

Sensoriamento Remoto e Sistemas de Informações Geográficas aplicados ao estudo dos recursos agronômicos e florestais

Yosio Edemir Shimabukuro¹, Eduardo Eiji Maeda², Antonio Roberto Formaggio¹

RESUMO

Este trabalho apresenta a contribuição do sensoriamento remoto (SR) e dos sistemas de informações geográficas (SIG) para a obtenção de informações sobre recursos agronômicos e florestais. Inicialmente, são dadas informações sobre os conceitos básicos de sensoriamento remoto; satélites de recursos naturais e respectivos sensores, técnicas de interpretação de imagens orbitais e sistemas de informações geográficas. A seguir, apresenta-se extensa revisão sobre as aplicações de sensoriamento remoto na avaliação dos recursos agronômicos e florestais, incluindo os projetos operacionais do Instituto Nacional de Pesquisas Espaciais (INPE) que utilizam as tecnologias de SR e SIG no estudo desses recursos a partir dessas informações pode-se comprovar a contribuição dessas tecnologias no mapeamento e no monitoramento dos recursos agronômicos e florestais. Além disso, o desenvolvimento de novos sensores com melhores características espaciais, espectrais e temporais tem permitido que esses recursos sejam monitorados de forma cada vez mais detalhada, a fim de garantir a qualidade e a sustentabilidade no Planeta.

Palavras-chave: Sensores remotos, satélites, índices de vegetação, imagens fração, interpretação visual, processamento digital de imagem.

ABSTRACT

Remote Sensing and Geographic Information Systems applied to the study of agriculture and forest resources

This work presents the contribution of Remote Sensing (RS) and Geographic Information Systems (GIS) in assessing agricultural and forest resources. Initially, the basic concepts of Remote Sensing, information about natural resources satellites and its respective sensors, and information about interpretation of satellite images are described. Subsequently, a brief description about Geographic Information Systems is presented. Then an extensive review of remote sensing applications to evaluate the agricultural and forest resources is done, including the operational projects of agricultural and forest resources, performed by the National Institute for Space Research, which uses RS and GIS technologies. In this context, we can confirm the contribution of these technologies for mapping and monitoring the agricultural and forest resources. In addition, the development of new sensors with improved spatial, spectral, and temporal characteristics has been allowing the monitoring of these resources in order to secure the quality and the sustainability in our planet.

Key words: Remote sensors, satellites, vegetation indices, fraction images, visual interpretation, digital image processing.

Recebido para publicação em março de 2009 e aprovado em junho de 2009

¹ Instituto Nacional de Pesquisas Espaciais. Av. dos Astronautas, 1758, 12227-010, São José dos Campos, SP., Brasil

² University of Helsinki, Department of Geography. Gustaf Hällströmin katu 2, 00014, Helsinki, Finland

INTRODUÇÃO

O sensoriamento remoto tem experimentado significativos avanços desde as primeiras décadas do século XX, quando as fotografias aéreas começaram a ser vistas como ferramentas de grande potencial para a obtenção de informações sobre áreas agrícolas e florestais de extensões variadas, desde pequenas fazendas até regiões, estados ou países. As pesquisas e os desenvolvimentos dos primeiros tempos buscavam entender as mudanças de refletância e emitância das folhas vegetais em função de sua espessura, espécies, estrutura do dossel, idade, densidade no dossel, estado nutricional e hídrico. Verificou-se então que os pigmentos foliares, em especial as clorofilas, que são responsáveis por absorções preferenciais em diferentes comprimentos de ondas do espectro óptico (~ 400 nm a 2500nm), constituem-se nas bases para o uso da refletância, tanto em índices de vegetação de sensores de banda larga, como também para os de sensores de banda estreita, como os espectrômetros hiperespectrais.

Paralelamente aos desenvolvimentos de novos sensores, que apresentam resoluções geométricas e espectrais cada vez melhores, os “softwares” de processamento de imagens digitais estão crescentemente mais eficientes e os modelos de simulação da refletância de dosséis vegetais vêm conseguindo descrever, cada vez melhor, os processos de interação entre a energia eletromagnética e os dosséis. O entendimento da refletância da folha e do dossel vegetal gera vários tipos de informações espacializadas e georreferenciadas sobre áreas agrícolas e florestais, como, por exemplo a área foliar, a porcentagem de cobertura verde sobre a superfície, a biomassa, o tipo de cobertura vegetal, os componentes bioquímicos, os teores de umidade etc.

Por outro lado, o Planeta passa atualmente por preocupantes problemas de mudanças climáticas globais, bem como por processos rápidos de alterações da cobertura vegetal e, desta forma, torna-se prioritário dispor de informações espacializadas sobre a distribuição dos recursos naturais e das áreas agrícolas, para o seu adequado monitoramento, bem como para imprescindíveis entendimentos e modelagens quanto aos impactos causados pelas aceleradas mudanças antrópicas sobre a superfície terrestre.

Sem dúvida, o sensoriamento remoto e os sistemas de informações geográficas desempenham papel insubstituível nesse vasto contexto da observação e do monitoramento da superfície terrestre e, dessa forma, será apresentada aqui uma visão sobre o estado-da-arte, em termos do entendimento sobre como o sensoriamento remoto e os sistemas de informações geográficas vêm sendo empregados para avaliar e monitorar, qualitativa e quantitativamente, os recursos agronômicos e florestais, bem como as perspectivas futuras para os pesquisadores dedicados à busca de avanços no sensoriamento remoto para aplicações agronômicas e florestais.

SENSORIAMENTO REMOTO

O Sensoriamento Remoto (SR) pode ser definido como a arte e a ciência de obter informações sobre objetos, sem que haja contato físico direto com o objeto (Jensen, 2007).

O SR passou a ser largamente utilizado ao longo das últimas décadas por permitir o rápido monitoramento, a avaliação de importantes variáveis ambientais e de diversos outros fatores relacionados com as atividades humanas. Atualmente, o SR está inserido, operacionalmente, nas mais diversas áreas do conhecimento, seja no âmbito acadêmico ou no comercial.

As imagens de SR podem ser obtidas, utilizando diferentes alturas de coleta: laboratório, campo, sub-orbital e orbital (Figura 1). Os níveis de coleta em laboratório e campo são utilizados quando existe a necessidade de maior controle de iluminação das amostras estudadas e visa geralmente ao entendimento mais detalhado das interações entre a energia eletromagnética (variáveis espectrais) e as variáveis dos alvos estudados. Nestes casos, a coleta de informações é comumente realizada com o uso de espectroradiômetros. O nível de coleta sub-orbital é realizado acoplando-se sensores em aeronaves, de forma a obter imagens aéreas para uma série de aplicações, como planejamento urbano, delimitação de propriedades rurais ou estimativas de parâmetros biofísicos da vegetação.




Figura 1. Níveis de coleta de dados de sensoriamento remoto.

No nível de coleta orbital, as informações são obtidas a partir de sensores transportados por satélites artificiais que orbitam ao redor da Terra. Uma vez que estão em grandes altitudes, os sensores orbitais possuem a capacidade de abranger em seu campo de visada uma grande porção da superfície terrestre. Além disso, esses sensores tornam possível o monitoramento periódico de alvos, propiciando um acompanhamento da evolução das propriedades dos objetos estudados ao longo do tempo.

