

UNIVERSIDADE FEDERAL DE VIÇOSA
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
DEPARTAMENTO DE ENGENHARIA CIVIL
SETOR DE ENGENHARIA DE AGRIMENSURA

Márcio Pupin de Mello

UTILIZAÇÃO DE REDES BAYESIANAS EM IMAGENS DE SENSORIAMENTO
REMOTO PARA DELINEAMENTO DE CULTURAS AGRÍCOLAS USANDO
ANÁLISE CONTEXTUAL

VIÇOSA - MG
2007

MÁRCIO PUPIN DE MELLO

UTILIZAÇÃO DE REDES BAYESIANAS EM IMAGENS DE SENSORIAMENTO
REMOTO PARA DELINEAMENTO DE CULTURAS AGRÍCOLAS USANDO
ANÁLISE CONTEXTUAL

Monografia apresentada a Universidade
Federal de Viçosa como parte das exigências da
disciplina EAM 497 – Seminário e Monografia, do
curso de Engenharia de Agrimensura.

Orientador: Carlos Antonio Oliveira Vieira
Co-Orientador: Luiz Alexandre Peternelli

VIÇOSA - MG
2007

UNIVERSIDADE FEDERAL DE VIÇOSA
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
DEPARTAMENTO DE ENGENHARIA CIVIL
SETOR DE ENGENHARIA DE AGRIMENSURA

“UTILIZAÇÃO DE REDES BAYESIANAS EM IMAGENS DE SENSORIAMENTO
REMOTO PARA DELINEAMENTO DE CULTURAS AGRÍCOLAS USANDO
ANÁLISE CONTEXTUAL”

por
Márcio Pupin de Mello

Monografia apresentada a Universidade Federal de Viçosa como parte das exigências da disciplina EAM 497 – Seminário e Monografia, do curso de Engenharia de Agrimensura.

Prof. Carlos Antonio Oliveira Vieira
ORIENTADOR

Prof. Luiz Alexandre Peternelli
CO-ORIENTADOR

VIÇOSA - MG
2007

*Aos meus pais
José Antero e Angela,
em recompensa pelas privações
e em reconhecimento ao apoio,
com todo meu amor.*

Agradecimentos

À Deus por me guiar;

Ao meu orientador Prof. Carlos Antonio Oliveira Vieira pela dedicação e trocas de experiências, de grande importância tanto na orientação desta monografia quanto na minha carreira acadêmica;

Ao grande amigo Prof. Luiz Alexandre Peternelli por mais essa orientação, pelos conselhos, pela dedicação e esforço em prol de minha formação acadêmica, pelo exemplo profissional e pessoal na minha vida e pela grandiosa amizade que construímos ao longo de minha estadia em Viçosa;

Ao meu pai José Antero, minhas irmãs Aline, Mayara e Lara, meu amado sobrinho e afilhado Nicolás e à Bianka pelo apoio em todos os momentos;

À minha mãe Angela por ser meu porto-seguro! Mãe, eu te amo!;

Aos professores do Departamento de Engenharia Florestal (DEF) Vicente Paulo Soares pelo uso da licença do software *Idrisi 32* e pelas trocas de conhecimentos e Carlos Antonio Alvares Soares Ribeiro (Prof. Charles) pela ajuda com os softwares e preciosas dicas;

Ao Prof. José Marinaldo Gleriani do DEF pelo apoio e dedicação aos meus interesses acadêmicos;

Ao Prof. Elpidio Inacio Fernandes Filho do Departamento de Solos (DPS), pelas dicas e ajudas quando se fizeram necessárias;

Ao Dr. César da Silva Chagas, da EMBRAPA, pelos dados (Modelo Digital de Elevação e Modelo Digital de Declividade, gerados no software *ARC/INFO*), dicas e ajudas valiosíssimas;

Aos engenheiros agrimensores e mestrandos em Informações Espaciais do Departamento de Engenharia Civil (DEC) Alessandra Lopes Braga, pelos dados e ajuda fornecida e Leonardo Campos de Assis, pela dica com o *Idrisi 32*;

Aos meus professores, colegas de curso, amigos, familiares, e todos que direta ou indiretamente contribuíram para a realização deste trabalho e/ou pela minha formação acadêmica, meus sinceros agradecimentos.

“Serei breve, mas não tão breve que a eternidade escape do coração.”

(Lindolf Bell)

Resumo

O Sensoriamento Remoto (SR) é uma ferramenta de grande potencial e aplicabilidade em várias vertentes do conhecimento humano. No entanto, a maioria de suas aplicações usufrui, genericamente, de identificação de feições, sendo desejável alcançar elevados índices de precisão. Ao longo de décadas o homem vem estudando e desenvolvendo metodologias para tal. Uma nova idéia seria usar o conceito de classificação contextual, fazendo uso de informações de contexto, no sentido de descrever com uma maior quantidade de variáveis os fenômenos e feições, facilitando assim sua identificação por meios computacionais. Uma das ferramentas potencialmente capazes de lidar com essas informações de contexto associadas à ponderações, e ainda pouco explorada na vertente do SR, são as Redes Bayesianas (RBs). A idéia é associar níveis de probabilidades inter-relacionadas entre variáveis aleatórias que representem as informações de contexto e as feições de interesse. Vislumbrando essa potencialidade esse trabalho objetivou introduzir uma “cultura” do uso das RBs aplicadas ao SR assim como mostrar a viabilidade dessa aplicação. A metodologia aplicada foi, tanto quanto possível, simples. A discretização das probabilidades *a priori* das variáveis de entrada da rede, assim como a própria simplicidade do modelo de rede escolhido não comprometeram os resultados em função dos objetivos, que mostraram o quanto promissora é a idéia de usar as RBs para delimitar feições em imagens orbitais de SR.

Palavras-chave: Inteligência Artificial. Redes Bayesianas. Classificação de imagens. Identificação de culturas agrícolas.

