
PREVISÃO DE SAFRA DA SOJA NO MUNICÍPIO DE CAPINÓPOLIS/MG ATRAVÉS DO SENSORIAMENTO REMOTO

WILLIAM TSE HORNG LIU¹
TATIANE ASSIS VILELA¹
CARLOS ANTÔNIO OLIVEIRA VIEIRA¹
TAIS VIRGÍNIA GOTTARDO¹
FELIX KOGAN²

¹ Universidade Federal de Viçosa - UFV

Departamento de Engenharia Civil - DEC

Setor Engenharia de Agrimensura, Viçosa – MG

² National Environmental Satellite, Data and Information Service-NESDIS

National Oceanic and Atmospheric Administration-NOAA

Center for Satellite Applications and Research-STAR, Campo Springs, MD, USA

Email: will_liu@ufv.br

RESUMO - Este estudo aplica os índices de vegetação gerados a partir de imagens orbitais na previsão da produtividade de soja do município de Capinópolis, MG. Sete modelos mensais progressivos foram construídos na estação das culturas de verão usando os dados de TCI e VCI de 1986 a 2001 e validados com os dados de 2002 a 2006. Os dados de produtividade publicados pelo IBGE foram usados como dados observados. Os dados de precipitação da Estação Meteorológica de Capinópolis foram usados para determinar a data do plantio. Os modelos YMT, YM1, YM2, YM3, YM4, YM5 e YM6 correspondem ao modelo de tendência tecnológica e ao modelo do primeiro ao sexto mês do ciclo da cultura, respectivamente. Os resultados mostram que a precisão da estimativa da produtividade melhorou progressivamente desde o início do plantio com a média dos erros de 15,2% à maturação de 7,1%. Concluiu-se que a produtividade pode ser prevista em março com uma precisão acima de 90%. A informação da data do plantio é crucial na construção do modelo. O método pode ser incorporado no sistema operacional de previsão da safra. Sugere-se a construção de modelos semanais para aumentar a frequência e a precisão da previsão ao longo do ciclo da cultura.

ABSTRACT - This study is to apply satellite derived vegetation indices to soybeans yield prediction for the Capinópolis City, Minas Gerais State. Seven monthly progressive models through the summer cropping season were constructed using TCI and VCI data of 1986 to 2001 and validated using data of 2002 to 2006. The soybeans yield data published by the IBGE were used as observed yield. The rainfall data recorded by the Capinópolis Meteorological Station were used to determine the planting date. The seven models were named as YMT, YM1, YM2, YM3, YM4, YM5 e YM6 representing technology trend model, first to six month's model, respectively. The results showed that the soybeans yield estimation accuracy had improved progressively from the initial of the growing stage with a mean error of 15.2% to its maturity of 7.1%. It is concluded that the model can predict the yield in March with an accuracy higher than 90%. The planting date information is important for model construction. It is recommended that the method may be incorporated to an operational crop yield prediction system. For the future study, it is suggested that the development of weekly models may increase prediction frequency as well as accuracy throughout the cropping season.

1 INTRODUÇÃO

A produção agrícola de uma determinada cultura é estimada multiplicando-se a produtividade pela área plantada. Por isso, a estimativa da produção final de uma cultura depende de dois parâmetros: área plantada e produtividade. Em relação à área plantada, os dados são tradicionalmente obtidos por meio de levantamento em campo, ou junto aos órgãos financiadores. Recentemente,

a estimativa da área plantada pode ser feita no início do estágio do crescimento vegetativo com uma boa precisão (>90%), usando os dados de satélite de alta resolução espacial (Alonson, et. Al., 1991; Quarmby, et. al., 1992; Ackinson et al. 1997; De Wit e Clevers, 2004). Por outro lado, a estimativa da produtividade envolve um processo dinâmico, em que os impactos dos fatores ambientais e das práticas do manejo das culturas podem afetar a produtividade em qualquer estágio do crescimento, desde

o plantio até a colheita. O desenvolvimento de métodos de previsão de safra é uma tentativa de prever a produtividade com a boa precisão antes da colheita. Atualmente, os métodos incluem observação das condições do crescimento da cultura em campo, modelos estatísticos agroclimatológicos, modelos de simulação de processos fisiológicos e modelos de índices de vegetação gerados com os dados de satélite (Liu, 2007).

Desde o início da década de 1970, os modelos estatísticos agroclimatológicos estão sendo aplicados em vários países na previsão de safra agrícola, com resultados bastante satisfatórios (McQuigg, 1975). No entanto, esses modelos não podem prever ocorrência de doenças e pragas, nem os eventos de anormalidades climáticas, tais como secas severas, excesso de pluviosidade ou outras variações meteorológicas extremas cujos valores não foram registrados historicamente (Katz, 1979).

