

Utilização de técnicas de sensoriamento remoto para o mapeamento de área plantada com as principais culturas na safra 2009/2010 no estado de Mato Grosso do Sul

Damaris Torres Pulliza¹
Roney Eduardo Rodrigues¹
Ana Luiza Mesquita de Souza¹
João Pinto Nardoto¹
Wanildo Menezes d'Alva¹
Leonardo Carlotto Portalette²
Lucas Galvan²

¹ Sinoptica Sistemas de Informação Geográfica
R. Arariboia, 101 S03 – Vila Velha, ES 29.100-340
sinoptica@live.com

² Federação da Agricultura e Pecuária do Mato Grosso do Sul – FAMASUL
Rua Marcino dos Santos, 401, Cachoeira II – Campo Grande, MS 79040-902
{lucas, leonardo}@famasul.com.br

Abstract. Agriculture (crops, forestry and livestock) plays an important role in the economy of Mato Grosso do Sul (MS) state, in mid-western Brazil (357.124,96 km²). An accurate assessment of crop area coverage and spatial distribution is the basis to many decision-making policies affecting the logistics of crop production and food supply management. From crop health, harvesting, and storage to food distribution, and road and railway networks, the knowledge of the location of each component is essential for a synoptic understanding of the process. Historically the Brazilian Geography and Statistics Institute (IBGE) has provided summaries of area occupied by crop per city, but makes no reference as to how such areas are distributed within each city limits. Remote Sensing techniques have proved to be very effective in mapping large crop areas, at low and medium scale. This work assessed the individual and combined capabilities of medium to high spatial resolution remotely sensed imagery to accurately map and quantify crop areas. Also, we evaluated the effectiveness of a freely distributed GIS software to train personnel of the local Federation of Agriculture. Supervised Classification techniques were applied to multi-temporal MODIS imagery, multi-spectral TM imagery, and topographic data. The resulting classified image (1:1.250.000 scale) was then manually edited over LISS-III image to increase spatial definition, resulting in a 1:100.000 scale map. Final results were validated with field data and interviews with local players such as farmers' associations, IBGE, and agriculture-related professionals. Future efforts should go towards monitoring in near-real time seeding and harvesting dynamics.

Palavras-chave: remote sensing, crop monitoring, crop mapping, land-use, land-cover, agriculture, agropecuária, uso e cobertura do solo, mapeamento agrícola, monitoramento agrícola.

1. Introdução

O estado do Mato Grosso do Sul, no centro-oeste brasileiro, possui área de 357.124,96 km² e população de 2.360.498 habitantes distribuídos em 78 municípios (IBGE, Estados). O setor agropecuário gerou aproximadamente R\$ 4,4 bilhões em 2007, além dos valores indiretos com comércio, indústria e serviços relacionados à atividade (IBGE, 2007). Dos US\$ 2 bilhões exportados pelo estado em 2008, 75,5% têm origem direta ou indireta na atividade agropecuária (SEMAG, 2010). O setor emprega um contingente de aproximadamente 210 mil pessoas, sendo 157.600 homens e 53.549 mulheres (IBGE, 2006). Tendo um forte impacto na economia e na vida dos sul-matogrossenses, as principais lideranças do segmento no estado têm uma grande demanda por informação confiável que sirva como base na definição de estratégias e políticas relacionadas ao processo produtivo agropecuário. Durante várias entrevistas constatamos que alguns dos dados desejáveis para possibilitar o acompanhamento desse processo são a quantificação da área plantada com cada cultura, sua distribuição espacial no estado e particularmente a relação entre essa distribuição espacial e a localização

de biomas, municípios, sistemas de transporte e de armazenamento e condições climáticas (Dalpasquale e Riedl, com. pes., 2010). O IBGE tem longa tradição no levantamento de informações sobre safra, apresentando totalizações por cultura por município, ou seja, sem localizações exatas de cada área plantada. O método usado para realizar tais levantamentos é subjetivo, baseado integralmente em entrevistas com atores regionais ligados à produção agropecuária, como por exemplo, “o próprio IBGE; o Ministério da Agricultura; as Secretarias de Agricultura dos estados; cooperativas e agroindústrias; empresas de assistência técnica e extensão rural; o Banco do Brasil e outras instituições da área de crédito e financiamento agrícola” (IBGE, 2002). As principais lideranças sul-matogrossenses do setor agropecuário manifestaram explicitamente seu desejo de contar com dados mais precisos e que pudessem ser integrados em um sistema amplo que permitisse mais profundas análises e gerasse mais completas informações (Dalpasquale e Riedl, com. pes., 2010).

