

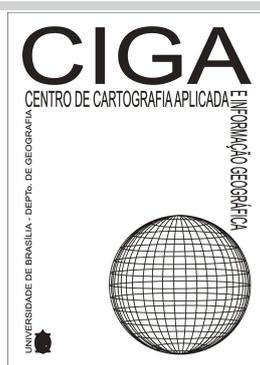
Artigo

# O USO DE IMAGENS HIPERESPECTRAIS COM EFEITOS DE REFLECTANCIA BIDIRECIONAL NA MELHORIA DA CLASSIFICAÇÃO DE CULTURAS AGRÍCOLAS

Vânia Lúcia Costa Alves Souza

p. 01-21

revista



T - T - T

Revista Eletrônica:  
Tempo - Técnica - Território,  
V.4, N.1 (2013), 1:21  
ISSN:2177-4366

DOI: <https://doi.org/10.26512/ciga.v4i1.16316>

Como citar este artigo:

SOUZA, V. L. C. A. O USO DE IMAGENS HIPERESPECTRAIS COM EFEITOS DE REFLECTÂNCIA BIDIRECIONAL NA MELHORIA DA CLASSIFICAÇÃO DE CULTURAS AGRÍCOLAS.

Revista Eletrônica: Tempo - Técnica - Território, v.4, n.1 (2013), p. 1:21 ISSN: 2177-4366. DOI: <https://doi.org/10.26512/ciga.v4i1.16316>

Disponível em:

<http://inseer.ibict.br/ciga/index.php/ciga/article/viewFile/167/126>

Este obra está licenciado com uma Licença Creative Commons Atribuição-NãoComercial 4.0 Internacional.

# O USO DE IMAGENS HIPERESPECTRAIS COM EFEITOS DE REFLECTÂNCIA BIDIRECIONAL NA MELHORIA DA CLASSIFICAÇÃO DE CULTURAS AGRÍCOLAS

Dissertation Master of GeoInformation Science

**Vânia Lúcia Costa Alves Souza**

Costa.vania0@gmail.com

MGI Student, Wageningen University

The Netherlands- 2008

Geography Teacher of Secretary of Education of Distrito Federal,  
Brasília, Brasil

**Resumo:** O mapeamento preciso de campos agrícolas é um dos principais desafios para monitorar áreas usando sensoriamento remoto. As plantações mudam durante o período de crescimento o que requer o uso de imagens de diferentes épocas para melhor identificação das plantas e conseqüentemente um alto investimento na aquisição destas imagens em várias datas.

No passado, a classificação de cultivos era principalmente realizada usando imagens obtidas por sensores de satélite multiespectrais que, por um lado, oferecem dados reunidos sobre uma grande área em poucas imagens de uma forma econômica, mas por outro lado, estas imagens possuem pequena resolução espectral. Os sensores hiperespectrais surgem para solucionar esta limitação dos sensores multiespectrais oferecendo coleta de informação em centenas de bandas num simples momento de aquisição. Em alguns casos, existe a possibilidade de combinação dos dados hiperespectrais com as informações de reflectância bidirecional nas imagens que auxiliariam a melhoria da classificação das culturas.

O propósito deste estudo foi analisar a possibilidade de melhorar a acurácia da classificação da vegetação usando imagens hiperespectrais com informações de reflectância bidirecionais. Este trabalho investigou os efeitos do número e da largura das bandas espectrais com informações de reflectância bidirecional de imagens hiperespectrais na classificação de culturas agrícolas. Foram utilizadas quatro imagens hiperespectrais AHS -16 que cobriam as áreas agrícolas localizadas na Região de Gelderse Poort, Países das Terras Baixas, Europa. Utilizou-se a classificação

supervisionada com o uso do algoritmo de Máxima Verossimilhança com as medidas de campo. As análises foram divididas em duas partes. Na primeira parte os efeitos da largura e o número de bandas foram investigados: Os resultados indicaram que a classificação agrícola utilizando imagens com bandas largas não se diferenciaram daquelas que utilizaram imagens com bandas estreitas. Porém, imagens hiperespectrais com maior número de banda apresentaram informações mais precisas sobre as culturas do que aquelas imagens multiespectrais com o menor número de bandas. A segunda parte dos estudos trabalhou com os efeitos da geometria dos ângulos de refletância bidirecional, número de bandas e largura das bandas na classificação agrícola. Imagens hiperespectrais com efeitos de refletância bidirecional apresentaram melhor classificação dos cultivos especialmente das classes com efeito de retroespalhamento.

**Palavras chave:** hiperespectrais, refletância bidirecional, classificação de culturas, análise dos componentes principais.

**Abstract:** Mapping accurately agricultural fields is one of the main challenges for monitoring areas using remote sensing. Crops change during the growing season and it is often desirable to use images acquired at several dates for plant identification. However, there is a high cost for these image acquisitions. Airborne or satellite campaigns usually cover specific regions for specific dates then offering limited data.

Advances in sensor technologies created hyperspectral sensors to overcome this spectral limitation of multispectral sensors. A hyperspectral sensor collects spectral data in several hundreds bands in a simple acquisition time offering opportunity to discriminate more precisely different plants. Thus, there is a chance that hyperspectral data produce better crop classification especially if it is combined with multiview angle information.

The purpose of this study was to evaluate the possible improvement of the accuracy of crop classification by using hyperspectral and directional remote sensing data. It investigated effects of number of bands, bandwidth and bidirectional information on classification. Four AHS-160 hyperspectral images were used in this research. They covered areas of barren lands, barley, beet, grass, horticulture, maize, onion, potato and wheat located in the region of the Gelderse Poort in the Netherlands. Classification accuracy was investigated using Maximum Likelihood with ground truth data. Analyses were divided in two parts: In the first part the effect of bandwidth and number of bands was investigated by comparing classification results of a hyperspectral image and a

simulated multispectral image. Results indicated that the size of bandwidth did not affect classification. An image with a narrow band and an image with a broad band had not a statistically different classification. The effects of the number of bands were analyzed comparing the classification of an image with 63 bands with an image with 6 bands. The image with 63 bands had better user and producer accuracy of crops than the image with 6 bands. The second part studied effects of multi view angle or bidirectional reflectance on classification. A common area in various images was considered in this part of study. Classification results using one image in one flight direction was compared with an overlap image that combined three flights directions. conclusion, Bidirectional reflectance increased classification accuracy of the majority of crops in hyperspectral images. The bidirectional reflectance influenced positively classification results of crops specially located in the principal plane.

