

4 Método Proposto

4.1. Descrição geral do modelo

Neste trabalho, cada classe (cobertura vegetal) possui um HMM específico. Os estágios fenológicos correspondem a estados e os símbolos observáveis a vetores contendo os números digitais registrados pelos sensores orbitais em cada banda espectral, assim como o NDVI (Rouse et al, 1973) calculado a partir das bandas 4 (infravermelho próximo - NIR, *near infrared*) e 3 (vermelho - Red) de acordo com

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad \text{Equação 23}$$

O HMM básico mostrado na figura 6 foi escolhido para modelar o comportamento temporal da cana de açúcar, da soja e do milho. As setas ilustram como os estados estão relacionados ao longo do tempo. Os estados PP, CR, AD e PA correspondem aos estágios de pré-plantio, crescimento, fase adulta e palhada (pós-colheita) respectivamente.




Figura 6 - HMM usado neste trabalho para cana de açúcar, soja e milho (PP = pré-plantio, CR = crescimento, AD = fase adulta e PA = palhada).

Para a pastagem e a mata-galeria, no período de tempo coberto pelas imagens disponíveis na base de dados, não ocorrem mudanças significativas nos atributos espectrais, isto porque essas coberturas vegetais não são plantadas nem colhidas e sim se encontram nas áreas em questão há muito tempo. Portanto um HMM específico foi escolhido para essas classes, tendo um único estado *AD* correspondente à fase adulta (figura 7).



Figura 7 - HMM usado neste trabalho para pastagem e mata-galeria (AD = fase adulta).

As figuras 8 e 9 mostram exemplos de áreas de cada cultura mencionada anteriormente (e estágios fenológicos), nas imagens de satélite (composição RGB 543). As amostras em questão encontram-se no centro das imagens nessas tabelas.

	Pastagem	Mata de Galeria
Fase Adulta		

Figura 8 - Exemplo de áreas de pastagem e mata-galeria nas imagens de satélite utilizadas.




Figura 9 - Exemplo de áreas de soja, milho e cana de açúcar nas imagens de satélite utilizadas.

4.2.

Ajustando o modelo à aplicação – Estimativa de parâmetros

O problema considerado neste trabalho diverge em alguns aspectos da descrição básica dos HMMs apresentada nas seções anteriores. Em primeiro lugar, as probabilidades de emissão de símbolos (b_{jk}) dependem de efeitos sazonais, os quais não são totalmente compensados na etapa de pré-processamento das imagens. Segundo, a distribuição de probabilidade a priori (π_i) não é constante ao longo do ano (ver Capítulo 5, Seção 1). Isto pode ser explicado pelo fato de cada cobertura vegetal possuir meses preferenciais para o seu plantio e colheita, condicionados principalmente pelo clima e por suas características próprias. Portanto, a probabilidade a priori de uma determinada cultura estar em um dado estado varia ao longo do ano. Terceiro, o modelo básico descrito no Capítulo 3 assume que os símbolos são emitidos em intervalos de tempo regulares. Na maioria das aplicações reais nem todas as imagens adquiridas com uma frequência

fixa são utilizáveis, por exemplo, devido à cobertura de nuvens sobre a área geográfica de interesse. É importante mencionar também que o modelo básico representado na figura 6 mostra transições possíveis entre estados que, no caso de símbolos emitidos em intervalos regulares, não seriam plausíveis. Por exemplo, a transição de PP para AD, sem passar pelo estado CR. A transição de PP para AD pode existir entre duas imagens consecutivas do banco de dados, caso o tempo que decorre entre elas seja suficientemente longo, de modo que a etapa intermediária de crescimento não tenha sido capturada. Se a base de dados disponível for analisada, existem os pares de imagens consecutivas de Outubro de 2002 e Janeiro de 2003 e também de Outubro de 2003 e Janeiro de 2004 (Apêndice II). O intervalo Outubro-Janeiro é justamente a primeira metade do ciclo da soja. Com isso, existem diversas amostras nesses pares de datas onde na data inicial (Outubro) existe a presença de soja no pré-plantio e na data seguinte (Janeiro) soja na fase adulta.

