

# Relação entre a resposta espectral da cana-de-açúcar, registrada nas imagens dos satélites AVHRR/NOAA, em São Paulo, e dados agroclimáticos, no período de 2001 a 2008

Renata Ribeiro do Valle Gonçalves<sup>1</sup>  
Jurandir Zullo Junior<sup>2</sup>

<sup>1</sup> Universidade Estadual de Campinas - UNICAMP/FEAGRI  
Caixa Postal 6011 - 13083-875 - Campinas - SP, Brasil  
renaribeiro@yahoo.com.br

<sup>2</sup> Centro de Pesquisas Meteorológicas e Climáticas Aplicadas a Agricultura - CEPAGRI  
Cidade Universitária Zeferino Vaz - 13083-970 - Campinas - SP, Brasil  
jurandir@cpa.unicamp.br

**Abstract.** Brazil is the largest sugar-cane producer of the world and has a privileged position to attend the national and world's sugar and alcohol needs. This fact shows the importance of sugar-cane to the country and also the necessity of operational systems that can monitor the vegetation growth through the crop yield on a regional scale. The main purpose of this study was to create models to evaluate how NDVI (Normalized Difference Vegetation Index) and WRSI (Water Requirements Satisfaction Index) behave and relate to each other, and also to foresee these indexes from April to December of 2007, in São Paulo state productive areas. All images used were automatically processed by NAVPRO system which generated radiometric and geometrical corrected images. With all images corrected, maximum value composition of monthly NDVI and temporal NDVI profile were generated. The agroclimatic conditions through the period of analyses were described by WRSI. To describe it a water balance was made and maximum and real evapotranspiration values were calculated on a 10-day period. The models generated by multivariate time series analyses were well adjusted. For all models, WRSI precedes NDVI, it means that NDVI depends on WRSI on every municipal district and the forecasting made was within the reliable interval, and then results became satisfactory. The forecasting models developed allow to use the previous crop yield results as basis to estimation of spectral and agroclimatic crop yield parameters.

**Palavras-chave:** time series, NDVI, WRSI, crop yield forecasting, séries temporais, NDVI, ISNA, previsão de safras.

## 1. Introdução

A produção de cana-de-açúcar no Brasil, de modo geral, vem crescendo nos últimos anos. De acordo com Conab (2005), a região Centro-Sul concentra a maior produção de cana-de-açúcar com 85,3% do total e, de igual forma, sendo que 86,3% destinam-se à indústria. A produção de cana-de-açúcar está fortemente concentrada no estado de São Paulo que produz 59% do total nacional, com destinação de 91,3% ao setor sucroalcooleiro, com safras alternadas, podendo manter sua presença no mercado mundial ao longo do ano.

A cultura da cana-de-açúcar possui função cada vez mais estratégica na economia do país devido à necessidade da substituição dos combustíveis fósseis por fontes de energia renováveis, como o álcool. Outro ponto importante na economia é a produção de açúcar, devido ao aumento das importações estimuladas pelos países asiáticos como a China, que estão aumentando paulatinamente o consumo. Assim, pode-se contar com uma pressão forte nas exportações de açúcar, impulsionadas pelos chineses nos próximos anos.

O Brasil conta com uma posição privilegiada para atender a demanda internacional crescente de açúcar e álcool combustível. Este fato ilustra a importância da cultura para o país e evidencia a necessidade de um sistema preciso de previsão de safras que auxilie o planejamento envolvido na produção e comercialização de produtos estratégicos para os mercados interno e externo.

A utilização de dados de sensoriamento remoto é uma alternativa para a melhoria da objetividade dos métodos de previsão de safras, tanto na estimativa da área plantada, quanto da produtividade das culturas agrícolas, pelos seguintes motivos: i) variedade de sistemas sensores disponíveis atualmente, com as mais diversas resoluções espaciais, temporais, espectrais e radiométricas, adequadas para utilização em aplicações agrícolas, como é o caso do monitoramento de previsão de safras; ii) experiência de vários grupos de pesquisa do Brasil no assunto adquirida após vários anos de trabalho na área; iii) diminuição dos custos de aquisição e processamento das imagens.