Os modelos de simulação dos processos fisiológicos são baseados na simulação da taxa diária de fotossíntese que converte a energia solar em matéria seca e na simulação dos efeitos do estresse hídrico por meio do balanço hídrico e das práticas de manejo de culturas. Atualmente, os softwares referentes aos modelos de processos fisiológicos das principais culturas, tais como trigo, milho, arroz, soja, sorgo, feijão, etc., um total de 10 culturas, são divulgados pela Universidade de Hawaii (Tsuji, et al. 1994). A precisão desses tipos de modelo pode chegar a valores acima de 95% (Hodges et al., 1987; Liu et al., 1989). Dois fatores podem comprometer sua aplicação. O primeiro é que os dados de culturas e meteorológicos são coletados em só um local que pode não representar a região inteira. O outro é que a produtividade final é calculada pela multiplicação de produtividade de uma planta com a densidade da plantação. Portanto, na escala operacional, as extrapolações pontuais dos dados de entradas e as extrapolações do crescimento e da produtividade de uma única planta para uma região inteira podem comprometer sua precisão.

Os dados digitais em várias bandas espectrais obtidos pelo sensoriamento remoto fornecem informações da superfície terrestre. As refletâncias espectrais das bandas nas regiões do visível, infravermelho próximo, infravermelho termal até microondas, medidas pelo sensoriamento remoto, são utilizadas para identificar tipos de vegetação e monitorar as condições do crescimento da vegetação e detectar os impactos das variabilidades ambientais (Moran et al., 1994; Wigneron, et al., 1997). As vantagens dos modelos de previsão da safra agrícola usando índices de vegetação incluem o fornecimento das informações com altas frequências espacial e temporal que possibilitam o monitoramento contínuo das condições do crescimento durante o ciclo fenológico da cultura e a escala da área de interesse variando-se de uma plantação, um estado, um país até o globo inteiro. Vários índices de vegetação gerados com os dados de satélite foram propostos para combinar as várias bandas espectrais que compactam os dados e corrigem parcialmente os efeitos das interferências atmosféricas. Bannari et al. (1995)

apresentaram uma revisão extensa sobre os índices de vegetação propostos nos últimos anos. Um índice mais usado é chamado NDVI (“*Normalized Difference Vegetation Index*”). O NDVI é calculado pela equação (1) a seguir:

$$NDVI = [NIR - VIS] / [NIR + VIS] \quad (1)$$

Em que:

NDVI = *Normalized Difference Vegetation Index*;

NIR = Banda 2 do satélite NOAA, banda do infravermelho próximo (0,725–1,10 μm);

VIS = Banda 1 do satélite NOAA, banda do Visível (0,550– 0,680 μm).

Rasmussen (1998) utilizou os dados de NDVI integrado ao ciclo fenológico da cultura subtraindo NDVI pré-plantio, corrigindo a porcentagem de vegetação da área considerada e os dados de temperatura da superfície como as variáveis independentes para a estimativa da produtividade de pastagem no Senegal. A temperatura da superfície foi calculada pelo método de Janela Dividida Local desenvolvido por Anderson (1997). Os resultados mostraram que o modelo tem o valor do coeficiente de determinação da regressão (R^2) de 0,82 com o erro padrão em 329 kg/ha e a média dos erros absolutos abaixo de 20%. Kogan (1990, 1995) apresentou dois índices de vegetação, VCI (“*Vegetation Condition Index*”) e TCI (“*Temperature Condition Index*”) para monitorar a variabilidade da seca regional eliminando os efeitos geográficos e climáticos regionais. Os VCI e TCI são calculados pelas equações (2) e (3) a seguir:

$$VCI_j = [NDVI_j - NDVI_{min}] / [NDVI_{max} - NDVI_{min}] \quad (2)$$

Em que:

VCI = Índice da condição de vegetação no período j;

NDVI_j = NDVI no período j;

NDVI_{max} e NDVI_{min} são os valores históricos de NDVI máximo e NDVI mínimo no mesmo período j.

$$TCI_j = [Tb4_{max} - Tb4_j] / [Tb4_{max} - Tb4_{min}] \quad (3)$$

Em que:

TCI_j = Índice da condição de temperatura de brilho no período j;

Tb4 = temperatura do brilho do canal 4 do satélite NOAA, (10,30 – 11,30 μm);

Tb4_j = Tb4 no período j;

Tb4_{max} e Tb4_{min} são os valores históricos de Tb4 máximo e Tb4 mínimo no mesmo período j.