**Key words:** *hyperspectral; bidirectional reflectance; viewing geometry; narrow bands; broad band; number of bands; crop classification;*

**Resumen:** Cartografiar campos agrícolas con precisión es uno de los principales retos para el monitoreo de áreas mediante teledetección. Isto porque los cultivos cambian durante la temporada de cultivo y a menudo es recomendable el uso de imágenes adquiridas en varias fechas para la identificación de plantas pero con un alto costo para estas adquisiciones de imagen. Campañas Airborne o satélite generalmente cubren regiones específicas para fechas específicas entonces ofrecen datos limitados.

Avances en las tecnologías de sensor crearan hyperspectral sensores para superar esta limitación espectral dos sensores multispectrales. Un sensor hiperespectral recoge datos espectrales en varios centenares de bandas en un tiempo de la adquisición simple que ofrece oportunidad de discriminar más precisamente diferentes plantas. Por lo tanto, existe la posibilidad de que datos hiperespectrales producen mejor clasificación de cultivos, especialmente si se combinado con la información del ángulo de multivisión.

El propósito de este estudio fue evaluar la posible mejora de la precisión de la clasificación de cultivos mediante hiperespectral y direccionales datos de sensores remotos. Investigaron los efectos del número de bandas, ancho de banda y bidireccional de información sobre clasificación. En esta

investigación se utilizaron cuatro imágenes hiperespectrales de AHS-160 que cubrieron áreas agrícolas situada en la región de Gelderse Poort en los Países Bajos. La precisión de la clasificación fue investigada usando la máxima verosimilitud con datos de verdad de tierra. Los análisis fueron divididos en dos partes:

En la primera parte el efecto del ancho de banda y número de bandas fue investigado. Los resultados indicaron que el tamaño del ancho de banda no afectó la clasificación. Una imagen con una banda estrecha y una imagen con una banda ancha no tenían una clasificación estadísticamente diferente. Se analizaron los efectos del número de bandas que comparaban que la imagen con 63 bandas tenía mejor usuario y exactitud del productor de cultivos que la imagen 6 bandas.

La segunda parte estudió los efectos de reflectancia de ángulo bidireccional en la clasificación. Resultados de la clasificación con una imagen en una dirección de vuelo se comparó con una imagen de superposición que combina tres direcciones de vuelos. En conclusión, la reflectancia bidireccional influyó positivamente los resultados de clasificación de cultivos ubicados especialmente en el plano principal del vuelo.

**Palabras clave:** hiperespectral; reflectancia bidireccional; banda estrecha; banda ancha; número de bandas; clasificación de cultivos.

## 1. Introdução,

O monitoramento do uso do solo agrícola requer informações precisas e periódicas para as pesquisas executadas por governos, companhias e autoridades locais (HAZEU, 2006). Monitorar a vegetação, através do sensoriamento remoto, em diferentes datas é necessário para entender o estágio de crescimento das plantas e melhor classificá-las. No entanto, o uso destas imagens requer um alto investimento para a obtenção da série temporal das imagens. Observando, que muitas vezes, estas imagens são obtidas por sensores instalados em aviões ou campanhas de satélites que cobrem específicas regiões em limitado tempo, portanto oferecendo limitada série temporal e especial.

Identificar e classificar os tipos de cultura é um dos maiores desafios para monitorar áreas usando sensoriamento remoto dado à especificidade da planta no momento da captura e interpretação correta de sua reflectância espectral (SU et al, 2007). A análise das reflectância das plantas é uma tarefa difícil porque a vegetação pode ter a resposta espectral diferente devido a vários fatores como

o estágio de crescimento, maturidade, condições de tempo, efeitos de vento, ângulo solar no momento da coleta de dados. (LANDGREBE, 1999).

Muitos estudos de classificação de culturas foram realizados usando sensores multiespectrais. No entanto, estes sensores oferecem limitada resolução espectral não oferecendo dados suficiente para uma boa identificação das culturas agrícolas.. Com o avanço das tecnologias dos sensores, surgem os sensores hiperespectrais que coletam dados em centenas de bandas espectrais somente em uma aquisição. Recentemente, muitos destes sensores foram instalados em plataforma de avião (AVIRIS, CASI, HYDICE, HYMAP, MIVIS, AHS 160, etc.) com a flexibilidade de ajuste da distância do solo (GSD) e abertura focal específica para análise agrícola (GIANINETTO e LECCHI, 2004). Em alguns voos é possível combinar dados hiperespectrais com a reflectância bidirecional e usar estas imagens em estudos de classificação de culturas agrícolas. (LIESEMBERG et al, 2007).

### **1.1 Objetivos**

Esta pesquisa pretende avaliar a melhoria na classificação de culturas usando imagens hiperespectrais com efeitos de reflectância bidirecional. Quatro questões orientaram esta pesquisa:

1. O número de bandas espectrais influencia a classificação de culturas agrícolas?
2. A largura das bandas das imagens é importante para classificação de culturas agrícolas?
3. A reflectância bidirecional é importante para a classificação de culturas agrícolas?
4. A combinação do número de bandas, do tamanho de banda e /ou reflectância bidirecional são importantes para a classificação das culturas agrícolas?

### **2. Literatura**

O processo de obtenção de dados agrícolas utilizando o sensoriamento remoto envolve três partes principais: o comportamento espectral do objeto; o tipo de sensor utilizado para captar esta energia eletromagnética do objeto e a forma de análise dos dados espectrais das imagens (LANDGREBE, 1999).

*O Objeto*

Os objetos da superfície emitem ou absorvem diferentes formas de energia eletromagnética que podem ser capturadas por sensores e analisadas pelas assinaturas espectrais. Típicas reflectâncias espectrais da vegetação revela três principais regiões do espectro eletromagnético: o espectro que denuncia a pigmentação e absorção de clorofila (0,45 e 0,67  $\mu\text{m}$ ), a reflectância das folhas (0,70 a 1,30  $\mu\text{m}$ ) e a absorção de água (1,40 e 1,90  $\mu\text{m}$ ).

O solo também influencia a reflectância do objeto ao estar combinado com outros elementos como ferro, óxidos ferrosos, matéria orgânica e formas da superfície (1,40  $\mu\text{m}$  e 1,90  $\mu\text{m}$ ).