Os satélites da série NOAA (*National Oceanic and Atmospheric Administration*), embora criados para fins meteorológicos, vêm sendo muito utilizados no monitoramento da vegetação em escala regional e global e, mais recentemente, estudos vêm sendo realizados enfocando o seu uso no monitoramento agrícola. Seu sensor AVHRR (*Advanced Very High Resolution Radiometer*) apresenta características que permitem sua utilização para estudos terrestres, com resolução espacial variando de um a quatro quilômetros e inclui um canal na banda correspondente ao vermelho e outro no infravermelho próximo, que são adotados em estudos de cobertura vegetal. Devido à sua alta resolução temporal, garantia de cobertura global e gratuidade das imagens, é elevada a probabilidade de obtenção de imagens em boas condições ao longo do ciclo de desenvolvimento da cultura comercial.

Os satélites da série NOAA têm grande potencial de aplicação em métodos operacionais e objetivos de previsão de safras, tanto na estimativa da área plantada quanto na da produtividade, pelas seguintes razões principais:

- a) Possibilidade de obtenção de coberturas globais diárias a partir de pelo menos dois satélites devidamente sincronizados;
- b) Disponibilidade de bandas espectrais termais calibradas;
- c) Existência de vários satélites em operação simultânea, ampliando a disponibilidade de imagens;
- d) Baixo custo de obtenção dos dados através de estações de recepção próprias ou com a NOAA;
- e) Longevidade do sistema, em operação desde 11 de dezembro de 1978, que faz com que haja uma vasta literatura sobre o mesmo, sendo reconhecido como um dos sistemas orbitais mais antigos e importantes de observação da Terra lançados até hoje;
- f) Perspectiva de continuidade do sistema por mais alguns anos ainda, com lançamento de um novo satélite, o NOAA-N'.

Para o monitoramento da vegetação em escalas regional e global utilizam-se índices de vegetação espectral, que é uma quantidade obtida através da razão, diferença, ou outra transformação espectral de dados, para a representação das características da cobertura vegetal, tais como: índice de área foliar (Prince, 1993), biomassa (Justice e Hiernaux, 1986; Tucker, 1979), peso da vegetação úmida, peso da vegetação seca e porcentagem de cobertura vegetal (Senay & Elliot, 2002).

O Índice de Vegetação da Diferença Normalizada (NDVI), que é o índice de vegetação mais estudado e utilizado, foi definido por Rouse et al. (1973), através da Equação 1.

$$NDVI = \frac{\rho_{IV} - \rho_V}{\rho_{IV} + \rho_V} \quad (1)$$

sendo,  $\rho_{IV}$  o fator de refletância no infravermelho próximo e  $\rho_V$  o fator de refletância no vermelho.

Os valores do NDVI variam no intervalo (-1, +1) e quanto maior a diferença entre o fator de refletância no infravermelho próximo e no vermelho, maior é o valor deste índice. Os valores menores e próximos de zero significam superfícies sem vegetação, e valores próximos a 1 (0,8-0,9), indicam superfícies vegetadas com maior densidade possível de folhas verdes.

Uma das formas de avaliar o impacto do clima na produção da cana-de-açúcar pode ser através da utilização de índices agroclimáticos, que englobem os principais parâmetros atmosféricos simultaneamente, ao invés de utilizar cada um deles individualmente. Como exemplo, cita-se o Índice de Satisfação das Necessidades de Água (ISNA), calculado por meio de simulações do balanço hídrico ao longo do ciclo da cultura. Este índice é obtido pela Equação 2.