Os Sistemas de Informação Geográficas (SIG) são um conjunto de processos, operadores e ferramentas computadorizados que permitem a captura, armazenamento, análise, modelagem e visualização de informação geograficamente referenciada, ou seja, de dados identificados segundos sua localização. Usuários também incluem os procedimentos, operadores e dados espaciais na definição de SIG (USGS, 2007). Por outro lado, Sensoriamento Remoto (SR) é a atividade de medição, através de sensores montados em plataformas aéreas ou orbitais, da energia emanada da superfície da terra. Tais medições são usadas para construir uma imagem da paisagem sob a plataforma com a capacidade de manter a localização e configuração geográfica da mesma (Richards e Jia, 2006). Juntas, as técnicas e ferramentas SIG e RS nos permitem gerar capas temáticas que formam um modelo representativo da superfície terrestre com suas distintas características, próprio para análises espaciais.

Este trabalho avaliou a eficiência do uso de técnicas de Sensoriamento Remoto para o mapeamento das áreas plantadas com as principais culturas da safra de verão, ou primeira safra (algodão, soja e milho), da safra de inverno, ou safrinha ou ainda segunda safra (milho, algodão e trigo), e das culturas perenes e semiperenes (florestas plantadas e cana-de-açúcar); avaliou ainda a efetividade da capacitação de técnicos da FAMASUL na utilização de um software de distribuição gratuita para o gerenciamento interno dos dados geográficos gerados a partir do levantamento das áreas de agricultura do estado; e finalmente avaliou a resposta e a aceitação por parte dos potenciais usuários dos dados SIG derivados deste trabalho.

2. Metodologia

2.1 Sistema de coordenadas

As áreas com menores distorções geográficas em uma projeção cilíndrica transversal são as que estão próximas ao meridiano central (Campbell, 1998). O estado de MS é dividido aproximadamente ao meio pela linha que limita as zonas UTM 21 e 22. Isso significa que as maiores distorções de ambas zonas ocorrem ao longo do meridiano com longitude 54°W, que corta o centro do estado. Para minimizar o efeito de tais distorções que afetam a medição de áreas de cobertura de usos de solo, um dos principais objetivos do trabalho, foi gerado um sistema de coordenadas único e homogêneo para todo o estado. Essa projeção elimina o problema de distorções no centro do estado, além de permitir comparações mais coerentes com os indicadores de área gerados, através de outros métodos, pelo IBGE. Para isso, definiu-se uma projeção Equivalente Cônica de Albers para o MS (ECAMS) com meridiano central em 54° W, paralelos-padrão em 18,75° S e 22,25° S, latitude de origem 25° S, falsos leste e norte 0 (Figura 1).

2.2 Coleta e Processamento de Dados

São necessárias quatro cenas MODIS para cobrir todo o estado do MS. Foram adquiridas imagens diárias MODIS de reflectância da superfície (produto MOD09GQ) e as respectivas

máscaras de nuvens (produto MOD35), imagens de reflectâncias da superfície compostas de 8 dias (produto MOD09Q1) e de 16 dias (MOD13Q1), todas com resolução espacial de 250 metros. Essas imagens foram processadas (mosaicadas, projetadas e clipadas) através do software MODIS Reprojection Tool. Foi calculado o Índice de Vegetação por Diferença Normalizada (NDVI) de cada uma dessas imagens a 16 bits para maximizar a informação disponível, e feita uma seleção das melhores datas em termos de cobertura de nuvens e continuidade de dados. Dessa seleção se geraram séries multitemporais de dados MODIS para a safra (dados de jun/2009 a jan/2010) e safrinha (dados de fev/2010 a mai/2010).