Independentemente do nível de coleta das informações, os sensores podem ser inseridos em duas grandes classes: sensores ativos ou sensores passivos. Os sensores passivos não possuem fonte própria de energia eletromagnética e, portanto, captam a energia emitida ou refletida pelos alvos. Os sensores ativos, por sua vez, possuem fonte própria de energia, na qual suas medições são baseadas. A grande vantagem dos sensores ativos está em sua capacidade de realizar imageamentos a qualquer horário, independentemente de luz solar e mesmo sob cobertura de nuvens (Moreira, 2001).

Outro importante conceito a ser compreendido no SR são as definições de resolução espacial, resolução espectral, resolução temporal e resolução radiométrica. A *resolução espacial* indica o tamanho da menor separação angular ou linear que um sensor pode identificar, sendo medida geralmente em metros, quilômetros ou graus. A *resolução espectral* indica o número e o tamanho de intervalos de comprimentos de ondas (bandas) do espectro eletromagnético no qual o instrumento é sensível (Jensen, 2007). Um sensor é classificado como multiespectral quando possui a capacidade de adquirir energia em diversas bandas do espectro eletromagnético. Um exemplo de um sensor multiespectral é o TM/Landsat-5, que pode captar informação em sete bandas espectrais. Já os sensores hiperespectrais podem, tipicamente, adquirir informação em centenas de bandas espectrais (Goetz, 2002). A Figura 2 ilustra um exemplo das bandas espectrais adquiridas por sensores multiespectrais (TM/Landsat-5 e HRV/SPOT) e um sensor hiperespectral (AVIRIS).

A *resolução temporal* refere-se à frequência (geralmente em dias ou horas) em que um determinado sensor pode capturar imagens consecutivas de um determinado alvo. A frequência de imageamentos de um sensor depende, entre outros fatores, da característica da órbita do satélite, da resolução espacial e da largura de imageamento do sensor. Por fim, a *resolução radiométrica* é definida como a sensibilidade do sensor a diferenças na magnitude do sinal que é medido, ou seja, ela define o número de níveis em que o sinal pode ser discriminado. Por exemplo, uma imagem com uma resolução radiométrica de 8 bits é capaz de representar o sinal recebido em 256 níveis (níveis de cinza). A Tabela 1 apresenta um resumo das características de alguns sensores orbitais atuais de grande importância para o monitoramento dos recursos agrônômicos e florestais.




Figura 2. Bandas espectrais adquiridas pelos sensores TM/Landsat-5 e HRV/SPOT (multiespectrais) e pelo sensor aerotransportado AVIRIS (hiperespectral). As barras correspondentes a cada sensor indicam as posições e as larguras das bandas, sendo que o AVIRIS possui 224 bandas espectrais de 10 nm de largura, cobrindo toda a região do visível até o infravermelho médio.

Os números digitais existentes nas imagens orbitais são proporcionais a valores de radiância, que foram medidos por cada um dos detectores, em cada faixa ou banda espectral em que o sensor atua.

A *refletância* de um objeto expressa a quantidade relativa de radiação eletromagnética que é refletida por esse objeto. Assim, um objeto que apresenta valores elevados de refletância em uma determinada faixa espectral, deverá apresentar níveis de cinza igualmente elevados em uma imagem adquirida por um sensor eletro-óptico, colocado a bordo de um satélite, na banda espectral correspondente. Portanto, espera-se que os valores de radiância medidos nessa banda sejam elevados e que, uma vez discretizados em uma escala de níveis de cinza, produzam um padrão “claro” desse objeto na imagem dessa banda.

Com isso, na região do visível, a vegetação apresenta valores de refletância relativamente baixos, por causa da ação dos pigmentos fotossintetizantes que absorvem a radiação eletromagnética incidente, para a realização da fotossíntese. Na região do infravermelho próximo, esses valores apresentam-se elevados por causa do espalhamento interno sofrido pela radiação, em função da disposição da estrutura morfológica da folha, aliada ainda ao espalhamento múltiplo entre as diferentes camadas de folhas, enquanto, no infravermelho médio, tem-se uma nova queda desses valores, decorrente da presença de água no interior da folha. De fato, esses fatores não atuam isoladamente. Em cada uma das regiões espectrais todos exercem sua influência concomitantemente. Assim, por exemplo, os níveis baixos de refletância na região do visível, esperados para uma cobertura vegetal, não se devem exclusivamente à absorção dos pigmentos existentes nas folhas, mas também às sombras que se projetam entre as folhas do dossel, as quais são dependentes

da geometria de iluminação, da DAF e da rugosidade do dossel em sua camada superior (topo do dossel). De qualquer forma, a vegetação apresenta-se escura, em uma imagem referente à região do visível; clara, em uma imagem referente à região do infravermelho próximo, e novamente escura, em uma imagem referente à região do infravermelho médio (Ponzoni & Shimabukuro, 2007).

A característica multiespectral da maioria dos dados de sensoriamento remoto proporciona a vantagem de gerar novas imagens por meio de transformações radiométricas. Essas novas imagens geradas representam uma alternativa para apresentação das informações em diferentes maneiras. Essas transformações podem realçar informações que não são muito visíveis nas imagens originais, ou podem preservar o conteúdo das informações (para uma determinada aplicação), com um número reduzido de bandas transformadas. Para o estudo da vegetação, o índice de vegetação (Moreira e Shimabukuro, 2004) e o modelo linear de mistura espectral (Shimabukuro & Smith, 1991) são as transformações amplamente utilizadas em várias aplicações (Ponzoni & Shimabukuro, 2007).

As imagens de Sensoriamento Remoto podem ser interpretadas de diversas formas de acordo com a necessidade e os recursos técnicos disponíveis. A seguir, é apresentada uma breve descrição dos modos mais comuns de interpretação.

INTERPRETAÇÃO VISUAL

Nesse procedimento o intérprete examina sistematicamente as imagens e, frequentemente, outros materiais auxiliares, como mapas e relatórios de campo, tendo em vista os elementos de interpretação visual descritos na literatura. Uma chave de interpretação é proposta para facilitar o trabalho de interpretação pelo analista com base nos objetivos e nas feições naturais presentes nas imagens obtidas pelo satélite. A técnica de interpretação visual tem sido amplamente utilizada para o mapeamento de áreas agrícolas e da cobertura florestal. A metodologia, entretanto, é subjetiva e o resultado varia com a experiência do intérprete.

INTERPRETAÇÃO VISUAL NA TELA DO COMPUTADOR

Essa é a técnica mais recente normalmente utilizada (Roy et al., 2002). Nesse método, a imagem digital multiespectral é visualizada na tela do computador, para propósito de interpretação temática e delineamento do tema direto na tela. A escala selecionada para interpretação depende da unidade mínima de mapeamento. Além disso, tal procedimento permite usar combinações de bandas diferentes para facilitar o trabalho do analista (Roy & Murthy, 1984).