$$ISNA = \frac{ETR}{ETM} \quad (2)$$

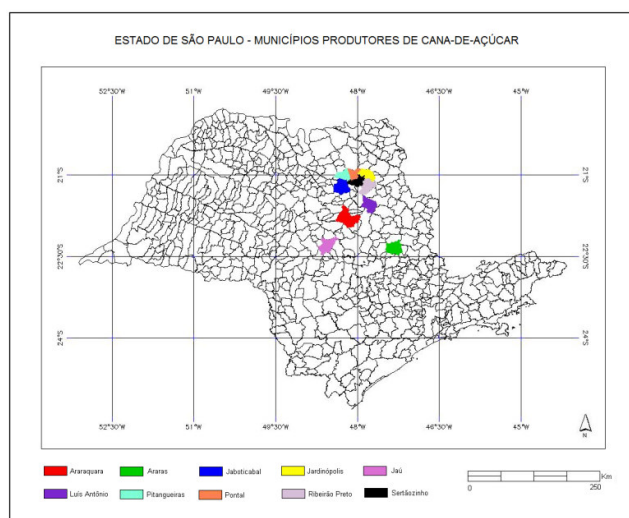
sendo, ETR a evapotranspiração real e ETM a evapotranspiração máxima.

O ISNA expressa a relação entre a quantidade de água que a planta consumiu e a que seria desejável a fim de garantir sua produtividade máxima (Assad et al., 1998). Este índice varia de zero a um, sendo máximo quando a quantidade de água armazenada no solo é adequada para a obtenção da produtividade máxima.

Considerando a importância da previsão de safras agrícolas, o objetivo principal deste trabalho foi criar modelos para avaliar como o NDVI e o ISNA se comportam e se inter-relacionam temporalmente e visando a realização da previsão destes índices, no período de abril a dezembro de 2007, em regiões produtoras de cana-de-açúcar do estado de São Paulo.

## 2. Metodologia de Trabalho

A área de estudo foi a região nordeste do estado de São Paulo, grande região produtora de cana-de-açúcar, que se caracteriza por apresentar áreas plantadas de grandes dimensões, em terreno de relevo plano e suavemente ondulado. O estado de São Paulo está situado entre as coordenadas geográficas 54°00' e 43°30' de longitude oeste e 25°30' e 19° 30' de latitude sul. Nesta área, foram selecionados dez municípios produtores de cana-de-açúcar para serem analisados. Os municípios selecionados foram: Araraquara, Araras, Jaboticabal, Jardinópolis, Jaú, Luís Antônio, Pitangueiras, Pontal, Ribeirão Preto e Sertãozinho, como ilustra a Figura 1.



**Figura 1:** Municípios selecionados produtores de cana-de-açúcar. Fonte: Gonçalves (2008).

A região de estudo corresponde à cena Landsat/TM órbita/ponto 220/75. Foram feitas duas máscaras para mapear as regiões de cana-de-açúcar, uma com a imagem Landsat-5/TM, adquirida em 26/03/1999, e outra com a imagem Landsat-7/ETM+, adquirida em 03/10/2002. A finalidade destas máscaras foi extrair somente os valores de NDVI da cana-de-açúcar, separando, assim, a área urbana, os solos nus e outras vegetações.

Utilizou-se o banco de imagens dos satélites AVHRR/NOAA do Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura, da Universidade Estadual de Campinas (Cepagri/Unicamp). Foram utilizadas imagens do satélite NOAA-16 para a safra 2001/2002 (abril de 2001 a março de 2002) e para os meses de abril, maio e junho da safra 2002/2003. Foram utilizadas imagens do satélite NOAA-17 de julho de 2002 a março de 2008. Isto totalizou sete safras de cana-de-açúcar com imagens de abril de 2001 a março de 2008.

O processamento das imagens do AVHRR/NOAA foi realizado pelo sistema automático de navegação NAVPRO. O NAVPRO é um sistema para processamento e geração automática de produtos de imagens AVHRR/NOAA, desenvolvido por pesquisadores do *Colorado Center for Astrodynamics Research (CCAR), Aerospace Engineering Sciences*, da Universidade do Colorado (Boulder/EUA), e implementado por Antunes (2005) e Esquerdo (2007). O sistema é compatível com a plataforma Linux e executado em “script *Shell*”, o qual realiza todo o processamento das imagens de forma automática, fazendo a conversão de formato, calibração radiométrica, correção geométrica (georreferenciamento preciso) e a geração de produtos (Esquerdo, 2006), como o NDVI.