Um total de 23 cenas Landsat TM, com resolução espacial de 30 metros, cobrem todo o estado de MS. Foram selecionadas cenas Landsat TM com datas dentro do período de cada safra, ao menos 4 datas para cada órbita-ponto. Também foram usadas neste trabalho imagens adquiridas pelo sensor LISS-III, a bordo do satélite IRS-P6 (lançado em 17/10/03), com resolução espacial de 23.5 metros. São necessárias 43 cenas LISS-III para cobrir todo o estado. Tanto as cenas TM como as LISS-III foram georeferenciadas utilizando a base de dados *Global Land Survey* da USGS como base, e projetadas em ECAMS.

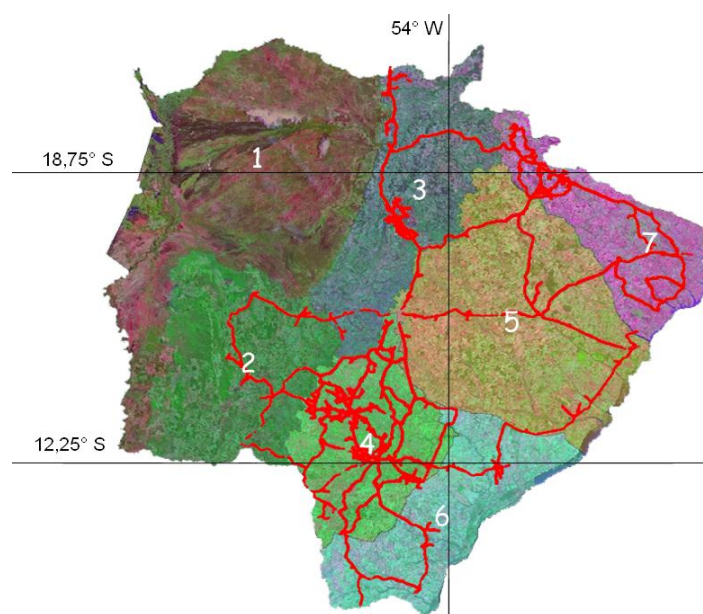


Figura 1. Localização dos paralelos e meridiano central da projeção ECAMS. Em vermelho os pontos mostrando as rotas de coleta de dados de campo. Os números indicam as regiões biogeográficas utilizadas como referência durante as análises.

2.3 Classificação da cobertura do solo

Os métodos de classificação supervisionada utilizados neste trabalho dependem crucialmente do conhecimento minucioso da área em estudo para possibilitar um bom treinamento das classes temáticas. Esses dados devem ser de qualidade indiscutível, oferecer representatividade de todas as classes espectrais envolvidas na classificação, e ter quantidade abundante para gerar redundância e conferir robustez ao modelo estatístico desenvolvido (Lillesand e Kiefer, 1994). Os dados de campo deste projeto foram coletados com GPS durante percurso por estradas e caminhos, sendo registradas observações à esquerda e à direita do veículo. As observações foram qualitativas e buscaram documentar as diferentes culturas, seus estádios de desenvolvimento e eventualmente quaisquer outras observações que fossem consideradas pertinentes. Durante os meses de janeiro a fevereiro de 2010 foram coletados 5.702 pontos-coordenada GPS com dados da primeira safra, e entre abril e julho de 2010 outros 7.206 pontos-coordenada GPS com dados da safrinha. No total foram registradas 25.816 observações feitas à direita e à esquerda de cada um dos 12.908 pontos, distribuídas

pelos principais regiões produtoras do estado (Figura 1). Durante os trabalhos de coleta de dados a campo, procurou-se sair das rotas principais e entrar por estradas e caminhos locais, para se obter uma distribuição de dados representativa dos diversos usos e coberturas de solo presentes no estado.

Como os pontos de GPS medidos a campo se localizam na verdade ao longo de estradas e caminhos, foi necessário reposicionar visualmente cada ponto sobre a área correspondente à cobertura de solo descrita, usando-se como base imagens TM e LISS-III. Para aumentar a quantidade de pontos de treinamento, foram gerados mais de um ponto sobre áreas de monocultura relativamente extensas nas quais o analista pôde reproduzir a confiança do trabalho de campo valendo-se de técnicas de interpretação visual, sempre observando a condição de estar a pelo menos 300 metros de distância das bordas, para evitar que fossem colocados em pixels mistos entre culturas geograficamente próximas (as análises foram feitas com imagens MODIS de 250 metros), e mantendo uma distribuição espacial relativa às dimensões das áreas de monocultura. No total, foram gerados ao redor de 60 mil pontos de treinamento sobre imagens TM e LISS-III, a partir das 25.816 observações de campo, que se reduziram a 46 mil pontos sobre MODIS (18 mil pontos usados no processo de classificação e controle para primeira safra e 28 mil para safrinha) dada a diferença em resolução espacial.