CLASSIFICAÇÃO DIGITAL

No método de classificação digital todos os pixels na imagem são categorizados em classes de cobertura. Essa tarefa pode ser realizada de duas formas: classificação supervisionada e não-supervisionada. Na classificação supervisionada o analista orienta o processo de categorização do pixel, especificando ao algoritmo do computador descritores numéricos de vários tipos de cobertura da Terra presentes na cena. Dentre os algoritmos usados para classificação supervisionada, pode-se citar a distância mínima, o paralelepípedo e a máxima verossimilhança. Na classificação não-supervisionada, os dados da imagem são classificados primeiro pela agregação deles em “clusters” ou grupos espectrais naturais presentes na cena. Os diferentes algoritmos normalmente utilizados para classificação não-supervisionada são: K-média, ISODATA e classificação baseada na textura. As classificações híbridas envolvem aspectos de classificação supervisionada e não-supervisionada e têm o propósito de melhorar a acurácia ou a eficiência do processo de classificação. A classificação hierárquica está entre a classificação supervisionada e não supervisionada, com o propósito de conseguir o melhor mapa de uso e cobertura da terra com máxima acurácia. As técnicas emergentes de classificação digital de imagem são as classificações baseadas em regras, análise de mistura espectral, classificação “fuzzy” e redes neurais (Foody & Arora, 1997). Recentemente, foi introduzida a classificação baseada em regiões (segmentação de imagens), em vez de pixel a pixel, sendo mais recomendada para o monitoramento de mudanças no uso e cobertura da terra.

SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS (SIGs)

Um Sistema de Informações Geográficas pode ser descrito como uma tecnologia computacional, desenvolvida a fim de capturar, armazenar, manipular e visualizar dados georeferenciados (Burrough & McDonnell, 1998). Os primeiros SIGs surgiram na década de 60 como programas computacionais relativamente simples. Atualmente, os SIGs são dotados de uma vasta e complexa lista de ferramentas para processamento e análises de dados espaciais. Além disso, as recentes melhorias nas interfaces gráficas e a disseminação de dados georeferenciados, como imagens de satélite e mapas temáticos, contribuíram fortemente para a popularização desta tecnologia (Reibel, 2007).

Ao longo dos últimos anos, os SIGs passaram a assumir um papel importante na convergência de diversas outras tecnologias, como o SR, GPS e “internet”, promovendo novos níveis de funcionalidade e acessibilidade (Drummond & French, 2008). Dessa forma, os SIGs estabeleceram-se como uma ferramenta indispensável, em áreas

como planejamento urbano (Prenzel, 2004; Easa & Chan, 2000), conservação do solo (Maeda et al., 2008; Szilassi et al., 2006; Jain et al., 2001), hidrologia (Miller et al., 2007; Ferraz et al., 1999), agricultura de precisão (Tschiedel & Ferreira, 2002), entre outras.

Dentre os diversos tipos de dados que podem ser utilizados com o auxílio dos SIGs, destacam-se os mapas temáticos, mapas cadastrais, imagens de satélite e modelos numéricos de terreno (MNT). Os mapas temáticos procuram descrever a distribuição espacial de alguma grandeza geográfica, de forma qualitativa, por exemplo, mapas pedológicos. Os mapas cadastrais diferem dos mapas temáticos, pois cada um de seus elementos possui atributos, e podem também estar associados a várias representações gráficas. Os modelos numéricos de terreno, por sua vez, são utilizados para representar, quantitativamente, uma grandeza que varia continuamente no espaço, por exemplo, altimetria e declividade (Câmara *et al.*, 1999).

A representação dos dados em um SIG pode ser dividida em duas grandes classes: representação vetorial e representação matricial. Na representação matricial, o SIG trata uma superfície contínua como uma malha quadriculada composta por células, onde cada célula recebe um atributo referente ao fenômeno estudado. A representação matricial é ideal para análise de fenômenos contínuos no espaço, como elevação, precipitação e uso da terra (Reibel, 2007). Na representação vetorial, os objetos são representados por pontos, linhas ou polígonos. Grande parte dos SIGs atuais possui ferramentas que permitem a conversão de representações vetoriais para matriciais, e vice-versa.

Outro fator importante a ser mencionado a respeito dos SIGs é a grande variedade de programas gratuitos e de código aberto que surgiram ao longo dos últimos anos. Uma extensa revisão a respeito de SIGs de código aberto é apresentada por Steiniger & Bocher (2008). Estes autores informam, relatam que atualmente existem mais de 300 projetos visando ao desenvolvimento desse tipo de ferramenta. O SIG GRASS (Geographic Resources Analysis Support System) é um dos mais bem sucedidos projetos nessa área. O GRASS começou a ser desenvolvido na década de 80, no Laboratório de Engenharia de Construção do Exército Estadunidense (CERL) e é atualmente, um dos SIGs de código aberto mais utilizado ao redor do mundo.

No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) ocupa uma posição de destaque no desenvolvimento de ferramentas computacionais para análise de dados geográficos. Dentre os projetos desenvolvidos pelo INPE, pode-se citar o programa SPRING, um SIG gratuito com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados espaciais (Câmara *et al.*, 1996).

Dentre os SIGs comerciais, destaca-se o pacote de programas ArcGIS desenvolvido pela ESRI (*Environmental Systems Research Institute*). O ArcGIS surgiu na década de 90 para integrar e aprimorar uma série de tarefas executadas pelos seus antecessores (ex: ArcView GIS 3.x e Arc/INFO). Atualmente, mesmo com a grande variedade de SIGs gratuitos disponíveis, o ArcGIS continua a dominar uma grande parcela do mercado.

RECURSOS AGRONÔMICOS

Desde o início da década de 1970, quando os satélites de observação da Terra começaram a ser lançados, já se compreendia que o sensoriamento remoto orbital, com suas características de abrangência de grandes áreas e de repetitividade temporal, teria um papel insubstituível no estudo e na geração de informações importantes para a agricultura de países de grandes extensões, como o Brasil. Com o rápido desenvolvimento da geoinformática, as potencialidades vêm sendo continuamente ampliadas, neste campo do conhecimento, relacionado com o uso de imagens para o estudo e o monitoramento da agricultura, conforme é exposto a seguir.

Determinação de componentes bioquímicos dos dosséis vegetais

As informações sobre a composição bioquímica e sobre o estado dos dosséis vegetais agrícolas têm utilidade em vários campos, desde as estatísticas agrícolas até as modelagens de produtividade das lavouras.

As folhas contêm pigmentos, especialmente a clorofila *a* e a clorofila *b*, que realizam a conversão da energia luminosa solar em energia bioquímica para os processos fisiológicos das plantas. Dessa forma, a quantidade de radiação solar absorvida pelas folhas será determinada pelo conteúdo de pigmentos fotossintéticos dessas folhas. Variações na concentração total de clorofila foliar, bem como nas proporções relativas de clorofila *a* e de clorofila *b*, podem indicar uma variedade de estresses fisiológicos, condições de desenvolvimento foliar e senescência (Blackburn & Ferwerda, 2008). Pode-se dizer que, quanto melhores as condições do sistema pigmentar das folhas das plantas agrícolas, maior será o potencial fotossintético e, conseqüentemente, a produção primária dessas plantas (Filella *et al.*, 1995).

Existe correlação entre o conteúdo de clorofila e o estado nutricional, em termos de nitrogênio (Moran *et al.*, 2000), ou *vs.* as condições de estresse e de senescência da cultura (Peñuelas & Filella, 1998; Carter & Knapp, 2001).

Assim como as clorofilas, os carotenóides também desempenham importantes funções nas folhas verdes, em termos de seu papel na organização estrutural das membra-

nas fotossintéticas, participando na coleta e transferência da luz, interceptação de oxigênio e de radicais livres. Variações de conteúdos de carotenóides e de suas proporções em relação às clorofilas têm sido utilizadas para diagnosticar o estado fisiológico das plantas durante seu ciclo fenológico, senescência, ou adaptação a diferentes ambientes e condições de estresses (Hatfield *et al.*, 2008).