O cálculo do NDVI foi feito a partir de imagens diárias do AVHRR/NOAA já pré-processadas, isto é, imagens com a calibração radiométrica, georreferenciamento preciso e recorte de São Paulo. O NDVI foi obtido pela Equação 1, que utiliza as bandas 1 e 2, que correspondem ao vermelho e infravermelho próximo, respectivamente. Neste processo, foram excluídos os pixels com ângulo zenital solar maior que 70° e ângulos de varredura maiores que 42°. Estes pixels receberam o valor -1,1. Para amenizar o efeito da atmosfera nas imagens, geraram-se Composições de Valor Máximo (MVC) de NDVI por meio de rotinas IDL elaboradas por Esquerdo (2007).

Com estas composições de NDVI, geraram-se perfis temporais com valores de NDVI. Através de uma rotina em IDL desenvolvida por Esquerdo (2007). Para executar esta rotina foi necessário obter um conjunto de coordenadas (Latitude/Longitude) das áreas de cana-de-açúcar selecionadas para os dez municípios, o vetor destes municípios e uma série temporal de imagens. Foram feitas sete séries temporais de imagens, uma para cada ano-safra (de abril a março).

Para determinar os valores do índice ISNA, fez-se o balanço hídrico proposto por Thornthwaite & Mather (1955), conforme roteiro apresentado por Pereira et al. (2002), utilizando dados climáticos (temperatura e precipitação) de 2001 a 2007, que foram obtidos pelo site [www.ciiagro.sp.gov.br/ciiagroonline/](http://www.ciiagro.sp.gov.br/ciiagroonline/), do Centro Integrado de Informações Agrometeorológicas do Instituto Agrônomo de Campinas (CIIAGRO - IAC). Com o balanço hídrico foi possível calcular as evapotranspirações real, potencial e máxima para períodos decendiais (10 dias) com armazenamento de água disponível no solo de 125mm,  $K_c = 1$ , isto é, evapotranspiração máxima igual a evapotranspiração potencial.

Estabeleceu-se que a cultura de cana-de-açúcar estava no mesmo estágio de crescimento vegetativo e com o ciclo vegetativo de um ano, no qual o plantio inicia-se em agosto e a colheita em julho. Esta padronização foi estabelecida porque a imagem AVHRR/NOAA tem baixa resolução espacial e cada pixel da imagem apresenta uma combinação das respostas espectrais de diversos talhões de cana-de-açúcar, nos diversos estágios de desenvolvimento.

A análise das séries temporais multivariadas de NDVI e ISNA foi feita utilizando o software livre JMulti. O modelo escolhido para analisar as séries temporais multivariadas foi o Auto-Regressivo Vetorial (VAR), que parte do seguinte princípio:

A série  $X_t$ , de ordem  $n \times 1$ , segue um modelo auto-regressivo vetorial de ordem  $p$ , dado pela Equação 3.

$$X_t = \phi_0 + \phi_1 * X_{t-1} + \dots + \phi_p * \phi_{t-p} + a_t \quad (3)$$

sendo  $a_t \sim RB(0, \Sigma)$ ,  $\phi_0 = (\phi_{10}, \dots, \phi_{n0})$  é um vetor  $n \times 1$  de constantes e  $\phi_k$  são matrizes  $n \times n$  constantes, com elementos  $\phi_{(k)ij}$ ,  $i, j = 1, \dots, n$ ,  $k = 1, \dots, p$ . O modelo auto-regressivo vetorial relaciona o valor corrente das séries ( $X_t$ ) com seus valores passados até a ordem  $p$ . A sigla RB significa Ruído Branco e quer dizer que  $a_t$  é uma variável aleatória com média zero e variância  $\Sigma$ . O termo  $a_t$  é responsável por causar uma variabilidade na série.

