do coeficiente Kappa foi estimada de acordo com a Equação 10 (HUDSON e RAMM, 1987).

$$\text{var}(\hat{K}) = \frac{1}{n} \left[ \frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (10)$$

Os termos  $\theta_1$ ,  $\theta_2$ ,  $\theta_3$ , e  $\theta_4$  foram determinados por meio das Equações 11, 12, 13 e 14, respectivamente:

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii} ; \quad (11)$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i\oplus} x_{\oplus i} ; \quad (12)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i\oplus} + x_{\oplus i}) ; \mathbf{e} \quad (13)$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j\oplus} + x_{\oplus j})^2 \quad (14)$$

em que,

$$x_{ij} = \text{Valor na linha } i \text{ e coluna } j \text{ da matriz de erros, adimensional;}$$

$x_{j\oplus}$  = Total da linha  $j$ , adimensional;

$x_{\oplus j}$  = Total da coluna  $j$ , adimensional;

### 3.1.5. Classificação do recorte da imagem pela RNA

Para testar a metodologia desenvolvida, foi feito um recorte na imagem de satélite de 1 km x 1 km (Figura 5), focalizando o entorno da cidade de Araponga.

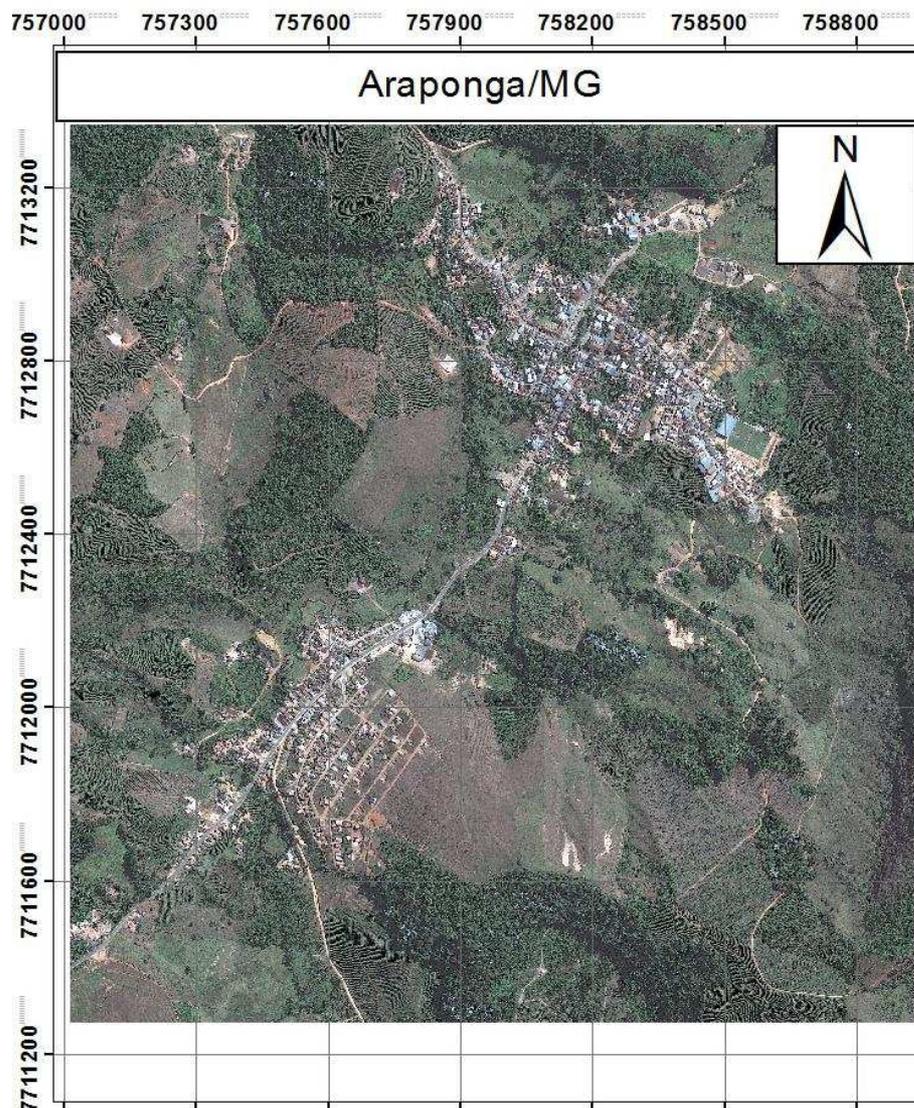


Figura 5: Recorte da imagem GeoEye focalizando o entorno da cidade de Araponga.

Com base na melhor combinação entre tamanho de bloco, ângulo de direção do pixel vizinho e resolução radiométrica, foi desenvolvida uma rotina no Matlab<sup>®</sup> que fez a classificação do recorte (Figura 5),

utilizando a melhor RNA definida na fase anterior (Apêndice F). Ao final do processamento foi obtido o mapa classificado pela RNA.

### **3.1.6. Desempenho da classificação da imagem**

Foi utilizado o Sistema de Informações Geográficas (SIG) ArcGIS (Versão 9, da ESRI Inc., Redlands, CA, EUA) para criar um mapa de uso e ocupação do solo, com o propósito de confrontá-lo com o mapa feito com a RNA treinada. O mapa de uso e ocupação do solo foi feito por meio de fotointerpretação, e ele foi utilizado na interpretação da imagem de satélite e para avaliar a precisão dos resultados.

A concordância entre os mapas temáticos desenvolvidos pela RNA e pelo SIG foi determinado pelo índice Kappa resultante da sobreposição destes mapas.

### 3.2. Segundo estudo de caso

No segundo estudo de caso, o objetivo foi de classificar as plantações de café de acordo com a idade de plantio e data de recepa.

Foram feitas visitas de campo para coleta dos parâmetros da cultura foram realizadas nos dias 18/09/12 e 09/10/12. Foram coletados dados referentes à idade e data de recepa através da consulta aos registros das fazendas com os seus respectivos responsáveis técnicos. Foram visitadas ao todo sete fazendas (Itatiaia, Rosário, Ponte, Boa vista, São Carlos, Pedra Redonda e Mundial), e identificados 59 talhões (Apêndice G).

Os parâmetros idade e data de recepa foram agrupados em classes e de acordo com as suas características. Foram agrupados de acordo com o ano de plantio das lavouras, e quando houve recepa (anos que se passaram após a recepa).

Foram definidas três classes: café novo (0-2 anos de idade ou 0-2 anos após a recepa), café em desenvolvimento (2-4 anos de idade ou 2-4 anos após a recepa) e café em produção (> 4 anos de idade ou > 4 anos após a recepa). Dessas três classes foram retiradas amostras representativas de cada classe (Figura 6).

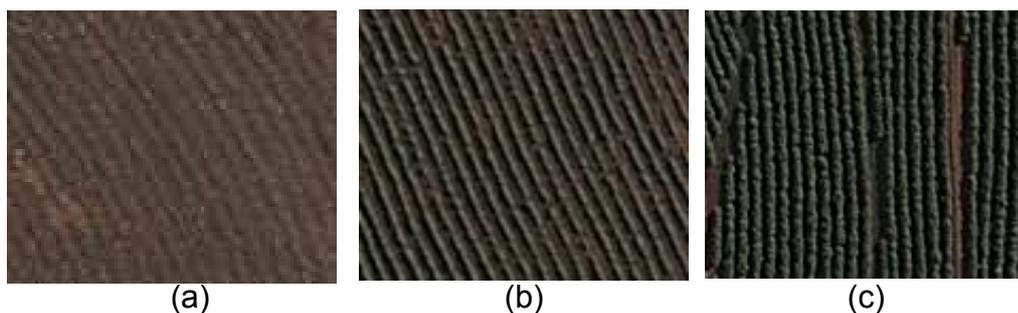


Figura 6: Exemplo dos recortes das regiões representativas de cada classe de interesse: Classe café novo (a); Classe café em desenvolvimento (b); Classe café em produção (c).

Para obtenção dos descritores texturais, foram selecionadas 40 amostras de cada uma dessas classes. Essas amostras foram retiradas das sete fazendas visitadas de acordo com a Tabela 4.

Tabela 4: Amostras retiradas de cada fazenda para desenvolvimento das RNAs

Fazenda	Classe1	Classe 2	Classe 3
Itatiaia	15	15	10
Pedra Redonda	15	10	10
Boa Vista	10	5	0
Rosário	0	5	5
São Carlos	0	5	5
Ponte	0	0	5
Mundial	0	0	5
Total	40	40	40

O vetor de entrada foi composto pelos descritores texturais, os quais foram determinados a partir de diferentes parâmetros: três resoluções radiométricas (8, 5 e 2), três tamanhos de bloco (9x9, 7x7 e 5x5), quatro ângulos de direção do pixel vizinho (0°, 45°, 90° e 135°) e quatro bandas espectrais (azul, verde, vermelho e infravermelho). A utilização desses diferentes combinações possibilitou a obtenção de 144 vetores, os quais foram avaliados.