Sumário

1. Introdução	8
2. Revisão de Literatura	10
3. Materiais e Métodos	14
3.1. Softwares Utilizados	14
3.2. Área de Estudo	14
3.3. Rede Bayesiana.....	15
3.3.1. Abordagem Gráfica do Modelo.....	15
3.3.2. Discretização das Probabilidades e Probabilidades a Priori.....	16
3.3.3. O Modelo Probabilístico	16
3.4. Geração da Máscara	17
4. Resultados e Discussões	18
4.1. Valores de Probabilidade <i>a Priori</i>	18
4.2. Aplicação do Modelo Probabilístico na Imagem	21
4.2.1. Um Exemplo Ilustrativo.....	21
4.2.2. O Mapa de Probabilidades	21
4.2.3. Criação da Máscara	22
4.2.4. Uma Análise da Máscara	23
5. Conclusão	24
6. Referências Bibliográficas	25

1. Introdução

O Sensoriamento Remoto é uma ferramenta importantíssima que se aplica à várias vertentes do conhecimento humano. Seu potencial vai desde cálculos de áreas de queimadas em florestas (FREITAS *et al.*, 2005), aplicações em projetos rodoviários (SCHAFER e LOCH, 2005), identificação de áreas potenciais de infecção por malária (KAYA *et al.*, 2002) e até seu uso por parte dos gestores governamentais nas estimativas de safras de culturas agrícolas. Atualmente, as previsões de safras no Brasil têm sido feitas através de questionários aplicados diretamente aos produtores ou a entidades relacionadas nas diversas regiões do país, o que torna o processo lento, oneroso e muito subjetivo.

A proposição do uso de ferramentas da geotecnologia, tais como o Sensoriamento Remoto (SR), integrado com os Sistemas de Informações Geográficas (SIGs), traz consigo o aspecto de inovação e eficiência (PONTES; ROCHA; LAMPARELLI, 2005). A idéia é usar técnicas de classificação de imagens para gerar mapas temáticos e assim conseguir as estimativas de área plantada de cada cultura agrícola em questão, de forma que os gestores governamentais e até mesmo as empresas envolvidas possam planejar suas ações e estratégias visando conduzir da melhor forma possível as negociações comerciais. O grande desafio, nesse caso e na maioria de outros casos de aplicações do SR, é conseguir com que as classificações atinjam níveis de precisão compatíveis a tornar viáveis tais processos.

Vários estudos sobre técnicas e métodos de classificação de imagens foram e vêm sendo desenvolvidos ao longo dos anos, tentando suprir a necessidade de aperfeiçoar os níveis de precisão das classificações (veja, por exemplo: IPPOLITI; EPIPHANIO; SHIMABUKURO, 1998; VIEIRA; MATHER, 2000). Classificações multitemporais e multisensor (VIEIRA; MATHER; McCULLAGH, 2000) elevaram consideravelmente a precisão das classificações.

Uma questão importante a se considerar em classificação de imagens de SR é que, na grande maioria ou quase totalidade dos casos, o classificador trabalha com um número menor de classes do que a(s) imagem(s) apresentam na realidade. Isso faz com que pixels pertencentes a classes reais e diferentes, sejam classificados em uma das classes informacionais pré-definidas, diminuindo assim a precisão da classificação.

Se de alguma forma for possível fazer um “refinamento” das imagens, ou seja, informar ao classificador quais regiões da(s) imagem(s) classificar e quais regiões ignorar, pode-se aumentar significativamente os níveis de precisão da classificação.

Uma das ferramentas potencialmente capazes de realizar essa tarefa, de forma automatizada, são as chamadas Redes Bayesianas (RBs) (*derivado do inglês: Bayesian Networks*).

As Redes Bayesianas são uma nova vertente em estudos de Inteligência Artificial, as quais simulam o processo de tomada de decisão lógica (JENSEN, 1996) através de modelos probabilísticos. Esses estudos estão relativamente bem disseminados em várias áreas do conhecimento humano, principalmente na medicina (veja, por exemplo: PESSETE; VIEIRA, 2002) e mostram, por exemplo, que é totalmente possível uma máquina ajudar um médico a fazer um diagnóstico com base nos sintomas do paciente. Isso pode parecer uma tarefa simples para uma pessoa, mas em termos de processamento em computadores, o processo de tomada de decisão quando envolvidas incertezas e condicionalidades é bastante complexo (JENSEN, 1996).

Vislumbrando a potencialidade das RBs, principalmente em aplicações à técnicas que resultem ou venham contribuir na melhoria da precisão de processos de classificação de imagens em SR, esse trabalho tem como objetivo introduzir os conceitos de RBs e suas aplicações assim como mostrar a viabilidade dessa técnica de Inteligência Artificial no contexto do Sensoriamento Remoto.

2. Revisão de Literatura

A melhoria e aperfeiçoamento dos métodos e precisões de classificações de imagens oriundas do Sensoriamento Remoto (SR), bem como a importância de alcançar uma boa precisão nas classificações, especialmente com aplicações a imagens obtidas por sensores orbitais (que possui a enorme vantagem de cobrir regiões extensas) é objeto constante de estudos pela comunidade científica (BROWN, 2004; IBRAHIM *et al.*, 2004; OZDOGAN; WOODCOCK, 2006; PAL; MATHER, 2001; VIEIRA; MATHER, 2000).

Estatisticamente falando, altas precisões significam valores estimados próximo dos valores aceitos como verdadeiros, além de baixa variabilidade dessas estimativas (ANDRIA *et al.*, 2000). É fato que os erros estão presentes em qualquer classificação. No caso dos processos feitos de forma manual, especificamente, esses erros estão associados à dificuldade de identificação de feições, generalização excessiva, variação na interpretação de detalhes entre outros (ANDRIA *et al.*, 2000). Contudo é desejável automatizar os processos de classificação.

O assunto “precisões” e as maneiras de analisá-las são sempre objetos de novos estudos e metodologias. Um forte exemplo disso é o trabalho de Vieira e Mather (2000) que descreve técnicas de estimativas de precisões nas classificações abordando o componente espacial na distribuição dos erros.

Andria *et al.* (2000) apresenta uma possibilidade de se abordar o erro das foto-interpretações de imagens SAR usando a matriz de erros. E também aborda o conceito de “*percentage correct*”, ou seja, uma informação da proporção de pixels classificados corretamente ou a amostra usada para construir a matriz. Já Pal e Mather (2001) conseguiram bons índices de precisão para classificação de culturas agrícolas em Littleport – Inglaterra usando modelagens de classificadores de “árvores de decisão” (*Decision Tree Classifiers*). Ibrahim *et al.* (2004), por sua vez, mostra que em seu trabalho, o uso de informações de probabilidade *a priori* em “back propagation” nas redes neurais ocasionou uma melhora média de 20% na exatidão das classificações, quando comparadas ao não uso da técnica.

