

Delimitação de zonas de manejo (ZMs) na cultura da cana-de-açúcar, através de dados de reflectância do satélite Landsat-8: uma abordagem em geoestatística multivariada

Anderson Antonio da Conceição Sartori¹

Vanessa Durante Polonio¹

Victor Costa Leda¹

Célia Regina Lopes Zimback¹

Universidade Estadual Paulista – UNESP/FCA

Caixa Postal 237 – 38807100 – Botucatu – SP, Brasil

sartori80@gmail.com; van_polonio@hotmail.com; victorleda@gmail.com;

czimback@gmail.com

Abstract. Given the complexity of interactions between factors which affect the crop of sugarcane, it becomes essential to determine the quantity and quality of yield then justifies the approach geostatistics multivariate for delineation of site-specific management units. The aim of this study was to delineate homogeneous management zones in sugarcane field. Geostatistical multivariate analysis was used for delineation of management zones by of spectral bands of Landsat-8. Multivariate analysis was performed with the package software ISATIS with the following steps: Gaussian Anamorphosis Modelling; Linear Model of Coregionalization (LMC) and Factorial Cokriging (FCK). For all spectral bands was assumed intrinsic stationary. The spectral bands used in the study were: band 1 - aerosol coast, band 2 – blue, band 3 – green, band 4 – red, band 5 - near infrared (NIR), band 6 - SWIR 1, band 7 - SWIR 2, band 10 and band 11 - thermal infrared. The results were: Management Zones (MZs) at short range for the first factor which is directly related to the surface temperature; (MZs) at long range for first and second factor which is directly and indirectly related to the water content in the crop and surface temperature, respectively. It was concluded that approach geostatistical multivariate allowed us to separate the different sources of spatial variation at different scales.

Palavras-chave: geostatistics multivariate, management zones, spectral data, geoestatística multivariada, zonas de manejo, dados espectrais.

1. Introdução

A cana-de-açúcar é uma das culturas energéticas importante comercialmente devido a sua alta produtividade em biomassa. Em muitos países, mais notavelmente no Brasil, a produção agrícola da cana foi otimizada e personalizada sob diferentes condições de crescimento. Conforme Goldemberg (2008), a cultura da cana-de-açúcar é de fundamental importância para o agronegócio brasileiro, já que permite produzir açúcar, etanol e energia elétrica.

A cana-de-açúcar, em função do seu ciclo perene, passa por influência das variações climáticas durante todo o ano. Para atingir alta produção de sacarose, a planta precisa encontrar épocas com condições de temperatura e umidade adequadas para permitir o máximo crescimento na fase vegetativa, seguida de um período com restrição hídrica ou térmica para favorecer o acúmulo de sacarose no colmo na época do corte. A cultura encontra suas melhores condições quando ocorre um período quente e úmido, com intensa radiação solar durante a fase de crescimento, seguido de um período seco durante as fases de maturação e colheita (Brunini, 2008).

O desenvolvimento de métodos de sensoriamento remoto levou a uma melhor compreensão nas mudanças de reflectância da folha em resposta à espessura da folha, características de dossel, idade da folha e estado de água. Absorção de clorofila nas folhas, em vários comprimentos de onda, fornece a base para a medição de reflectância tanto com radiômetros típicos de sensores multiespectrais, nas plataformas de satélite atuais ou sensores hiperespectrais que medem a reflectância em faixas muito estreitas (Ahamed et al., 2010).

O objetivo principal do sensoriamento remoto na agricultura é delinear e caracterizar zonas homogêneas de manejo para otimizar a gestão agrícola como adubação, irrigação ou outras operações agrotécnicas (Franzen et al., 2002; Yan et al., 2007; De Benedetto et al.,

2013). Modernas produções agrícolas dependem do monitoramento próximo do estado das culturas. Isto permite uma gestão eficiente dos recursos disponíveis para obter lucratividade com práticas agrícolas sustentáveis (Thenkabail et al., 2012).

Investigações de sensoriamento remoto nos canaviais são geralmente relacionadas à classificação e mapeamento (Rudorff; Sugawara, 2007), manejo da cultura (Fiorio et al., 2000; Wiegand et al., 1996) e estimativa da produtividade (Picoli et al., 2009). No entanto, a maioria dos estudos limitam-se a classificação e caracterização da produtividade na cana-de-açúcar e não são utilizados para delinear zonas homogêneas de manejo em agricultura de precisão. Estas ZMs são definidas como sub-áreas onde se espera que os efeitos sobre a cultura das diferenças sazonais de clima, solo, manejo etc, para ser mais ou menos uniforme (Lark, 1998).