Primeiramente, foram digitalizados sobre imagens TM e LISS-III as áreas com construções, usando-se como referência o mapa de localidades brasileiras do IBGE, dessa forma gerando-se a classe “Urbano”. Áreas com construções menores, como usinas e armazéns, identificadas nas imagens também foram incluídas nesta classe. Os principais corpos d’água foram identificados por meio de processo semi-automatizado a partir de imagens TM e LISS-III, classificados como “Água”. As classes “Remanescente”, “Pastos” e “Agricultura Geral” foram obtidas através de classificação não supervisionada ISOCCLUS da série multitemporal MODIS (dados de outubro de 2009 a janeiro de 2010). A classe “Agricultura Geral” foi analisada, redefinida e melhorada visualmente a fim de se obter uma cobertura contínua e completa das terras cultivadas no estado. O primeiro produto gerado por este processo é portanto um mapa geral das áreas com agricultura anual, perene e semiperene para todo o estado. Estas áreas mapeadas como “Agricultura Geral” foram então estratificadas em subclasses, através de classificação supervisionada da série multitemporal MODIS. Cinco algoritmos de classificação supervisionada amplamente aceitos foram testados durante este processo para comparar suas capacidades considerando os tipos de paisagem presentes em MS; Paralelepípedo, Distância Mínima, Distância Mahalanobis, *Maximum Likelihood* (ML) e *Support Vector Machine* (SVM). Adicionalmente também se testaram os benefícios, em termos de acurácia da classificação, obtidos com a inclusão de uma imagem multispectral TM, e de dados topográficos (Jarvis *et.al.*, 2008) à série multitemporal MODIS. As imagens TM selecionadas para essa análise têm entre si intervalos de menos de um mês, apresentam baixa ou nenhuma cobertura de nuvens, passaram por correções radiométrica e atmosférica, posteriormente foram degradadas a 250 metros, mosaicadas para constituir uma única imagem contínua por biorregião e adicionadas à série MODIS. Os tipos de cultura ou classes de interesse para a safra de verão 2009-2010 são “Algodão”, “Soja”, “Milho”, “Cana-de-Açúcar” e “Reflorestamento”. As culturas de interesse para a safrinha 2010 são “Algodão”, “Trigo”, “Milho”, “Cana-de-Açúcar” e “Reflorestamento”. Em termos gerais, cada uma dessas classes temáticas deve apresentar ciclos de crescimento e esquemas de coloração característicos às distintas etapas de desenvolvimento, manejo e padrões climáticos seguindo uma curva próxima ao normal.

Entretanto, ao analisar o comportamento dos pontos de treinamento para cada cultura derivados dos valores temporais de NDVI se observou grande variabilidade intraclasses. Para entender melhor o comportamento dos dados foram efetuadas várias análises estatísticas. Também se realizaram análises de separabilidade (por exemplo, medida de separabilidade

Jeffries-Matusita e Divergência Transformada (Richards, 1999), e visualização de nuvens de pontos em n Dimensões) para eliminar interativamente os pontos que fogem ao padrão, mantendo-se aqueles pontos mais representativos de cada classe, com isso formando uma amostra de pontos de treinamento mais pura por classe. Apesar deste estudo focar em terras cultivadas com culturas específicas de interesse, para que se possa ter um melhor entendimento do comportamento espectral e temporal dos dados, foi necessário analisar o sinal de todas as observações feitas a campo, mesmo aquelas cujas classes não eram de interesse para este projeto. Dentre as culturas de primeira safra, algodão se mostrou ser a classe com maior variabilidade interna, seguido de soja e cana (Figura 2). Se considerou que tal variabilidade poderia ser devida a diferenças na agenda de plantio das distintas regiões de MS, a fatores naturais que variam dentro do estado, ou a ruídos presentes na imagem proveniente possivelmente dos processos de remoção de cobertura de nuvens. Porém, se a variabilidade fosse causada por ruídos da imagem se observaria também uma alta variabilidade naquelas classes que não variam significativamente durante o ano, e não foi o caso. Por exemplo, amostras de áreas de pasto, classe que está bem representada em número de dados e distribuição espacial por todo o estado, mostra um dos desvios-padrão mais baixos, junto com a classe eucalipto. De modo que a variabilidade interna dos pontos coletados para representar cada uma das classes deve ser decorrente dos distintos tipos de manejo dos agricultores, o que por sua vez pode ser influenciados por condições ambientais (p.ex., clima, solo, etc.) presentes nas várias zonas biogeográficas de MS.