Para identificar a ordem  $p$  do modelo VAR( $p$ ) ajustou-se sequencialmente modelos VAR de ordens 1, 2, ...,  $k$  e testou-se a significância dos coeficientes ( $\phi_k$  - matrizes), por exemplo, por testes da razão de verossimilhança. Então, para identificar a ordem dos modelos, utilizaram-se alguns critérios de informação, tais como, AIC (Akaike), BIC (Schwarz), HCQ (Hannan-Quinn) e FPE (Final Prediction error, Akaike). Todos esses critérios foram construídos baseados na verossimilhança do modelo e ponderados por alguma relação envolvendo a quantidade de parâmetros no modelo ou número de observações da série.

Foi realizada a análise de cada componente individual  $X_{1t}$  e  $X_{2t}$  através da metodologia de Box-Jenkins (Box et al., 1994). Esta metodologia parte do pressuposto que o comportamento de uma determinada série pode ser, em grande parte, explicada por informações contidas na própria série. Assim os modelos ARMA ( $p, d, q$ ) não requerem, necessariamente, outras variáveis externas à série e pressupõe-se que o passado da própria série captura a maior parte das informações relevantes para explicar o seu comportamento, por meio de um conjunto de componentes.

O primeiro passo foi fazer com que as séries temporais ficassem estacionárias, pois tanto a metodologia de Box-Jenkins, quanto os modelos auto-regressivos vetoriais, requerem que as séries sejam estacionárias. Uma série é estacionária quando ela oscila em torno de uma média constante, com uma variância também constante ao longo do tempo. Também para a estacionariedade das séries deve-se garantir que o valor da covariância entre os dois períodos de tempo dependa apenas da distância entre esses períodos, ou seja, dependa somente da defasagem. Quando uma série é estacionária, as suas propriedades não são afetadas por uma mudança na origem do tempo. Para o modelo VAR, a condição de estacionariedade é satisfeita se as soluções estiverem fora do círculo unitário. Essa relação é a que evidencia a ausência de uma raiz unitária no polinômio auto-regressivo.

Para testar a não-estacionariedade das séries, foi feita a construção de uma função de autocorrelação (ACF – Autocorrelation Function). Basicamente a ACF que consiste na representação gráfica da dependência (correlação) entre as observações de uma série de dados, em função dos diversos intervalos atribuídos aos dados. Geralmente, a sua representação gráfica evidencia a estacionariedade de uma série quando são observadas grandes autocorrelações para uma seqüência grande de defasagem.

Para verificar se os modelos estão adequados, todas as suposições mencionadas devem ser satisfeitas. Desta forma, algumas técnicas de diagnóstico foram utilizadas para checar a adequabilidade do modelo. Primeiro verificou-se a não presença da raiz unitária, pois os autovalores devem estar fora do círculo unitário. Depois as funções de autocorrelação foram construídas, pois os ruídos devem ser não correlacionados. A suposição de ruídos não correlacionados foi verificada pelo teste de Portmanteau, cuja hipótese nula é que as autocorrelações até a defasagem  $h = 1, 2, \dots$ , são nulas. O teste Bera e Jarque foi utilizado para testar a normalidade dos resíduos.

Os modelos adquiridos com estas análises foram utilizados para avaliar como as variáveis se comportam e se inter-relacionam temporalmente e para fazer a previsão dos valores de NDVI e ISNA no período de abril de 2007 a dezembro de 2007. Os valores previstos por estes modelos foram comparados e validados com os dados observados no mesmo período.

### 3. Resultados e Discussão

Selecionou-se um município, Luís Antônio, para apresentar os resultados obtidos conforme a metodologia descrita. Pela análise de séries temporais multivariadas, utilizando os critérios AIC, BIC, HCQ e FPE, ajustou-se um modelo para Luís Antônio. O modelo ajustado foi auto-regressivo de ordem 3, e através da análise de resíduos observou-se grandes autocorrelações em defasagens maiores que 3, especificamente nos “lags” 7, 10 e 12. Vários modelos foram considerados, sendo que, o modelo auto-regressivo de ordem 10 foi o que apresentou melhor ajuste, em relação à análise de resíduos. O modelo bivariado ajustado é descrito pelas Equações 4 e 5.