Devido a complexidade das interações entre os fatores que afetam a produtividades nas culturas em qualidade e quantidade, uma abordagem multivariada para a determinação de zonas de manejo é aconselhável. Abordagem multivariada dentro da teoria geoestatística é preferível quando as relações entre as variáveis são dependentes de escala e podem ser associada à diferentes fontes de variabilidade. A abordagem nesta tese utilizada denominou-se Análise de Cokrigagem Fatorial (AKF) (Matheron, 1982).

O objetivo deste estudo foi delinear zonas homogêneas de manejo em uma área cultivada com cana-de-açúcar, região central do estado de São Paulo-Brasil. A abordagem geoestatística multivariada foi utilizada no delineamento das zonas homogêneas de manejo por meio das bandas espectrais no visível (R, G, B), infravermelho próximo (NIR), infravermelho de ondas curtas (SWIR) e sensor térmico (TIRS) do satélite Landsat-8.

2. Material e Métodos

2.1 Caracterização da área do estudo

A área do está localizada no município de São Manuel, na Fazenda Boa Vista, cerca de 8 km do centro urbano em uma região central do estado de São Paulo, conforme Figura 1.

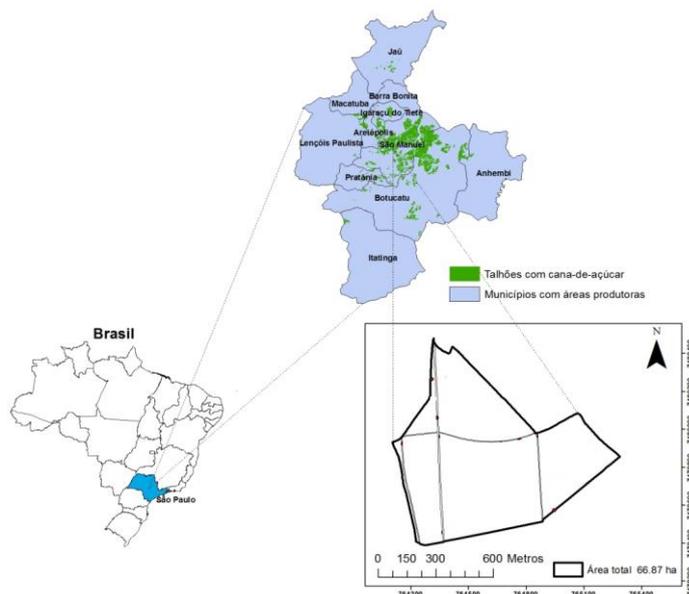


Figura 1. Localização das áreas produtoras de cana-de-açúcar da Usina Açucareira São Manuel S.A. São Paulo.

O município de São Manuel encontra-se próximo às coordenadas de 22 ° 45' de latitude sul e 48 ° 30' de longitude a oeste de Greenwich. Sua altitude média é de 520 m, com as

temperaturas médias mínimas e máximas, no verão, de 19 e 29 °C e, no inverno de 12 e 25 °C, respectivamente. O tipo climático predominante na região é o Cwa, de acordo com o critério de Köppen, caracterizado como clima tropical de altitude, com inverno seco e verão quente.

2.2 Imagem Landsat-8 e pré-processamento

Este estudo utilizou uma cena do satélite Landsat-8 relativo a 21 janeiro de 2014, órbita/ponto 220/076, resolução radiométrica de 16 bits, resolução temporal 16 dias, projeção da imagem UTM, datum WGS 84, (projeção cilíndrica) sendo necessário projetá-las para o hemisfério Sul. O tamanho aproximado da cena Landsat-8 é de 170 km ao norte-sul por 183 km de leste a oeste.

Neste estudo as bandas dos instrumentos OLI e TIRS (números digitais) foram convertidas para o topo da atmosfera (TOA), em radiância espectral, usando os elementos de brilho redimensionado fornecidos no arquivo de metadados.

2.3 Análise geoestatística multivariada

Para todas as bandas espectrais foi assumida estacionariedade intrínseca. Todas as análises de geoestatística multivariada foram realizadas com o pacote do programa ISATIS (Geovariances, 2014).