Apesar dos grandes avanços nos satélites de SR nos últimos trinta anos, as aplicações do SR são limitadas pela resolução espacial das imagens orbitais, segundo Blaschke *et al.* (2002). Em trabalho recente, Ozdogan e Woodcock (2006) afirmam que a resolução espacial depende da área de aplicação e ainda exemplifica apresentado que campos de culturas em Anhui, província chinesa, são em média pequenos (0,7 ha) e sendo assim, seria apropriado o uso de sensores de resolução espacial não

muito maiores que 45 metros para se trabalhar em classificação de culturas agrícolas. Enquanto que em Conversely – Califórnia (USA) pode usar resolução espacial de 500 metros para os mesmos fins.

Certamente, a resolução espacial não é a única variável em consideração em estudos dessa natureza. Ippoliti, Epiphaniou e Shimabukuro (1998) procuraram obter estimativas de áreas plantadas com culturas usando dados multitemporais. Nesse estudo foi comentada a necessidade de melhorar as precisões da classificação para aplicação de estimativas agrícolas municipais. Outro exemplo, de aspecto semelhante, é abordado por Blaschke *et al.* (2002) mostrando que, para uma área de estudo localizada na divisa da Alemanha e Áustria, o uso de classificações baseadas em segmentações de objetos foi eficientemente melhor que a classificação tradicional (pixel-a-pixel). Uma vez que a classificação pixel-a-pixel, causou o conhecido efeito de ruídos nas imagens classificadas enquanto que a classificação por regiões, não o fez. Já Ravan, Roy e Sharma (1995) relatam que obtiveram sensíveis melhorias na precisão de classificação de vegetações em imagens do *Madhav National Park* – Índia, quando do uso de dados multitemporais. Seguindo a mesma linha de raciocínio Hyypä *et al.* (1997) conseguiu melhorar a precisão, em todos os testes realizados em seu trabalho, combinando imagens do ERS e Landsat TM, ou seja, análise multiespectral.

Em outras aplicações, que não a de classificação de culturas agrícolas, a precisão das classificações de imagens de SR também são tomadas como importantes. Uma exemplificação do exposto vem do trabalho de Castro Filho (2006) que sugere que o uso do SR como apoio e base de dados aos processos de cadastro técnico municipal é válido quando conseguidos bons índices de precisão.

Sobre o uso de informações contextuais, segundo Mather (1999) dois tipos de informações não espectrais (informações contextuais) podem ser abordados nos processos de classificação. O primeiro deles é a textura e o segundo é a chamada informação externa, ou seja, informação não registrada pelos sensores, tais como modelos de elevação ou informações derivadas de mapas de geologia e solos.

Na vertente das informações contextuais podem ser citados alguns trabalhos como o de Niel *et al.* (2003) que fez um estudo de técnicas de classificação com elevadas precisões. Nesse estudo foram comparados resultados de classificações de culturas de arroz usando informações contextuais como índice de umidade, com a técnica padrão de classificação supervisionada, encontrando uma diferença, entre as máximas precisões dos dois métodos (97,74% e 95,81%, respectivamente), de 1,93%

em melhoria da precisão da classificação, quando do uso da informação de umidade. Também o trabalho de Brown (2004) que usa informações contextuais como elevação e declividade para conseguir bons índices de precisão na classificação de habitats costeiros na Inglaterra. Essas informações são extraídas do Modelo Digital de Elevação (MDE) derivado de dados multiespectrais mostrando que a exatidão foi 8,5% maior quando usado declividade e elevação de forma conjunta. Quando do uso individual de cada uma dessas informações o acréscimo na exatidão foi de 2,9% para o uso da elevação e de 1,2% para o uso da declividade. Assim também Chagas (2006) usou informações contextuais como geologia, declividade, elevação entre outros aplicados a redes neurais e ao método de máxima verossimilhança obtendo resultados expressivos na classificação automatizada de classes de solos.

De modo geral, as conclusões de vários trabalhos convergem para o fato de que informações contextuais podem ser usadas para encontrar melhores resultados em processamento de imagens em SR (veja, por exemplo: CAMPOS *et al.*, 2005). Essas informações contextuais podem ser abordadas usando a técnica das Redes Bayesianas.

O termo “Bayesiano” é derivado do nome “Bayes”. Thomas Bayes foi um reverendo presbiteriano que viveu no início do século XXVIII (1701? – 1761) na Inglaterra, e suas contribuições culturais e intelectuais podem ser encontradas, hoje, em milhares de artigos científicos (PENA, 2006).

Na estatística, generalizando, existem duas grandes vertentes. Uma delas é a frequentista e a outra é a bayesiana. Essa última aborda aspectos de probabilidade como grau de credibilidade. Pode-se dizer que o grande primórdio da abordagem bayesiana a problemas de inferência partiu da publicação por Richard Price, em 1763, da obra póstuma de Thomas Bayes intitulada “*An essay towards solving a problem in the doctrine of chances*” (Ensaio buscando resolver um problema na doutrina das probabilidades) (PAULINO; TURKMAN; MURTEIRA, 2003) onde estava presente a demonstração do famoso teorema de Bayes (PENA, 2006).

A idéia de se trabalhar com probabilidades como grau de credibilidade, de suma importância para compreender a filosofia bayesiana, é longínqua. Acredita-se que Bernoulli, em sua obra “*Ars Conjectandi*” (em 1713), foi um dos primeiros autores a definir probabilidade como grau de confiança numa dada proposição, que ainda não se conhece a respeito de sua veracidade (PAULINO; TURKMAN; MURTEIRA, 2003).

A idéia do bayesianismo tem dois grandes alicerces epistemológicos. O primeiro é ver o universo com base em graus de credibilidade, ao invés da idéia

booleana de “tudo-ou-nada”. O outro é uma abordagem matemática que quantifica a mudança das crenças quando de novos dados empíricos (PENA, 2006).

A modelagem matemática do teorema de Bayes propõe cálculos de probabilidades, com base em conhecimentos *a priori* e condicionalidades probabilísticas, ou seja, ela liga a inferência racional (probabilidade *a posteriori*) à subjetividade (probabilidade *a priori*) e a experiência empírica (probabilidades condicionais) (PENA, 2006). É como escrito de forma poética por Yudkowski (2003): “O teorema de Bayes liga a razão humana ao universo físico”.