A arquitetura da RNA utilizada foi do tipo 6-n<sub>1</sub>-n<sub>2</sub>-3: um vetor de entrada com seis variáveis, duas camadas intermediárias com n<sub>1</sub> e n<sub>2</sub> neurônios artificiais e três neurônios na camada de saída. O vetor de entrada foi composto pelos seis descritores texturais e o vetor de saída correspondia às três classes temáticas. O número de neurônios nas

camadas intermediárias variou de 1 a 20. Nas duas camadas intermediárias usou-se a função de ativação tangente hiperbólica

A camada de saída da rede foi predefinida com a função de ativação do tipo linear. O vetor da camada de saída da RNA foi codificado da seguinte forma: (1, 0, 0) para a classe café novo, (0, 1, 0) para a classe café em desenvolvimento e (0, 0, 1) para a classe café em produção.

Para evitar o efeito do excesso de ajuste (*overfitting*), foi utilizado o método de parada mais cedo. Os dados foram subdivididos aleatoriamente em três subconjuntos: 60% dos dados utilizados no conjunto de treinamento, 20% dos dados utilizados na validação da rede e os 20% restantes, utilizados para o teste.

Tendo em vista que, no início do treinamento, os parâmetros livres são gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final do treinamento, cada uma das combinações das RNAs foram treinadas 10 vezes. Dentro dessas 10 RNAs treinadas, armazenou-se a que apresentou o menor erro quadrático médio relativo do teste.

Para testar a metodologia desenvolvida foi feito um recorte na imagem de satélite (Figura 7), focalizando o entorno das fazendas: Itatiaia e Pedra Redonda.

A Figura 7 apresenta um recorte da imagem GeoEye onde foram identificados as fazendas Itatiaia e Pedra Redonda.

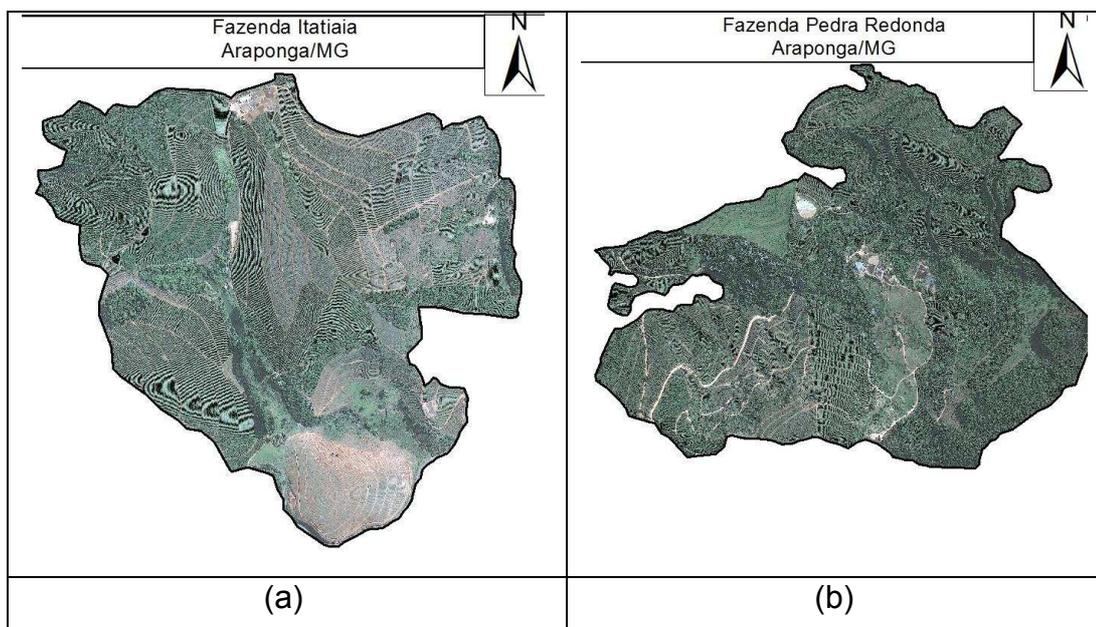


Figura 7: Recorte da imagem GeoEye focalizando as fazendas Itatiaia (a), e Pedra Redonda (b)

Com base na melhor combinação entre tamanho de bloco, ângulo de direção do pixel vizinho e resolução radiométrica foram feitas as classificações desses dois recortes. Foi utilizada a melhor RNA definida na fase anterior. Ao final do processamento foi obtido o mapa classificado pela RNA.

Foi utilizado o Sistema de Informações Geográficas (SIG) ArcGIS (Versão 9, da ESRI Inc., Redlands, CA, EUA) para criar um mapa de uso e ocupação do solo, com o propósito de confrontá-lo com o mapa feito com a RNA treinada. O mapa de uso e ocupação do solo foi utilizado na interpretação da imagem de satélite e para avaliar a precisão dos resultados.

A concordância entre os mapas temáticos desenvolvidos pela RNA e pelo SIG foi determinado pelo índice Kappa resultante da sobreposição destes mapas.

## **4. RESULTADOS E DISCUSSÃO**

### **4.1. Primeira estudo de caso**

#### **4.1.1. Análise dos parâmetros de entrada para composição das RNAs**

Após o desenvolvimento das RNAs e análise da classificação pelo índice Kappa, chegamos a 12 classificadores que apresentaram os maiores Kappas (Tabela 5). Esses 12 classificadores não diferiram estatisticamente entre si pelo teste Z, a um nível de significância de 5%.

Os 12 classificadores apresentados na Tabela 5 estão com resolução radiométrica de 8 bits, pois foi a resolução que apresentou uma melhor classificação quando comparadas com as outras duas resoluções radiométricas. O ângulo de orientação do pixel vizinho de 90° foi o que teve tendência de apresentar maior exatidão global para as bandas do azul, verde e vermelho. Não houve representante com tamanho de bloco 5x5 e nem com a banda do infravermelho.

Tabela 5: Valores de exatidão global e índice Kappa para os melhores classificadores

RNA <sup>1</sup>	Banda	Bloco	Ângulo	N. de Neurônios		EG <sup>2</sup>	Kappa
				1 <sup>a</sup> Camada	2 <sup>a</sup> Camada		
1	Vermelho	9x9	90	14	11	0,74	0,67
2	Vermelho	9x9	45	15	12	0,71	0,63
3	Azul	9x9	0	11	17	0,69	0,62
4	Azul	9x9	90	14	11	0,69	0,62
5	Verde	9x9	90	16	17	0,69	0,61
6	Vermelho	7x7	0	10	17	0,65	0,57
7	Verde	9x9	135	16	17	0,65	0,57
8	Verde	9x9	0	15	13	0,65	0,56
9	Azul	9x9	135	10	15	0,65	0,56
10	Vermelho	9x9	0	13	10	0,7	0,63
11	Verde	7x7	0	10	10	0,68	0,60
12	Verde	9x9	45	17	11	0,68	0,60

<sup>1</sup>RNA: Rede Neural Artificial; <sup>2</sup>EG: exatidão global

As 12 RNAs apresentadas na Tabela 5 foram obtidas na resolução radiométrica de 8 bits, pois foi a resolução que apresentou uma melhor classificação quando comparadas com as resoluções 5 e 2 bits. O ângulo de orientação do pixel vizinho de 90° foi o que teve tendência de apresentar maior exatidão global para as bandas do azul, verde e vermelho. O bloco 5x5 e a banda do infravermelho não geraram coeficientes Kappas satisfatórios. Observa-se que o número de neurônios ideal ficou no intervalo entre 10 e 17 para primeira camada e entre 10 e 17 para segunda camada. Um número elevado de neurônios (18-20) levou a rede a memorizar os dados de entrada, fazendo com que perca o poder de generalização. A definição do número de neurônios nas camadas intermediárias é um dos maiores desafios na montagem da

arquitetura das RNAs, pois não existe na literatura uma regra geral, que determine o número de neurônios para a solução de um determinado problema.

De uma maneira geral, o bloco com dimensão 9x9 pixel apresentou maiores valores de exatidão global e índice Kappa na maioria das situações trabalhadas. Isso se deve ao fato de que blocos com dimensões maiores abrangem maior região da imagem contendo uma quantidade maior de informações da textura das classes estudadas. Por outro lado, quanto maior o bloco, maior a confusão do classificador na fronteira entre duas classes. Esse mesmo comportamento da influência da dimensão dos blocos na classificação foi descrito por Li et al. (2012). Para que regiões de uma imagem sejam corretamente classificadas é preciso que o tamanho dos blocos seja grande o suficiente para a obtenção dos padrões texturais. Os descritores texturais devem identificar unicamente uma região de textura, ou uma classe, assim em blocos com dimensões pequenas, os descritores texturais podem não representar a classe em questão, tendo como consequência uma classificação com baixo índice de acerto.

Após a análise da Tabela 5, e pelo fato de ter apresentado maior exatidão global, foi selecionada a configuração com banda espectral do vermelho, ângulo de orientação do pixel vizinho de 90°, tamanho de bloco de 9x9 e resolução radiométrica de 8 bits. A matriz de confusão para esta combinação está sendo apresentada na Tabela 6.