As bandas espectrais utilizadas no estudo foram: banda 1 - aerossol Costeira, banda 2 - Azul, banda 3 - Verde, banda 4 - Vermelho, banda 5 - infravermelho próximo (NIR), banda 6 - SWIR 1, banda 7 - SWIR 2, banda 10 e banda 11 - termal infravermelha.

2.3.1 Modelagem Anamorfose Gaussiana

A dificuldade na aplicação prática da abordagem multivariada ocorre quando as variáveis são de tamanhos muito diferentes. A solução foi padronizar as bandas individualmente dando a cada uma uma média de zero e uma variância de unidade (1). A modelagem do variograma, pela presença de outliers na distribuição dos dados, torna-se mais complexa. Neste caso, é melhor realizar uma normalização dos dados por meio da Modelagem Anamorfose Gaussiana Chilès e Delfiner (1999).

2.3.2 Modelo Linear de Corregionalização (MLC)

O Modelo Linear de Corregionalização (MLC) foi ajustado para todos os variogramas experimentais dos dados de solo e espectral, tanto para os diretos como os variogramas cruzados, referentes aos dados transformados. O MLC, desenvolvido por Journel e Huijbregts (1978), considerou todas as n variáveis estudadas como resultado dos mesmos processos físicos independentes, atuando em diferentes escalas espaciais u . Os $n(n+1)/2$ variogramas simples e cruzados das variáveis foram modelados por uma combinação linear N_S dos variogramas padronizados pelo valor do patamar, $g^u(\mathbf{h})$. Usando a notação matricial, a MLC pode ser escrita pela Equação 1:

$$\Gamma(\mathbf{h}) = \sum_{u=1}^{N_S} \mathbf{B}^u g^u(\mathbf{h}) \quad (1)$$

onde: $\Gamma(\mathbf{h})=[\gamma_{ij}(\mathbf{h})]$ é uma matriz simétrica de ordem $n \times n$, cujos elementos diagonal e fora da diagonal representam variogramas simples e cruzados, respectivamente; $\mathbf{B}^u=[b^u_{ij}]$ é chamada de matriz corregionalização e é uma matriz semi-definida positiva de forma simétrica, de ordem $n \times n$ com os elementos reais b^u_{ij} a uma escala espacial específica u . O modelo é viável de aplicação se as funções $g^u(\mathbf{h})$ são modelos ajustados ao variograma (Castrignanò et al., 2000).

2.3.3 Cokrigagem Fatorial (CKF)

Mapeamento dos fatores regionalizados fornece uma ilustração do comportamento e das relações entre as variáveis em diferentes escalas espaciais. A estimativa dos fatores foi realizada por um sistema de cokrigagem modificada, descrito por Wackernagel (1988) e Castrignano et al. (2000).

É importante reconhecer que os pressupostos subjacentes da CKF são linearidade e independência dos fatores. Além disso, a cokrigagem fatorial depende da modelagem do variograma, ou seja, uma escolha um tanto arbitrária do número e/ou tipo das estruturas aninhadas e alcance do modelo do variograma. Assim, para a modelagem dos variogramas, qualquer conhecimento físico dos fenômenos atuantes na área de estudo deve ser levado em conta.

3. Resultados e Discussão

3.1 Análise descritiva dos dados

A estatística descritiva das bandas espectrais da imagem do Landsat-8 está resumida na Tabela 1. Foi evidente que as distribuições das bandas espectrais mostraram enviesadas, com exceção da banda 5 com valores sensíveis a distribuição normal. A dificuldade na aplicação da abordagem multivariada ocorre quando as variáveis possuem diferentes tamanhos e com diferentes variâncias. A solução foi padronizar as variáveis individuais dando uma média de zero e uma variância de unidade 1. Neste caso, foi realizada a normalização dos dados através da Modelagem Anamorfose Gaussiana.