Recentemente, os dados de TCI e VCI foram aplicados para a construção dos modelos de previsão da safra com os resultados promissores. Hayes e Decker (1996) apresentaram um modelo de regressão simples para a previsão de safra do milho usando o valor médio de VCI dos estágios de pico do crescimento vegetativo do milho para a estimativa da produtividade da região

produtora do milho chamada cinturão do milho (“*Corn Belt*”) nos Estados Unidos. Os erros nas estimativas passaram de 20% em alguns casos. Unganai e Kogan (1998) aplicaram os dados de TCI e VCI na construção dos modelos estatísticos de estimativa de produtividade do milho na África do Sul obtendo as estimativas com erros abaixo de 20%. Zielinska et al. (2002) apresentaram os modelos de TCI e VCI para a estimativa das produtividades do trigo nas 49 regiões da Polônia em um único ano. A precisão alcançou valores superiores a 95% apresentando uma média dos erros igual a 3,82%. Mas o modelo não foi validado com os dados independentes de outros anos. Liu e Kogan (2002) apresentaram os modelos de estimativa da produtividade da soja em função de TCI e VCI para oito principais estados produtores de soja no Brasil. Os modelos foram construídos e validados com os dois conjuntos de dados diferentes. A média dos erros absolutos alcançou 8,2%. Porém tiveram sete casos em um total de vinte sete casos de previsão que ainda apresentam erros acima de 10%. Dois fatores podem causar erros significantes. O primeiro é que o uso do valor médio de TCI ou VCI em uma área extensa, tal como um estado ou um país, pode não inferir bem as condições do crescimento de uma determinada cultura, porque as condições ambientais podem variar consideravelmente no espaço e no tempo. O segundo é que a data do plantio pode variar de um ano para outro e de uma região para outra. O uso dos dados cronologicamente fixos de TCI e VCI para inferir as condições do crescimento pode não coincidir com as condições do crescimento nos vários estágios do ciclo da cultura. Portanto, este estudo objetiva aumentar a precisão da previsão da safra agrícola usando uma área de estudo menor, tal como o município de Capinópolis, e reajustar a data do plantio de cada ano de acordo com a variação do início da estação chuvosa para minimizar os efeitos das variabilidades espacial e temporal dos dados de TCI e VCI.

2. MATERIAL E METODOLOGIA

2.1 Área de Estudo e Dados Usados

O município de Capinópolis foi selecionado como uma área de estudo piloto para o desenvolvimento de métodos inovadores no campo de previsão de safra agrícola. A Figura 1 apresenta o município de Capinópolis localizado na meso-região do Triângulo Mineiro. O município possui uma área de 632,2 km² e está situado na principal região produtora de soja do Estado de Minas Gerais. A área plantada de soja aumentou cerca de 10.000 hectares antes do ano 1998, alcançou um pico de 27.600 hectares em 2004 mantendo-se acima de 20.000 hectares desde então. Cerca de um terço da área do município é ocupada pelas plantações de soja. A média da produção de soja do município é em cerca de 55.000 toneladas por ano, o que representa cerca de 2% da produção do Estado de Minas Gerais (IBGE, 2008). Uma área de 18 km x 18 km, com as coordenadas: 18°34'36''S - 18°45'24''S e 49°27'36''W - 49°38'24''W,

foi delineada para extrair os dados de TCI e VCI. A área em estudo ocupa aproximadamente 50% da área total do município.

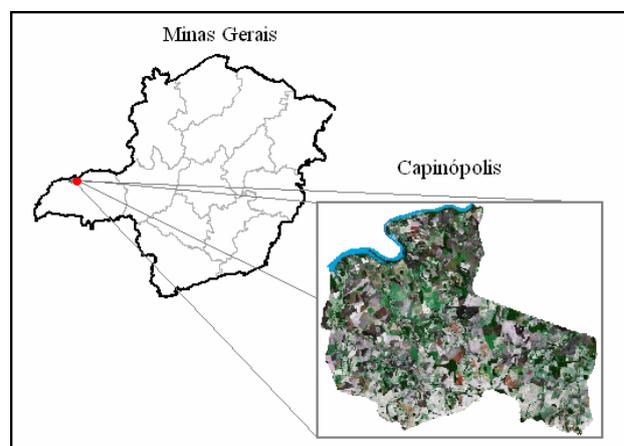


Figura 1 – Município de Capinópolis localizado na meso-região do Triângulo Mineiro, oeste do estado. A imagem foi obtida no Google (2008).