$$\begin{aligned}
 NDVI(mês) = & 0,383 * NDVI(mês - 1) + 0,110 * ISNA(mês - 1) + 0,322 \\
 & * NDVI(mês - 2) + 0,068 * ISNA(mês - 3) - 0,147 * NDVI(mês - 4) \\
 & + 0,042 * ISNA(mês - 4) - 0,306 * NDVI(mês - 9) + 0,034 \\
 & * ISNA(mês - 9) + 0,324 * NDVI(mês - 10) - 0,041 * S_{jun}(mês) \\
 & - 0,029 * S_{jul}(mês) - 0,041 * S_{set}(mês) + 0,112 * S_{nov}(mês) + 0,092 \\
 & * S_{dez}(mês) + 0,073 * S_{jan}(mês) + 0,052 * S_{fev}(mês) + a_{NDVI}(mês)
 \end{aligned} \tag{4}$$

$$\begin{aligned}
 ISNA(mês) = & 0,282 * ISNA(mês - 1) + 0,406 * NDVI(mês - 3) + 0,185 \\
 & * ISNA(mês - 3) - 0,622 * NDVI(mês - 7) + 0,831 * NDVI(mês - 10) \\
 & + 0,248 * S_{out}(mês) + 0,286 * S_{nov}(mês) + 0,355 * S_{dez}(mês) + 0,249 \\
 & * S_{jan}(mês) + 0,152 * S_{fev}(mês) + a_{ISNA}(mês)
 \end{aligned} \tag{5}$$

sendo,  $S_i(mês)$ ,  $i = jan, fev, \dots, dez$ , indicadores que incorporam a sazonalidade presente na série bivariada.  $S_i(mês) = 1$ , se  $mês = i$  e  $S_i(mês) = 0$ , se  $mês \neq i$ .

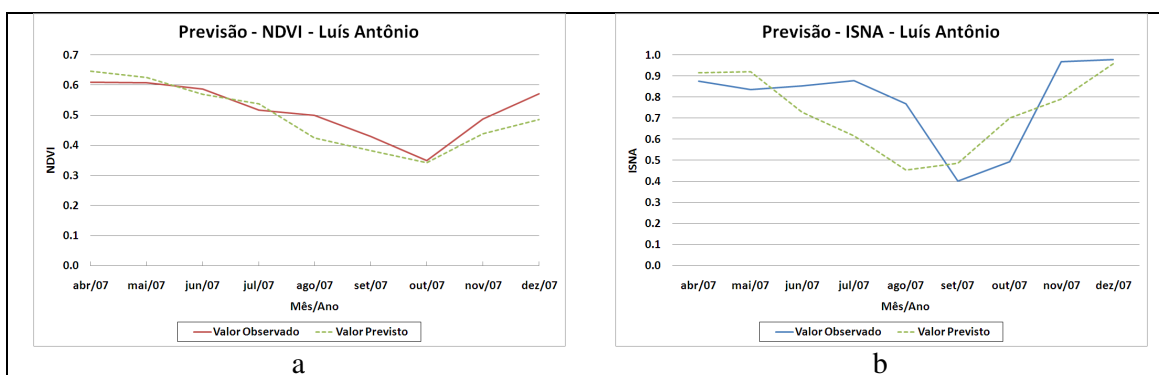
Trata-se de um processo estacionário, nota-se que o NDVI foi influenciado pelos seus valores passados (defasagens 1, 2, 4, 9 e 10) e pelos valores passados do ISNA (defasagens 1, 3, 4 e 9). Observa-se que o ISNA foi influenciado pelos seus valores passados (defasagens 1 e 3) pelos valores passados de NDVI (defasagens 3, 7 e 10). Estas defasagens ocorrem, pois as séries temporais são sazonais, com período de 12 meses. Os meses que compõem os modelos de previsão (Equações 4 e 5) aparecem quando são significativos para a previsão e quando há uma informação importante nas séries de dados.