Tabela 1. Estatística descritiva das bandas espectrais do Landsat-8

Variáveis	Min	Max	Média	Des.Pad.	Simetria	Curtose
Banda 1	0.1108	0.1523	0.1146	0.0025	5.7487	7.3348
Banda2	0.0924	0.1118	0.0964	0.0027	1.8135	7.0055
Banda 3	0.0866	0.1118	0.0934	0.0041	2.2231	9.9194
Banda 4	0.0582	0.1626	0.0751	0.0133	1.8467	7.9801
Banda 5	0.2657	0.4396	0.3628	0.0337	-0.1915	2.4682
Banda 6	0.1487	0.2660	0.1770	0.0189	1.0552	3.9983
Banda 7	0.0614	0.2141	0.0914	0.0234	1.2224	4.6586
Banda 10	9.9933	10.9682	10.3100	0.1741	0.7618	2.8762
Banda 11	9.2531	9.9158	9.4665	0.1159	0.8057	3.1708

3.2 Análise de correionalização

Geoestatística multivariada assume que há uma relação subjacente entre a assinatura espectral da cultura e suas propriedades bioquímicas ou biofísicas. Ferramentas multivariadas extraem essa relação subjacente como um modelo de correionalização.

As principais causas de variação espacial na reflectância espectral da vegetação são complexas porque são afetadas por vários fatores, tais como: condições climáticas, características das propriedades do solo, índice de área foliar (cobertura vegetal por unidade de área), fase de crescimento (estado de desenvolvimento da cultura), biomassa (densidade de massa verde), folha (forma, posição, teor de água, pigmentação, estrutura interna) entre outros.

Os variogramas experimentais isotrópicos foram calculados para as bandas espectrais, para o tamanho do passo (lag) foi de 75 m com número de passos (lag) em 8.

A inspeção visual dos variogramas sugeriu a presença de três componentes básicos, o que corresponde a diferentes escalas espaciais (efeito pepita, escala curta = 400 m modelo esférico e escala longa = 900 m modelo esférico).

Na primeira estrutura foi observado um efeito pepita, compreendendo a variação espacial não resolvida que ocorrem a distâncias menores do que a escala de amostragem e ao erro de

medição. A segunda estrutura refletiu um processo espacial transitivo na escala média, aproximadamente a uma distância de 400 m, e foi relevante para as bandas térmicas 10 e 11. A terceira estrutura representou um modelo transitivo com uma gama relativamente grande (de 400 a 900 m). Esta estrutura foi predominante para as bandas espectrais 1, 2, 3, 4, 6 e 7.

A maioria dos variogramas diretos mostraram-se bem estruturado, com um mesmo componente geral de efeito pepita. Nos variogramas cruzados das bandas espectrais, foram correlacionados espacialmente apenas entre bandas espectrais, enquanto que a correlação espacial foi nula entre bandas térmicas e espectrais.

O bom ajuste do MLC foi verificado através do teste de validação cruzada, através de duas estatísticas de erros médios, a média e a variância do erro, não reportados neste estudo.

Coefficiente de correlação alto foi observado na escala curta (Tabela 2) para os pares de bandas, 2-1, 3-1, 6-3, 7-3, 5-4, 10-4, 10-5, 11-4 e 11-5. Essas relações estruturais denotam variabilidade semelhante para os elementos acima na escala curta e sugerem a presença de fontes locais comuns de variação, provavelmente relacionada a propriedades locais do solo e das culturas (índice de área foliar, fase de crescimento, a densidade de massa verde e teor de água folha).

Na escala longa (Tabela 3), os coeficientes de correlação entre as bandas do visível tiveram um aumento em comparação com os de escala curta. As bandas 6 e 7 de onda curta no infravermelho também tiveram aumento na correlação com as bandas do visível. Ocorreu uma alta correlação entre as bandas 04-10, 4-11, 11-4 e 11-5 essas correlações com as bandas térmicas estão relacionadas com as alterações das temperaturas radioativas de superfície.

Tabela 2. Coeficientes estruturais na escala curta.

Variáveis	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 6	Banda 7	Banda 10	Banda 11
Banda 1	1								
Banda 2	-0,99	1							
Banda 3	-0,62	0,67	1						
Banda 4	0,13	0,26	0,50	1					
Banda 5	0,47	0,38	0,35	-0,62	1				
Banda 6	-0,22	-0,15	0,56	0,35	0,05	1			
Banda 7	0,09	0,20	0,73	0,87	-0,31	0,65	1		
Banda 10	0,41	0,32	0,28	-0,67	0,99	0,06	-0,37	1	
Banda 11	0,26	0,15	0,07	-0,81	0,95	-0,08	-0,52	0,96	1

Tabela 3. Coeficientes estruturais na escala longa.