Os dados de produtividade da soja do município de Capinópolis do período de 1986 a 2006, publicados pelo IBGE (2008), foram utilizados com os dados oficiais observados. Os dados mensais de precipitação do período de 1985 a 2006 da Estação Meteorológica de Capinópolis do INMET (2008) foram usados para a determinação do início da data do plantio para a construção dos modelos.

Os dados semanais de TCI e VCI da área de estudo do período de setembro de 1986 a 2006 disponíveis na NOAA (2008) foram usados. Os dados de TCI e VCI foram gerados com os dados da NOAA AVHRR GVI (“*National Oceanic and Atmospheric Administration, Advanced Very High Resolution Radiometers, Global Vegetation Index*”) com uma resolução espacial de 6 km x 6 km. Os dados de TCI e VCI do ano 1995 não foram usados devido à falta dos dados da NOAA AVHRR no final do ano 1994. Os dados semanais foram convertidos em dados mensais usando os valores médios de cada 4 semanas. A área de estudo abrange 3 pixels x 3 pixels dos dados de TCI ou VCI. Os valores médios de 9 pixels de dados de TCI e VCI foram calculados para a construção dos modelos.

2.2 Construção e Validação dos Modelos

Os modelos de estimativa de produtividade da soja em função de TCI e VCI foram construídos usando as técnicas de regressão múltipla, disponíveis no software SAS (“*Statistical Analysis System*”). O ciclo fenológico da cultura de soja é de 150 dias ou cinco meses. Mas neste estudo, os dados mensais de TCI e VCI de um período de seis meses foram usados para a construção dos modelos, considerando que o crescimento da soja é afetado desde a preparação do solo, antes o plantio, que necessita de uma chuva suficiente para recarregar a umidade do solo após uma estação seca até a colheita, e

que necessita de um período de seca e alta insolação para a maturação e a colheita. Portanto, os modelos foram construídos considerando a produtividade em função das variáveis independentes dos dados mensais de TCI e VCI de um período de seis meses. O início da estação chuvosa geralmente ocorre no mês de outubro, mas pode variar de outubro a dezembro, em alguns anos. Portanto, os dados de TCI e VCI do período do ciclo fenológico da soja foram usados para a construção dos modelos. Neste estudo, o mês com a precipitação total acima de 100 mm foi usado como o início da data do plantio.

As informações da produtividade potencial ao longo do período do crescimento no ciclo fenológico da soja são importante para o manejo da cultura e para a comercialização no mercado. Portanto, seis modelos mensais progressivos foram construídos para fornecer a estimativa da produtividade potencial ao longo do ciclo fenológico da soja. Os seis modelos são denominados como YM1, YM2, YM3, YM4, YM5 e YM6 que correspondem aos modelos do primeiro ao sexto mês do ciclo da cultura, respectivamente. Um modelo de tendência tecnológica (YMT), que projeta a produtividade da soja em função dos avanços tecnológicos do sistema de manejo da cultura ao longo do tempo, também foi construído. Os dados de TCI e VCI do período de 1986 a 2001 foram usados na construção dos sete modelos e os de 2002 a 2006 na validação. As produtividades calculadas de um modelo a partir dos dados do período de 1986 a 2001 usados na construção são conhecidas como produtividades simuladas e as produtividades calculadas com os dados dos anos que não foram usados na construção do modelo, são conhecidas como produtividades previstas. As produtividades previstas são usadas para a validação do modelo.

3. RESULTADOS E DISCUSSÕES

As equações (4) à (10) representam os modelos YMT, YM1, YM2, YM3, YM4, YM5 e YM6 que correspondem o modelo da tendência tecnológica e os seis modelos do primeiro ao sexto mês do ciclo da cultura, respectivamente.

$$YMT = 1895,798 + 15,7603 * (\text{ANO} - 1980) \quad (4)$$

$$YM1 = 2251,339 + 5,9662 * \text{TREND} - 65,6051 * V1 + 31,8011 * TV1 + 0,3098 * QV1 - 0,3481 * QT1 \quad (5)$$

$$YM2 = 962,512 + 24,8683 * T1 + 14,8147 * TV1 - 0,158 * QV2 - 0,40497 * QT2 \quad (6)$$

$$YM3 = 1001,904 + 44,587 * T1 - 20,882 * TV1 + 27,185 * TV2 - 0,5094 * QT2 - 0,0953 * QV3 \quad (7)$$

$$YM4 = 1879,758 - 13,219 * V1 + 13,0816 * V2 - 2,5391 * T2 + 3,286 * T3 + 4,8172 * T4 \quad (8)$$

$$YM5 = 1427,424 - 16,5706 * V1 + 22,7414 * V2 + 9,8871 * T4 - 0,0736 * QV3 + 0,0755 * QV5 \quad (9)$$

$$YM6 = 703,494 - 8,9477 * T1 + 10,07349 * T2 + 12,3634 * T4 - 23,2426 * V1 + 28,6213 * V2 + 11,444 * V6 \quad (10)$$