### *Sensores*

Em geral, os sensores registram a variação da energia eletromagnética emitida ou refletida pelos objetos em imagens. Esta energia é capturada eletronicamente de forma digital e expressa pela dimensionalidade dos arranjos dos pixels. Nos dias de hoje, os sensores hiperespectrais e multiespectrais são utilizados para a coleta de dados agrícolas.

Os sensores multiespectrais utilizam um conjunto de bandas largas (LILLESAND et al, 2004). A resolução espectral das imagens multiespectrais é usada principalmente na classificação de amplas classes como água e vegetação. Adicionalmente é possível melhor identificar plantações combinando informação espectral e temporal das plantas adquiridas em diferentes estágios da planta (CHAMPAGNE et al. 2005).

Os sensores hiperespectrais adquirem imagens em muitas e estreitas contínuas bandas espectrais (LILLESAND et al, 2004) utilizadas principalmente para estimar aspectos biofísicos e bioquímicos das plantas (PRICE, 1992), medir o stress (CARTER, 1998), medir a clorofila das plantas, detectar mudanças na vegetação (BLACKBURN, 1999), medir a variação de umidade melhorando a classificação da vegetação (COCHRANE, 2000) e classificação de categorias agrícolas (THENKNAIL et al, 2004).

### *Análise de dados*

A análise dos dados envolve o uso de técnicas para melhor interpretação da reflectância dos objetos na área de estudo. Os passos mais importantes para uma boa classificação de culturas requerem: correção atmosférica, dimensionalidade dos dados e técnicas de classificação.

A correção atmosférica é necessária quando se trabalha com estudos na superfície anisotrópica e geometria de ângulos nas imagens. A correção diminui os efeitos de absorção e espalhamento da reflectância (scattering) na atmosfera captado nas imagens.

Em relação à dimensionalidade, as imagens hiperespectrais trabalham com muitas bandas coletando muitos dados. Estes dados hiperespectrais requerem armazenamento e processamento de dados apropriados para realizar a classificação agrícola utilizando o classificador da Máxima

Revista Eletrônica: Tempo - Técnica - Território, V.4, N.1 (2013), 1:21 ISSN: 2177-4366

Verossimilhança. Em muitos casos, é recomendada a extração de informações das bandas mais potentes utilizando a Análise dos Componentes Principais ou principal component analysis, PCA, permitindo a classificação das culturas.

O classificador da Máxima Verossimilhança utiliza a matriz de confusão que quantifica as variações entre a verdade do campo e a imagem classificada. Quanto mais bem diferenciada espectralmente uma classe agrícola, melhor será a classificação. A análise da separação de classes é feita pela medida de distâncias entre classes Jeffrey Matsushita que computa a separação de classes embasada na estatística de treinamento de áreas (ITT, 2007).

#### *Efeito da Bireflectância Direcional*

A função da distribuição da reflectancia bidirecional, Bidirectional Reflectance Distribution Function (BRDF) ou dados multiangulares, multiviews (MVD) se refere à variação da reflectividade dos elementos da superfície e depende da localização do sensor em relação ao Sol e do objeto de estudo (ASNER et al, 1998).

A reflectância bidirecional oferece a reflexão do objeto como uma função da iluminação geométrica de visada (no plano solar). Muitos ângulos são importantes para a reflectância bidirecional como os ângulos - zênite solar, azimutal solar, zênite e azimutal.

Os efeitos da reflectância bidirecional podem ser observados pelo brilho ou sombra e aparência do pixel na imagem. De acordo com Beisl (2001, p.37) esse efeito é dominado pelo efeito de sombra. Isto significa que cada pixel da imagem pode ser composto da mistura do pixel puro com o material ou efeito sombra. A quantidade do efeito sombra aumenta com o aumento do ângulo de zênite solar e depende do ângulo de visada e do efeito da BRDF; a anisotropia aumenta quando o ângulo solar aumenta (KUKKO, 2005). Outros estudos demonstraram que o efeito BRDF aumenta com o aumento do ângulo do scanner e diminui com o ângulo azimute. Isto significa que o BRDF é máximo quando o azimute solar é paralelo à linha de scanner e o pixel na borda da imagem (DANAHER et al, 2001).

A posição do sol e as diferenças na reflexão na direção e longe do sol produzem efeitos de retroespalhamento/ backscatter e espalhamento/foward scattering na imagem. Essas variações de reflectância podem influenciar a classificação. Os efeitos retroespalhamento/ backscatter significam a radiação refletida para a direção geral da fonte de iluminação. Ele ocorre quando o ângulo relativo

do azimute é menor que  $90^\circ$ . A vegetação com alto efeito retroespalhamento/ backscatter aumenta a índice de reflectância da superfície. O espalhamento/foward scattering tem a radiância refletida longe da direção geral de iluminação. Isto ocorre nas imagens com o azimute relativo maior que  $90^\circ$ . Algumas vegetações com espalhamento/foward scattering tem a diminuição da reflectância de superfícies (LISENBERG et al, 2004).

O fenômeno de anisotropia é dependente do comprimento de onda. O efeito da BRDF é dinâmico e varia com qualquer coisa que muda as características óticas e físicas da superfície. A vegetação é fortemente anisotrópica por causa dos diferentes tipos de plantas e interações com a superfície. As macroestruturas (tamanho das copas e distância entre as plantas) e microestruturas (índice de área foliar/LAI) das plantas influenciam o BRDF (LANDEMEIR et al, 1999). A reflectância do solo é afetada pela presença das partículas, umidade e óxido de ferro. Solo e vegetação tem normalmente diferente resposta espectral, mas existe maior influência da reflectância do solo especialmente para plantas jovens ou com pequena copa.