Os resíduos não apresentaram estrutura de correlação, fato confirmado pelo teste de Portmanteau e pela versão multivariada da estatística de Box-Ljung-Pierce, com P-valor = 0,6346 e P-valor = 0,3234, respectivamente. Pelo teste de normalidade de Bera e Jarque, não houve evidências para rejeitar a hipótese de normalidade dos resíduos, com P-valor = 0,2244 e P-valor = 0,4991, dos modelos 4 e 5, respectivamente.

A previsão do NDVI, segundo a Tabela 1, apresentou erros relativos inferiores a 15,1%. O erro relativo médio no período considerado foi de 7,69%. No caso da previsão do ISNA, segundo a Tabela 2, o erro relativo médio nos nove meses analisados foi de 20,27%. Estes valores, 7,69% e 20,27%, explicam a maior proximidade entre as linhas de previsão e observação na Figura 2a, e o maior distanciamento na Figura 2b. A maior diferença observada na previsão do ISNA pode ter sido ocasionada por uma possível defasagem existente entre os períodos de previsão e observação que não foi precisamente descrita pela Equação 5.

Considerando uma defasagem de um mês entre os valores previstos e valores observados do ISNA, o erro relativo médio foi de 14,4%. Com esta defasagem os valores previstos ficaram mais próximos dos valores observados, apresentando erros relativos mais baixos, nos primeiros meses previstos de maio a outubro, em relação aos erros relativos do modelo. Os

meses de novembro e dezembro tiveram a melhor previsão feita pelo modelo, conforme a Tabela 2.



**Figura 2:** Gráficos de previsão do NDVI (a) e ISNA (b) do período de abril a dezembro de 2007.

**Tabela 1:** Valores observados e previstos, limites inferiores e superiores do intervalo de confiança e erros relativos do NDVI para os meses de abril a dezembro de 2007 para o município de Luís Antônio.

Mês	Valor do NDVI		Limite do IC		Erro Relativo (%)
	Observado	Previsto	Inferior	Superior	
Abril	0,6102	0,6471	0,5916	0,7026	6,1
Maio	0,6093	0,6263	0,5599	0,6927	2,8
Junho	0,5877	0,5703	0,4959	0,6448	3,0
Julho	0,5180	0,5392	0,4547	0,6237	4,1
Agosto	0,4993	0,4238	0,3299	0,5176	15,1
Setembro	0,4297	0,3827	0,2836	0,4818	11,0
Outubro	0,3496	0,3419	0,2387	0,4451	2,2
Novembro	0,4886	0,4389	0,3329	0,5450	10,2
Dezembro	0,5713	0,4863	0,3786	0,5939	14,9

**Tabela 2:** Valores observados e previstos, limites inferiores e superiores do intervalo de confiança e erros relativos do ISNA para os meses de abril a dezembro de 2007 para o município de Luís Antônio.

Mês	Valor do ISNA			Limite do IC		Erro Relativo (%)	
	Observado	Original Previsto	Previsto	Inferior	Superior	Original	Previsto
Abril	0,8767	0,9161	-	0,6796	1,1526	4,5	-
Maio	0,8365	0,9197	0,9161	0,6740	1,1654	9,9	9,5
Junho	0,8523	0,7293	0,9197	0,4828	0,9757	14,4	7,9
Julho	0,8785	0,6153	0,7293	0,3622	0,8684	30,0	17,0
Agosto	0,7696	0,4540	0,6153	0,1974	0,7105	41,0	20,0
Setembro	0,4023	0,4856	0,4540	0,2275	0,7437	20,7	12,8
Outubro	0,4939	0,7001	0,4856	0,4397	0,9605	41,8	1,7
Novembro	0,9674	0,7917	0,7001	0,5290	1,0544	18,2	27,6
Dezembro	0,9778	0,9582	0,7917	0,6950	1,2213	2,0	19,0

#### 4. Conclusões

Com os resultados das análises de séries temporais multivariadas, de forma geral, pode-se dizer que o ISNA é antecedente ao NDVI, ou seja, o NDVI pode ser melhor previsto utilizando informações passadas de ISNA. Todas as previsões feitas para o NDVI e ISNA foram satisfatórias, pois os valores previstos ficaram dentro do intervalo de confiança.