Assim, um HMM para o problema tratado neste trabalho tem que considerar as probabilidades de emissão de símbolos, assim como matrizes de probabilidade de transição de estado distintas para cada par de imagens consecutivas disponíveis no conjunto de dados.

Em benefício da legibilidade, a notação adotada neste texto para as probabilidades a priori (π_i) de ocorrência de estado, para as probabilidades de emissão de símbolos (b_{jk}) e para as probabilidades de transição de estados (a_{ij}) omite a dependência do tempo.

Em relação às probabilidades de emissão de símbolos, admitiu-se, neste trabalho, que elas possuem distribuição Gaussiana. Dessa forma, a densidade de probabilidade de emissão de um símbolo x (vetor contendo as bandas espectrais e o NDVI) é dada por:

$$p = \frac{1}{(2\pi)^{d/2} |\Sigma_{cs}|^{1/2}} \exp \left[-\frac{(x - \mu_{cs})^T \Sigma_{cs}^{-1} (x - \mu_{cs})}{2} \right] \quad \text{Equação 24}$$

onde μ_{cs} e Σ_{cs} correspondem respectivamente ao vetor de média e a matriz de covariância para a cultura c e o estado s , d é a dimensão de x e p é a função densidade de probabilidade para o caso de x possuir distribuição normal

multivariada (que é usada neste trabalho para descrever a probabilidade de emissão de símbolos).

A estimativa dos valores dos parâmetros dos modelos é feita para cada tipo de cultura agrícola separadamente a partir de amostras de treinamento, seguindo os passos mostrados na figura 10.




Figura 10 - Processo de estimativa dos valores dos parâmetros do HMM de cada cultura.

4.2.1.

Estimativa da matriz de transição de estado

As probabilidades de transição de estado a_{ij} são estimadas para cada par de imagens consecutivas do conjunto de treinamento, em que apenas segmentos das imagens, correspondentes à cultura sendo modelada, são considerados.

Para esta etapa é utilizada a técnica *leave-one-out* (Brovelli et al., 2006).

Em primeiro lugar, uma matriz acumuladora é criada para cada par de datas por cobertura vegetal. Suas linhas e colunas correspondem respectivamente aos estados nas datas anterior e posterior. Em seguida, para todas as linhas e colunas, o elemento na linha i e na coluna j é incrementado para cada amostra de segmento nos estados S_i e S_j em datas consecutivas. Cabe ressaltar que as transições de estado correspondentes à sequência de teste não são levadas em consideração no cálculo da matriz acumuladora (o incremento não é realizado).

Uma vez tendo sido considerados todos os segmentos de treinamento para aquela cobertura vegetal e par de datas, os elementos da matriz acumuladora são analisados para correção. Os elementos nulos que correspondem a transições possíveis naquele par de datas são carregados com o valor “1” (um). Esta correção se justifica em vista da escassez de padrões disponíveis no conjunto de dados. Ocorre em alguns casos que o segmento retirado para teste na técnica *leave-one-out* é o único exemplo de transição entre dois estados. Sem esta correção a probabilidade de transição seria estimada como sendo nula, o que teria

impacto não desprezível na avaliação de desempenho do método. A informação quanto às transições possíveis é considerada neste trabalho com um conhecimento *a priori* fornecido por um foto intérprete conhecedor das práticas e coberturas vegetais analisadas.

Por último, a matriz acumuladora é normalizada, dividindo cada um de seus elementos pela soma da linha correspondente. O resultado é a estimativa da matriz de transição de estado para aquela cobertura vegetal e para aquele par de datas.

4.2.2.

Estimativa das probabilidades a priori de estados

O procedimento para estimar a distribuição de probabilidade a priori dos estados π_i é similar (utiliza-se também aqui a técnica *leave-one-out*).

Novamente, apenas segmentos das imagens correspondentes às classes da cobertura vegetal modelada naquela data são considerados. Um vetor acumulador é criado, contendo um elemento por estado. O *i-ésimo* elemento é incrementado para cada amostra de treinamento no estado S_i . Assim como na subseção anterior, a informação referente à sequência de teste não é levada em consideração no cálculo do vetor acumulador (o incremento não é realizado).