Em que:

YMT = modelo de produtividade em função da tendência tecnológica;

YM = modelo mensal progressivo de produtividade;

T = TCI mensal;

V = VCI mensal;

TV = TCI + VCI;

QT = TCI * TCI;

QV = VCI * VCI;

TREND = ANO - 1980;

Os números representam os meses da estação das culturas de verão, o primeiro mês refere-se ao início do plantio, o sexto mês refere-se ao final da estação.

A Tabela 1 apresenta os valores do coeficiente de determinação da regressão (R^2) para os sete modelos construídos. Foi observado que o baixo valor de R^2 (igual a 0,083) do modelo YMT implica em dizer que os avanços tecnológicos têm poucos efeitos no aumento da produtividade da soja em Capinópolis desde o ano 1986. O valor de R^2 aumentou progressivamente de 0,261 a 0,798 quando o modelo incorporou os estágios de crescimento mais avançados do primeiro ao sexto mês, correspondendo às equações de (5) à (10). Isto significa que a precisão da previsão aumenta quando a cultura se aproxima do final do ciclo fenológico.

Tabela 1 – Comparações entre os valores de coeficiente de determinação da regressão (R^2), porcentagem da média dos erros absolutos (%MEA) das produtividades simuladas e previstas dos modelos de tendência tecnológica (YMT), modelo do primeiro mês ao sexto mês (YM1 – YM6).

Modelo	R^2	Simulado (%MEA)	Previsto (%MEA)
YMT	0,083	9,9	15,2
YM1	0,261	9,2	17,3
YM2	0,517	7,4	15,6
YM3	0,696	5,8	12,2
YM4	0,499	7,0	10,3
YM5	0,648	6,1	8,4
YM6	0,798	4,7	7,1

A Tabela 1 também mostra que as médias dos erros absolutos (%MEA) do período de 1986 a 2001 das produtividades simuladas pelos modelos YMT, YM1, YM2, YM3, YM4, YM5 e YM6 foram de 9,9%; 9,2%; 7,4%; 5,8%; 7,0%; 6,1% e 4,7% respectivamente. As médias dos erros absolutos (%MEA) do período de 2002 a 2006 das produtividades previstas pelos modelos YMT, YM1, YM2, YM3, YM4, YM5 e YM6 foram de 15,2%; 17,3%; 15,6%; 12,2%; 10,3%; 8,4% e 7,1%

respectivamente. A precisão da estimativa de produtividade da soja melhorou progressivamente desde o início do plantio com a média dos erros de 15,2% à maturação com a média dos erros de 7,1%.

A média dos erros previstos foi pouco mais alta que a dos erros simulados (4,7% contra 7,1%). Vários fatores podem ter contribuído para este aumento do erro, incluindo a falha na determinação do início da data do plantio baseada nos dados de precipitação e os índices de TCI e VCI não inferem exatamente o que foi definido. No primeiro caso, as decisões dos agricultores podem variar, de uma fazenda para outra, na decisão de iniciar a plantação da soja, apesar de a quantidade de chuva poder ser bem próxima na mesma região. Portanto, o fato da data do plantio começar em um único mês, para uma região inteira, pode contribuir para ocasionar algum erro no modelo. No segundo caso, um alto valor de TCI pode ocorrer juntamente com um baixo valor de VCI, se esta área for uma área com o excesso hídrico. Isto porque a temperatura de uma superfície úmida é baixa, o que resulta em um alto valor de TCI, mas ao contrário resulta em um baixo valor de VCI, porque o valor de NDVI é próximo de zero ou até negativo em superfície úmida. Neste caso, o baixo valor de VCI não significa que as culturas sofreram um déficit hídrico, mas excesso hídrico. O efeito do excesso hídrico no crescimento da cultura é diferente do efeito causado pelo déficit hídrico. Por consequência, pode afetar a estimativa da produtividade. Mas em geral, a média dos erros previstos de 7,1% é menor que 10%. Isto demonstra que o método desenvolvido pode alcançar uma precisão acima de 90% o que é um avanço significativo.