O conceito de Redes Bayesianas vem do desenvolvimento “em cadeia” do cálculo de probabilidades de Bayes. Redes Bayesianas são grafos acíclicos dirigidos, ou seja, representações de relações causais entre variáveis aleatórias interdependentes em modelos probabilísticos (LAURÍA; DUCHESSI, 2006; KIM; NEVATIA, 2000). Segundo Pena (2006) as RBs são diagramas que analisam problemas reais através de um mapeamento probabilístico das relações de causa e efeito entre variáveis.

Não muitos trabalhos citam o uso de redes bayesianas aplicadas à técnicas de SR (veja, por exemplo: PALUBINSKAS; DATCU; PAC, 1999; MÁXIMO; FERNANDES, 2003; GORSEVSKI; JANKOWSKI; GESSLER, 2005). No entanto as aplicações dessa vertente de Inteligência Artificial (IA) em outras áreas como a medicina (PESSETE; VIEIRA, 2002, por exemplo) controle ambiental (ARAUJO; NEHME, 2001), e, de um modo geral, quando se trabalha com incertezas (veja: CAVALHIERI, 2006; LUNA, 2004) é bastante promissor (veja também: McFARLANE; EVANS; ACKERMAN, 2001). Entretanto a grande dificuldade de utilização de RBs, está na estimativa dos modelos probabilísticos *a priori* e de modelar quantitativamente o conhecimento empírico em um ambiente não-freqüentista (ARAUJO; NEHME, 2001).

3. Materiais e Métodos

3.1. Softwares Utilizados

Foram usados os softwares: *Microsoft Bayesian Networks* (KADIE; HOVEL; HORVITZ, 2001) na construção e testes de modelos probabilísticos; *ARC/INFO* (ESRI, 1997) na geração do Modelo Digital de Elevação e Modelo Digital de Declividade; e *Idrisi 32* na criação do índice de vegetação NDVI (do inglês: *Normalized Difference Vegetation Index*) e aplicação do modelo probabilístico escolhido (mais detalhes são abordados em seqüência).

3.2. Área de Estudo

A área de estudo em questão possui área de 1.474,560 ha e está localizada poucos quilômetros à oeste da mancha urbana no município de Viçosa – MG. Ela está compreendida entre as coordenadas UTM 7.701.273,460m N e 7.705.113,460m N e 713.914,377m E e 717.754,377m E, zona 23 S (Figura 1). O modelo de declividade utilizado (Figura 2-b) foi derivado de um modelo digital de elevação (MDE) (Figura 2-a) obtido utilizando-se o módulo TOPOGRID do software *ARC/INFO*, a partir das curvas de nível (20m), hidrografia e pontos cotados contidos nas cartas topográficas do IBGE. Para algumas abordagens, como a geração do NDVI (Figura 2-c), foi usada uma imagem ASTER (VNIR) de resolução espacial igual a 15 metros e composta de 3 bandas (verde, vermelho e infra-vermelho próximo) de onde foi extraída uma sub-imagem de 256 x 256 pixels (num total de 65536 pixels), o que corresponde a área de estudo em questão (destacada na Figura 1).




Figura 1 - Imagem em composição falsa-cor da área de estudo localizada no município de Viçosa – MG.




Figura 2 - (a) Modelo Digital de Elevação (MDE); (b) Modelo Digital de Declividade; (c) NDVI

3.3. Rede Bayesiana

A abordagem para a modelagem da rede bayesiana tentou ser a mais simples possível, mas sempre tentando conciliar a simplificação de modo a não prejudicar a eficiência de implementação do processo.

3.3.1. Abordagem Gráfica do Modelo

O modelo de rede bayesiana aplicada pixel a pixel é como descrita em seqüência (Figura 3).

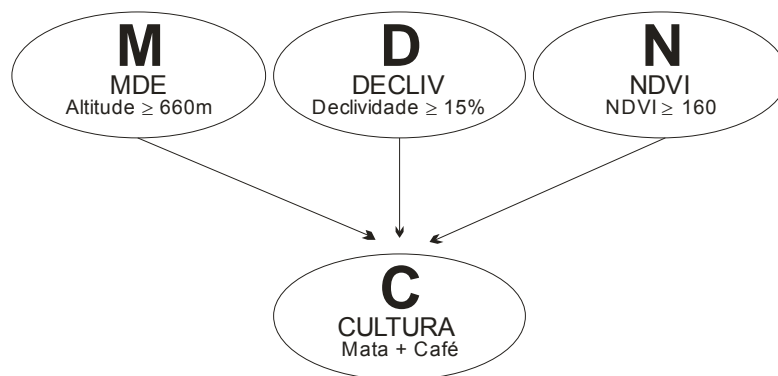


Figura 3 - Modelo de rede bayesiana utilizado onde: M (MDE), D (DECLIV) e N (NDVI) são as variáveis de entrada e C (CULTURA) é a variável de saída.

3.3.2. Discretização das Probabilidades e Probabilidades a Priori

Cada uma das variáveis de entrada (M, D e N) tiveram suas funções de probabilidades assumidas como discretas, associadas à ocorrência ou não de valores maiores ou iguais a um certo “valor-limite”. Esses valores-limites são 660m, 15% e 160, para Altitude (M), Declividade (D) e NDVI (N), respectivamente.

Os valores de probabilidade *a priori* foram obtidos da probabilidade geométrica dessas ocorrências, ou seja, exemplificando para a Declividade (D): do total de pixels digitalizados (Figura 4-b) (33916) obteve-se os que estavam localizados em regiões com declividade maior ou igual a 15% (27015), logo a probabilidade da ocorrência de áreas de declividade igual ou superior a 15% é (27015 / 33916) 79,7% e a probabilidade de ocorrência de áreas com declividade menor que 15% é (1 – 0,797) 20,3% (Os valores de probabilidade obtidos por probabilidade geométrica, como supra descrito, são abordados em “Resultados e Discussões”).