Variáveis	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 6	Banda 7	Banda 10	Banda 11
Banda 1	1								
Banda 2	0,99	1							
Banda 3	0,99	0,99	1						
Banda 4	0,93	0,93	0,89	1					
Banda 5	-0,17	-0,17	-0,06	-0,48	1				
Banda 6	0,98	0,99	0,97	0,94	-0,17	1			
Banda 7	0,96	0,96	0,92	0,99	-0,41	0,96	1		
Banda 10	0,42	0,42	0,32	0,68	-0,95	0,40	0,62	1	
Banda 11	0,53	0,54	0,44	0,78	-0,92	0,53	0,73	0,97	1

3.3 Análise regionalizada fatorial

A fim de sintetizar as relações espaciais multivariadas e identificar número restrito de regiões a serem submetidos ao diferencial de gestão, análise fatorial cokrigagem foi realizado através do mapeamento dos fatores regionalizados. Na análise fatorial apenas os autovetores correspondentes a valores próprios superiores a um (1) foram mantidos devido à padronização das variáveis a variância 1.

A variação na escala curta foi explicada apenas pelo primeiro fator regionalizada com 89,00%. A variação acumulada em escala longa foi explicada pelo primeiro (80,00%) e segundo (18,63%) fatores regionalizados com cerca de (98,63%) assumindo como suficiente para caracterizar a estrutura deste campo na escala dependente.

Os valores de carga indicam que o primeiro fator na escala curta é influenciado principalmente de forma positiva pelas bandas espectrais 10 e 11. Na escala longa o primeiro fator é influenciado pelas bandas espectrais 1,2,3,4, 6 e 7 com maior peso e de forma positiva; já o segundo fator pela banda 5 pesando positivamente e pelas bandas termais 10 e 11 com maior peso e negativamente.

Isto significa que o primeiro fator na escala curta está relacionado diretamente com a temperatura de superfície. O primeiro e segundo fator na escala longa está relacionado diretamente com conteúdo de água na planta e, indirectamente com a temperatura da superfície, respectivamente. A análise conjunta de dados multivariados como: bandas termais para verificar remotamente a temperatura do dossel, banda 6 –SWIR 1 e banda 7-SWIR 2 para caracteriar o estresse hídrico da cultura, tais como condutância foliar e potencial de água na folha ou caule, podem servir como ferramentas de apoio à decisão a irrigação (Möller et al., 2007).

Na figura 2 o mapa F1 na escala curta foi dividido em três classes de mesma frequência (alta, média e baixa) que podem ser caracterizadas como zonas homogêneas que influenciam o conteúdo hidrico na cultura através da temperatura do dossel. O estado dos estômatos das folhas, que controlam o processo de evapotranspiração, podem ser afetados pela temperatura da folha. Essa característica foi delimitada nas classes de valores altos.

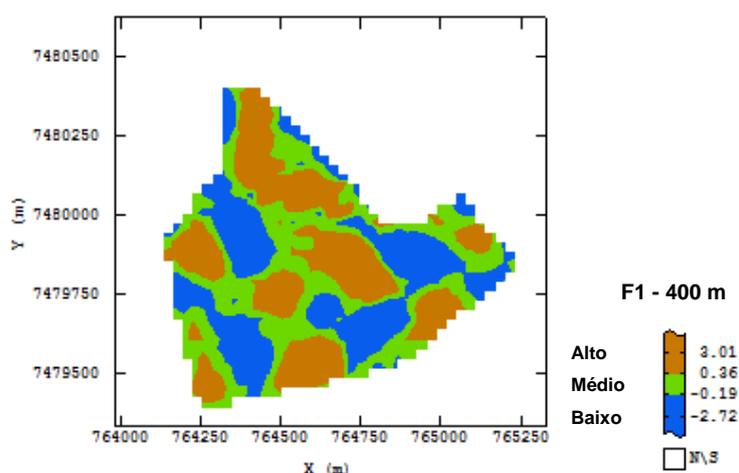


Figura 2. Mapa em três zonas de manejo (MZs) de acordo com o primeiro fator.

As figuras 3 e 4 referentes aos mapas F1e F2 em longa escala foram divididos em três classes de mesma frequência (alta, média e baixa) que podem ser interpretados como zonas homogêneas em conteúdo de água na cultura pelas (banda do visível, bandas SWIR 6 e 7) e temperatura da superfície pelas (bandas termais 10 e 11), respectivamente.