A Figura 2 mostra as comparações entre as produtividades observadas (Yo) e as simuladas (1986 a 2001) ou previstas (2002 a 2006) pelos modelos a.YMT, b.YM1, c.YM2, d.YM3, e.YM4, f.YM5 e g.YM6, respectivamente. Na Figura 2a, foi observado que o modelo YMT tem a tendência de aumentar linearmente a estimativa da produtividade de 1990,4 kg/ha no ano de 1986 para 2305,6 kg/ha no ano de 2006 com uma taxa de 15 kg/ha/ano. O modelo YM1 ainda incorporou o efeito da tendência tecnológica na estimativa da produtividade (Figura 2b). A partir do modelo YM2, a tendência tecnologia já não tem mais efeito (Figura 2c). Em geral os modelos não apresentaram boa estimativa nos anos com as produtividades mais baixas (< 1800 kg/ha) que ocorreram nos anos de 1990, 1991, 1994 e 2004 com os erros acima de 10%. Somente o modelo YM6 teve melhor desempenho apresentado os erros menores que 10% em todos os anos exceto no ano de 2004 com um erro de -10,2% (Figura 2g). Isto demonstra que a produtividade da soja é afetada pelas variabilidades climáticas ao longo de todos os estágios do ciclo da cultura. Portanto, a variação da distribuição de chuva na estação chuvosa é um fator crucial na produção de soja na região.

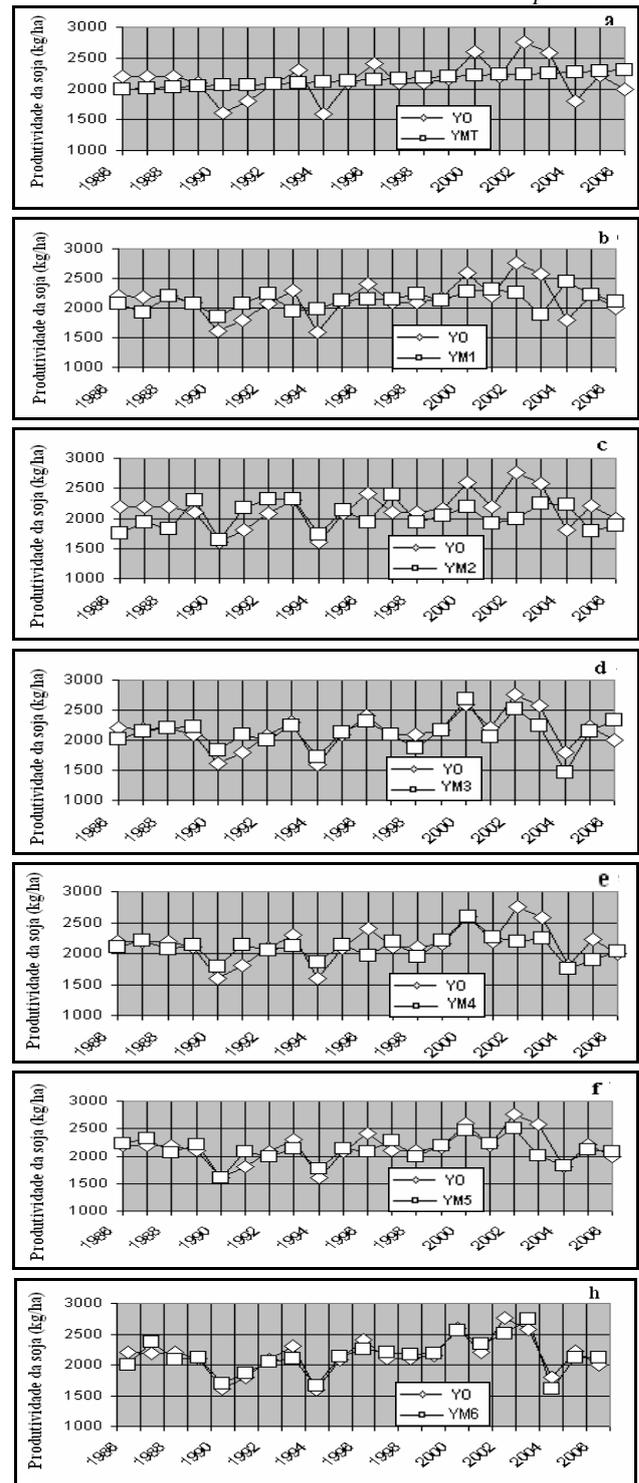


Figura 2 - Comparações entre as produtividades observadas (Yo) e as simuladas (1986 a 2001) e entre as observadas e as previstas (2002 a 2006) pelos modelos a.YMT, b.YM1, c.YM2, d.YM3, e.YM4, f.YM5 e g.YM6.