3.3.3. O Modelo Probabilístico

Seguindo o modelo de rede escolhido (Figura 3), desenvolve-se a seguinte modelagem probabilística (lembrando sempre que o interesse é encontrar a probabilidade de que um determinado pixel seja Cultura):

$$P(C / M, D, N) = \frac{P(C, M, D, N)}{P(M, D, N)}, \text{ isolando } P(C, M, D, N) \text{ temos:}$$

$$P(C, M, D, N) = P(C / M, D, N) * P(M, D, N) \quad (1)$$

Em que:

C: Cultura (podendo assumir os resultados C=s quando da ocorrência de Cultura ou C=n quando da não ocorrência de Cultura);

- M*: Elevação (podendo assumir os resultados $M=s$ quando da ocorrência de valores iguais ou acima de 660m ou $M=n$ para os demais valores);
- D*: Declividade (podendo assumir os resultados $D=s$ quando da ocorrência de valores iguais ou acima de 15% ou $D=n$ para os demais valores);
- N*: NDVI (podendo assumir os resultados $N=s$ quando da ocorrência de valores iguais ou acima de 160 ou $N=n$ para os demais valores).

Como *M*, *D* e *N* são mutuamente independentes, ou seja, a ocorrência de qualquer um deles não influencia na ocorrência dos demais, então podemos escrever:

$$P(M, D, N) = P(M) * P(D) * P(N) \quad (2)$$

Logo,

$$P(C, M, D, N) = P(C / M, D, N) * P(M) * P(D) * P(N) \quad (3)$$

A Eq. 3 apresenta o modelo geral, onde cada valor de probabilidade para cada pixel é variável, segundo as evidências encontradas nesse pixel, ou seja, exemplificando para um pixel em um local de elevação (*M*) maior que 660 m, declividade (*D*) menor que 15% e NDVI (*N*) maior que 160, em que se deseja a probabilidade do pixel ser Cultura (*C*), o modelo seria (detalhes sobre os valores usados abaixo serão abordados em “Resultados e Discussões”):

$$P(C = s, M = s, D = n, N = s) = P(C = s / M = s, D = n, N = s) * P(M = s) * P(D = n) * P(N = s)$$

$$P(C = s, M = s, D = n, N = s) = 0,94956 * 0,95539 * 0,20347 * 0,42859 = 0,07911 \approx 7,91\%$$

Onde as letras “s” ou “n” após a igualdade em cada variável significa a evidência dessa variável, sendo o primeiro para “igual ou acima do valor-limite” e o segundo para “abaixo do valor limite”. Já o referido à “C” ($C=s$) trata da probabilidade do pixel ser Cultura.

3.4. Geração da Máscara

Após a aplicação do modelo probabilístico em toda a imagem, foi gerada uma imagem correspondente onde, em cada pixel, tínhamos o valor da probabilidade de que aquele pixel fosse Cultura. Em seqüência o valor de 6% foi experimentalmente escolhido como limite para o critério de decisão, ou seja, pixels com probabilidade de ser “Cultura” menor que 6% foram descartados e então gerou-se uma máscara onde apenas os pixels correspondentes a probabilidades iguais ou superiores a 6% seriam considerados.

4. Resultados e Discussões

Sobre a imagem da área de estudo foram digitalizados duas classes denominadas: *Cultura* e *Outros*. A primeira delas continha pixels correspondentes a Café e Mata e a outra continha os pixels que aparentemente não pertenciam à classe *Cultura*. O resultado da digitalização, tomado como *Imagem de Referência* é mostrado na seqüência (Figura 4-b).




Figura 4 - (a) Composição falsa-cor da área de estudo e (b) Imagem de Referência.

4.1. Valores de Probabilidade *a Priori*

A discretização dos valores de probabilidade de cada uma das variáveis de entrada da rede bayesiana pode ser vista na seqüência (Tabela 1)

Tabela 1 - Discretização de probabilidades das variáveis de entrada da RB e seus respectivos valores.

Variável	Evidência	Código da Evidência	Probabilidade	Prob. %
M (MDE)	≥ 660	s	$\frac{32403}{33916} = 0,95539$	95,5%
	< 660	n	$\frac{1513}{33916} = 0,04461$	4,46%
D (DECLIV)	≥ 15%	s	$\frac{27015}{33916} = 0,79653$	79,7%
	< 15%	n	$\frac{6901}{33916} = 0,20347$	20,3%
N (NDVI)	≥ 160	s	$\frac{14536}{33916} = 0,42859$	42,9%
	< 160	n	$\frac{19380}{33916} = 0,57141$	57,1%

Vale lembrar que esses valores de probabilidade foram obtidos da seguinte forma: exemplificando para a primeira linha da Tabela 1 (MDE \geq 660m), divide-se o número de pixels digitalizados (classes: Cultura e Outros, na Imagem de Referência) que estão localizados em regiões com altitude igual ou superior a 660 metros (32403), pelo total de pixels digitalizados (33916). Assim o valor de probabilidade da ocorrência de áreas com altitudes iguais ou superiores a 660 m é de $(32403/33916 = 0,95539)$ aproximadamente 95,5%.

Da mesma forma seguem as probabilidades condicionais (dado necessário na solução do modelo probabilístico proposto) (Tabela 2):

Tabela 2 - Probabilidades condicionais de Cultura (C) dado as evidências de elevação (M), declividade (D) e NDVI (N).

M (MDE)	D (DECLIV)	N (NDVI)	n. cenário	cód. cenário	P(C=s/M,D,N)
≥ 660	$\geq 15\%$	≥ 160	1	sss	$\frac{11264}{11589} = 0,97196$
		< 160	2	ssn	$\frac{730}{14208} = 0,05138$
	$< 15\%$	≥ 160	3	sns	$\frac{2711}{2855} = 0,94956$
		< 160	4	snn	$\frac{138}{3751} = 0,03679$
< 660	$\geq 15\%$	≥ 160	5	nss	$\frac{27}{78} = 0,34615$
		< 160	6	nsn	$\frac{0}{1140} = 0 \approx 0,01^{(*)}$
	$< 15\%$	≥ 160	7	nns	$\frac{3}{14} = 0,21429$
		< 160	8	nnn	$\frac{0}{281} = 0 \approx 0,01^{(*)}$

(*) Aproximação feita apenas para eliminar valores iguais a zero.

Uma árvore de valores de probabilidades pode ser montada segundo as evidências (Tabela 3), usando o modelo proposto (Eq. 3). Essa técnica é conhecida como árvore de Bayes.