Tabela 6: Matriz de confusão da classificação das amostras pela RNA

	Área		Água	Mata	Solo		Total	Exatidão do Usuário
	Urbana	Café			Exposto	Total		
Área Urbana	24	3	0	2	0	29	87,76%	
Café	2	22	1	6	0	31	70,96%	
Água	0	0	37	1	1	39	94,87%	
Mata	9	12	0	30	5	56	53,57%	
Solo Exposto	5	3	2	1	34	45	75,55%	
Total	40	40	40	40	40	200		
Exatidão do produtor	60%	55%	92,5%	75%	85%			
Exatidão Global=73,5%; Kappa=0,6687; Variância=0,0015								

Na Tabela 6 está a matriz de confusão para um conjunto de 200 amostras com a RNA que apresentou maior exatidão global. Os resultados dessa classificação, obtidos com base nas amostras apresentaram uma exatidão global de 73,5% e índice Kappa de 0,6687, com variância de 0,0015.

Nesta avaliação, a classe que apresentou maior erro na classificação foi a classe café, com 45% das amostras que deveriam ser assinaladas para esta classe, foram assinaladas a outras, principalmente á classe mata, com a qual apresentou maior confusão (30%). Esta confusão também foi verificada por Martínez-Verduzco et. al. (2012). Por outro lado, as classes água e solo exposto (com exatidão de 92,5% e 85% das amostras classificadas corretamente) foram as classes que apresentaram melhor resultado, conforme apresentado na Tabela 6.

#### 4.1.2. Classificação do recorte da imagem utilizando a melhor RNA treinada

Na Figura 8 é apresentado o mapa de referência, obtida por fotointerpretação suportada por visitas de campo, e o mapa de uso e ocupação do solo classificado pela RNA. Na Tabela 7 é apresentada a matriz de confusão entre o mapa de referência e o mapa de classificado pela RNA.

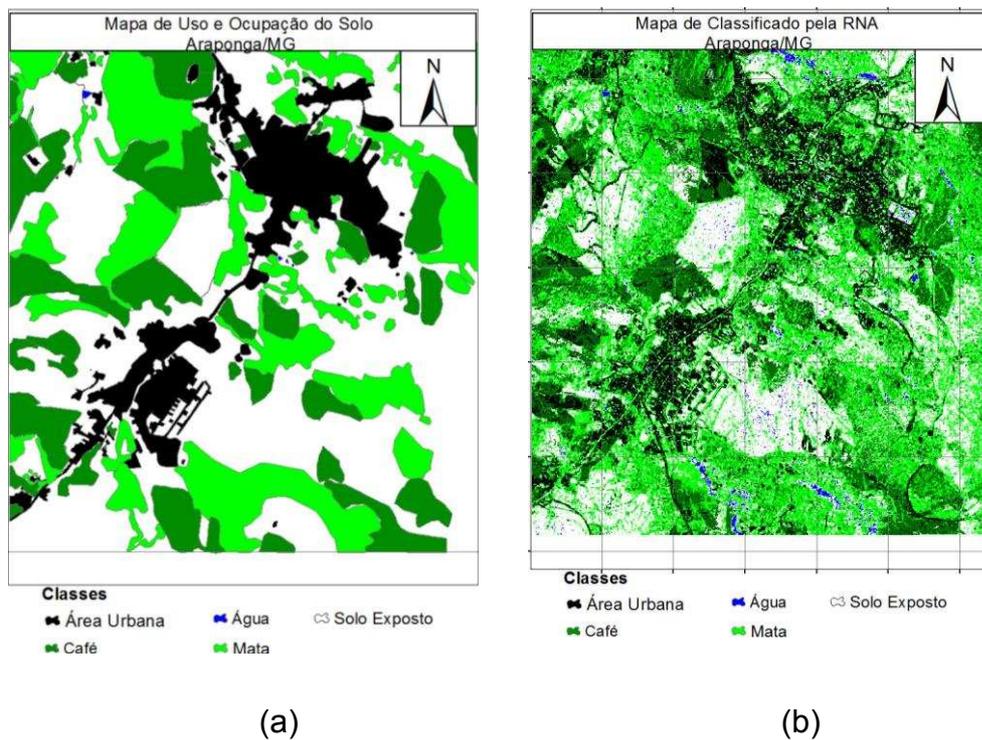


Figura 8 – (a) Mapa de referência e (b) mapa classificado pela rede neural artificial para o primeiro estudo de caso.

Tabela 7 - Matriz de confusão entre o mapa de referência e o mapa classificado pela RNA para o primeiro estudo de caso

	Área urbana	Café	Água	Mata	Solo exposto
Área urbana	60,18	4,88	0	22,44	12,5
Café	7,65	55,22	0	29,67	7,46
Água	0	2,48	92,59	0	4,93
Mata	5	18,07	2,5	71,93	2,5
Solo exposto	0	0	2,23	16,89	80,88

O coeficiente Kappa do mapa classificado pela RNA foi de 65,18%, em relação ao mapa de referência. Segundo Landis e Koch (1977) essa classificação é considerada Muito Boa. Viera et al. (2009) fizeram um trabalho com o objetivo de identificar áreas cafeeiras usando uma RNA, o índice Kappa determinado foi de 46,66%. Os autores concluíram que o reconhecimento de padrões da cultura cafeeira por métodos automatizados foi dificultado pela similaridade espectral da mata nativa com as plantas de café. No presente trabalho, o coeficiente Kappa também pode ter sido prejudicado pelos fatores ambientais que interferem no padrão espacial dos pixels da imagem, no entanto, acredita que os principais fatores foram à existência de culturas intercalares e o relevo acidentado, que causou sombreamento na imagem.

Como pode ser observado na Tabela 7, a RNA apresentou maior confusão para distinguir entre as classes café e mata. Verifica-se que somente 55,22% da área de café no mapa de referência foi classificada corretamente pela RNA. Aproximadamente 29,67% da área classificada como café não correspondia a essa classe, pertencendo a classe mata. O melhor desempenho foi obtido pela RNA na classificação da classe mata, com Coeficiente Kappa de 71,93% em relação à referência. A classificação da mata apresentou confusão com as áreas de café, sendo aproximadamente 18,07% classificado incorretamente como café. Esta dificuldade em diferenciar a plantação de café da vegetação natural por técnicas de sensoriamento remoto em região de montanha também foi

relatado por Martínez-Verduzco et al. (2012). A proximidade das lavouras de café com a área urbana e com a floresta gera uma mudança abrupta de uma classe para outra, o que acaba acarretando uma confusão do classificador. Na Fazenda Pedra Redonda, onde a sede é rodeada de árvores, e em alguns talhões de café há a integração lavoura-floresta o que acaba gerando uma mudança abrupta de uma classe pra outra.

## 4.2. Segundo estudo de caso

### 4.2.1. Análise dos parâmetros de entrada para composição das RNAs

De um total de 57600 combinações de dados de entrada utilizados para treinamento da rede neural para classificação de café novo, café em desenvolvimento e café em produção, foram selecionadas 8 RNAs com maiores coeficientes Kappas, conforme apresentado na Tabela 8. Os Coeficientes Kappas, apresentados na Tabela 8, não diferiram entre si, ao nível de 5% de significância.

Tabela 8 – Redes neurais artificiais que apresentam os maiores coeficientes Kappas com amostras representativas de cada classe de interesse (café novo, café em desenvolvimento, café em produção)

RNA <sup>1</sup>	Resolução	Banda	Ângulo	N. de Neurônios		EG <sup>2</sup>	Kappa
				1 <sup>a</sup>	2 <sup>a</sup>		
	Radiométrica	Espectral		Camada	Camada		
1	8	Verde	45	10	13	0,84	0,76
2	8	Vermelho	45	16	12	0,82	0,74
3	5	Vermelho	45	16	16	0,81	0,71
4	5	Azul	135	13	11	0,79	0,69
5	5	Verde	135	16	17	0,79	0,69
6	8	Azul	45	12	10	0,85	0,78
7	8	Verde	90	16	14	0,78	0,68
8	5	Vermelho	90	17	15	0,77	0,65

<sup>1</sup>RNA: Rede Neural Artificial; <sup>2</sup>EG: exatidão global

Não houve diferença estatística na classificação utilizando os descritores de textura para as resoluções radiométricas de 8 e 5 bits apresentadas na Tabela 8. Sendo que a resolução radiométrica de 8 bits tendeu a apresentar uma maior exatidão global. Segundo Murray et al. (2010) reduzir a dimensionalidade de características pode ser uma boa opção para eliminar informações redundantes e que muitas das vezes não tem relevância significativa para a resolução do problema. No presente trabalho foram feitas reduções na dimensionalidade da resolução radiométrica e foi feita uma análise estatística para avaliar o efeito da redução da resolução radiométrica na classificação. Como não houve diferença significativa a 5% de probabilidade pelo teste z entre as resoluções radiométricas de 8 e 5 bits. Dessa forma, foi escolhida a banda espectral vermelho, ângulo de orientação do pixel vizinho de 45°, tamanho de bloco de 7x7 e resolução radiométrica de 5 bits em função do menor tempo de processamento.

#### 4.2. Classificação da imagem para o segundo estudo de caso

Na Figura 9 é apresentado o mapa de referência, classificado por fotointerpretação suportados por visitas de campo, e o mapa classificado pela RNA para a fazenda Itatiaia. Na Tabela 9 é apresentada a matriz de confusão entre o mapa de referência e o mapa classificado pela RNA.