Portanto, ter a capacidade de fornecer informações espacializadas e da dinâmica temporal sobre a clorofila e demais pigmentos foliares é de considerável valor, tanto sob o ponto de vista científico, quanto para investigações relacionadas com interações planta-ambiente e para perspectivas de usos e manejos agrícolas, florestais e ambientais.

Os principais processos ecológicos envolvidos com intercâmbios de energia e matéria, como a fotossíntese, a evapotranspiração, a respiração, a produção primária líquida e a decomposição estão relacionados com as condições de estado nutricional e de crescimento, indicados pelos conteúdos de clorofila e carotenóides, água, proteínas, celulose e lignina.

Visto que as folhas são as mais importantes superfícies vegetais que interagem com a energia solar, é fundamental entender os processos fisiológicos que relacionam as propriedades ópticas foliares às correspondentes condições e características biofísicas.

Dados multi e hiperespectrais têm sido utilizados para estimar variáveis tais como: o índice de área foliar (Houborg & Boegh, 2008), pigmentos (Ferri *et al.*, 2004), variedades genéticas (Galvão *et al.*, 2005, 2006), conteúdo de água (Chen *et al.*, 2005; Serrano *et al.*, 2000a).

Em particular, uma alta prioridade tem sido atribuída quanto a relacionar a absorção e o espalhamento da luz solar com os constituintes bioquímicos. Duas abordagens têm sido consideradas: a) correlações estatísticas entre a refletância foliar (Figura 3) e os conteúdos bioquímicos (Jacquemoud *et al.*, 1995); e (b) modelos físicos de transferência radiativa, que simulam o transporte de fótons dentro das folhas e dos dosséis vegetais (Jacquemoud *et al.*, 1996). Contudo, um problema fundamental com a abordagem estatística para a estimativa de variáveis biofísicas é a dificuldade de generalização e de extrapolação, uma vez que a refletância de dosséis vegetais depende de uma complexa interação de fatores internos e externos (Baret, 1991), que podem variar, significativamente, no tempo e no espaço e de uma cultura para outra, de modo que não existe uma relação universal entre determinada variável do dossel e o seu comportamento espectral. Consequentemente, as relações espectrais serão dependentes de local, fator temporal e cultura, tornando inexistente que uma determinada relação estatística seja estendida para toda uma grande região (Baret & Guyot, 1991; Colombo *et al.*, 2003; Gobron *et al.*, 1997; Houborg & Boegh, 2008).




Figura 3. Variações sazonais na refletância de um dossel de milho, obtidas a partir de um sensor de oito canais, verificando-se altas refletâncias na região do infravermelho próximo, causadas pela estrutura interna das folhas, e, na região do vermelho, altas absorções causadas pelos pigmentos foliares. (Fonte: adaptado de Hatfield *et al.*, 2008)

A abordagem estatística apresenta problemas, como o das dificuldades quanto à correspondência entre diferentes conjuntos de dados e, por isso, o uso dos modelos de simulação da refletância tem sido a forma mais indicada, dadas as bases físicas que os sustentam e, assim, permitem uma mais fundamentada extração de informações bioquímicas de dosséis vegetais (Grossman *et al.*, 1996).

Estimativas de produtividade das culturas

As aplicações da tecnologia de S.R. têm apresentado potencial para monitorar as condições das culturas, bem como para realizar previsões da produtividade dessas culturas em escalas regionais.

Tradicionalmente, a abordagem empírica, baseada em modelos estatísticos de regressão, tem sido utilizada e, na maioria dos casos, fundamentada em que os valores sazonais cumulativos do Índice de Vegetação da Diferença Normalizada (NDVI – Normalized Difference Vegetation Index, proposto por Rouse *et al.*, 1973) correlacionam-se com rendimentos agrícolas (Mochheim & Barber, 1998). Doraiswamy & Cook (1995) demonstraram que valores cumulativos de NDVI, para trigo, obtidos na fase de enchimento dos grãos, melhoraram as estimativas de produtividade no estado de Dakota do Norte, nos EUA. A abordagem baseada em regressão estatística, contudo, é aplicável somente para específicas condições de proximidade, e de idênticas condições meteorológicas, para as quais foram desenvolvidas.

Outra forma de abordagem para determinação da produtividade, com imagens de satélites, tem sido o uso da variável fração da radiação fotossinteticamente ativa absorvida (fAPAR, do inglês *fraction of Absorbed Photosynthetically Active Radiation*). Lobell *et al.* (2003)

incorporaram a variável fAPAR num modelo baseado em eficiência do uso da luz para predizer fitomassa e produtividade das culturas. Entretanto, modelos que utilizam somente um processo fisiológico que contribui para a produtividade final podem não gerar resultados consistentes, para condições climáticas não estáveis.

Conforme expõem Doraiswamy et al. (2005), um método bastante promissor é o uso de modelos de crescimento de cultura, que incorporem parâmetros biofísicos atualizáveis, obtidos a partir de dados de satélite, bem como avaliações de produtividade, escalonadas do local para o regional.

Melhorias vêm sendo adicionadas a esta abordagem usando modelos de transferência radiativa, tais como o SAIL (Scattering by Arbitrary Inclined Leaves) (Verhoef, 1984), que simulam a refletância dos dosséis vegetais e têm a capacidade de integrar variáveis do próprio dossel e do sensor utilizado.

Trabalhos como os de Serrano et al. (2000b) mostram como dados de sensores, tanto provenientes de plataformas aéreas [p.ex., CASI (NASA, 2009a), AVIRIS (NASA, 2009b)], quanto orbitais [p.ex., Hyperion/EO-1 (USGS, 2008), CHRIS/PROBA (ESA, 2009)], cada vez mais aperfeiçoados, podem ser usados a partir de modelos de transferência radiativa [p.ex., SUITS (Suits, 1972); SAIL (Verhoef, 1984); PROSPECT (Jacquemoud & Baret, 1990; Jacquemoud et al., 2000)] que simulam processos de interação energia-matéria, tanto em nível de folhas como dossel, para estimar as condições das culturas e os rendimentos agrícolas.

Mapeamentos de áreas agrícolas

Outro campo de largo interesse no sensoriamento remoto agrícola são os mapeamentos das lavouras via imagens orbitais. O potencial das imagens de sensoriamento remoto para mapeamento de culturas pode ser explorado, tanto para pequenas áreas (Ippoliti-Ramilo *et al.*, 2003), como para extensas regiões agrícolas (Rizzi & Rudorff, 2005; INPE, 2009).

Conforme estes autores relatam, contudo, a alta probabilidade de cobertura de nuvens nas imagens orbitais, como as do Landsat, ou do SPOT, ou do CBERS, pode dificultar e, até mesmo, em determinadas oportunidades, impedir o uso dessas imagens para o mapeamento e a estimativa da área com culturas agrícolas, principalmente as de verão.

Como indicam Van Niel & Mcvicar (2004) e Sugawara *et al.* (2008), a questão da nebulosidade merece ainda mais consideração para culturas como a soja ou a cana-de-açúcar, para as quais se tornam necessárias análises multitemporais, ou seja, a conjugação e a integração de interpretações advindas de imagens, obtidas em múltiplas datas, durante o ano agrícola.