Tabela 3 - Árvore de probabilidades ($P(C=s)$), segundo as evidências de M, D e N.

M (MDE)	D (DECLIV)	N (NDVI)	n. cenário	cód. cenário	P(C=s) dadas as evidências	P(C=s)%
≥ 660	≥ 15%	≥ 160	1	sss	0,31701	31,7%
		< 160	2	ssn	0,02234	2,23%
	< 15%	≥ 160	3	sns	0,07911	7,91%
		< 160	4	snn	0,00409	0,41%
< 660	≥ 15%	≥ 160	5	nss	0,00527	0,53%
		< 160	6	nsn	0,00020	0,02%
	< 15%	≥ 160	7	nns	0,00083	0,08%
		< 160	8	nnn	0,00005	0,00% ^(*)

(*) Lembrando que esse valor não é exatamente zero, mas assim é mostrado pelo arredondamento do valor 0,00005.

Note que, pelo limite estabelecido experimentalmente como critério de decisão entre ser ou não cultura ($P(C=s) \geq 6\%$) apenas os cenários 1 (sss) e 3 (sns) foram considerados como pertencente a classe Cultura, ou seja, apenas os pixels correspondentes a locais com mais de 660 metros de altitude e com o NDVI acima de 160 foram considerados prováveis de ser da classe Cultura. É importante ressaltar também que, apesar do NDVI ter sido de fundamental importância na modelagem da rede bayesiana (e isso pode ser notado quando se observa tendências a altas probabilidades quando da evidência do NDVI=s, mesmo que a probabilidade *a priori* deste seja baixa quando comparada com as outras duas variáveis de entrada) ele, sozinho, não seria capaz de prever valores condizentes de probabilidade. Isso pode ser evidenciado nos pixels correspondentes aos cenários 5 (nss) e 7 (nns) que têm evidência NDVI=s mas possuem baixos valores de probabilidade de ser Cultura ($P(C=s)$).

Uma observação importante é os “baixos” valores de probabilidade encontrados (Tabela 3), mesmo no cenário 1 (sss), onde as condições são “tendenciosas” a altos valores. Isso é explicado pela característica da área de estudo, onde existem muitas regiões de pastagem. Assim, mesmo que o pixel esteja localizado em uma região com altitude maior ou igual a 660 m, declividade maior ou igual a 15% e de NDVI maior ou igual a 160, existe uma grande probabilidade de que esse pixel corresponda a uma região de pastagem, e, portanto, não pertencer à classe Cultura (que engloba apenas Mata e Café).

Caso se faça necessário, as probabilidades $P(C=n)$ para cada cenário podem ser obtidas subtraindo o valor de $P(C=s)$ para o cenário desejado da unidade.

4.2. Aplicação do Modelo Probabilístico na Imagem

4.2.1. Um Exemplo Ilustrativo

Para facilitar o entendimento da metodologia aplicada, um pequeno exemplo será dado, passo-a-passo, mostrando as etapas que decorrem da aplicação da rede bayesiana modelada.

Considere o pixel contido na linha 201 e coluna 19 (a sub-imagem analisada possui 256 x 256 pixels). Vamos chamá-lo de *Pixel X*. Primeiro analisa-se as evidências quanto a Elevação (MDE – M) ser maior ou igual a 660m, depois quanto a Declividade ser maior ou igual a 15% (DECLIV – D) e depois se o NDVI (N) é maior ou igual a 160 ou não.

Dados do *Pixel X*:

Elevação ($M=m_x$) = 696,938 m \geq 660 m (evidência = s);

Declividade ($D=d_x$) = 7,766% < 15% (evidência = n);

NDVI ($N=n_x$) = 204 \geq 160 (evidência = s).

Logo ele se encaixa no cenário 3 (sns). Sendo assim o modelo probabilístico aplicado fica:

$$P(C = s, M = s, D = n, N = s) = P(C = s / M = s, D = n, N = s) * P(M = s) * P(D = n) * P(N = s)$$

$$P(C = s, M = s, D = n, N = s) = 0,94956 * 0,95539 * 0,20347 * 0,42859 = 0,07911 \approx 7,91\%$$

Então a probabilidade de que esse pixel seja cultura é de aproximadamente 8%, como esse valor é maior que o valor-limite estabelecido (6%) esse pixel é considerado como provável de ser cultura e é incluído (ID = 1) na Máscara (mais detalhes quanto a Máscara será dado adiante).

4.2.2. O Mapa de Probabilidades

De posse do modelo probabilístico (Eq. 3), das probabilidades *a priori* e condicionais necessárias (Tabelas 1 e 2) o modelo foi aplicado a cada um dos pixels da imagem. O valor de probabilidade era calculado de acordo com as evidências encontradas no pixel em questão (veja Tabela 3) resultando em um “Mapa de Probabilidades” (Figura 5).




Figura 5 - Mapa de Probabilidades gerado como resultado da aplicação do modelo probabilístico à área de estudo.

Note que o Mapa de Probabilidades tem suas feições muito bem definidas quando comparadas com a imagem da área de estudo (Figura 4 – a), mostrando que o modelo escolhido foi, pelo menos visualmente, eficiente.

4.2.3. Criação da Máscara

A máscara tem o objetivo de identificar, efetivamente pixels prováveis de ser Cultura. Foram assim considerados os pixels com o valor maior ou igual a 0,06 (6%) no Mapa de Probabilidades, resultando numa imagem *booleana* (Figura 6) onde o identificador 0 representa NÃO e 1 SIM.




Figura 6 - Máscara gerada a partir do Mapa de Probabilidades

A idéia é usar a Máscara sobre a imagem da área de estudo de forma que a nova imagem resultante contenha apenas os pixels prováveis de ser Cultura. Assim o classificador, numa posterior etapa de classificação, não teria o “trabalho” de

classificar pixels com pequenas probabilidades de ser Cultura, caso seja esse o interesse, e assim aumentar a eficiência da classificação.

4.2.4. Uma Análise da Máscara

Uma análise da eficiência da máscara foi feita aplicando-a à Imagem de Referência (Figura 7). Os pixels azuis (ID = 2) são os que foram considerados como “Outros” na Imagem de Referência, mas que têm grande probabilidade de ser “Cultura”, segundo a rede Bayesiana aplicada. Já os pixels verdes (ID = 1) são os que são considerados “Cultura” na Imagem de Referência e na Máscara.