A Tabela 2 mostra as comparações dos valores dos erros (E%) e dos erros absolutos (%EA) das produtividades simuladas do período de 1986 a 2001 e das previstas do período de 2002 a 2006 pelo modelo

YM6 e o mês usado como o início do plantio para a previsão de produtividade da soja no município de Capinópolis, MG. Foi observado que os erros variam de -9,1% a 8,2% com a média dos erros absolutos igual a 4,7% nas produtividades simuladas nos quinze anos, e de -10,2% a 6,3% com a média de 7,1% nas produtividades previstas nos cinco anos. As faixas dos erros entre as produtividades simuladas e as previstas foram bem próximas. Isso demonstra que o modelo desenvolvido é bem estável.

Tabela 2 - Lista de erro (E%) e erro absoluto (%EA) das produtividades simuladas do período de 1986 a 2001 e as previstas do período de 2002 a 2006 pelo modelo YM6 e mês do plantio para a previsão da produtividade da soja no município de Capinópolis, MG.

Ano	Yo (kg/ha)	YM6 (kg/ha)	E (%)	EA (%)	Data do Plantio
1986	2200	2000,4	-9.1	9.1	Out
1987	2192	2372,4	8.2	8.2	Out
1988	2200	2081,0	-5.4	5.4	Out
1989	2100	2120,7	1.0	1.0	Out
1990	1603	1688,0	5.3	5.3	Nov
1991	1800	1858,1	3.2	3.2	Out
1992	2082	2057,5	-1.2	1.2	Dec
1993	2300	2096,3	-8.9	8.9	Out
1994	1600	1667,1	4.2	4.2	Nov
1995	2090
1996	2410	2255,8	-6.4	6.4	Nov
1997	2100	2203,1	4.9	4.9	Out
1998	2100	2170,4	3.4	3.4	Out
1999	2160	2188,1	1.3	1.3	Out
2000	2600	2554,8	-1.7	1.7	Dec
2001	2200	2333,4	6.1	6.1	Nov
Média	2109,8	2111,2		4,7	
2002	2760	2514,3	-8.9	8.9	Out
2003	2580	2741,6	6.3	6.3	Dec
2004	1800	1615,7	-10.2	10.2	Out
2005	2220	2121,7	-4.4	4.4	Out
2006	2000	2116,7	5.8	5.8	Out
Média	2272	2222,0		7,1	

4 CONCLUSÕES

Concluiu-se que a informação correta da data do plantio de cada ano é crucial na construção de um modelo adequado para a previsão da safra, usando os dados e TCI e VCI. O método desenvolvido pode ser recomendado para o desenvolvimento de um sistema operacional de previsão da safra agrícola no Brasil. No próximo passo da pesquisa, sugere-se que os *pixels* com a superfície úmida, ou mesmo excesso de água, sejam excluídos na construção do modelo, e o início do plantio seja determinado em cada *pixel* e reajustado com os dados coletados em campo. Sugere-se também o

desenvolvimento de modelos semanais e quinzenais para aumentar a frequência e a acurácia da previsão ao longo do ciclo fenológico da cultura.

AGRADECIMENTOS

Os autores agradecem à Estação Experimental da Universidade Federal de Viçosa em Capinópolis, MG e ao 5° Distrito de Meteorologia, Belo Horizonte, MG do INMET, pelo fornecimento dos dados meteorológicos de médias mensais do período de 1986 a 2006 da Estação Meteorológica de Capinópolis/MG. O projeto de pesquisa foi financiado pelo CNPq através do auxílio da bolsa de pesquisador visitante, nível 1 do Dr. William Tse Horng Liu à Universidade Federal de Viçosa, Viçosa, MG. Vigência de 01/fevereiro/2008 a 31 de janeiro e 2009. CNPq. Processo N°: 301144/2007-9.

REFERÊNCIAS

ACKINSON, P.; CUTLER, M.; LEVIS, H. Mapping subpixel proportional land cover with AVHRR imagery. **International Journal of Remote Sensing**, V18. p917-935. 1997.

ALONSON F. C.; SORIA, S. L.; GOZADO, J. M. Comparing two methodologies for crop area estimation in Spain using Landsat TM images and ground-gathered data. **Remote Sensing of Environment**, V.35. p.29-35. 1991,

ANDERSON, H. S. Land surface temperature estimation based on NOAA AVHRR data during the HEPEX Sahel Experiment. **Journal of Hydrology**. V.188. p.788-814. 1997.