Figura 2. Gráfico mostrando a média multi-temporal de valores NDVI para os pontos de treinamento. As barras de erro refletem o desvio-padrão das classes em cada data.

Para diminuir os efeitos introduzidos pelas diferentes agendas de manejo de solo, plantio e colheita, o estado foi dividido em 7 regiões biogeográficas levando em consideração padrões topográficos, hidrologia, tipo de solos, vegetação e biomas (Figura 1). Estas informações foram obtidas de dados compilados dentro do Macrozoneamento Geoambiental do Estado de Mato Grosso do Sul (1989). Com base nessa subdivisão, a imagem do estado foi segmentada em regiões mais homogêneas para análise, reduzindo assim a variabilidade interna das classes temáticas e gerando amostras de treinamento mais puras para o processo de classificação de imagens.

Finalmente, os mapas resultantes da Classificação Supervisionada foram usados como indicativos da presença de cada um dos tipos de culturas. Após a aceitação do resultado do processo de classificação por tipo de cultura derivado de MODIS, procedemos com o delimitamento das bordas dos polígonos manualmente e em detalhe sobre as imagens TM e LISS-III, gerando-se os mapas finais a escala aproximada de 1:100.000.

Para armazenar e gerir esses e outros dados geográficos foi instalado em dois computadores da FAMASUL o software de livre distribuição Kosmo, selecionado entre outras opções por sua capacidade de lidar com diversos formatos raster. Um técnico com formação em Agronomia e extensiva experiência em serviços de topografia foi contratado e recebeu 160 horas de capacitação para a utilização do software na análise e cruzamento dos dados.

3. Resultados e Discussão

Realizou-se uma seleção aleatória estratificada por classe dos dados originais de campo para servir de base para a análise de acurácia da classificação. Também se estabeleceu que a amostra aleatória fosse proporcional ao número total de pontos disponíveis para cada classe. Os pontos separados para esta análise não foram incluídos como pontos de treinamento. Isso resultou na seleção de 3.345 pontos para safra e de 3.850 pontos para safrinha, dos quais se gerou uma matriz de confusão (*Confusion Matrix*) junto com a imagem de classificação SVM da que se obtiveram medidas estatísticas de Concordância Total, Índice Kappa e outros (Tabela 1). Os resultados para Concordância Total e Índice Kappa, respectivamente 87.8% e 0.82 para safra e de 88.3% e 0.85 para safrinha, são considerados altamente satisfatórios para a escala e resolução espacial deste trabalho.

Tabela 1. Matriz de confusão e acurácia da classificação

	ALG	CAN	EUC	MIL	PST	REM	SER	SOJ	SOR	Total
ALG	73	0	0	3	1	0	0	8	0	85
CAN	0	279	2	1	32	12	0	17	1	344
EUC	0	0	3	0	0	0	0	0	0	3
MIL	5	2	0	63	1	0	0	21	0	92
PST	2	74	3	1	1124	25	7	34	1	1271
REM	0	26	5	0	11	156	0	5	0	203
SER	0	0	0	0	0	0	5	0	0	5
SOJ	0	23	1	49	30	3	0	1235	1	1342
SOR	0	0	0	0	0	0	0	0	0	0
Total	80	404	14	117	1199	196	12	1320	3	3345
Concordância Total (2938/3345): 87.83%										
Índice Kappa: 0.82										