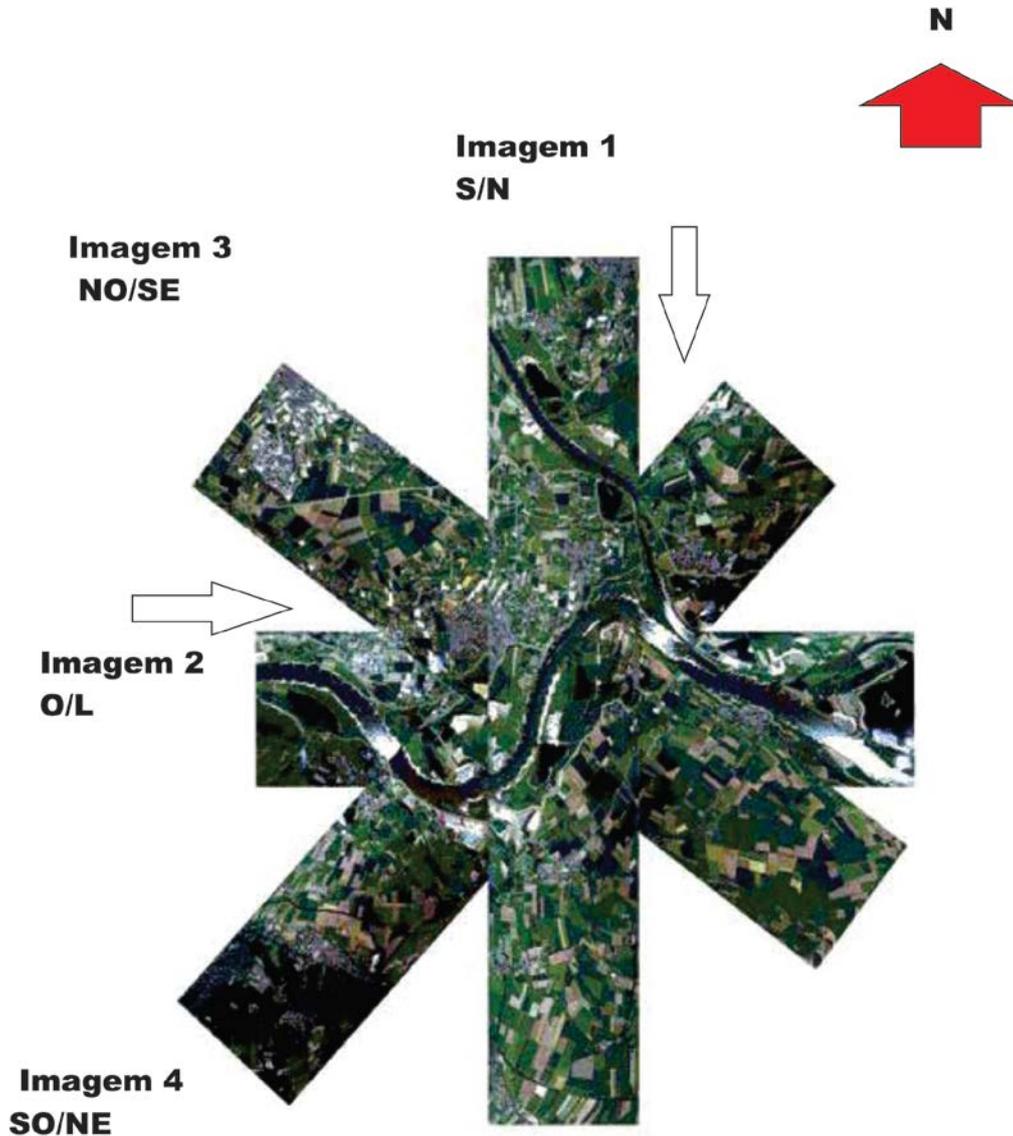
### 3. Metodologia

A Área de estudo se localiza na região de Gelderse Poort, perto da fronteira sudeste da Holanda com a Alemanha, próxima às cidades de Arnhem, Nijmegen e Emmerich. Neste local existem 60 fazendas com técnicas intensivas de cultivo de beterraba, batata, milho, trigo, horticultura, trigo, cevada, criação de gado para leite e corte.

As imagens Hyperespectrais utilizadas neste estudo foram obtidas por um avião com um scanner whiskbroom AHS 160 operado pelo INTA instituto de Tecnologia Aeroespacial da Espanha. Este scanner opera com 80 bandas, possui quatro filtros dicróicos que dividem a radiação em quatro portas óticas de comprimentos de onda que variam de 0,43 a 12,7  $\mu\text{m}$ . O voo ocorreu em 19 de junho de 2005, próximo às 12 horas e cobriu a mesma área em quatro diferentes direções com uma sobreposição da área central. Imagem 1 - direção sul/norte, Imagem 2 - direção oeste/leste, Imagem 3- direção noroeste/sudeste. Imagem 4 - direção sudoeste/nordeste (figura 1). No mesmo dia do voo, foi realizada uma campanha com verificação em campo das culturas presentes na área de estudo: Beterraba, batata, milho, cevada, trigo, horticultura, grama, cebola e terra desnuda (CLEVERS e KOOISTRA, 2008).

As imagens hiperespectrais tiveram correções radiométricas e atmosféricas realizadas pela VITO ,Instituto Belga de Pesquisa Tecnológica. A altitude do voo era de 1834m e as imagens possuíam 4,75 m de resolução espacial. As imagens foram corrigidas geometricamente usando ortofotos de

2004 e das coordenadas holandesas nacionais RD. As imagens finais foram produzidas usando a projeção WGS 84.



**Figura 1.** Imagens AHS 160 da Região de Gelderse Poort, Holanda, junho de 2005.

Para responder as quatro perguntas da pesquisa, este estudo foi estruturada em duas partes: Parte A- Estudo da influência dos números de bandas e da largura da banda na classificação de culturas utilizando imagens hiperespectrais. Parte B influência dos efeitos de reflectância bidirecional em imagens hiperespectrais na classificação de culturas.

### 3.1 Parte A- Estudo da influência dos números de bandas e da largura da banda na classificação de culturas

#### 3.1.1 Parte A.1. Influência dos números de bandas na classificação de culturas.

A classificação das culturas foi realizada em dois tipos de imagens: A Imagem 1 AHS 160 com 63 bandas e a Imagem 1 Sintética Estreita do tipo Landsat 7ETM com 6 bandas. A Imagem 1 AHS 160 foi escolhida por possuir a maior parte das culturas estudadas. A Imagem 1 Sintética Estreita foi obtida com a seleção de uma específica banda que trabalhava no espectro similar à imagem Landsat 7ETM (tabela 1). A escolha da imagem do tipo Landsat 7 ETM se justifica por esta possuir as bandas espectrais em intervalos específicos para o estudo das plantas. : variação da pigmentação (0,45- 0,52  $\mu\text{m}$ ), medida da clorofila e do nitrogênio (0,52 -0,60  $\mu\text{m}$ ), índice de área foliar (0,63 – 0,60  $\mu\text{m}$ ), umidade do solo (0,76 -0,9  $\mu\text{m}$ ) (THENKABAIL et al, 2004).