Felizmente há excelentes possibilidades de contornar essa questão da nebulosidade com a multiplicidade de satélites em órbita (Wulder *et al.*, 2008), a capacidade de visadas laterais (Xavier, 2007), as constelações de satélites (Dorigo *et al.*, 2007) ou, por exemplo, pela utilização de imagens quase diárias, adquiridas pelo sensor “Moderate Resolution Imaging Spectroradiometer” (MODIS), a bordo das plataformas Terra e Aqua (Justice & Townshend, 2002).

Como destacam Sugawara et al. (2008), no Brasil, até o momento, não se tem conhecimento do uso operacional das imagens de SR, para o mapeamento sistemático e anual de uma grande cultura de verão em escala regional ou nacional.

Um exemplo do uso de imagens de SR para a estimativa de área cultivada com cana-de-açúcar, porém, é o projeto Canasat (<http://www.dsr.inpe.br/canasat/>), que desde 2003 vem sistematicamente mapeando as lavouras de cana-de-açúcar no Estado de São Paulo e, desde 2005, nos demais estados da região Centro-Sul. Esse projeto fornece a estimativa da área de cana-de-açúcar disponível para colheita, antes do início de cada ano safra (Rudorff & Sugawara, 2007; INPE, 2009).

Uma outra possibilidade de obtenção de estatísticas agrícolas com o auxílio de geotecnologias, especificamente estimativas de áreas plantadas, é via métodos estatísticos de amostragem, como os que foram desenvolvidos pelo Instituto Nacional de Pesquisas Espaciais (MCT/INPE), denominados PREVS (Mueller et al., 1988) e Geosafra (Luiz, 2006).

Destaca-se que, no campo do uso de sensoriamento remoto e das geotecnologias para agricultura, há ainda outras possibilidades, como a agricultura de precisão (Moran *et al.*, 1997) e estimativas de perdas de solos por erosão hídrica (Desmet & Govers, 1996; Maeda et al., 2008).

RECURSOS FLORESTAIS

O uso de sensoriamento remoto no estudo de recursos florestais fornece três níveis de informação (Boyd & Danson, 2005): 1) a extensão da cobertura florestal, que pode ser usada para estudar a dinâmica da cobertura florestal; 2) o tipo de floresta e 3) as propriedades biofísicas e bioquímicas da floresta. O acesso a essas informações, de maneira freqüente, permite o monitoramento dos recursos florestais. Como todas as aplicações de sensoriamento remoto, a medida dos recursos florestais é baseada na interação da radiação eletromagnética com os alvos e a análise do sinal de retorno, que é coletado pelos sensores remotos. Em geral, as plataformas orbitais têm carregado a bordo dois tipos de sistema sensores, ou seja, o óptico e o radar de abertura sintética (SAR) ativo, mencionados anteriormente. O sistema óptico mede radiação refletida em uma ou mais bandas discretas, localizadas na faixa espectral de 400 a 3000 nm, enquanto que o radar mede radiação de micro-

ondas, em comprimentos de onda entre 1 a 1000 cm. Comprimentos de onda ópticos são várias ordens de grandeza menores do que as folhas e galhos que formam o dossel florestal e, conseqüentemente, a radiação pode ser absorvida e espalhada por esses componentes. No caso dos comprimentos de microondas longas, o espalhamento, por folhas, galhos, troncos e o solo, é o mecanismo predominante. Com isso, os sistemas de sensoriamento remoto fornecem informações da quantidade de folhagem e suas propriedades bioquímicas, enquanto sistemas de microondas fornecem informações sobre a biomassa e estrutura da floresta. Além disso, alguns sistemas sensores também medem radiação emitida (entre 3000 a 15000 nm), para fornecer medidas importantes de fluxos de energia e temperatura da superfície (Quattrochi & Luvall, 1999).

Os administradores florestais necessitam de informações geoespaciais acuradas e frequentes, sobre as condições das florestas e práticas de manejo, em locais específicos e escalas regionais. No mesmo tempo, a ciência e as tecnologias associadas com o manejo florestal estão evoluindo rapidamente. Tecnologias geoespaciais, como o sensoriamento remoto, sistemas de informações geográficas e sistema GPS (Global Positioning System) fornecem suporte para coletar, analisar e armazenar todo tipo de informação geoespacial. Informações sobre características vegetativas, derivadas de dados sensoriados remotamente, são importantes para o levantamento dos recursos florestais. Os detalhes dependem amplamente das resoluções espacial e espectral da imagem utilizada (Roy, 2002).

Mapeamento e monitoramento de áreas florestais

O índice de vegetação da diferença normalizada (NDVI) e as imagens-fração derivadas do modelo linear de mistura espectral (MLME), dentre várias técnicas de transformações radiométricas disponíveis, têm sido amplamente utilizados para gerar informações da cobertura vegetal.

As imagens-fração são importantes para trabalhos de mapeamento da cobertura vegetal. O uso dessas imagens, tanto individualmente, como em conjunto, tem permitido mapear a cobertura vegetal local e regionalmente, utilizando dados de diferentes sensores. A cobertura vegetal do Estado do Mato Grosso tem sido mapeada, utilizando as imagens-fração, derivadas dos sensores com diferentes resoluções espaciais e espectrais, como o AVHRR/NOAA (Advanced Very High Resolution Radiometer/National Oceanic and Atmospheric Administration) de 1,1 km (Rodríguez Yí et al., 2000), o VEGETATION/SPOT de 1 km (Carreiras et al., 2002), e MODIS/Terra (250 m) (Anderson et al., 2005). Localmente, as imagens-fração derivadas do sensor TM/Landsat-5 têm sido utilizadas em diferentes ecossistemas (Mata Atlântica, Cerrado, Amazônia, etc.).

Além disso, na Amazônia Brasileira, as imagens-fração têm sido utilizadas para muitos estudos, tais como o de desflorestamento (Shimabukuro et al., 1998), o de corte seletivo (Souza & Barreto, 2000; Asner, 2005), o de queimada (Cochrane & Souza, 1998; Almeida-Filho & Shimabukuro, 2004), e o de áreas de regeneração (Braswell et al., 2003; Lu et al., 2003, Espírito-Santo et al., 2005).

Os projetos PRODES (<http://www.obt.inpe.br/prodes/>) (INPE, 2002) e DETER (<http://www.obt.inpe.br/deter/>) (Shimabukuro et al., 2006) são exemplos práticos da utilização de técnicas de sensoriamento remoto e de sistemas de informações geográficas, no mapeamento e monitoramento da floresta Amazônica brasileira. Os dois projetos utilizam o mesmo procedimento metodológico, que consiste basicamente na geração das imagens-fração, segmentação dessas imagens, classificação não supervisionada, mapeamento de classes e edição da classificação (interpretação visual na tela do computador) (Shimabukuro et al., 1998, 2006). Enquanto o DETER utiliza os dados do sensor MODIS, com resolução espacial moderada (250 e 500 m), mas com repetitividade de 2 dias na região Amazônica, o PRODES tem utilizado principalmente os dados do Landsat TM e ETM+ com resolução espacial de 30 m, mas com frequência de aquisição a cada 16 dias. Portanto, o DETER tem o propósito de detectar as fontes de desflorestamento em tempo quase real (sistema de alerta) e o PRODES realiza a estimativa anual de desflorestamento na região Amazônica.