Após a obtenção de resultados satisfatórios seguindo métodos tradicionais de classificação de imagens procedemos com a utilização de métodos de correção contextual *a-posteriori* combinando o melhor de cada um dos parâmetros analisados paralelamente (p.ex., algoritmo de classificação, topografia, Landsat TM). Isso com o propósito de se obter o melhor mapa possível com as ferramentas e recursos disponíveis. Entre os algoritmos de classificação avaliados foram ML e SVM os que repetidamente apresentaram os valores de acurácia mais altos. Merece menção o fato que ML apresentou os melhores resultados para se classificar áreas de agricultura relativamente pequenas, enquanto SVM gerou classificações com menos ruído, mais consistentes e mais coerentes. A adição das bandas multiespectrais Landsat-TM à análise multitemporal se mostrou de grande valia por melhorar a discriminação e definição de culturas perenes e semiperenes (p.ex., cana-de-açúcar e reforestamento) as quais, por obedecer a um comportamento temporal diferente das culturas anuais foram frequentemente confundidas com a vegetação estabelecida (p.ex., pasto ou remanescentes). Por outro lado, a inclusão de topografia apresentou os maiores benefícios naquelas regiões com alta variabilidade de relevo e em áreas de cobertura altamente mistas. Nas biorregiões

com tais características (p.ex., biorregiões 2 e 3) além de melhorar os valores de acurácia, a adição de topografia produziu resultados visualmente melhorados por reduzir os ruídos da classificação. As áreas que mostraram melhorias durante esta segunda etapa de análise foram identificadas e adicionadas ao mapa de classificação principal, gerando assim um mapa temático MODIS médio com os melhores resultados, considerando as particularidades de cada biorregião.

Os mapas finais, em escala 1:100.000, foram extensivamente discutidos e avaliados por diversos atores no estado, como por exemplo técnicos do IBGE, CONAB, Sindicatos de Produtores Rurais, revendas agrícolas, cooperativas e entidades de assistência técnica. Essas reuniões, além de servirem como apresentação do projeto à comunidade em geral, foram fonte importante de informações usadas em ajustes e correções *a posteriori* do trabalho. Nestas reuniões as totalizações por municípios foram frequentemente comparadas com dados gerados pelo IBGE, por ser a referência mais bem estabelecida. Diferenças entre os números eram esperados devido às diferenças entre métodos e tipo de dados usados (por exemplo, dados de Sensoriamento Remoto versus dados de pesquisas), mas ainda assim foi um exercício válido para identificar e investigar as causas de possíveis discrepâncias entre dados (Wardlow, 2008). Um outro aspecto que foi discutido é que a natureza da metodologia usada pelo IBGE dificulta muito a validação ou contestação dos dados levantados, por lidar apenas com totalizações municipais. Ao contrário, o mapeamento das áreas ocupadas com cada cultura permite que se valide cada uma dessas áreas, com o auxílio de um GPS simples, sempre que houver dúvidas sobre a acurácia dos dados. O mapeamento da safra também oferece uma segunda característica importante. Há muitos casos de sedes municipais que se localizam próximas a limites municipais secos. Por proximidade e facilidade de acesso estas acabam absorvendo residência, domicílio fiscal, registro de imóvel rural, relacionamento bancário e comercial, entre outros, de proprietários de áreas do município vizinho. Portanto todos os entrevistados tenderão a considerar as áreas plantadas nestas propriedades como pertencente ao seu município, apesar da localização geográfica do imóvel ser no município vizinho. Divisas secas nem sempre são culturalmente reconhecidas. Quando se realiza o mapeamento de cada área plantada, o município ao qual cada uma pertence é facilmente identificado.

Desde a disponibilização dos dados para o departamento técnico da FAMASUL diversas demandas por dados específicos de determinadas regiões puderam ser atendidas internamente, através de análises SIG e geração de mapas temáticos. A disseminação da informação tem se dado de forma rápida, eficiente e dinâmica, e novos dados espaciais têm sido adicionados ao SIG. As primeiras impressões foram altamente positivas quanto ao impacto que a incorporação de um SIG trouxe às decisões tomadas no setor agropecuário em MS.