Como na seção anterior, o vetor acumulador sofre uma correção, ou seja, os elementos nulos deste vetor, que correspondem a um estado possível de ocorrer no par de datas em questão, é carregado com o valor “1”. Por último, o vetor acumulador é dividido pela soma de todos os seus elementos. O resultado é a estimativa da distribuição de probabilidade a priori dos estados para aquela cobertura vegetal e para aquela data.

4.2.3.

Estimativa da emissão de símbolo

Como foi mencionado anteriormente, foi assumido que as probabilidades de emissão de símbolos possuem distribuição Gaussiana; com isso, o problema de estimar esses parâmetros reduz-se a estimar os vetores média e as matrizes de covariância para cada estado de cada cultura em cada imagem.

Neste trabalho classificam-se segmentos. Cada segmento é descrito por um vetor que contém os valores médios dos pixels que compõem o segmento a ser

classificado nas seis bandas e do correspondente valor de NDVI. Assim, todos os pixels que compõem um mesmo segmento dão origem a um único padrão a ser classificado. Tem-se desta forma um número muito menor de padrões do que haveria no caso da classificação pixel-a-pixel, para um mesmo conjunto de imagens. Esta redução no número de padrões pode implicar um número insuficiente de padrões de treinamento para estimar o vetor média e especialmente a matriz de covariância que representam os símbolos emitidos por cada estado.

Para contornar este problema, o vetor média e a matriz de covariância foram estimados a partir dos valores espectrais dos pixels contidos em cada segmento. Embora na fase de teste se classifiquem segmentos descritos por seus valores espectrais médios, as estimativas do vetor média e da matriz de covariância é feita com base nos valores dos pixels internos aos segmentos de treinamento.

O procedimento adotado foi o seguinte: a segmentação das imagens foi realizada em duas etapas. Na primeira etapa, o conjunto de 12 imagens, cada uma com seis bandas foi empilhado de modo a formar uma imagem sintética contendo 72 bandas. Este conjunto foi segmentado como se fosse uma única imagem, utilizando o método baseado em *watershed* descrito em (Mota et al., 2007). Os valores dos parâmetros de segmentação foram escolhidos por tentativa-e-erro, até que o resultado da segmentação fosse considerado consistente em toda a sequência de imagens por um foto intérprete, ou seja, até que cada segmento produzido fosse homogêneo em cada uma das 12 imagens.

A segunda etapa de segmentação foi realizada para cada uma das imagens individualmente utilizando o mesmo algoritmo e o mesmo conjunto de valores dos parâmetros de segmentação da primeira etapa. De um modo geral, os segmentos resultantes desta segunda etapa são maiores e contêm os segmentos obtidos na primeira etapa.

Os segmentos assim obtidos são divididos em duas partes, contendo cada uma aproximadamente a metade dos pixels. As estimativas do vetor médias e matriz de covariância foram feitas considerando os pixels de uma das partes. Para a fase de teste, foram considerados os valores espectrais médios da outra parte do segmento.

As estimativas do vetor média são obtidas através da média dos vetores de treinamento que representam o tipo de cobertura vegetal e o estágio fenológico

naquela data particular. Similarmente, a covariância amostral (Johnson & Wichern, 1998) é usada para estimar a matriz de covariância.

4.3. Classificação

Uma vez que o HMM tenha sido definido e seus parâmetros estimados, a classificação da imagem é feita da seguinte forma (a figura 11 ilustra esse processo).




Figura 11 - Processo de classificação.

Cada segmento de teste é representado, em cada data, por um vetor composto pelos valores das bandas espectrais e do NDVI naquela data. Este vetor corresponde ao símbolo emitido pelo segmento naquela data.

Consideram-se nesta avaliação apenas seqüências de datas em que o segmento analisado pertence a uma única cultura. O classificador calcula, para cada modelo, a probabilidade da cultura correspondente emitir a seqüência de vetores de símbolos observada naquelas datas (solução do problema 1 mencionado na Seção 3.4.3.1). O segmento de teste é atribuído à classe cujo modelo retorna a maior probabilidade de emissão. Uma descrição detalhada de como as probabilidades de emissão das seqüências de símbolos são calculadas de modo eficiente encontra-se na Seção 3.4.3.1. A Seção 3.4.3.2 descreve o algoritmo que permite inferir, para cada modelo e para cada segmento, qual o estado mais provável em cada data que compõe a seqüência.