DE WIT A. J.; CLEVERS, J. G. Efficiency and accuracy of per-field classification for operational crop mapping. **International Journal of Remote Sensing**, V.25. p.4091-4112. 2004.

GALLEGO, J.; DELINCÉ, J. **Area estimation by segment sampling. Special Report: The MARS Project, Action 1: Regional Inventories**. Rome: European Community Commission, Institute for Remote Sensing Applications Press. 1995. 126p.

GOOGLE. **Google Earth: Imagem do município de Capinópolis, Minas Gerais**. Disponível em < <http://www.google.com.br> > Acesso 15 maio 2008.

HAYES M. J.; DECKER, W.L. 1996, Using NOAA AVHRR data to estimate maize production in the US Corn Belt. **International Journal of Remote Sensing**, V.17. p.3189-3200. 1996.

HODGES, T. D.; BOTNER; SAKAMOTO, C.; HANG, J. Using the CERES-maize model to estimate production

- for the US Cornbelt. **Agriculture and Forest Meteorology**, V.40. p.293-303. 1987.
- IBGE. **Produção Agrícola Municipal**. Disponível em <<http://www.sidra.ibge.gov.br>>. Acesso: 03 março 2008.
- INMET. **Dados Meteorológicos de Capinópolis, MG. Médias Mensais do período de 1985 a 2007**. Belo Horizonte: INMET, 5º Distrito de Meteorologia, 2008. 24p.
- KATZ, R.W. Sensitivity analysis of statistical crop weather models, **Agriculture and Forest Meteorology**, V.20. p.291-300. 1979.
- KOGAN, F. N. Remote sensing of weather impacts on vegetation in non-homogeneous areas. **International Journal of Remote Sensing**, V.11. p.1405-1420. 1990.
- KOGAN F. N. Application of vegetation index and brightness temperature for drought detection. **Advanced Space Research**, V.15. p.91-100. 1995.
- LIU, W. T. **Aplicações de Sensoriamento Remoto**. Campo Grande: Editora da UNIDERP, 2007. 908p.
- LIU, W. T.; BOTNER, D. M.; SAKAMOTO, C. M. Application of CERES-maize model to yield prediction of a Brazilian-maize Hybrid. **Agriculture and Forest Meteorology**, V.45. p.299-312. 1989.
- LIU, W. T.; KOGAN, F. N. Monitoring Brazilian soybean production using NOAA AVHRR based vegetation condition index. **International Journal of Remote Sensing**, 22:1161-1179. 2002.
- MCQUIGG, J. D. **Economic impacts for weather variability**. Columbia: University of Missouri Press, 1975. 82p.
- MORAN, M. S.; CLARKE, T.R.; INOUE, Y.; VIDAL, A. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. **Remote Sensing of Environment**, V.49. P.246-263. 1994.
- NOAA. **Global vegetation health indices**. Disponível em <<http://www.star.nesdis.noaa.gov/smcd/emb>>, Acesso: 06 março 2008.
- QUARMBY, N. A.; TOWNSHEND, J. R.; SETTLE, P. J.; WHITE, K. H.; MILNES, M. HINDLE, T. L.; SILLEOS, N. Linear mixture modelling applied to AVHRR data for crop area estimation. **International Journal of Remote Sensing**, V.13. P.415-426. 1992.
- RASMUSSEN, M. S. Developing simple operational consistent NDVI vegetation models by applying environmental and climatic information: part 2: crop yield assessment. **International Journal of Remote Sensing**, V.19. p.118-219. 1998.
- TSUJI, G. Y.; UEHARA, G.; BALAS, S. **A decision support system for agrotechnology transfer version 3**. Hawaii: University of Hawaii Press, 1994. 787p.
- UNGANAI, L. S.; KOGAN, F. N. Drought monitoring and corn yield estimation In Southern Africa from AVHRR data. **Remote Sensing of Environment**, V.63. p.219-232. 1998.
- WIGNERON, J. P.; KERR, Y.; PRÉVOT, M. Retrieval of soil and vegetation features from passive microwave measurements. **Remote Sensing Reviews**, V.15. p.157-177. 1997.
- ZIELINSKA, K. D.; KOGAN, F. N.; CIOLKOSZ, A.; GRUSZCZYNSKA, M.; KOWALIK, W. K. Modelling of crop growth conditions and crop yield in Poland using VHRR-bases indices. **International Journal of Remote Sensing**, V.23. p.1109-1123. 2002.