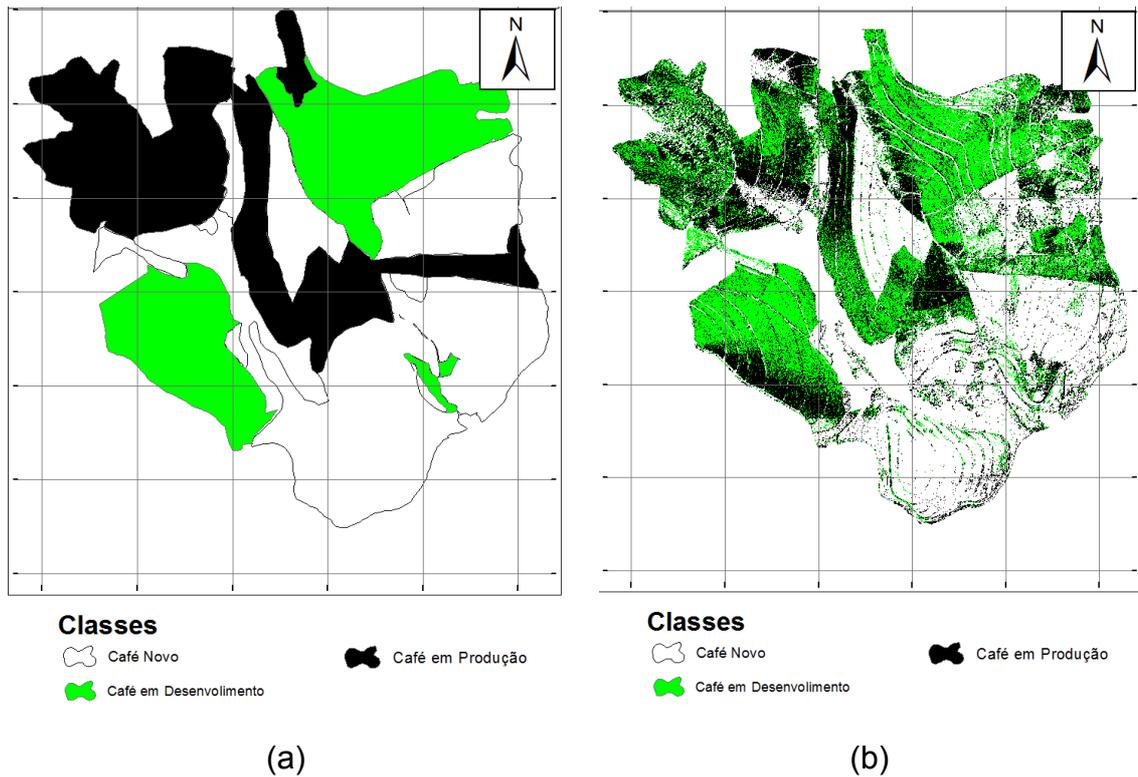


Figura 9 – (a) Mapa de referência e (b) mapa classificado pela Rede Neural Artificial para a fazenda Itatiaia no segundo estudo de caso.

Tabela 9 - Matriz de confusão entre o mapa de referência e o mapa classificado pela RNA para a fazenda Itataia no segundo estudo de caso.

	Café em Produção	Café em desenvolvimento	Café Novo
Café em Produção	60	30	10
Café em desenvolvimento	12,5	85	2,5
Café Novo	5	5	90

A classificação da fazenda Itatiaia apresentou uma exatidão global de 78,33% e coeficiente Kappa do mapa classificado pela RNA foi de 0,675, o que segundo Landis e Koch (1977), é considerado um índice muito bom. Moreira et al. (2008) fizeram um trabalho com o objetivo de desenvolver metodologias capazes de caracterizar a cafeicultura no estado de Minas Gerais. De uma forma geral, o desempenho do classificador foi variável, ficando o índice Kappa no intervalo (65,4-84,8). Segundo os autores o que mais influenciou na classificação foi a heterogeneidade do comportamento espectral das lavouras, que são relacionadas com os parâmetros agronômicos de manejo. Na classificação da fazenda Itatiaia o coeficiente Kappa foi prejudicado pela complexidade na discriminação da cultura, que é influenciada em parte pelo manejo diferenciado entre os talhões, fazendo com que cada classe tenha vários padrões na imagem, dificultando assim a classificação, conforme também retratado por Moreira et al., 2010.

Como pode ser observado na Tabela 9, a RNA treinada encontrou dificuldades para fazer a distinção correta entre as classes café em produção e café em desenvolvimento. Verifica-se que somente 60 % da área de café em produção no mapa de referência, foi classificada corretamente pela RNA na imagem orbital. Aproximadamente 30% da área classificada como café em produção não correspondia a essa classe, pertencendo na verdade a classe café em desenvolvimento. Já

em relação à identificação da classe café em produção, a RNA apresentou um melhor desempenho e obteve um índice de 85 % em relação ao mapa de referência. O classificador confundiu somente 12,5 % da área que era café em desenvolvimento com a classe café em produção.

Na Figura 10 é apresentado o mapa de referência e o mapa classificado pela RNA para a fazenda Pedra Redonda. Na Tabela 10 é apresentada a matriz de confusão entre o mapa de referência e o mapa classificado pela RNA para o segundo estudo de caso.

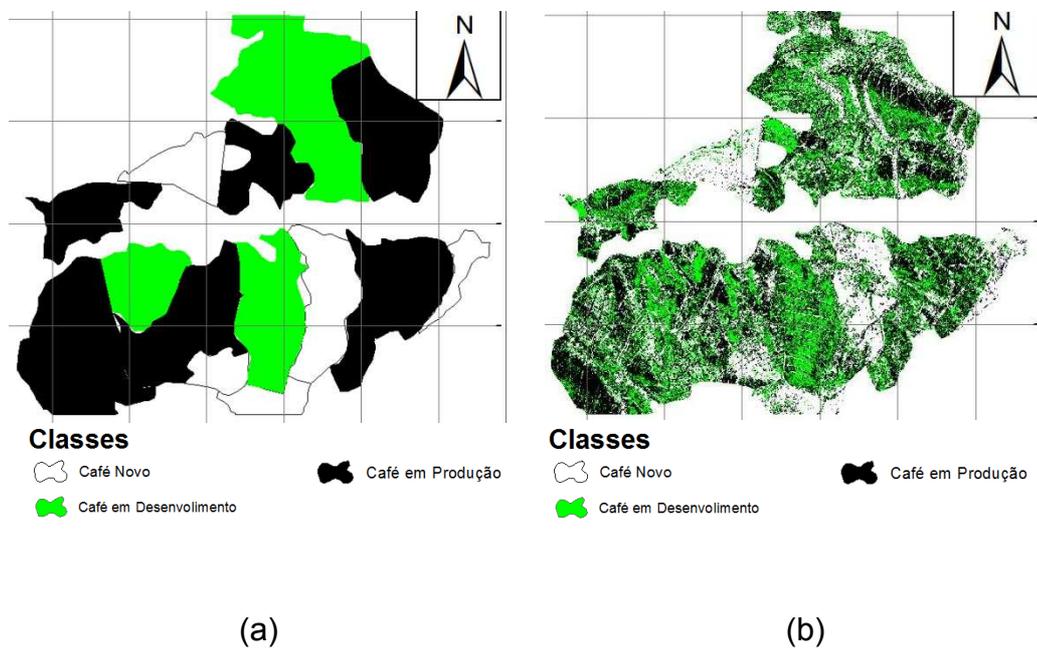


Figura 10 – (a) Mapa de referência e (b) mapa classificado pela rede neural artificial para a fazenda Pedra Redonda no segundo estudo de caso.

Tabela 10 - Matriz de confusão entre o mapa de referência e o mapa classificado pela RNA para a fazenda Pedra Redonda no segundo estudo de caso

	Café em Produção	Café em desenvolvimento	Café Novo	
Café em Produção	52,3	36,5	11,2	100
Café em desenvolvimento	14,66	64,87	20,47	100
Café Novo	5,25	16,26	78,49	100

A fazenda Pedra Redonda apresentou uma exatidão global de 65,22% e o coeficiente Kappa do mapa classificado pela RNA foi de 0,4783, o que segundo Landis e Koch (1977), é considerado um índice bom. A piora do desempenho do classificador pode ser atribuída à presença de árvores no meio das lavouras de café e o relevo desta fazenda ser mais acidentado, causando confusão no classificador.

Como pode ser observado na Tabela 5, a RNA treinada apresentou uma maior confusão para a correta classificação entre as classes café em produção e café em desenvolvimento. Verifica-se que somente 52,3 % da área de café em produção no mapa de referência foi classificada corretamente. Aproximadamente 36,5 % da área classificada como café em produção não correspondia a essa classe, pertencendo na verdade a classe café em desenvolvimento. Em relação à identificação da classe café em produção, a RNA apresentou um melhor desempenho e obteve um índice de 64,87% em relação ao mapa de referência. O classificador confundiu 20,47% da área que era café em desenvolvimento com a classe café em produção.