**Tabela 1. Características da Imagem 1 Banda estreita**

Características espectrais Landsat 7 ( $\mu\text{m}$ )	Imagem 1 Sintética Estreita 6 bandas (AHS 160 / $\mu\text{m}$ )
Banda 1 0,45- 0,52	Banda 3 0,47- 0,54
Banda 2 0,52-0,60	Banda 5 0, 53 – 0,60
Banda 3 0,63-0,69	Banda 8 0,62-0,69
Banda 4 0,76- 0,90	Banda 13 0,76 – 0,83
Banda 5 1,55- 1,75	Banda 21 1,41-1,82
Banda 7 2,08- 2,35	Banda 40 2,22- 2,26

Em seguida foram definidas 162 polígonos das regiões de interesse (ROIs) na Imagem 1, sendo que metade destas áreas foi utilizada como áreas de treino e outra metade como área de validade. Estas ROIs possuíam o número de pixel entre 100 e 400 pixels, localização longe das fronteiras e distribuição espacial representativa das culturas pela região (CAMPBELL, 2006). As áreas de treino foram avaliadas segundo a sua separação de classes verificadas pelas assinaturas espectrais e diagrama de dispersão de espalhamento/scatter plot e análise de separação J.M.

A classificação supervisionada foi realizada usando Máxima Verossimilhança onde cada pixel é assinado na classe com alta probabilidade de classificação. As matrizes de confusão foram comparadas assim como os índices Kappa. Por último foi aplicado o teste de hipóteses O teste de cálculo de p para fazer a decisão sobre a diferença estatística entre as classificações onde  $p \leq 0,025$ .

### 3.1.2 Parte A.2 Influência da largura de bandas na classificação de culturas

Nesta parte do estudo a Imagem 1 AHS 160 foi utilizada para gerar a Imagem Sintética Larga. A criação da Imagem Sintética Larga do tipo Landsat 7ETM foi realizada combinando **todas** as bandas da imagem 1 AHS 160. Esta combinação utilizou a função matemática de bandas do programa ENVI como o descrito na tabela 1. Esta Imagem Sintética Larga teve a sua classificação comparada com a Imagem 1 Sintética Estreita (tabela 1) criada na parte A.1.

**Tabela 2. Características da Imagem Banda Larga**

Landsat 7 (µm)	AHS 160 (µm) Imagem Sintética Larga
1. 0,45- 0,52	$(b1+b2+b3)/3$ 0,42-0,54
2. 0,52-0,60	$(b4+b5+b6)/3$ 0,50-0,63
3. 0,63-0,69	$(b7+b8+b9)/3$ 0,50-0,72
4. 0,76- 0,90	$(b11+b12+b13+b14+b15+b16+b17)/7$ 0,71-0,95
5. 1,55- 1,75	$(b21)/1$ 1,41- 1,82
6. 2,08- 2,35	$(b25+b26+b27+b28+b29+b30+b31+b32+b33+b34+b35+b36+b37+b38+b39+b40+b41+b42+b43+b44+b45+b46+b47+b48+b49+b50+b51)/27$ 2,05- 2,38

A classificação foi realizada conforme o descrito na parte A.1.

### 3.2 Parte B Influência do efeito de reflectância bidirecional na classificação das culturas.

#### 3.2.1 Parte B.1 Estudo dos efeitos de reflectância bidirecional e o número de bandas na classificação de culturas

Esta parte do estudo estudou se as informações de reflectância bidirecional e número de bandas influenciam a classificação agrícola. Trabalhou-se com a classificação agrícola utilizando 2 tipos de imagens: Imagens Subsets 1,2 e 3 apresentando uma direção de voo e Imagem Comb. Subsets, apresentando a combinação de direções de vôo.

As Imagens dos Subsets 1,2 e 3 (63 bandas cada) foram criadas a partir das Imagens 1,2 e 3 AHS 160, estas três imagens continham o mesmo número de cultivos. As informações angulares foram obtidas com as imagens sem a correção geométrica. O ângulo do sol foi considerado invariável com o valor de  $29,54^\circ$ , desta forma os valores dos ângulos de visada e o ângulo azimutal relativo foram estimados e usados neste estudo. A área de estudo nas três imagens tinham as mesmas coordenadas geográficas, o que significa que os polígonos utilizados na classificação tinham as mesmas coordenadas nas três imagens aqui denominadas de Subsets (imagens com mesma área de estudo) 1, 2, 3. Os polígonos que demarcaram as áreas agrícolas (ROIs) obedeceram os requisitos: o número de pixel por campo entre 200 e 500 pixels e localização longe das bordas representando vários campos da região.

A Imagem Comb. Subset (189 bandas) foi criada combinando as Imagens dos Subsets 1,2 e 3. Esta imagem passou pela Análise dos Componentes Principais, PCA, permitindo a classificação das culturas.

As classificações das Imagens Subsets 1, 2, 3 (63 bandas cada) e Imagem Comb. Subset (189 bandas) foram realizadas e os resultados comparados.

3.2.2 Parte B.2. Influência da reflectância bidirecional e da largura da banda na classificação de culturas.

Imagens sintéticas foram criadas para investigar o efeito da largura das bandas na classificação agrícola. As Imagens Subsets 1 e 2 (63 bandas cada) e Imagem Comb. Subset (189 bandas) tiveram suas bandas selecionadas para a criação de imagens com bandas estreitas do tipo descrito na tabela 1/parte A.1. Estas imagens sintéticas estreitas serão aqui denominadas Imagens Subset 1e 2 Estreito (6 bandas) e Imagem Comb subsets Estreito (18 bandas). O subset 3 também foi utilizado para a composição da Imagem Com subsets Estreito.

O procedimento de classificação foi o mesmo descrito na parte B.1.

## **4. Resultados e discussão**

4.1.1 Parte A.1. Influência do número de bandas na classificação de culturas

A classificação agrícola utilizando a Imagem 1 AHS 160 com informação de 63 bandas teve a melhor resultado na classificação das culturas do que a Imagem 1 Sintética Estreita com 6 bandas. A acurácia da classificação da Imagem 1 AHS 160 foi de 86,08 e coeficiente kappa 0,808 valores

maiores do que classificação obtida com a Imagem 1 Sintética Estreita de 6 bandas que foi de 82,19 e coeficiente kappa 0,766. Estes resultados são estatisticamente diferentes ( $p \leq 0,025$ ).