Estimativa de parâmetros biofísicos florestais

De acordo com Boyd & Danson (2005), vários estudos têm encontrado relações não-lineares positivas entre o retroespalhamento e a biomassa aérea, com a saturação da resposta ocorrendo em diferentes níveis, dependendo do comprimento de ondas utilizado (Imhoff, 1995; Fransson & Israelsson, 1999), da polarização e da geometria de visada do sensor (Le Toan et al., 1992; Baker et al., 1994). A acurácia da estimativa é também dependente da estrutura florestal e das condições no solo (Baker & Luckman, 1999; Ranson & Sun, 2000). Ranson et al. (1997) mostraram que os dados SIR-C podem ser usados para mapear biomassa aérea de floresta boreal, para um limite de 150 t ha⁻¹. Florestas tropicais, em geral, atingem nível maior de biomassa do que outras florestas e têm mostrado diferentes relações. A banda L pode ser usada para discriminar entre diferentes níveis de biomassa de florestas regeneradas (até aproximadamente 20 anos de idade e 60 t ha⁻¹) o retroespalhamento de polarização cruzada é mais sensível a mudanças em densidade de biomassa do que o retroespalhamento de polarização simples. Além disso, tem sido obtido algum sucesso no uso de dados SAR, para o mapeamento de propriedades dos estandes florestais. Diferentemente da classificação

de dados ópticos, a classificação de tipos de cobertura florestal explora as diferenças na macroestrutura entre estandes de diferente espécies, idade ou densidade (Ranson & Sun, 1994; Saatchi & Rignot, 1997; Castel *et al.*, 2002). A altura florestal tem sido estimada usando-se a coerência interferométrica dos dados SAR (Castel *et al.*, 2000; Balzter, 2001; Tetuko *et al.*, 2001).

CONSIDERAÇÕES FINAIS

O sensoriamento remoto tem contribuído com informações importantes sobre a localização, tipo e condições da cobertura vegetal, assim fazendo parte de qualquer sistema de informações de recursos agrônômicos e florestais. Além disso, o desenvolvimento de novos sensores com melhores características espaciais, espectrais e temporais tem permitido e permitirá que esses recursos sejam monitorados, para garantir a qualidade de vida no planeta.

A combinação de novas tecnologias de sensoriamento remoto com novas técnicas de análises e com o avanço de modelagem de ecossistemas tem garantido o papel importante do sensoriamento remoto e dos sistemas de informações geográficas no mapeamento e monitoramento dos recursos agrônômicos e florestais.

O verdadeiro sucesso do sensoriamento remoto entretanto, quando resultados dessas pesquisas são transferidas para organizações que têm o poder de usar essas informações na política de decisão sobre o uso e manejo sustentado dos recursos florestais (Franklin, 2001; Hayes & Sader, 2001) e dos recursos agrônômicos.

REFERÊNCIAS

- Almeida-Filho R & Shimabukuro YE (2004) Cover: Monitoring biomass burning in the Brazilian Amazônia. *International Journal of Remote Sensing* 25:5537-5542.
- Anderson LO, Shimabukuro YE, Lima A & Medeiros JS (2005) Mapeamento da cobertura da terra do estado do Mato Grosso através da Utilização de dados multitemporais do sensor MODIS. *Geografia, Rio Claro, SP*, 30(2):365-380.
- Asner GP, Knapp DE, Broadbent EN, Oliveira PJC, Keller M & Silva JN (2005) Selective Logging in the Brazilian Amazon. *Science* 310:480-482.
- Baker JR & Luckman AJ (1999) Microwave observations of boreal forests in the NOPEX area of Sweden and a comparison with observations of a temperate plantation in the United Kingdom. *Agricultural and Forest Meteorology* 98:389-416.
- Baker JR, Mitchell PL, Cordey RA, Groom GB, Settle JJ & Stileman MR (1994) Relationships between physical characteristics and polarimetric radar backscatter for Corsican Pine stands in Thetford Forest, UK. *International Journal of Remote Sensing* 15:2827-94.
- Balzter H (2001) Forest mapping and monitoring with interferometric synthetic aperture radar InSAR. *Progress in Physical Geography* 25:159-177.
- Baret F (1991) Vegetation canopy reflectance: Factors of variation and application for agriculture. In D. Hunt (Ed.), *Physical measurements and signatures in remote sensing* (pp. 145-167). France: Courchevel.
- Baret F & Guyot G (1991) Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment* 35:161-173.
- Blackburn GA, Ferwerda, JG (2008) Retrieval of chlorophyll concentration from leaf reflectance spectra using wavelet analysis. *Remote Sensing of Environment* 112:1614-1632.
- Boyd DS & Danson FM (2005) Satellite remote sensing of forest resources: three decades of research development. *Progress in Physical Geography* 29(1):1-26.
- Braswell BH, Hagen SC, Froking SE & Salas WA (2003) A multivariable approach for mapping sub-pixel land cover distributions using MISR and MODIS: Application in the Brazilian Amazon region. *Remote Sensing of Environment* 87:243-256.
- Burrough PA & McDonnell RA (1998) *Principles of Geographical Information Systems*: Oxford University Press.
- Câmara G, Souza RCM, Freitas UM & Garrido J (1996) SPRING: Integrating remote sensing and GIS by object-oriented data modeling. *Computers & Graphics* 20:395-403.
- Câmara G, Davis C, Monteiro AMV, Paiva JA & D'Alge JCL (1999) *Geoprocessamento: Teoria e Aplicações*. INPE - Edição On-line, v.1.
- Carreiras JMB, Pereira JMC & Shimabukuro YE (2002) Fraction images derived from SPOT-4 VEGETATION and NOAA AVHRR data to assess land cover change over Mato Grosso state, Brazil. *International Journal of Remote Sensing* 23:4979-4983.
- Carter GA & Knapp AK (2001) Leaf optical properties in higher plants: Linking spectral characteristics to stress and chlorophyll concentration. *Am. J. Bot.* 84:677-684.
- Castel T, Martinez JM, Beaudoin A, Wegmuller U & Strozzi T (2000) ERS INSAR data for remote sensing hilly forested areas. *Remote Sensing of Environment* 73:73-86.
- Castel T, Guerra F, Caraglio Y & Hollier F (2002) Retrieval biomass of a large Venezuelan pine plantation using JERS-1 SAR data. Analysis of forest structure impact on radar signature. *Remote Sensing of Environment* 79:30-41.
- Chen D, Huang, J & Jackson TJ (2005) Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. *Remote Sensing of Environment* 98:225-236.
- Cochrane MA & Souza CM (1998) Linear mixture model classification of burned forests in the Eastern Amazon. *International Journal of Remote Sensing* 19:3433-3440.
- Colombo R, Bellingeri D, Fasolini D & Marino CM (2003) Retrieval of leaf area index in different vegetation types using high resolution satellite data. *Remote Sensing of Environment* 86:120-131.
- Desmet PJJ & Govers G (1996). A GIS procedure for automatically calculating the USLE LS factor on topographically complex landscape units. *Journal of Soil and Water Conservation* 51(5):427-433.
- Doraiswamy PC, Sinclair TR, Hollinger S, Akhmedov B, Stern A & Prueger J (2005) Application of MODIS derived parameters for regional crop yield assessment. *Remote Sensing of Environment* 97:192-202.
- Dorigo WA, Zurita-Milla R, De Wit AJW, Brazile J, Singh R & Schaepman ME (2007) A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. *International Journal of Applied Earth Observation and Geoinformation* 9:165-193.
- Drummond WJ & French SP (2008) The Future of GIS in Planning: Converging Technologies and Diverging Interests. *Journal of the American Planning Association* 74(2):161-174.
- Easa S & Chan Y editors (2000) *Urban Planning and Development Applications of GIS*. Reston, Virginia: ASCE.