Os resultados obtidos nesse trabalho assemelharam-se aos resultados obtidos no trabalho realizado por Moreira et. al. 2004, que enfatizaram que a heterogeneidade da diversidade espectral da cultura do café associado aos parâmetros de manejo da cultura influencia na

classificação. Pode-se considerar que a utilização das RNAs se mostrou uma ferramenta promissora para a discriminação das lavouras de café, contudo em trabalhos futuros seria interessante entrar com outros parâmetros além da idade e data de recepa.

## 5. CONCLUSÕES

O uso de redes neurais utilizando as características espaciais mostrou-se uma alternativa viável para a classificação de imagens orbitais. A análise da resolução radiométrica mostrou que ao reduzir sua dimensionalidade há uma diminuição no tempo de processamento, mas há uma piora no poder de discriminação do classificador.

O tamanho dos blocos influencia no processo de classificação da imagem, sendo que o tamanho ideal dos blocos é aquele que consegue identificar unicamente uma região de textura, ou uma classe.

O índice Kappa obtido para discriminação das lavouras cafeeiras das outras classes temáticas foi de 65,18 %, que é índice considerado bom. O erro na classificação da rede neural é influenciado pela ambiguidade existente entre as áreas de café com as áreas ocupadas pela mata, tendo em vistas que os padrões dessas duas classes são semelhantes.

O índice Kappa para discriminar as lavouras cafeeiras em função da sua idade e data de recepa variável (0,675 a 0,4783), sendo considerado muito bom para a fazenda Itatiaia e razoável para a fazenda Pedra Redonda. O erro na classificação da rede neural pode ser atribuído à variabilidade de padrões existente dentre das classes de estudo.

## 6. Referências Bibliográficas

ALVES, R. S.; FIALHO, E. S.; SILVA, A. C. S. Uma análise comparada de parâmetros climáticos em situação de inverno (2011), ao longo do perfil Ubá-Ponte Nova, na zona da mata mineira. **ACTA Geográfica**, v.1, n.1, p. 87-100, 2012.

AMORÓS, L. J.; IZQUIERDO, V. E.; GÓMEZ, C. L.; MUÑOZ, M. J.; RODRÍGUEZ, B. J. Z.; CAMPS, V. G.; CALPE, M. J. Land cover classification of VHR airborne images for citrus grove identification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 115-123, 2011.

BRAGA, A.P.; CARVALHO, P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teorias e aplicações**. Rio de Janeiro: LTC, 2000.

BRITES, R. S.; SOARES, V. P.; RIBEIRO, C. A. A. S. **Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais**. 8º Simpósio Brasileiro de Sensoriamento Remoto. Abril de 1996. Instituto Nacional de Pesquisas Espaciais: Salvador, BA.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v.20, p.37-46, 1960.

CLAVERIE, M.; DEMAREZ, V.; DUCHEMIN, B.; HAGOLLE, O.; DUCROT, D.; MARAIS-SICRE, C.; DEJOUX, J. F.; HUC, M.; KERAVEC, P.; BÉZIAT, P.; FIEUZAL, R.; CESCHIA, E.; DEDIEU, G. Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data. **Remote Sensing of Environment**, v. 124, p. 844-857, 2012.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). Safra de Grãos. Disponível em: <<http://www.conab.gov.br>>. Acesso em: 27 fev. 2013.

CONGALTON, R.G.; MEAD, R.A. **A quantitative method to test for consistency and correctness in photointerpretation.** Photogrammetric Engineering & Remote Sensing, v.49, n.1, p.69-74, 1983.

CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, v.55, n. 37, p. 35-46, 1991.

GALVÃO, L.S.; ROBERTS, D.A.; FORMAGGIO, A.R.; NUMATA, I.; BREUNIG, F.M. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data. **Remote Sensing of Environment**, v.113, n.4, p.846-856, 2009.

GOMEZ, C.; MANGEAS, M.; PETIT, M.;CORBANE, C.; HAMON, P.; HAMON, S.; DE KOCHKO, A.; LE PIERRES, D.; PONCET, V.; DESPINOY, M. Use of high-resolution satellite imagery in an integrated model to predict the distribution of shade coffee tree hybrid zones. **Remote Sensing of Environment**, v. 114, n. 11, p. 2731-2744, 2010.

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

HARALICK, R.M.; SHANMUGAN, K; ITSHAK, D. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v.3, n.6, 1973.

HAYKIN, S. **Redes neurais: princípio e prática**. Porto Alegre: Bookman, 2001.

HUDSON, W.D.; RAMM, C.W. Correct formulation of the Kappa coefficient of agreement. **Photogrammetric Engineering & Remote Sensing**, v.53, n.4, p.421-422, 1987.

ILEA, D. E.; WHELAN, P. F. Image segmentation based on the integration of colour texture descriptors: A review. **Pattern Recognition**, v. 44, n. 10-11, p. 2479-2501, 2011.

IPPOLITI-RAMILO, G.A.; EPIPHANIO, J.C.N.; SHIMABUKURO, Y.E.; FORMAGGIO, A.R. Sensoriamento remoto orbital como meio auxiliar na previsão de safras. **Agricultura em São Paulo**, v.46, n.1, p.89-101, 1999.

KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes. 1928. Wall-map 150cmx200cm.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, v. 33, n. 3, p. 159-179, 1977.

LAMPARELLI, R. A. C.; JOHANN, J. A.; SANTOS, E. D.; ESQUERDO, J. C. D. M.; ROCHA, J. V. USE OF DATA MINING AND SPECTRAL PROFILES TO DIFFERENTIATE CONDITION AFTER HARVEST OF

COFFEE PLANTS **Engenharia Agrícola Jaboticabal** v. 32, n. 1, p. 184-196, jan./fev 2012.

LI, G.; LU, D.; MORAN, E.; DUTRA, L.; BATISTELLA, M. A comparative analysis of ALOS PALSAR L-band and RADARSAT-2 C-band data for land-cover classification in a tropical moist region. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 70, p. 26-38, 2012.

LOPEZ-GOMEZ, A. A., WILLIAMS-LINERA, G.; MANSON, R. H. Tree species diversity and vegetation structure in shade coffee farms in Veracruz, Mexico. **Agriculture, Ecosystems and Environment**, v. 124, n. 3-4, p. 160-172, 2008.

MARTÍNEZ-VERDUZCO, G. C.; GALEANA-PIZAÑA, J. M.; CRUZ-BELLO, G. M. Coupling Community Mapping and supervised classification to discriminate Shade coffee from natural vegetation. **Applied Geography**, v. 34, p. 1-9, 2012.

MOREIRA, M.A.; ADAMI, M.; RUDORFF, B.F.T. Análise espectral e temporal da cultura do café em imagens Landsat-5. **Pesquisa Agropecuária Brasileira**, v.39. n.3, p.223-231, 2004.

MOREIRA, M. A.; BARROS, M. A.; RUDORFF, B. F. T. Geotecnologias no mapeamento da cultura do café em escala municipal. **Saúde e Natureza**, v. 20, n. 1, p. 101-110, 2008.

MOREIRA, M.A.; RUDORFF, B.F.T.; BARROS, M.A.; DE FARIA, V.G.C.; ADAMI, M. Geotecnologias para mapear lavouras de café nos Estados de Minas Gerais e São Paulo. **Engenharia Agrícola Jaboticabal**, v.30, n.6, p.1123-1135, 2010.

MURRAY, H.; LUCIEER, A.; WILLIAMS, R. Texture-based classification of sub-Antarctic vegetation communities on Heard Island. **International Journal of Applied Earth Observation and Geoinformation**, v. 12, n. 3, p. 138-149, 2010.

NIEDERHAUSER., N.; OBERTHÜR., T.; KATTNIG., S. Information and its management for differentiation of agricultural products: The example of specialty coffee. **Computers and Electronics in Agriculture**, v. 61, n. 2, p. 241-253, 2008.

PEDRINI, H.; SCHWARTZ, R. W. **Análise de imagens digitais: Princípios, Algoritmos e Aplicações**. São Paulo, 2008.

PEÑA-BARRAGÁN, J. M.; NGUGI, M. K.; PLANT, R. E.; SIX, J. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, v. 115, n. 6, p. 1301-1316, 2011.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São Jose dos Campos: Parêntese, 2010. v.2, 127p.

RIZZI, R.; RUDORFF, B.F.T. Imagens do sensor MODIS associadas a um modelo para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, v.42, p.73-80, 2007.

RUDORFF, B.F.T.; AGUIAR, D.A.; SILVA, W.F.; SUGAWARA, L.M.; ADAMI, M.; MOREIRA, M.A. Studies on the rapid expansion of sugarcane

for ethanol production in São Paulo state (Brazil) using Landsat data. **Remote Sensing**, v.2, n.4, p.1057-1076, 2010.

RUIZ, L. A.; RECIO, J. A.; FERNÁNDEZ-SARRÍA, A.; HERMOSILLA, T. A feature extraction software tool for agricultural object-based image analysis. **Computers and Electronics in Agriculture**, v. 76, n. 2, p. 284-296, 2011.

SHIGUEMORI, E.H; MARTINS, M.P; MONTEIRO, M.V.T. Landmarks recognition for autonomous aerial navigation by neural networks and gabor transform. **Image Processing**, v.6497, n.1, p.1-8, 2007.