As assinaturas espectrais das Imagem 1 AHS 160 ofereceram detalhada informação das classes: cevada, solo, beterraba, grama, horticultura, milho, cebola, batata e trigo. Houve uma boa separação de classes grama, milho, beterraba e trigo, observados no diagrama de dispersão/scatter plot e pelo índice Jeffrey Matsushita. As classes batata, horticultura e cebola apresentaram dificuldades de separação, provavelmente relacionadas ao estágio de desenvolvimento destas plantas.

Este aumento na acurácia da classificação usando imagens hiperespectrais era esperado já que alta resolução espectral e a boa escolha das ROIs contribuem muito na separação das classes agrícolas (fig.2).

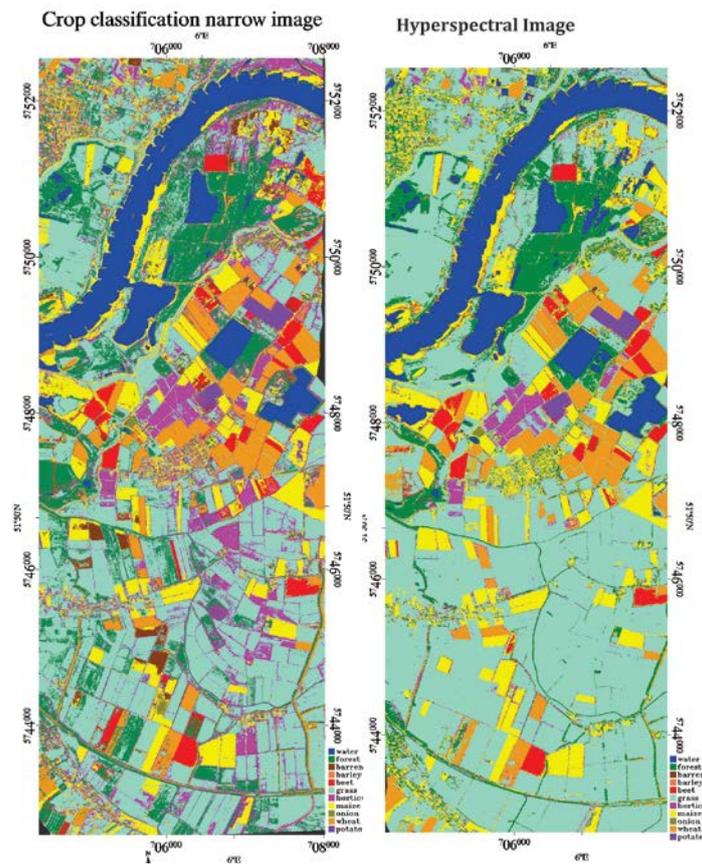


Figura 2 Classificação das culturas utilizando imagens com menor (narrow image) e maior número de bandas (Hyperspectral image)

#### 4.1.2 Parte A.2. Influência da largura de bandas na classificação de culturas

Os resultados da classificação das classes agrícolas presentes na Imagem 1 Sintética Estreita não se diferenciou daquela presente na Imagem Sintética Larga. Na Imagem Sintética Larga, a acurácia foi de 82,19% e coeficiente Kappa 0,766 enquanto a Imagem 1 Sintética Estreita apresentou a acurácia de 81,00% e Kappa 0,760, valores que analisados estatisticamente não são diferentes ( $p > 0,025$ ). Os mapas finais gerados pelas bandas estreitas e bandas largas não apresentaram diferenças visuais.

Analisando as diferenças das assinaturas espectrais nas duas- Imagem 1 Sintética Estreita e Imagem Sintética Larga notou-se que as culturas cevada, beterraba, horticultura, grama, milho, cebola, batata, trigo tinham melhor separação nas regiões de absorção de clorofila (0,52 -0,60  $\mu\text{m}$ ) e umidade do solo (0,76 -0,9  $\mu\text{m}$ ). Estes resultados não se diferenciam dos resultados obtidos por Thenknail (2004) usando imagens hiperespectrais para a classificação de culturas, que concluiu que 22 pequenas bandas estreitas são importantes para melhor identificar e classificar as culturas, sendo o requisito mais importante à localização destas bandas em três intervalos principais como os intervalos 0,45 a 0,67 que assinala a variação de cloroplastos; 0,74 a 1,3 a variação de biomassa e influência das folhas; 1,4 a 1,9 a área de absorção de água. Portanto, a largura da banda não é fator relevante para a classificação das culturas agrícolas e sim o bom posicionamento no espectro eletromagnético favorável à identificação das plantas.

#### 4.2 Parte B Influência do efeito da reflectância bidirecional na classificação de culturas

##### 4.2.1 B.1 Estudo da reflectância bidirecional e o número de bandas na classificação de culturas

###### *Análise das Imagens Subsets 1, 2,3/ uma direção de voo.*

A superfície anisotrópica foi observada na geometria dos ângulos das Imagens subsets 1, 2,3, observando as diferenças entre o ângulo de visada e o ângulo azimute relativo. Todas as três Imagens Subsets permitiram a classificação razoável de quatro classes: beterraba, grama, milho e trigo. Cevada não foi classificada em nenhuma imagem

A Imagem Subset 1 tinha a maioria das culturas localizadas no Plano Ortogonal com relativo azimute, maior que  $90^\circ$  e possivelmente efeito de espalhamento/forward scattering na imagem. A classificação mostrou acurácia de 85,9 e índice kappa 0,80. A Imagem Subset 1 classificou bem as culturas beterraba, milho.

A Imagem Subset 2 teve maioria das culturas localizadas no plano principal com ângulo azimutal menor que  $90^\circ$  e possível efeito de retroespalhamento/backscatter. A classificação mostrou acurácia

de 87,6 e kappa 0,83. A Imagem Subset 2 todas as classes obtiveram os melhores valores de classificação comparados com os resultados de classificação dos outros subsets.

A Imagem Subset 3 teve culturas localizadas tanto no plano ortogonal quando no plano principal, possuindo tanto efeitos de retroespalhamento como o de espalhamento. A Imagem Subset 3 teve a sua acurácia de 73,44 e kappa 0,63. As culturas piores classificadas na Imagem Subset 3 foram grama e beterraba provavelmente decorrente da combinação dos efeitos de retroespalhamento e espalhamento presentes nesta imagem.