Figura 7 - Imagem resultada da aplicação da Máscara à Imagem de Referência.

Analisando a imagem (Figura 7) obtemos os seguintes dados (Tabela 4):

Tabela 4 - Comparativo do número de pixels em cada classe na Imagem de Referência antes e depois da aplicação da Máscara

Classe	Antes da Máscara	Depois da Máscara
Não Digitalizado	31620	51092
Cultura	14873	13975
Outros	19043	469
TOTAL	65536	65536

Como pode ser visto (Tabela 4) 898 pixels (14873-13975) antes tomados como verdade da classe Cultura tinham baixa probabilidade de pertencer a essa classe. Já 469 pixels que anteriormente tomados como verdadeiramente pertencentes à classe Outros têm grande probabilidade de pertencer à classe Cultura.

5. Conclusão

Ao término desta pesquisa, verifica-se que os objetivos foram alcançados, no sentido em que começa a ser criada uma cultura do uso de técnicas de inteligência artificial, nesse caso especificamente, o uso das Redes Bayesianas (RB), aplicadas no contexto do sensoriamento remoto, que mostrou-se extremamente promissora.

Os valores de probabilidades encontradas seguindo o modelo probabilístico conseguiram descrever limiares de modo a permitir a criação de uma máscara consistente, ou seja, que identificou e delimitou com certo rigor, através de informações contextuais (altitude, declividade e NDVI), pixels com probabilidades consideráveis em uma determinada classe de interesse (o que nesse caso foi a identificação de feições do tipo “Cultura” que abrangia Mata e Café).

Uma limitação fundamental foi o tempo. Certamente menores quantidades de simplificações como a discretização das variáveis de entrada ao invés da adoção de modelos probabilísticos que melhor as descrevessem, assim como uma abordagem mais complexa do modelo de Rede Bayesiana adotado contribuir-se-ia para o alcance de melhores resultados.

Sugere-se que, em trabalhos futuros, a abordagem do assunto seja mais detalhada, com os modelos probabilísticos adequados, sem muitas simplificações, além de um modelo de Rede Bayesiana mais complexo, no sentido da melhor descrição do fenômeno de estudo. Sugere-se também a realização de uma classificação dentro da feição identificada pelo uso da Rede Bayesiana, ou seja, se o objetivo do estudo é a identificação de Culturas (café, cana-de-açúcar, milho, soja e trigo, por exemplo) que após o uso da técnica de RBs e a identificação dos pixels com probabilidades consideráveis de ser “Cultura”, que se faça uma classificação para identificar cada classe (supracitada no parêntese anterior) após a aplicação da máscara e compare os resultados com a classificação sem a aplicação da máscara.

Apesar de mostrar uma tendência promissora, a aplicação de Redes Bayesianas no auxílio de identificação de feições e classificações contextuais em sensoriamento remoto é uma linha de pesquisa muito recente e certamente necessita de aprofundamentos.

6. Referências Bibliográficas

ANDRIA, G.; D'ORAZIO, A.; EKUAKILLE, A. L.; MORETTI, M.; PIERI, P.; TRALLI, F.; TROPEANO, M. Accuracy assessment in photo interpretation of remote sensing ERS-2/SAR images. *In: Instrumentation and Measurement Technology Conference*. Maryland, USA: IEEE, v. 1. p. 392-394, 2000.

ARAUJO, P. H. M.; NEHME, C. C. Uso de modelos de incerteza no controle ambiental do processo erosivo na bacia do Alto Taquari. *In: III Brazilian Symposium on GeoInformatics*. Rio de Janeiro, 2001. Disponível em: <www.geoinfo.info/geoinfo2001/papers/112pedro.pdf>. Acesso em: 20 out. 2006.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. *Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications*. University of Salzburg: Austria, p. 555-570. Disponível em: <http://enviroinfo.isep.at/UI%20200/Blaschke_et_al_engl200700.el.hsp.pdf>. Acesso em: 7 dez. 2006.

BROWN, K., Increasing classification accuracy of coastal habitats using integrated airborne remote sensing. *In: EARSeL eProceedings*, v. 3, Inglaterra, p. 34-42, 2004.

CAMPOS, V. O.; FEITOSA, R. Q. MOTA, G. L. A.; PACHECO, M. A. C.; COUTINHO, H. L. C. Um método para modelagem do conhecimento multitemporal no processo de classificação automática de imagens de sensores remotos. *Revista Brasileira de Cartografia*. n. 57/01. p. 28-35, 2005.

CASTRO FILHO, C. A. P. Análise temática de classificação orientada a segmentos para apoio ao cadastro técnico multifinalitário urbano. *In: Congresso Brasileiro de Cadastro Técnico Multifinalitário*. UFSC: Florianópolis, 2006. 10 p.

CAVALHIERI, M. A. *Modelo comportamental baseado em crenças e teoria bayesiana para simulações de vida artificial com humanos virtuais*. Tese de Mestrado, USP: São Paulo, 2006. 95 p.

CHAGAS, C. S. *Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de mar de morros*. Tese de Doutorado. UFV/DPS. Viçosa-MG, 2006. 223 p.

ESRI - Environmental Systems Research Institute, Arc Info 7.1.1. <http://www.esri.com/software/arcinfo/index.html>, 1997.

FREITAS, S. R.; LONGO, K. M.; DIAS, M. A. F. S.; DIAS, P. L. S. Emissões de queimadas em ecossistemas da América do Sul. *Estud. av.*, v. 19, n. 53. São Paulo, 2005. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-40142005000100011&lng=en&nrm=iso>. Acesso em: 07 nov. 2006.

GORSEVSKI, P. V.; JANKOWSKI, P.; GESSLER, P. E. Spatial prediction of landslide hazard using fuzzy k-means and Dempster-Shafer theory. *GIS*, v. 9. n. 4. p. 455-474, 2005.

HYYPÄ, J.; INKINEN, M.; HYYPÄ, H.; ENGDAHL, M. HALLKAINEN, M. Comparing accuracy of satellite-and airborne remote sensing data in the retrieval of forest stand

attributes. *In: Geoscience and Remote Sensing Symposium*. Florence, Italy: IEEE International, v. 2. p. 1081-1083, 1997.