SKLANSKY, J. Image segmentation and feature extraction. **IEEE Transactions on Systems, Man and Cybernetics**, v. 8, n. 4, p.237-247, 1978.

SOARES, D.M.; GALVÃO, L.S.; FORMAGGIO, A.R. Crop area estimate from original and simulated spatial resolution data and landscape metrics. **Scientia Agricola**, v.65, n.5, p.459–467, 2008.

TRABAQUINI, K.; MIGLIORANZA, E.; FRANÇA, V.; NETO, P.C.O. Caracterização de lavouras cafeeiras, utilizando técnicas de geoprocessamento e sensoriamento remoto, no município de Umuarama – PR. **Ciência e Agrotecnologia**, v. 35, n.1, p. 35-44, 2011.

TSANEVA, M. G.; KREZHOVA, D. D.; YANEV, T. K. Development and testing of a statistical texture model for land cover classification of the Black Sea region with MODIS imagery. **Advances in Space Research**, v. 46, n. 7, p. 872-878, 2010.

VIEIRA, T. G. C. V.; LACERDA, W. S. & BOTELHO, T. G.. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de Três Pontas, Minas Gerais. **Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, v. 14, p. 7947-7954, 2009.

WOOD, E. M.; PIDGEON, A. M.; RADELOFF, V. C.; KEULER, N. S. Image texture as a remotely sensed measure of vegetation structure. **Remote Sensing of Environment**, v. 121, p. 516-526, 2012.

## APÊNDICE A

Algoritmo utilizado para fazer o recorte da imagem orbital.

```
%Seleção da pasta de entrada

dir_in =
uigetdir('C:\Users\Windows\Desktop\Lucas\Mestrado\Dissertação\Recorte_I_Idades');

dir_out =
uigetdir('C:\Users\Windows\Desktop\Lucas\Mestrado\Dissertação\Recorte_I_Idades');

% Início do processamento

ct=0;

continua='Ok';

while strcmp(continua,'Ok')

    clc

    % Abrir a imagem no diretório

    [nome,caminho]= uigetfile(fullfile(dir_in,'*c*.tif'),'Selecione a
imagem RGB ');

    rgb = imread(strcat(caminho,nome));

    % Desenhando polígono para recorte

    imshow(rgb, []); % title('Recortar de placas');

    resp = msgbox('Recorte da área','modal');

    hFH = impoly();

    pos = getPosition(hFH);
```

```

% Recorte da área da imagem para apresentação na tela

x1=min(pos(:,1,:)); y1=min(pos(:,2,:)); %posição mínima do recorte

y2=max(pos(:,2,:)); x2=max(pos(:,1,:)); %posição máxima do recorte

D= x2-x1;

L=y2-y1;

ic_rgb=imcrop(rgb,[x1,y1,D,L]); % Recorte da imagem original nas
posições específicas

% Plota imagens recortadas

figure, imshow(ic_rgb);

title('Recorte')

resp=questdlg('Recorte          Ok?', 'Recorte          de
Imagem', 'Sim', 'Não', 'default');

    close all %fecha figuras

    if strcmp(resp, 'Sim') % salva imagens recortadas

        clc

        ct=ct+1;

        nomearc=strcat('ii', num2str(ct));

        imwrite(ic_rgb, strcat(dir_out, '\', nomearc, '.tif'));

    end

continua          =          questdlg('Continua?', 'Recorte          de
Imagem', 'Ok', 'Não', 'default');

end

clc

disp('Fim do Processamento!');

```

## APÊNDICE B

Algoritmo utilizado para recorte dos blocos da imagem.

```
% Algoritmo para recorte das amostras da imagem em blocos com
tamanho

% diferenciado

clear;clc;

warning off;

disp('Quais tamanho de imagens deseja gerar?'); disp(' ');

disp('    1. 2 imagens 5;');

disp('    2. 2 imagens 7;');

disp('    3. 2 imagens 9;');

Opcao = input('\n---> Sua opcao de calculo: ','s'); disp(' ');

switch Opcao

    case '1'

        TamanhoImagem = 5;

    case '2'

        TamanhoImagem = 7;

    case '3'

        TamanhoImagem = 9;

    otherwise

        disp(' '); disp('Esta opcao nao existe.');
```

end

```
disp(' '); disp(' '); disp(' ');
```

```

if (Opcao == '1') | (Opcao == '2') | (Opcao == '3')

    dir_in =
uigetdir('C:\Users\Windows\Desktop\Lucas\Mestrado\Dissertação\Recorte_I_Idades\Recorte_Imagens\Solo_Exposto');

    dir_out =
uigetdir('C:\Users\Windows\Desktop\Lucas\Mestrado\Dissertação\Recorte_I_Idades\Recorte_Imagens\Solo_Exposto\Validação\9x9\');

    [nome1,caminho1]= uigetfile(fullfile(dir_in,'*.*'),'Selecione a imagem RGB ');

    rgb = imread(strcat(caminho1,nome1));

    rgb=uint8(rgb);

    %imshow (rgb);

    [NumLins,NumCols] = size(rgb);

for ct = 1:200

    % Recorte da imagem RGB

    imshow(rgb)

    impixelinfo

    k = waitforbuttonpress;

    point1 = get(gca,'CurrentPoint')

    finalRect = rbbox;

    point2 = get(gca,'CurrentPoint');

    point1 = point1(1,1:2);

    point2 = point2(1,1:2);

    p1 = min(point1,point2);

    offset = abs(point1-point2);

```

```

x = point1(1,2);%[p1(1)];
y = point1(1,1);%[p1(2)];
LinhaRand = x;
ColunaRand = y;
ParteImagem=rgb(x:x+TamanhoImagem-1,y:y+TamanhoImagem-
1,:);
nome=nome1(1,1:(size(nome1,2)-4));

imwrite(ParteImagem,strcat(strcat(dir_out,'\ ',num2str(ct),'.tif'))
);

close all

end

end

if (Opcao == '1') | (Opcao == '2') | (Opcao == '3')

disp('====> Imagens geradas...');

end

.

```

## APÊNDICE C

Algoritmo utilizado cálculo dos descritores texturais.

```
% Algoritmo para calculo dos descritores

clc;clear;close all;

for p=1:200

    filename
    =['C:\Users\Windows\Desktop\Lucas\Mestrado\Dissertação\Recorte_I_I
dades\Textura\Dados_Validação\Dados_Validação_8\5x5\'    num2str(p)
'.tif'];

    x= imread(filename);

    x=x(:, :, 1);

    x=double(x);

Ng=2^8;

L=2^8;

if Ng==L

    im=x;

else

    fator=Ng/L;

    im=fix(x/fator);

end

im=im+1;
```

```

[lin,col]=size(im);

% inicializando as matrizes de co-ocorrencias

cc_0=zeros(L,L);

cc_45=zeros(L,L);

cc_90=zeros(L,L);

cc_135=zeros(L,L);

% percorrendo a imagem pixel a pixel (sem contar as bordas da
imagem)

for ii=2:lin-1

    for jj=2:col-1

        i=double(ii);j=double(jj);

        cc_0(im(i,j),im(i,j-1))=cc_0(im(i,j),im(i,j-1))+1;

        cc_0(im(i,j),im(i,j+1))=cc_0(im(i,j),im(i,j+1))+1;

        cc_45(im(i,j),im(i-1,j+1))=cc_45(im(i,j),im(i-1,j+1))+1;

        cc_45(im(i,j),im(i+1,j-1))=cc_45(im(i,j),im(i+1,j-1))+1;

        cc_90(im(i,j),im(i+1,j))=cc_90(im(i,j),im(i+1,j))+1;

        cc_90(im(i,j),im(i-1,j))=cc_90(im(i,j),im(i-1,j))+1;

        cc_135(im(i,j),im(i-1,j-1))=cc_135(im(i,j),im(i-1,j-1))+1;

        cc_135(im(i,j),im(i+1,j+1))=cc_135(im(i,j),im(i+1,j+1))+1;

    end

end

end

```

```

% primeira linha

i=1;

for j=1:col

    if j==1

        cc_0(im(i,j),im(i,j+1))=cc_0(im(i,j),im(i,j+1))+1;

        cc_90(im(i,j),im(i+1,j))=cc_90(im(i,j),im(i+1,j))+1;

        cc_135(im(i,j),im(i+1,j+1))=cc_135(im(i,j),im(i+1,j+1))+1;

    elseif j==col

        cc_0(im(i,j),im(i,j-1))=cc_0(im(i,j),im(i,j-1))+1;

        cc_45(im(i,j),im(i+1,j-1))=cc_45(im(i,j),im(i+1,j-1))+1;

        cc_90(im(i,j),im(i+1,j))=cc_90(im(i,j),im(i+1,j))+1;

    else

        cc_0(im(i,j),im(i,j-1))=cc_0(im(i,j),im(i,j-1))+1;

        cc_0(im(i,j),im(i,j+1))=cc_0(im(i,j),im(i,j+1))+1;

        cc_45(im(i,j),im(i+1,j-1))=cc_45(im(i,j),im(i+1,j-1))+1;

        cc_90(im(i,j),im(i+1,j))=cc_90(im(i,j),im(i+1,j))+1;

        cc_135(im(i,j),im(i+1,j+1))=cc_135(im(i,j),im(i+1,j+1))+1;

    end

end

%ultima linha

i=lin;

for j=1:col

    if j==1