Comparando a classificação entre A Imagem Subset 1 e a Imagem Subset 2 nota-se que estas não são estatisticamente diferentes ( $p > 0,025$ ). Uma possível explicação seria porque as culturas que aparecem na Imagem Subset 1 estavam localizadas próximas ao Nadir e mostraram uma alta reflectância na região infravermelho. Na Imagem Subset 2 os efeitos de retroespalhamento colaboraram na identificação das culturas, confirmando os resultados encontrados por Lisemberb et al (2007) que demonstrou alta anisotropia a resposta espectral para os campos localizados no Plano Principal. Campos com efeitos de retroespalhamento tiveram melhor classificação demonstrado na classificação da Imagem Subset 2

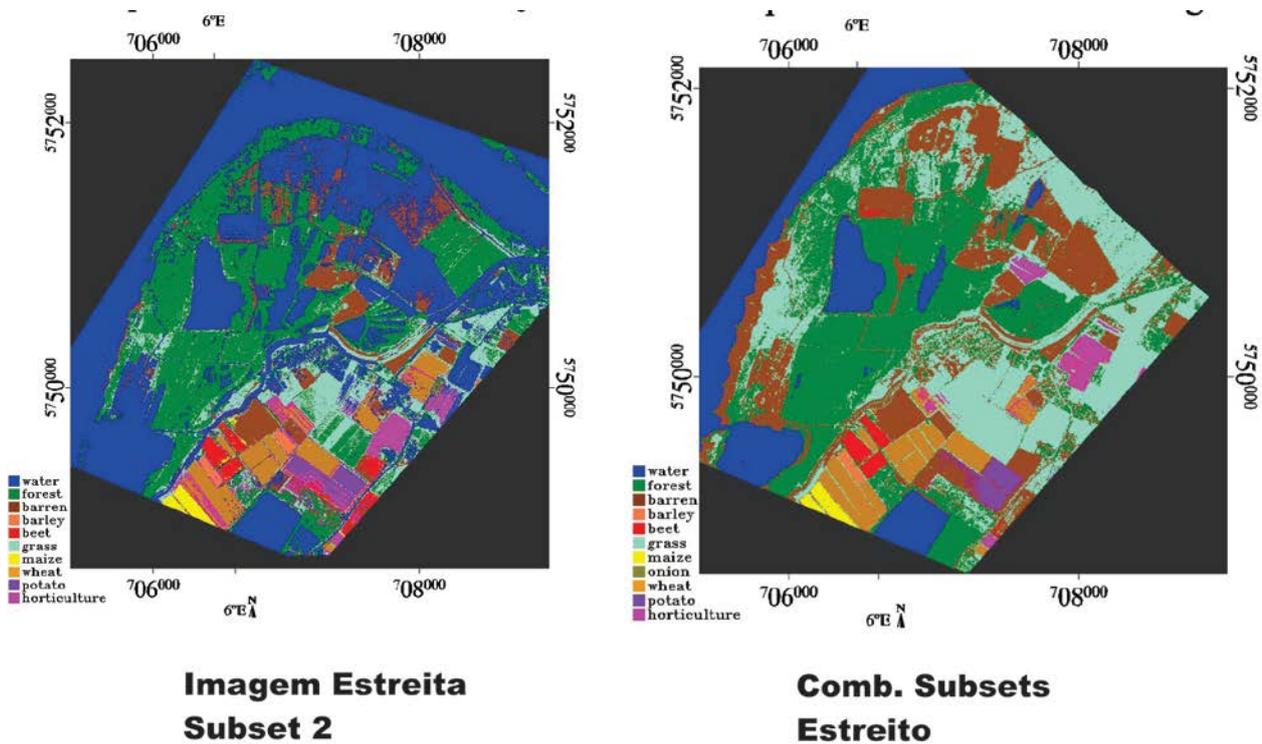
#### *A análise da classificação da Imagem Comb. Subset/ combinação de direções de voo.*

A classificação da Imagem Comb. Subset obteve a acurácia de 95,61 e kappa 0,935 e 100% acurácia na classificação da grama, milho, trigo, não classificando cevada e beterraba. Comparando este resultado da Imagem Comb. Subset com Imagem Subset 1,2 e 3, observou-se que estes resultados de classificação são estatisticamente diferentes ( $p \leq 0,025$ ). Portanto a classificação da Imagem Comb. Subset teve melhor acurácia na classificação das culturas grama, milho e trigo. Os pixels das classes beterraba e cevada não obtiveram classificação nesta imagem.

#### 4.2.2 B.2 Influência da reflectância bidirecional e a largura das bandas na classificação das culturas

O resultado das classificações das Imagens Subset 1,2 Estreito e Imagem Comb. subsets Estreito mostrou que a Imagem Subset 2 Estreito teve melhor acurácia na classificação das culturas. A acurácia da Imagem Subset 2 Estreito foi de 91,82 e kappa 0,882, valores estatisticamente

diferentes à acurácia das Imagens Subset 1 Estreito com acurácia 87,96 e kappa 0,81 e Imagem Comb. subsets Estreito com acurácia 89,06 e kappa 0,8261 (fig.3).



**Figura 3. Melhor classificação para a Imagem Estreita Subset 2 (uma direção de vôo) comparada com a classificação da Imagem Comb. Subsets Estreito ( várias direções de vôo).**

A Imagem Subset 2 Estreito classificou melhor a quatro culturas: beterraba, grama, milho e trigo do que a Imagem Subset 1 Estreito e Imagem Comb. subsets Estreito. Observando que esta imagem teve melhor acurácia de classificação principalmente por possuir vegetação com os efeitos retroespalhamento/backscatter captados nas bandas estreitas da imagem. Estes resultados confirmaram a teoria de Price (1992) e Thenkabail (2002) que recomendaram contíguas bandas hiperespectrais para a identificação das culturas.

A Imagem Subset 1 Estreito classificou mal a grama. Uma possível explicação para esta baixa acurácia pode estar relacionada à sua estrutura. Geralmente a vegetação com a estrutura *erectophila* com folhas verticais como a grama, trigo e cevada interferem na reflectância e pode influenciar negativamente a classificação principalmente para as plantações com efeitos de espalhamento/forescatter presente na imagem (SANDEMEIR e DIERING, 1999).

A Imagem Comb. subsets Estreito classificou apenas três culturas: grama, milho e trigo. Comparando as classificações da Imagem Comb. subsets Estreito (18 bandas) com a Imagem comb.

subset/parte B1 (189 bandas) nota-se que a acurácia da classificação aumenta com o uso de imagens hiperespectrais.