As condições hídricas na cultura é uma propriedade biofísica chave usada no gerenciamento da irrigação, bem como para avaliar a saúde da cultura; por outro lado, pode também servir como um indicador do estado da cultura. Neste estudo as zonas homogêneas foram delineadas em escala longa devido a diferentes teores de água do dossel. No mapa da (Figura 3) foi observado polígonos com maiores teores de água definidos pela classe alta, onde a vegetação se encontra mais exuberante com maior biomassa.

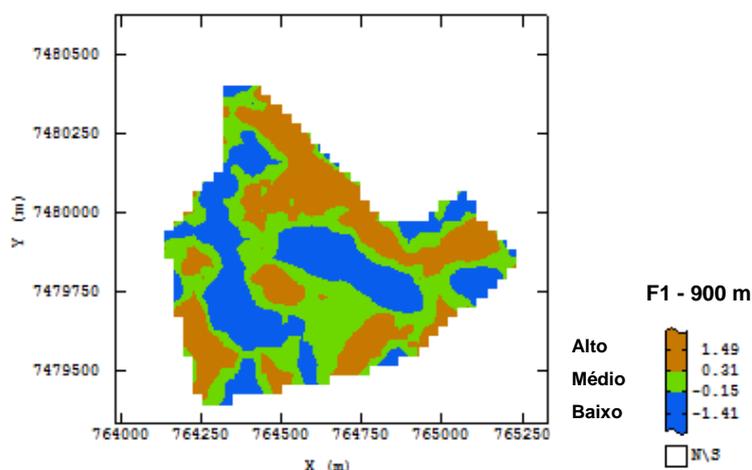


Figura 3. Mapa em três zonas de manejo (MZs) de acordo com o primeiro fator.

Outro fator que influencia o conteúdo hídrico nas culturas é a temperatura do dossel. O estado dos estômatos das folhas, que controlam o processo de evapotranspiração, podem ser afetados pela temperatura da folha. Bandas termais foram usadas para delinear zonas caracterizadas com potencial ao estresse hídrico na cultura, conforme mostra a (Figura 4).

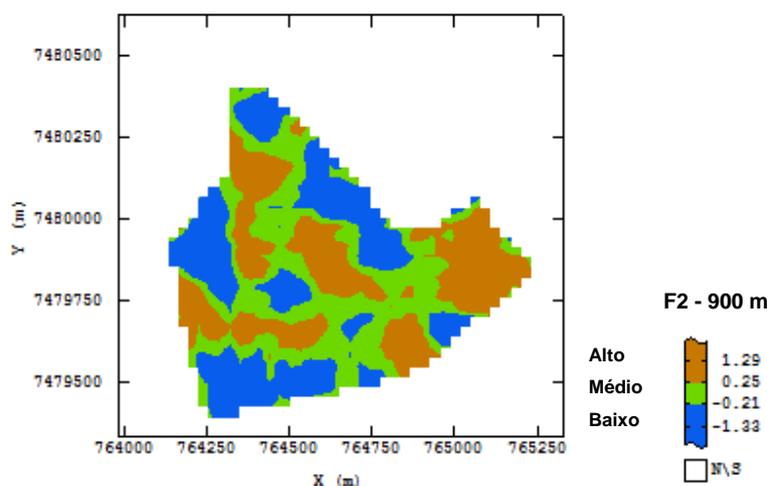


Figura 4. Mapa em três zonas de manejo (MZs) de acordo com o segundo.

4. Conclusões

Análise geoestatística multivariada permitiu separar as diferentes fontes de variação espacial em diferentes escalas, oferecendo a oportunidade para a formulação de hipóteses sobre as prováveis fontes de variação da resposta espectral da cultura.

Possibilitou uma melhor compreensão das variações dentro da área de estudo, permitindo o desenvolvimento de manejos mais sofisticados da cultura o qual pode ser definido como uma vantagem operacional na Agricultura de Precisão. Neste último aspecto, a abordagem Análise da Cokrigagem Fatorial demonstrou-se ser um método altamente eficaz para definir zonas homogêneas de manejo.

5. Agradecimentos

Agricultural Research Council Research - Unit for cropping systems in dry environments (CRA-SCA) em Bari Itália, pela oportunidade e estrutura oferecida na execução deste trabalho com a utilização do programa ISATIS (Geovariances, 2014).