```

```

        cc_0(im(i,j),im(i,j+1))=cc_0(im(i,j),im(i,j+1))+1;

        cc_90(im(i,j),im(i-1,j))=cc_90(im(i,j),im(i-1,j))+1;

        cc_45(im(i,j),im(i-1,j+1))=cc_45(im(i,j),im(i-1,j+1))+1;

elseif j==col

        cc_0(im(i,j),im(i,j-1))=cc_0(im(i,j),im(i,j-1))+1;

        cc_90(im(i,j),im(i-1,j))=cc_90(im(i,j),im(i-1,j))+1;

        cc_135(im(i,j),im(i-1,j-1))=cc_135(im(i,j),im(i-1,j-1))+1;

else

        cc_0(im(i,j),im(i,j-1))=cc_0(im(i,j),im(i,j-1))+1;

        cc_0(im(i,j),im(i,j+1))=cc_0(im(i,j),im(i,j+1))+1;

        cc_45(im(i,j),im(i-1,j+1))=cc_45(im(i,j),im(i-1,j+1))+1;

        cc_90(im(i,j),im(i-1,j))=cc_90(im(i,j),im(i-1,j))+1;

        cc_135(im(i,j),im(i-1,j-1))=cc_135(im(i,j),im(i-1,j-1))+1;

end

end

end

%primeira coluna

j=1;

for i=2:lin-1

        cc_0(im(i,j),im(i,j+1))=cc_0(im(i,j),im(i,j+1))+1;

        cc_45(im(i,j),im(i-1,j+1))=cc_45(im(i,j),im(i-1,j+1))+1;

        cc_90(im(i,j),im(i+1,j))=cc_90(im(i,j),im(i+1,j))+1;

        cc_90(im(i,j),im(i-1,j))=cc_90(im(i,j),im(i-1,j))+1;

        cc_135(im(i,j),im(i+1,j+1))=cc_135(im(i,j),im(i+1,j+1))+1;

end

```

```

%ultima columna

j=col;

for i=2:lin-1

    cc_0(im(i,j),im(i,j-1))=cc_0(im(i,j),im(i,j-1))+1;

    cc_45(im(i,j),im(i+1,j-1))=cc_45(im(i,j),im(i+1,j-1))+1;

    cc_90(im(i,j),im(i+1,j))=cc_90(im(i,j),im(i+1,j))+1;

    cc_90(im(i,j),im(i-1,j))=cc_90(im(i,j),im(i-1,j))+1;

    cc_135(im(i,j),im(i-1,j-1))=cc_135(im(i,j),im(i-1,j-1))+1;

end

%MCC normalizada

cc_0=cc_0/sum(cc_0(:));

cc_45=cc_45/sum(cc_45(:));

cc_90=cc_90/sum(cc_90(:));

cc_135=cc_135/sum(cc_135(:));

%SEGUNDO MOMENTO ANGULAR

sma1=[sum(sum(cc_0.*cc_0))];

sma2=[sum(sum(cc_45.*cc_45))];

sma3=[sum(sum(cc_90.*cc_90))];

sma4=[sum(sum(cc_135.*cc_135))];

%VARIANCIA

%media

media_0=0;media_45=0;media_90=0;media_135=0;

```

```

for i=0:L-1

    media_0=media_0+i*sum(cc_0(i+1,:));

    media_45=media_45+i*sum(cc_45(i+1,:));

    media_90=media_90+i*sum(cc_90(i+1,:));

    media_135=media_135+i*sum(cc_135(i+1,:));

end

%var

vari=[0 0 0 0];;

for i=0:L-1

    vari(1,1)=vari(1,1)+(i-media_0)^2*sum(cc_0(i+1,:));

    vari(1,2)=vari(1,2)+(i-media_45)^2*sum(cc_45(i+1,:));

    vari(1,3)=vari(1,3)+(i-media_90)^2*sum(cc_90(i+1,:));

    vari(1,4)=vari(1,4)+(i-media_135)^2*sum(cc_135(i+1,:));

end

vari;

%ENTROPIA

ent=[entropy(cc_0) entropy(cc_45) entropy(cc_90) entropy(cc_135)];

%CONTRASTE

contr=[0 0 0 0];;

for i=0:L-1

    for j=0:L-1

        contr(1,1)=contr(1,1)+(i-j)^2*cc_0(i+1,j+1);

        contr(1,2)=contr(1,2)+(i-j)^2*cc_45(i+1,j+1);

        contr(1,3)=contr(1,3)+(i-j)^2*cc_90(i+1,j+1);

```

```

        contr(1,4)=contr(1,4)+(i-j)^2*cc_135(i+1,j+1);

    end

end

contr;

%CORRELACAO

corre=[0 0 0 0];;

for i=0:L-1

    for j=0:L-1

        corre(1,1)=corre(1,1)+(i-media_0)*(j-
media_0)*cc_0(i+1,j+1)/vari(1,1);

        corre(1,2)=corre(1,2)+(i-media_45)*(j-
media_45)*cc_45(i+1,j+1)/vari(1,2);

        corre(1,3)=corre(1,3)+(i-media_90)*(j-
media_90)*cc_90(i+1,j+1)/vari(1,3);

        corre(1,4)=corre(1,4)+(i-media_135)*(j-
media_135)*cc_135(i+1,j+1)/vari(1,4);

    end

end

corre;

%HOMEGENEIDADE

homo=[0 0 0 0];;

for i=0:L-1

    for j=0:L-1

        homo(1,1)=homo(1,1)+cc_0(i+1,j+1)/(1+(i-j)^2);

```

```

        homo(1,2)=homo(1,2)+cc_45(i+1,j+1)/(1+(i-j)^2);

        homo(1,3)=homo(1,3)+cc_90(i+1,j+1)/(1+(i-j)^2);

        homo(1,4)=homo(1,4)+cc_135(i+1,j+1)/(1+(i-j)^2);

    end

end

homo;

T_0 = [sma1; vari(1,1); entropy(cc_0); contr(1,1); corre(1,1);
homo(1,1)];

T_45=[sma2; vari(1,2); entropy(cc_45); contr(1,2); corre(1,2);
homo(1,2)];

T_90 = [sma3; vari(1,3); entropy(cc_90); contr(1,3);
corre(1,3);homo(1,3)];

T_135=[sma4; vari(1,4); entropy(cc_135); contr(1,4); corre(1,4);
homo(1,4)];

if p==1

xlswrite('All.xlsx', T_0, 1, 'D5');xlswrite('All.xlsx', T_45, 2,
'D5');xlswrite('All.xlsx', T_90, 3, 'D5');xlswrite('All.xlsx',
T_135, 4, 'D5');

end

end

```

## APÊNDICE D

Algoritmo utilizado para o desenvolvimento das RNAs.

```
clear;clc;

clear all

% Entrada de dados do excel

p=xlsread('verde.xlsx'); % ler planilha no excel e armazenar na
variavel p

t= xlsread('Saida.xlsx');

%Criação da Rede Neural

MSE2=1;

for i = 1:20

    N1=i % Neuronios da camada oculta 1

        for j= 1:20

            N2=j % Neuronios da camada oculta 2

                for k = 1:10

net=newff(p,t,[N1 N2 ],{'tansig', 'tansig'},'trainlm');

net.trainParam.epochs=200;

net.trainParam.goal=0.00003;

net.divideParam.trainRatio=0.60;

net.divideParam.valRatio=0.20;

net.divideParam.testRatio=0.20;

%Treinamento da rede neural

[net TR]=train(net,p,t);
```

```

ERROTODAS=TR.tperf;

[A Linha]=size(TR.tperf);

MSE=TR.tperf(A,Linha);

if MSE < MSE2

    MSE2=MSE;

    %salvando dados da camada oculta 1

    IW=net.IW{1,1};

    b1=net.b{1,1};

    %salvando dados da camada oculta 2 LW

    LW1=net.LW{2,1};

    b2=net.b{2,1};

    %salvando dados da saida

    LW2=net.LW{3,2};

    b3=net.b{3,1};

    filename = [ 'C:\Users\Windows\Desktop\Nova pasta (2)\' num2str(i)
num2str(j) num2str(k) '.mat' ];

    save(filename);

end

    end

    end

end