- ESA (European Space Agency). CHRIS / PROBA Web Page. Disponível online: <http://www.chris-proba.org.uk/> Consulta em 05/03/2009.
- Espírito-Santo FDB, Shimabukuro YE & Kuplich TM (2005) Mapping forest successional stages following deforestation in Brazilian Amazonia using multitemporal Landsat images. *International Journal of Remote Sensing* 26(3):635-642.
- Ferraz FFB, Milde LCE, Mortatti J (1999) Modelos Hidrológicos Acoplados a Sistemas de Informações Geográficas: um Estudo de Caso. *Revista de Ciência & Tecnologia* 14:45-56.
- Ferri CP, Formaggio AR & Schiavinato MA (2004) Narrow band spectral indexes for chlorophyll determination in soybean canopies [Glycine max (L.) Merrill]. *Braz. J. Plant Physiol.* 16(3):131-136.
- Filella I, Serrano I, Serra J & Penuelas J (1995) Evaluating wheat nitrogen status with canopy reflectance indices and discriminant analysis. *Crop Sci.* 35:1400-1405.
- Foody GM & Arora MF (1997) An evaluation of some factors affecting the accuracy of classification by an artificial neural network. *International Journal of Remote Sensing* 18: 799-810.
- Franklin SE (2001) Remote sensing for sustainable forest management. Boca Raton, FL, Lewis.
- Fransson JES & Israelsson H (1999) Estimation of stem volume in boreal forests using ERS-1 C- and JERS-1 L-band SAR data. *International Journal of Remote Sensing* 20:123-137.
- Galvão LS, Formaggio AR & Tisot DA (2005) Discrimination of sugarcane varieties in Southeastern Brazil with EO-1 Hyperion data. *Remote Sensing of Environment* 94:523-534.
- Galvão LS, Formaggio AR & Tisot DA (2006) The influence of spectral resolution on discriminating Brazilian sugarcane varieties. *International Journal of Remote Sensing* 27(4):769-777.
- Gobron N, Pinty B & Verstraete MM (1997) Theoretical limits to the estimation of the leaf area index on the basis of visible and near-infrared remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing* 35(6):1438-1445.
- Goetz SJ (2002) Recent advances in remote sensing of bio-physical variable: an overview of the special issue. *Remote Sensing of Environment* 79:145-146.
- Grossman YL, Ustin SL, Jacquemoud S, Sanderson EW, Schmuck G & Verdebout J (1996) Critique of stepwise multiple linear regression for the extraction of leaf biochemistry information from leaf reflectance data. *Remote Sensing of Environment* 56(3):182-193.
- Hatfield JL, Gitelson AA, Schepers JS & Walthall CL (2008) Application of Spectral Remote Sensing for Agronomic Decisions. *Agronomy Journal* 100:S-117-S-131.
- Hayes DJ & Sader SA (2001) Comparison of change-detection techniques for monitoring tropical forest clearing and vegetation regrowth in a time series. *Photogrammetric Engineering and Remote Sensing* 67:1067-1075.
- Houborg R & Boegh E (2008) Mapping leaf chlorophyll and leaf area index using inverse and forward canopy reflectance modeling and SPOT reflectance data. *Remote Sensing of Environment* 112:186-202.
- Imhoff ML (1995) A theoretical analysis of the effect of forest structure on synthetic aperture radar backscatter and the remote sensing of biomass. *IEEE Transactions on Geoscience and Remote Sensing* 33:341-352.
- Instituto Nacional de Pesquisas Espaciais (INPE) (2002) Monitoring of the Brazilian Amazonian forest by satellite, 2000-2001. São José dos Campos, SP.
- Instituto Nacional de Pesquisas Espaciais (INPE) CANASAT. Mapeamento da cana via imagens de satélite de observação da Terra. Disponível on line: <http://www.dsr.inpe.br/mapdsr/>. Consulta em: 02/03/2009.
- Ippoliti-Ramilo GA, Epiphanyo JCN & Shimabukuro YE (2003) Landsat-5 Thematic Mapper data for pre-planting crop area evaluation in tropical countries. *International Journal of Remote Sensing* 24:1521-1534.
- Jacquemoud S, Verdebout J, Schmuck G, Audreoli G & Hosgood B (1995) Investigation of leaf biochemistry by statistics, *Remote Sensing of Environment* 54:180-188.
- Jacquemoud S, Ustin SL, Verdebout J, Schmuck G, Andreoli G & Hosgood B (1996) Estimating Leaf Biochemistry using the PROSPECT Leaf Optical Properties model. *Remote Sensing of Environment* 56(3):194-202.
- Jacquemoud S & Baret F (1990). PROSPECT: a model of leaf optical properties spectra. *Remote Sensing of Environment* 34:75-91.
- Jacquemoud S, Bacour C, Poilve H & Frangi JP (2000) Comparison of four radiative transfer models to simulate plant canopies reflectance: Direct and inverse mode. *Remote Sensing of Environment* 74(3):471-481.
- Jain SK, Kumar S & Varghese J (2001) Estimation of Soil Erosion for a Himalayan Watershed Using GIS Technique. *Water Resources Management* 15:41-54.
- Jensen JR. (2007) Remote sensing of the environment: an Earth Resources Perspective. 2. ed. Upper Saddle River: Prentice-Hall. 592p.
- Justice CO & Townshend JRG (2002) Special issue on the Moderate Resolution Imaging Spectroradiometer (MODIS): a new generation of land surface monitoring. *Remote Sensing of Environment* 83:1-2.
- Le Toan T, Beaudoin TA, Riom J & Guyon D (1992) Relating forest biomass to SAR data. *IEEE Transactions on Geoscience and Remote Sensing* 30:403-411.
- Lobell DB, Asner GP, Ortiz-Monasterio JI & Benning TL (2003) Remote sensing of regional crop production in the Yaqui Valley, Mexico: Estimates and uncertainties. *Agriculture, Ecosystems and Environment* 94:205-220.
- Luiz AJB (2005) Estatísticas agrícolas por amostragem auxiliadas por sensoriamento remoto. In: Simpósio Brasileiro de Sensoriamento Remoto, 10., 2005, Goiânia. Anais... São José dos Campos: INPE, 16-21. Disponível na biblioteca digital URLib: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.19.22.11/doc/181.pdf>>. Acesso em 16 jan. 2006
- Maeda EE, Formaggio AR & Shimabukuro YE (2008) Impacts of land use and land cover changes on the sediment yield in Brazilian Legal Amazon drainage basin. *GIScience & Remote Sensing* 45:443-453.
- Miller SN, Goodrich DC, Hernandez M, Semmens DJ, Miller RC, Kepner WG & Guertin DP (2007) The Automated Geospatial Watershed Assessment tool. *Environmental Modelling & Software* 22:365-377.
- Mochheim KP & Barber DG (1998) Canada's using NOAA NDVI data. *Canadian Journal of Remote Sensing* 24:17-27.
- Moran MS, Inoue Y & Barnes EM (1997) Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment* 61: 319-346.
- Moran JA, Mitchell AK, Goodmanson G & Stockburger KA (2000) Differentiation among effects of nitrogen fertilization treatments on conifer seedlings by foliar reflectance: A comparison of methods. *Tree Physiol.* 20:1113-1120.