## 5. Conclusão

Esta pesquisa verificou se como o grande número de bandas e bandas estreitas e informação dos efeitos de BRDF influenciam os resultados da classificação de culturas. De acordo com o material usado pode-se concluir:

1. O número de bandas influencia a classificação das classes agrícolas beterraba, milho, trigo e grama. Este estudo demonstrou que a Imagem 1 AHS 160 com 63 bandas teve uma classificação melhor que Imagem 1 Sintética Estreita com 6 bandas. Qualitativamente o mapa com imagem hiperespectral tem uma melhor separação de classes do que o mapa da imagem multiespectral.
2. A largura das bandas não se mostrou relevante na classificação das classes agrícolas deste estudo. A Imagem Sintética Larga e Sintética Estreita obtiveram resultados semelhantes na classificação das culturas. O mais importante é utilizar imagens que trabalhem com as bandas posicionadas no espectro eletromagnético entre 0,45 a 1.9  $\mu\text{m}$  para a classificação agrícola.
3. Os efeitos de reflectância bidirecional são importantes para a classificação agrícola. A investigação da reflectância bidirecional mostrou que o efeito da geometria de ângulos especialmente o efeito de retroespalhamento/backscatter influencia positivamente a classificação das culturas em imagens multiespectrais e hiperespectrais.
4. A combinação do número de bandas, da largura da banda e efeitos de reflectância bidirecional é importante para a classificação agrícola. A Imagem com combinação de informações de reflectância bidirecional e grande número de bandas (189) obteve melhor acurácia comparado com as Imagens com menor número de bandas e menores efeitos de reflectância bidirecional (63 bandas).

## 6. Recomendações

As resoluções espaciais e espectrais da AHS 160 foram apropriadas para a classificação de algumas culturas. Estas imagens hiperespectrais da campanha ofereceram dados necessários para a classificação de culturas grama, milho e trigo.

Estudos futuros devem considerar outros métodos de classificação para o estudo de horticultura, solo desnudo, cebola e batata. Deve-se procurar explorar outros modos de classificação que melhor discriminaram essas culturas considerando número maior das áreas de treinamento para a classificação.

Algumas culturas com estrutura *erectophila* tiveram efeito negativo na classificação. Estudos futuros de reflectância bidirecional devem considerar medidas de geometria de ângulos nos campos de forma a auxiliar melhor as análises das imagens.

### Agradecimentos

Agradeço aos professores e pesquisadores de Wageningen University, Holanda: Jan Clevers, Harm Bartholomeus e Allard de Witt pelas orientações e sugestões durante a execução desta pesquisa.

### Referências Bibliográficas

ASNER, G. Braswell et al. **Ecological research need from multiple remote sensing data**. Remote Sensing of Environment (63), 1998 p.155-156.

BEISL, U. **Correction of Bidirecional effects in imaging Spectrometer Data**, Remote Sensing Series, 37, 2001.

BLACKBURN, G. A. **Towards the remote sensing of matorral vegetation physiology: relationships between spectral reflectance, pigment, and biophysical characteristic semiarid bush land canopies**. Remote Sensing of Environment, 70. 1999, p.278-292.

CAMPBELL, J.B. **Introduction to Remote Sensing**, fourth edition ed., Taylor & Francis, New York, 2006.

CARTER, G. A. **Reflectance bands and indices for remote estimation of photosynthesis and stomatal conductance in pine canopies**. Remote Sensing of Environment, 63, 1998, P61-72.

CHAMPAGNE, C. et al. **Exploiting spectral variation from crop phenology agricultural land use classification** *Proceedings for SPIE- The international Society for Optical Engineering*, 588. 2005, p.1-9.

CLEVERS, J.G.P., KOOISTRA, L. **AHS 2005: The 2005 airborne imaging spectroscopy campaign in the Milligerwaaard**, The Netherlands, Centre for Geo-Information (CGI) report, Wageningen University, 2005

COCHRANE, M. A., **Using vegetation reflectance variability for species level classification of hyperspectral data**, *International Journal of Remote Sensing*, 21 (10), 2000, p.2075-2087

DANAHER, T. et al. **Bi-directional Reflectance Distribution Function Approaches to Radiometric Calibration of Landsat ETM+ Imagery**, *IEE Transactions of Geoscience and Remote Sensing*, 6, 2001, p2654-2657.

GIANINETTO, M., LECHI, G. **The development of super spectral approaches for the improvement of land cover classification**. *IEE transactions of Geoscience and Remote Sensing*, 42 (11), 2004, p. 2670-2679.

HAZEU G. **Land use mapping and monitoring in the Netherlands (LGN 5)**, paper presented at 2<sup>nd</sup> EARsel workshop on land use and land cover, Bonn, set, 2006, p28-30

ITT, C. ENVI user forum <disponível [www.itvis.com](http://www.itvis.com)> Acessado em dezembro de 2007.

KUKKO, A., et al. **Use of HRSC-A for sampling bidirectional reflectance**, *ISPRS Journal of photogrammetry and Remote Sensing*, 59 (6) , 2005, p323-341.

LANDGREBE, D. **Some fundamentals and methods for hyperspectral image data analysis**, *Systems and technologies for clinical diagnostics and drug discovery*, 2 (3603)6. 1999.

LIESENBERG, V. et al. **Variations in reflectance with seasonality and viewing geometry, implications for classification of Brazilian savanna physiognomics with MISR** .*Terra data, Remote Sensing of Environment*, 107, , 2007, p276-286.

LILLESAND, T et al. **Remote Sensing and Image Interpretation**, 5<sup>th</sup> edition, John Wiley, New York, EUA, 2004.

PRICE, J. C. **Variability of high-resolution crop reflectance spectra**, International Journal of Remote Sensing, 13 (14), 1992, p2593-2610.

SANDEMEIER, S., DEERING D.W. **Structure Analysis and Classification of Boreal Forests using airborne hyperspectral BRDF data from ASAS**, Remote Sensing of Environment, 69,1999.p.281-295.

SU, L. et al. **Differentiation of semiarid vegetation types based on multi-angular observation from MIRS and MODIS** , International journal of Remote Sensing, 28 (5/6), 2007, p1419-1424.

THENKABAIL, P.S. **Optimal hyperspectral narrow bands for discriminating agricultural crops**, Remote Sensing Reviews, 20 (4), 2002, p.257-291.

THENKABAIL, P.S.et al., **Accuracy assessment of hyperspectral waveband performance for vegetation analysis applications**, Remote Sensing of Environment, 9 (3/4), 2004, p354-376.