```

## APÊNDICE E

### Algoritmo para validação das RNAs.

```
clear;clc;
p2=xlsread('Dados_Vermelho_9x9.xlsx');
load('Nova pasta14111.mat')
resp = sim(net,p2);
[l,c]=size(resp);
Classes=[];
for J=1:c

    if resp(1,J) > resp(2,J) & resp(1,J) > resp(3,J) &
resp(1,J)> resp(4,J) & resp(1,J)> resp(5,J)
        Classe=1;
    elseif resp(2,J) > resp(1,J) & resp(2,J) > resp(3,J) &
resp(2,J)> resp(4,J) & resp(2,J)> resp(5,J)
        Classe=2;
    elseif resp(3,J) > resp(1,J) & resp(3,J) > resp(2,J) &
resp(3,J)> resp(4,J) & resp(3,J)> resp(5,J)
        Classe=3;
    elseif resp(4,J) > resp(1,J) & resp(4,J) > resp(2,J) &
resp(4,J)> resp(3,J) & resp(4,J)> resp(5,J)
        Classe=4;
    elseif resp(5,J) > resp(1,J) & resp(5,J) > resp(2,J) &
resp(5,J)> resp(3,J) & resp(5,J)> resp(4,J)
        Classe=5;
    end
    Classes=[Classes Classe];
end

%ÍNDICE Kappa
Classe_A=sort(Classes(1:40));Classe_B=sort(Classes(41:80));Classe_
C=sort(Classes(81:120));Classe_D=sort(Classes(121:160));Classe_E=s
ort(Classes(161:200));
Ca1=sum(Classe_A(:)==1);Ca2=sum(Classe_A(:)==2);Ca3=sum(Classe_A(:)
)==3);Ca4=sum(Classe_A(:)==4);Ca5=sum(Classe_A(:)==5);CTa=(Ca1+
Ca2+ Ca3+ Ca4 +Ca5);
```

```

Cb1=sum(Classe_B(:)==1);Cb2=sum(Classe_B(:)==2);Cb3=sum(Classe_B(:)
)==3);Cb4=sum(Classe_B(:)==4);Cb5=sum(Classe_B(:)==5);CTb=(Cb1+
Cb2+ Cb3+ Ca4 +Cb5);
Cc1=sum(Classe_C(:)==1);Cc2=sum(Classe_C(:)==2);Cc3=sum(Classe_C(:)
)==3);Cc4=sum(Classe_C(:)==4);Cc5=sum(Classe_C(:)==5);CTc=(Cc1+
Cc2+ Cc3+ Ca4 +Cc5);
Cd1=sum(Classe_D(:)==1);Cd2=sum(Classe_D(:)==2);Cd3=sum(Classe_D(:)
)==3);Cd4=sum(Classe_D(:)==4);Cd5=sum(Classe_D(:)==5);CTd=(Cd1+
Cd2+ Cd3+ Ca4 +Cd5);
Ce1=sum(Classe_E(:)==1);Ce2=sum(Classe_E(:)==2);Ce3=sum(Classe_E(:)
)==3);Ce4=sum(Classe_E(:)==4);Ce5=sum(Classe_E(:)==5);CTe=(Ce1+
Ce2+ Ce3+ Ca4 +Ce5);
CTA=(Ca1 + Cb1 + Cc1 + Cd1 + Ce1); CTB=(Ca2 + Cb2 + Cc2 + Cd2 +
Ce2); CTC=(Ca3 + Cb3 + Cc3 + Cd3 + Ce3); CTD=(Ca4 + Cb4 + Cc4 +
Cd4 + Ce4); CTE=(Ca5 + Cb5 + Cc5 + Cd5 + Ce5); CTT=(CTA + CTB +
CTC + CTD + CTE);
CTAa=(Ca1 + Ca2 + Ca3 + Ca4 + Ca5); CTBb=(Cb1 + Cb2 + Cb3 + Cb4 +
Cb5); CTCc=(Cc1 + Cc2 + Cc3 + Cc4 + Cc5); CTDd=(Cd1 + Cd2 + Cd3 +
Cd4 + Cd5); CTEe=(Ce1 + Ce2 + Ce3 + Ce4 + Ce5);

MC=[Ca1 Cb1 Cc1 Cd1 Ce1 CTA;Ca2 Cb2 Cc2 Cd2 Ce2 CTB;Ca3 Cb3 Cc3
Cd3 Ce3 CTC;Ca4 Cb4 Cc4 Cd4 Ce4 CTD;Ca5 Cb5 Cc5 Cd5 Ce5 CTE;CTAa
CTBb CTCc CTDd CTEe CTT]

K=(CTT*(Ca1 + Cb2+ Cc3 + Cd4 + Ce5)-(CTA*CTAa + CTB*CTBb +
CTC*CTCc + CTD*CTDd + CTE*CTEe))/((CTT*CTT) - (CTA*CTAa + CTB*CTBb
+ CTC*CTCc + CTD*CTDd + CTE*CTEe))

```

## APÊNDICE F

Algoritmo para calcular os descritores texturais da imagem.

```
clc;clear;close all;
Im = imread('ii1.tif');
Im=Im(:,:,3);
[l c]=size(Im);
sma_3=[];vari_3=[];entropy_90=[];contr_3=[];corre_3=[];homo_3=[];
for I=4:(l-3)
    for J=4:(c-3)
        x=[Im(I-3:I+3,J-3:J+3)];
        im=x+1;
        % MCC
        mcc= graycomatrix (im, 'offset', [-1 1], 'Symmetric',
        true,'NumLevels',256,'G',[1 256]);
        % Descritores texturais
        stats = graycoprops(mcc,{'Energy','contrast','Correlation'});
        MCCn=mcc/sum(mcc(:));
        MCCn=double(MCCn);
        L=256;
        media=0;
        for i=0:L-1
            media=media+i*sum(MCCn(i+1,:));
        end
        %var
```

```

vari=0;

for i=0:L-1

    vari=vari+(i-media)^2*sum(MCCn(i+1,:));

end

vari;

%HOMEGENEIDADE

homo=0;

for i=0:L-1

    for j=0:L-1

        homo=homo+MCCn(i+1,j+1)/(1+(i-j)^2);

    end

end

homo;

ent=[entropy(MCCn)];

T_0 = [stats.Energy; vari; ent; stats.Contrast; stats.Correlation;
homo];

Classes=[];

for a=1:1:1

    for b=1:1:10

load('12107')

resp = sim(net,T_0);

[l1,c1]=size(resp);

```

```

for J1=1:c1

    if resp(1,J1) > resp(2,J1) & resp(1,J1) > resp(3,J1)

        Classe=1;

    elseif resp(2,J1) > resp(1,J1) & resp(2,J1) >
resp(3,J1)

        Classe=2;

    elseif resp(3,J1) > resp(1,J1) & resp(3,J1) >
resp(2,J1)

        Classe=3;

    end

    Classes(a:a,b:b)= [ Classe];

end

end

end

end

end

filename1 =
['C:\Users\Windows\Documents\ArcGIS\Imagem_Araponga\RecorteImagem_
cafe\Classes.xlsx'];

save(filename1, Classes)

```

## APÊNDICE G

Tabela 3: Levantamento das fazendas e talhões visitados em campo, idade de plantio (ano), idade da recepa (ano), classe atribuída.

Fazenda	Talhão	Idade (Plantio)	Idade (Recepa)	Classe
Itatiaia	Jamides	2007		3
Itatiaia	Coqueiro	1980	2006	3
Itatiaia	Jamides II	2006		3
Itatiaia	Lavoura Velha	1980		3
Itatiaia	Matinha	1990		3
Itatiaia	Cacau		2010	2
Itatiaia	Capela		2008	3
Itatiaia	Capela		2008	3
Itatiaia	Capela		2008	3
Itatiaia	Eucalipto	2004		3
Itatiaia	Eucalipto	2004		3
Itatiaia	Capelinha	2010		2
Itatiaia	Pasto	2010		2
Itatiaia	Pasto	2010		2
Itatiaia	Brotação da Tulha		2009	2
Itatiaia	B. Nova da tulha		2011	1

Itatiaia	B. Nova da tulha	2011	1	
Itatiaia	A. do cerrado	2010	2	
Itatiaia	Nair Cornélio	2010	2	
Itatiaia	Nair Cornélio	2010	2	
Itatiaia	Onésio	2010	2	
Itatiaia	Bem vindo	2004	3	
Itatiaia	Onésio	2010	2	
Itatiaia	Lavoura Velha	1980	3	
Itatiaia	Epamig	2004	3	
Itatiaia	Pinguim	2011	1	
Itatiaia	Pomar	2010	2	
Boa Vista		2012	1	
Boa Vista		2009	2	
Boa Vista		2001	2011	1
Boa Vista		2001	3	
São Carlos		2008	3	
São Carlos		2008	3	
São Carlos		2001	3	
São Carlos		2009	2	
São Carlos		2009	2	
Pedra redonda	Baroa	2000	2010	2

Pedra redonda	Baroa	2000	2010	2
Pedra redonda	Baroa	2000	2010	2
Pedra redonda	Baroa	2000	2010	2
Pedra redonda	Limão	2001	2010	2
Pedra redonda	Tanque	2000	2008	3
Pedra redonda	Tolé	2001	2006	3
Pedra redonda	Bananeira	2001	2011	1
Pedra redonda	Eucalipto	2001	2010	2
Pedra redonda	Eucalipto	2001	2011	1
Pedra redonda	Eucalipto	2001		3
Pedra redonda	Torre	2001	2009	2
Pedra redonda	Torre	2001	2009	2
Pedra redonda	Torre	2001	2009	2
Pedra redonda	Leocena	2000	2010	2
Pedra redonda	Leocena	2000	2010	2
Pedra redonda	Leocena	2001	2009	2
Pedra redonda	Poste	1999	2008	3
Mundial		1987	2002	3
Ponte		1987	1999	3
Rosário		2003		3
Rosário			2010	2