- Moreira MA (2001) Fundamentos do sensoriamento remoto e metodologia de aplicação. São José dos Campos: INPE, 250 p. (INPE-8465-RPQ/723).
- Moreira MA & Shimabukuro YE (2004) Cálculo do Índice de Vegetação a Partir do Sensor AVHRR. In: Ferreira NJ Aplicações Ambientais Brasileiras dos Satélites NOAA e TIROS-N. São Paulo-SP: Oficina de Textos, Cap. 4, p. 271.
- Mueller CC, Silva G & Villalobos AG (1988) Pesquisa agropecuária do Paraná - safra 1986/87 (Programa de Aperfeiçoamento das Estatísticas Agropecuárias). Revista Brasileira de Estatística 49:55-84.
- NASA (National Aeronautics and Space Administration). 2009a. Compact Airborne Spectrographic Imager (CASI) Webpage. Disponível on line: http://geo.arc.nasa.gov/sge/jkskiles/top-down/OTTER/OTTER_docs/CASI.html. Consulta em 05/03/2009.
- NASA (National Aeronautics and Space Administration). 2009b. AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) Homepage. Disponível on line: <http://aviris.jpl.nasa.gov/>. Consulta em 05/03/2009.
- Peñuelas J & Filella I (1998) Visible and near-infrared reflectance techniques for diagnosing plant physiological status. Trends Plant Sci. 3:151-156.
- Ponzoni FJ & Shimabukuro YE (2007) Sensoriamento Remoto no estudo da vegetação. São José dos Campos: Ed. Parêntese, 130p.
- Prenzel B (2004) Remote sensing-based quantification of land-cover and land-use change for planning. Progress in Planning 61(4):281-299.
- Ranson KJ & Sun G (1994) Northern forest classification using temporal multifrequency and multipolarimetric SAR images. Remote Sensing of Environment 47:142-153.
- Ranson KJ & Sun G (2000) Effects of environmental conditions on boreal forest classification and biomass estimates with SAR. IEEE Transactions on Geoscience and Remote Sensing 38:1242-1252.
- Ranson KJ, Sun G, Lang RH, Chauhan NS, Cacciola RJ & Kilic O (1997): Mapping of Boreal forest biomass from spaceborne Synthetic Aperture Radar. Journal of Geophysical Research 102:599-610.
- Reibel M (2007) Geographic Information Systems and Spatial Data Processing in Demography: a Review. Population Research and Policy Review 26, Numbers 5-6 / December, 2007.
- Rizzi R & Rudorff BFT (2005) Estimativa da área de soja no Rio Grande do Sul por meio de imagens Landsat. Revista Brasileira de Cartografia 57:226-234.
- Rodriguez Yi JLR, Shimabukuro YE & Rudorff BFT (2000) Image Segmentation for Classification of Vegetation using NOAA-AVHRR data. International Journal of Remote Sensing, 21(1):167-172.
- Rouse JW, Haas RH, Schell JA & Deering DW (1973) Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources Technology Satellite -1 Symposium, 3, 1973, Washington. Anais. Washington, D.C.: NASA, Goddard Space Flight Center 1:309-317.
- Roy PS & Murthy JD (1984) Forest type delineation from space borne data using visual and computer aided technique - a case study from eastern Himalayas, India. Proceedings of XV International Congress of Photogrammetry and Remote Sensing. Rio de Janeiro, Brazil, 1984.
- Roy PS, Dutt CBS & Joshi PK (2002) Tropical forest resource assessment and monitoring. Tropical Ecology 43(1):21-37.
- Rudorff BFT & Sugawara LM (2007) Mapeamento da cana-de-açúcar na região Centro-Sul via imagens de satélites. Informe Agropecuário 28:79-86.
- Saatchi SS & Rignot E (1997) Classification of Boreal forest cover types using SAR images. Remote Sensing of Environment 60:270-281.
- Serrano L, Ustin SL, Roberts DA, Gamon JA & Penuelas J (2000a) Deriving water content of chaparral vegetation from AVIRIS data. Remote Sensing of Environment 74:570-581.
- Serrano L, Filella I & Penuelas J. (2000b) Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. Crop Sci. 40:723-731.
- Shimabukuro YE & Smith JA (1991) The Least-Squares Mixing Models to Generate Fraction Images Derived From Remote Sensing Multispectral Data, IEEE Transactions on Geoscience and Remote Sensing 29:16-20.
- Shimabukuro YE, Batista GT, Mello EMK, Moreira JC & Duarte V (1998) Using shade fraction image segmentation to evaluate deforestation in Landsat Thematic Mapper images of the Amazon region. International Journal of Remote Sensing 19(3):535-541.
- Shimabukuro YE, Duarte V, Anderson LO, Valeriano DM, Arai E, Freitas RM, Rudorff BFT & Moreira MA (2006) Near real time detection of deforestation in the Brazilian Amazon using MODIS imagery. Ambiente e Água 1:37-47.
- Souza C & Barreto P (2000) An alternative approach for detecting and monitoring selectively logged forests in the Amazon. International Journal of Remote Sensing 21:173-179.
- Steiniger S & Bocher E (2008) An Overview on Current Free and Open Source Desktop GIS Developments. International Journal of Geographic Information Science. in press.
- Sugawara L, Rudorff BFT & Adami M (2008) Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. Pesquisa Agropecuária Brasileira (PAB) 43.
- Suits G (1972). The calculation of the directional reflectance of a vegetative canopy. Remote Sensing of Environment 2:117-125.
- Szilassi P, Jordan G, van Rompaey A & Csillag G (2006) Impacts of historical land use changes on erosion and agricultural soil properties in the Kali Basin at Lake Balaton, Hungary. Catena 68(2-3):96-108.
- Tetuko J, Tateishi R & Wikantika K (2001) A method to estimate tree trunk diameter and its application to discriminate Java-Indonesia tropical forests. International Journal of Remote Sensing 22:177-183.
- Tschiedel M & Ferreira MF (2002) Introdução à agricultura de precisão: conceitos e vantagens. Ciência Rural 32(1):159-163.
- USGS (United States Geological Service) Hyperion / EO-1 Sensor Webpage. Disponível on line: <http://eo1.usgs.gov/hyperion.php>. Consulta em 05/03/2009.
- Van Niel TG & Mcvicar TR (2004) Determining temporal windows for crop discrimination with remote sensing: a case study in south-eastern Australia. Computers and Electronics in Agriculture 45:91-108.
- Verhoef V (1984) Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. Remote Sensing of Environment 16:125-141.
- Xavier AS (2007) Estudo da influência da geometria de visada na resposta espectral de classes de cobertura selecionadas na região amazônica a partir de dados MISR/Terra. Dissertação de Mestrado em Sensoriamento Remoto. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 138p. (INPE-14211-TDI/1112).
- Wulder MA, Butson, CR & White JC (2008) Cross-sensor change detection over a forested landscape: options to enable continuity of medium spatial resolution measures. Remote Sensing of Environment 112:796-809.