Os modelos descritos pelas Equações 4 e 5 permitem estimar a resposta espectral (representada pelos valores de NDVI) e as condições agroclimáticas (expressas pelos valores do índice ISNA) em safras futuras a partir dos valores destes índices em safras passadas subseqüentes, em Luís Antônio e em cada um dos dez municípios analisados e localizados no estado de São Paulo. São equações, portanto, úteis para o planejamento agrícola em escala regional, pois permitem acompanhar o desenvolvimento da cana-de-açúcar de forma objetiva e sistemática a partir de dados fornecidos por sensores remotos e estações meteorológicas de superfície. Ressalta-se que a incorporação de novos anos-safra pode ser uma forma de aumentar a precisão dos modelos desenvolvidos.

#### Agradecimentos

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo apoio financeiro. Ao Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura (CEPAGRI) pela disponibilização das imagens do satélite AVHRR/NOAA

#### Referências Bibliográficas

- Antunes, J. F. G. **Aplicações de lógica fuzzy para estimativa de área plantada da cultura de soja utilizando imagens AVHRR/NOAA**. 2005. 91p. Dissertação (Mestrado em Engenharia Agrícola) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas. 2005.
- Assad, E. D.; Sano, E. E.; Bezerra, H. S.; Silva, S. C.; Lobato, E. J. E. Uso de modelos numéricos de terreno na especialização de épocas de plantio. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas. Aplicações na agricultura**. Brasília: Embrapa-SPI/Embrapa Cerrados, 1998.
- Box, G. E. P.; Jenkins, G. M.; Reinsel, G. **Time Series Analysis: Forecasting and Control**. 3ed. Englewood Cliffs: Prentice Hall, 1994.
- Companhia Nacional de Abastecimento (CONAB). **Cana-de-açúcar: Safra 2005/2006 – Segundo Levantamento**. 2005. Disponível em: <<http://www.conab.gov.br>> Acesso em: 22 abril 2008.
- Esquerdo, J. C. D. M. **Utilização de perfis multi-temporais do NDVI/AVHRR no acompanhamento da safra de soja no oeste do Paraná**. 2007. 168p. Tese (Doutorado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2007.
- Esquerdo, J. C. D. M.; Antunes, J. F. G.; Baldwin, D. G.; Emery, W.; Zullo Júnior, J. An automatic system for AVHRR land surface product generation. **International Journal of Remote Sensing**, v.27, n.18, p.3925-3942, 2006.
- Gonçalves, R. R. V. **Relação entre a resposta espectral da cana-de-açúcar, registrada nas imagens dos satélites AVHRR/NOAA, em São Paulo, e dados agroclimáticos, no período de 2001 a 2008**. 2008. 185p. Dissertação (Mestrado em Engenharia Agrícola) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2008.
- Justice, C.O.; Hiernaux, P.H.Y. Monitoring the glasslands of the Sahel using NOAA AVHRR data: Niger, 1983. **International Journal of Remote Sensing**, v.7, n.11, p.1475-1498, 1986.
- Pereira, A. R.; Angelocci, L. R.; Sentelhas, P. C. **Agrometeorologia: Fundamentos e aplicações práticas**. Guaíba: Agropecuária, 2002. 478p.
- Prince, J.C. Estimating leaf area index from satellite data. **IEEE Transactions on Geoscience and Remote Sensing**, v.31, n.3, p.727-734, 1993.
- Rouse, J. W.; Haas, R. H.; Schell, J. A.; Deering, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources Technology Satellite-1 Symposium, 3., Washington, 1973. **Proceedings...** Washington: NASA, v.1, p.309-317, 1973.
- Senay, G.B.; Elliot, R.L. Capability of AVHRR data in discriminating rangeland cover mixtures. **International Journal of Remote Sensing**, v.23, n.2, p.299-312, 2002.
- Thornthwaite, C. W.; MATHER, J. R. The water balance. **Climatology**, v.8, n.1, 104p., 1955.
- Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v.8, n.2, p.127-150, 1979.