4. Conclusões

Este trabalho se une a uma série de estudos prévios que confirmam as capacidades dos dados de NDVI derivados de imagens MODIS de 250 metros para o mapeamento de grandes extensões de terras cultivadas. Porém, além da indispensável resolução temporal deste sensor para detectar alterações subsequentes de biomassa, é altamente vantajoso o uso de dados auxiliares e de técnicas de segmentação de imagem, e edição contextual para otimizar seu uso e produzir documentos cartográficos com o nível de detalhe necessário para o manejo de recursos e tomada de decisões. Ainda que o processo tenha sido bastante trabalhoso e demorado, acreditamos que o levantamento das áreas de safra permite e facilita a implementação de políticas eficazes voltadas à produção, armazenagem e escoamento da safra agrícola de MS. Além disso, a base cartográfica advinda deste projeto possibilita a inclusão e análise de novos dados que poderão ser de fundamental importância na proteção fitossanitária, incremento de produtividade agrícola, proteção ambiental, estabelecimento de estrutura viária e outras políticas relacionadas ao setor produtivo agropecuário de MS.

O alto nível de acurácia que foi atestado pelos principais atores do setor, somado à receptividade que esses dados tiveram junto aos mesmos, demonstra não apenas a factibilidade da utilização de técnicas de Sensoriamento Remoto para a geração de dados confiáveis e disponíveis, mas principalmente o impacto positivo que os dados resultantes de tal processo têm na gestão dos recursos naturais de extensas áreas, a nível regional e nacional.

Agradecimentos

Gostaríamos de agradecer a todas as pessoas que cooperaram na revisão e validação dos dados, particularmente aos colegas do IBGE-MS, SEPROTUR-MS, e todos os Sindicatos Rurais do sistema FAMASUL - Federação da Agricultura e Pecuária de MS. Também agradecemos à equipe técnica da Sinóptica, incluindo ex-funcionários, que tomaram parte neste esforço.

Referências Bibliográficas

Dalpasquale, A. e Riedl, E. 2010. Em reunião com a Associação dos Produtores de Soja de Mato Grosso do Sul - APROSOJA SUL, ea Federação da Agricultura e Pecuária de Mato Grosso do Sul - FAMASUL, comunicação pessoal. 18 de novembro de 2010.

Campbell, J. **Map use and analysis**. McGraw-Hill, 3 edição, 1998.

IBGE. **Estados**. Disponível em: <<http://www.ibge.gov.br/estadosat/perfil.php?sigla=ms>>. Acesso em: 21.nov.2010.

IBGE: **Censo Agropecuário 2006**. Disponível em: <<http://www.ibge.gov.br/estadosat/temas.php?sigla=ms&tema=censoagro>>. Acesso em: 21.nov.2010.

IBGE: **Contas Regionais do Brasil 2007**. Disponível em: <http://www.ibge.gov.br/home/estatistica/economia/contasregionais/2003_2007/defaulttab_esp.shtm>. Acesso em: 21.nov.2010.

IBGE: **Pesquisas agropecuárias 2002**. Disponível em: <<http://www.ibge.gov.br/home/estatistica/indicadores/agropecuaria/PesquisasAgropecuarias2002.pdf>>. Acesso em: 21.nov.2010.

Jarvis, A.; Reuter, H.I.; Nelson, A.; Guevara, E. **Hole-filled seamless SRTM data**. Centro Internacional de Agricultura Tropical V4 2008.

Lillesand, T. M. e Kiefer, R. W. **Remote sensing and image interpretation**. John Wiley & Sons, 3 edição, 1994.

Mato Grosso do Sul. Secretaria de Planejamento. **Macrozoneamento Geoambiental do Estado de Mato Grosso do Sul**. Campo Grande, MS: SEPLAN/FIPLAN 1989, 242 p.

Richards J.A., 1999, **Remote Sensing Digital Image Analysis**, Springer-Verlag, Berlin, p. 240.

Richards, J. A. and Jia, X., 1999 **Remote sensing digital image analysis: an introduction**. Third Edition. Springer-Verlag, New York, N.Y., 363p.

SEMAC: **Dados estatísticos de Mato Grosso do Sul 2010**. Disponível em: <http://www.semac.ms.gov.br/control/ShowFile.php?id=71531>. Acesso em: 21.nov.2010

U.S. Geological Survey, 2007, **Geographic information systems**. Disponível em: <http://egsc.usgs.gov/isb/pubs/gis_poster>. Acesso em: 15.out.2010.

Wardlow, B. D.; Egbert, S. L. **Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains**. Remote Sensing of Environment 112 (2008) 1096 - 1116.