IBRAHIM, M. A.; ARORA, M. K.; GHOSH, S. K.; CHEN, H. Approaches to improve accuracy of neural network classification of images dominated by mixed pixels. *In: Geoscience and Remote Sensing Symposium*. Anchorage, Alaska: IEEE International, v. 1. p. 568-571, 2004.

IPPOLITI, G. A.; EPIPHANIO, J. C. N.; SHIMABUKURO, Y. E. Utilização de sensoriamento remoto na previsão de área a ser plantada com culturas de verão em três municípios do estado de São Paulo. *In: IX Simpósio Brasileiro de Sensoriamento Remoto*, Santos: INPE. p. 25-37, 1998.

JENSEN, F. V. *An Introduction to bayesian networks*. Londres: University College London. 1996. 178 p.

KADIE, C. M.; HOVEL, C.; HORVITZ, E. *MSBNx: A component-centric toolkit for modeling and inference with bayesian networks*. Microsoft Research Technical Report MSR-TR-2001-67, 2001. Disponível em: <<http://research.microsoft.com/adapt/MSBNx/MSBNxTechreport.pdf>>. Acesso em: 1 dez. 2006.

KAYA, S.; PULTZ, T. J.; MBOGO, C. M.; BEIER, J. C.; MUSHINZIMANA, E. The use of radar remote sensing for identifying environmental factors associated with malaria risk in coastal Kenya. *Submitted to the International Geoscience and Remote Sensing Symposium*. Toronto, 2002. 3 p. Disponível em: http://www.pcigeomatics.com/services/support_center/tech_papers/igarss02_kaya_paper.pdf. Acesso em: 7 dez. 2006.

KIM, Z.; NEVATIA, R. Learning bayesian networks for diverse and varying numbers of evidence sets. *In: Seventeenth International Conference on Machine Learning*. Standord, CA, USA. p. 479-486, 2000.

LAURÍA, E. J. M.; DUCHESSI, P. J. A methodology for developing bayesian networks: an application to information technology (IT) implementation. *European Journal of Operational Research*, v. 179. p. 234-252, 2006.

LUNA, J. E. O. *Algoritmos EM para aprendizagem de redes bayesianas a partir de dados incompletos*. Tese de Mestrado, UFMS: Campo Grande, 2004. 120 p.

MATHER, P. M. *Computer processing of remotely-sensed images: an introduction*. 2. ed. Chichester, Inglaterra: John Wiley & Sons, 1999. 292 p.

MÁXIMO, O. A.; FERNANDES, D. Uso de graus de confiança das classes em classificadores bayesianos. *In: XI Simpósio Brasileiro de Sensoriamento Remoto*, Belo Horizonte: INPE, 2003.

McFARLANE, S. A.; EVANS, K. F.; ACKERMAN, A. S. Liquid water cloud retrievals – a bayesian approach. *In: Eleventh ARM Science Team Meeting*. Atlanta, USA, 2001. 8 p.

NIEL, T. G. V.; McVICAR, T. R.; FANG, H.; LIANG, S. Calculating environmental moisture for per-field discrimination of rice crops. *International Journal of Remote Sensing*, v. 24. n. 4. p. 885-890, 2003.

OZDOGAN, M.; WOODCOCK, C. E. Resolution dependent errors in remote sensing of cultivated areas. *Remote Sensing of Environment*, v. 103. p. 203–217, 2006.

PAL, M.; MATHER, P. M. Decision tree based classification of remotely sensed data. *In: 22nd Asian Conference of Remote Sensing*. Singapura: Nacional University of Singapore, 2001. 4 p.

PALUBINSKAS, G.; DATCU, M.; PAC, R. Clustering algorithms for large sets of heterogeneous remote sensing data. *In: Geoscience and Remote Sensing Symposium*. Hamburg, Germany: IEEE International, v. 3. p. 1591-1593, 1999.

PAULINO, C. D.; TURKMAN, M. A. A.; MURTEIRA, B. *Estatística bayesiana*. Lisboa: Fundação Calouste Gulbenkian, 2003. 446 p.

PENA, S. D. Bayes: o “cara”!. *Revista Ciência Hoje*, v. 38. n. 228. p. 22-29, 2006.

PESSETE, R. S.; VIEIRA, K. M. M. Redes bayesianas no diagnóstico médico. *Ciência da Computação quinta fase, INE*. 2002. Disponível em: <www.inf.ufsc.br/~barreto/trabaluno/IA_kleber_Renato_RB.pdf>. Acesso em: 20 out. 2006.

PONTES, P. P. B.; ROCHA, J. V.; LAMPARELLI, R. A. C. Análise temporal de índices de vegetação como subsídio à previsão de safras de cana-de-açúcar. *In: XII Simpósio Brasileiro de Sensoriamento Remoto*. Goiânia: INPE. p. 217-224, 2005.

RAVAN, S. A.; ROY, P. S.; SHARMA, C. M. Space remote sensing for spatial vegetation characterization. *Indian: J. Biosci.*, v. 20. n. 3. p. 427-438, 1995.

SCHAFER, A. G.; LOCH, R. E. N. Aplicação do sensoriamento remoto em projetos rodoviários: um histórico, uma realidade e uma necessidade como disciplina em cursos de engenharia. *In: XII Simpósio Brasileiro de Sensoriamento Remoto*. Goiânia: INPE. p. 1361-1368, 2005.

VIEIRA, C. A. O. *Accuracy of remotely sensing classification of agricultural crops: a comparative study*. Ph. D. Thesis. University of Nottingham: Nottingham, UK, 2000. 327 p.

VIEIRA, C. A. O.; MATHER, P. M. Visualisation of measures of classifier reliability and error in remote sensing. *In: 4th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Science*. Amsterdam: Delft University, 2000. 8 p.

VIEIRA, C. A. O.; MATHER, P. M.; McCULLAGH, M. The spectral-temporal response surface and its use in the multi-sensor, multi-temporal classification of agricultural crops. *In ISPRS: IAPRS, v. XXXIII, part B2*, Amsterdam. p. 582-589, 2000.

YUDKOWSKY, E. *An intuitive explanation of bayesian reasoning*, 2003. Disponível em: <<http://yudkowsky.net/bayes/bayes.html>>. Acesso em: 9 dez. 2006.