6. Referências

- Ahamed, T.; Tian, L.; Zhang, Y.; Xiong, Y.; Zhao, B.; Jiang, Y. Site-specific management for biomass feedstock production: development of remote sensing data acquisition systems. **Anais Book**. Proceedings of 10th international conference on precision agriculture. Denver Colorado; 18e21 July 2010.
- Brunini, O. Ambientes climáticos e exploração agrícola da cana-de-açúcar. In: Dinardo, M. L. L.; VASCONCELOS, A.C M. de; ANDRADE, L., M. G. Cana-de-açúcar. Campinas: **Instituto Agrônômico**, 2008. p. 205-218.
- Castrignanò, A.; Giugliarini, L.; Risaliti, R.; Martinell, N. 2000. Study of spatial relationships among some soil physico-chemical properties of a field in central Italy using multivariate geostatistics. **Geoderma**. 97, 39–60.
- Chilès, J.P.; Delfiner, P., 1999. **Geoestatistics: Modeling spatial uncertainty**. New York: Wiley.
- De Benedetto, D.; Castrignanò, A.; Rinaldi, M.; Ruggieri, S.; Santoro, F.; Figorito, B.; Gualano, S.; Diacono, M.; Tamborrino, R. An approach for delineating homogeneous zones by using multi-sensor data. **Geoderma** 199 (2013) 117–127.
- Fiorio, P. R., Dematte, J. A. M., Sparovek, G. (2000). Chronology and environmental impact of land use on Ceveiro microbasin in Piracicaba region, Brazil. **Pesquisa Agropecuária Brasileira**, 35, 671– 679.
- Franzen, D.W.; Hopkins, D.H.; Sweeney, M.D.; Ulmer, M.K.; Halvorson, A.D. 2002. Evaluation of soil survey scale for zone development of site-specific nitrogen management. **Agron. J.** 94, 381–389.
- Geovariances, Ecole Des Mines De Paris, 2014. Isatis Technical Ref., release 10.04. **Geovariances**, Avon Cedex, France.
- Goldemberg, J.; Coelho, S. T.; Guardabassi, P. The sustainability of ethanol production from sugarcane. **Energy Policy**, v.36, p. 2086-2097, 2008.
- Journel, A.G.; Huijbregts, C.J. 1978. Mining geostatistics. **Academic Press**, New York, 600p.
- Lark, R.M., 1998. Forming spatially coherent regions by classification of multivariate data: an example from the analysis of maps of crop yield. **Int. J. Geogr. Inf. Sci.** 12, 83–98.
- Matheron, G., 1982. Pour une analyse krigeante des donnees regionalisées. **Technical Report No. 732**. Centre de Geostatistique, Fontainebleau.
- Moller, M.; Alchanatis, V.; Cohen, Y.; Meron, M.; Tsipris, J.; Naor, A.; Ostrovsky, V.; M. Sprintsin, M.; Cohen, S. Use of thermal and visible imagery for estimating crop water status of irrigated grapevine. **Journal of Experimental Botany**, Vol. 58, No. 4, pp. 827–838, 2007.
- Picoli, M.C.A.; Rudorff, B.F.T.; Rizzi, R.; Giarolla, A. Índice de vegetação do sensor modis na estimativa da produtividade agrícola da cana-de-açúcar. **Revista Bragantia**, Campinas, v.68, n.3, p.789-795, 2009.
- Rudorff, B.F.T.; Sugawara, L.M. Mapeamento da cana-de-açúcar na Região Cenro-Sul via imagens de satélite. **Informe Agropecuário**, Belo Horizonte, v.28, n.241, p.79-86, 2007.
- Thenkabail, P.; Lyon, J.G.; Huete, A. 2012. **Hyperspectral Remote Sensing of Vegetation**. 2012. Taylor e Francis Group.
- Wackernagel, H. (1988). Geostatistical techniques for interpreting multivariate spatial information. In: Quantative analysis of mineral and energy resources. **R. (eds). Reidal**, Dordrecht, The Netherlands, 393 – 409.
- Wiegand, C.; Anderson, G.; Lingle, S.; Escobar, D. (1996). Soil salinity effects on crop growth and yield: Illustration of an analysis and mapping methodology for sugarcane. **Journal of Plant Physiology**, 148, 418–424.
- Yan, L.; Zhou, S.; Feng, L.; Hong-Yi, L. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture** 56 (2007) 174–186.